

# 基于数据驱动的 IGBT 故障预测研究

黎白泠 方晓春 林帅 杨中平 林飞 都佳美

(北京交通大学电气工程学院 北京 100044)

**摘要** 绝缘栅双极晶体管 (Insulated Gate Bipolar Transistor, IGBT) 是一种功率半导体器件, 作为重要的控制或能量变换器件而广泛用于中高功率应用, 例如电机驱动及电源等。IGBT 随着使用年限的延长将持续性老化, 直到出现故障为止。因此, 预测 IGBT 老化故障是提高器件可用性, 减少系统停机时间并防止电力电子设备故障, 从而保证系统可靠性的重要途径。本文在进行 IGBT 失效分析的基础上, 研究了一种改进的 IGBT 故障预测算法。在这种算法中,  $V_{CE(ON)}$  作为老化特征参数。针对 IGBT 的阶段性退化状态, 将灰色 Verhulst 模型和无迹卡尔曼粒子滤波算法结合起来, 完成了 IGBT 的故障预测。并结合具体数据仿真分析其精确性, 算法结果误差较小, 可以在故障预测中应用。

**关键词:** 绝缘栅双极晶体管 失效分析 灰色预测模型 无迹卡尔曼粒子滤波 预测  
**中图分类号:** TP 301.6

## Research on Failure Prognostic of IGBT Based on Data-driven

Li Bailing Fang Xiaochun Lin Shuai Yang Zhongping Lin Fei Du Jiamei

(Beijing Jiaotong University Beijing 100044 China)

**Abstract** Insulated Gate Bipolar Transistor (IGBT) is a power semiconductor device. It is widely used as an important control or energy conversion device in medium and high power applications, such as motor drives and power supplies. IGBT will continue to age with the extension of service life until it fails. Therefore, predicting IGBT aging failures is an important way to improve device availability, reduce system downtime, and prevent power electronic equipment failures, thereby ensuring system reliability. In this paper, based on the analysis of IGBT failure, an improved IGBT failure prognostic algorithm is studied. In this algorithm,  $V_{CE(ON)}$  is used as the precursor parameter. Aiming at the staged degradation state of IGBT, the gray Verhulst model and the Unscented Kalman Particle Filter algorithm are combined to complete the IGBT failure prediction. Combined with specific data simulation to analyze its accuracy, the algorithm result has less error and can be used in failure prognostic.

**Keywords:** IGBT, failure analysis, grey prediction model, Unscented Kalman Particle Filter, prognostic

中央高校基本科研业务费专项资金资助 (2019JBM061), 本课题研究得到《台达电力电子科教发展计划》的资助 (DREG2019017)。  
收稿日期 2020-08-26

## 0 引言

功率半导体器件比如 IGBTs, 是电子或电气系统必不可少的组成元素, 在一些大功率等级的场合, 比如车辆控制、通信、导航以及雷达系统等领域应用广泛。IGBT 是由双极型三极管 (BJT) 和绝缘栅型场效应管 (MOSFET) 组成的复合全控型电压驱

动式功率半导体器件, 兼有 MOSFET 的高输入阻抗和 BJT 的低导通压降两方面的优点, 驱动功率小而饱和压降低, 从而得到广泛应用。图 1 是根据行业调查得出的电力电子系统中最易损的组件的分布图<sup>[1]</sup>。图中可看出, 有 34% 的受访者认为 IGBT 是最易损坏的组件。IGBT 在工作期间连续受到电、热

冲击和机械应力的累加后,其内部结构将缓慢变化,从而模块将逐渐老化。研究 IGBT 模块的可靠性并分析 IGBT 模块的老化特征参数,有助于避免因过度维修或不维修而引起的问题。有统计说明,电子系统中约有 40% 的故障是由电源系统引起的,而电源故障的原因是功率器件失效的比率大约占 31%<sup>[2]</sup>。因此,研究 IGBT 器件在运行中的失效行为对于保证系统的运行可靠性和防止一些意外故障非常重要。

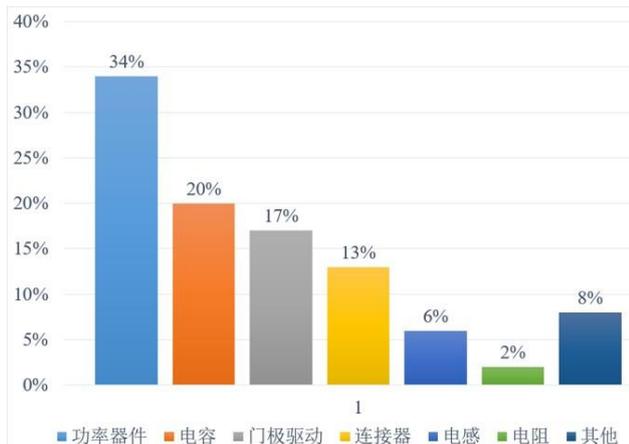


图 1 行业调查中电力电子系统中最易损组件的分布

Fig.1 Distribution of the most frangible components in power electronic systems from the industry survey

综合国内外研究,IGBT 的可靠性研究主要分为三种方法,基于可靠性模型的故障预测方法、基于物理模型的故障预测方法和基于数据驱动的故障预测方法<sup>[3]</sup>,这三种方法各有特点。基于可靠性模型的方法应用概率密度函数预测故障,“浴盆曲线”为典型的可靠性故障概率曲线;基于物理模型的故障预测方法一般要求已知对象的物理失效模型,并且基于预测对象系统的稳态或瞬态负载、温度或其他测试信息构建预测模型框架,并统计设备或系统历史运行情况,进行系统未来运行状态的仿真测试<sup>[4]</sup>;在基于数据驱动的可靠性评估方法中,是在已知系统或设备的老化特征值的前提下,将实际运行状态下的特征值予以比较,判断当前运行状况并预测未来的运行状态。

前两种方法可以通过物理建模及仿真从理论上分析 IGBT 的可靠性。基于可靠性模型的方法主要利用一段时间内的经验反馈数据调整预先设定的可靠性模型参数进而获取可靠性模型,获取的模型将用来预测失效前时间 (Time To Failure, TTF) 或者剩余寿命<sup>[3]</sup>,现有的文献中提出了一些失效模型,比如:威尔布 (Weibull) 模型、杜安 (Duane) 模

型、指数模型、泊松分布模型、贝叶斯方法等。其中 Weibull 模型被广泛应用于系统或设备的故障预测和剩余寿命估计中,此种方法准确率较低。

典型的基于物理模型的故障预测方法有:基于失效物理 (Physics-of-Failure, PoF)、累积损伤模型、疲劳寿命模型、随机损伤传播模型、层次化系统模型和集总参数模型等<sup>[4]</sup>。目前国内外已有一些研究,Sasaki 等人通过估计温度循环小于 30℃ 情况下的 IGBT 模块循环次数来验证了一种基于损伤方法<sup>[5]</sup>,这种退化现象是由环境状态中的一系列参数里的一个或多个变量来表达的。Zhang 等人将基于多规则的云推理器应用于弹药的加速老化试验<sup>[6]</sup>。Huang 等人提出了一种估计逆变器寿命的方法<sup>[7]</sup>。

此方法依赖于模型的参数,但是针对于工程应用中的复杂对象系统,精确的数学模型难以建立,尤其是对于复杂电子系统,其故障模式与失效机理较为复杂,因此基于物理模型的故障预测方法具有一定局限性。

从上面两种方法分析得,基于数据驱动的方法可以规避建立复杂失效模型这一缺陷,将成为研究趋势。在保证失效机理不变的前提下,通常采用加速寿命实验的方法研究电子元器件可靠性。确定老化特征参数和失效阈值,通过实验的方法得到老化特征参量随时间退化的数据。通过算法分析等方法建立功率 IGBT 退化模型,进而进行故障预测,研究寿命分布规律。文献[8]中,Batzel 等人基于卡尔曼 (Kalman) 滤波模型提出一种寿命评估方法,并将预测结果在航天飞机的电源数据上进行验证,文献[9]基于 CRH2 型动车组列车的键合图模型确定多层贝叶斯网络结构,采用多树传播的推理法,实现了高速列车整流器 IGBT 功率器件的故障预测,文献[10]中,Alghassi 等人使用了一种时延神经网络来预测 IGBT 的剩余寿命,文献[11]使用了一种 K 近邻算法来将 IGBT 分为健康和故障状态,文献[12]提出一种自组织映射方法来识别 IGBT 的退化状态,文献[13]使用蒙特-卡罗方法 (Monte-Carlo Method) 预测 IGBT 的剩余使用寿命。

基于数据驱动的故障预测方法以状态监测数据为基础,估计对象的未来运行趋势,但是在实际工程应用中,一些历史数据的获取困难或者获取代价高昂,获取到的数据也具有有一定不确定性和不完整性,这些增加了数据驱动方法的难度。但相较于其他两种方法,数据驱动的故障预测方法分类众多也

更加符合当前大数据技术发展迅速的趋势。本文提出了一种组合型故障预测方法，考虑到 IGBT 性能退化参数的退化趋势，采用灰色 Verhulst 模型与无迹卡尔曼粒子滤波相结合的算法完成 IGBT 的故障预测，其精确度比使用单一算法精确度要高。

## 1 IGBT 失效分析

IGBT 的失效分析是研究其可靠性的重要环节，失效分析即是指在大量实验的基础上，研究器件的失效模式和失效机理。从器件老化的角度分析，功率 IGBT 的失效过程建立在以时间为横轴的坐标系中。器件一些外部物理参数的变化和键合线断裂、焊料层疲劳等结构上的变化标志着不同的失效模式，每一种失效模式可能对应着多种失效机理。一般将功率 IGBT 的失效模式分为两种，封装结构失效和芯片相关失效<sup>[14]</sup>。图 2 给出了常见的 IGBT 失效模式。

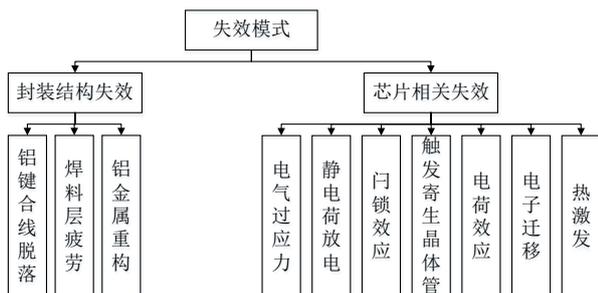


图 2 IGBT 失效模式关系

Fig.2 IGBT failure mode relationship

### 1.1 封装结构失效

IGBT 典型封装要素包括：芯片层、陶瓷基敷铜板层和底板层，层与层之间用焊料连接，其结构如图 3 所示。典型的封装结构失效分为焊料层疲劳、铝键合引线断裂及脱落和铝金属重构等。总体来说，器件发生封装结构失效主要是由于其层叠式结构，各层材料、厚度、膨胀系数等各不相同。在热机械应力的冲击下，导致器件内部结构发生不同程度的膨胀，温度的变化也会导致作用力增大或减小，随着时间的推移，老化的加剧，便会发生变形、分层、孔洞和铝键合线脱落、断裂，最终导致器件失效<sup>[15]</sup>。

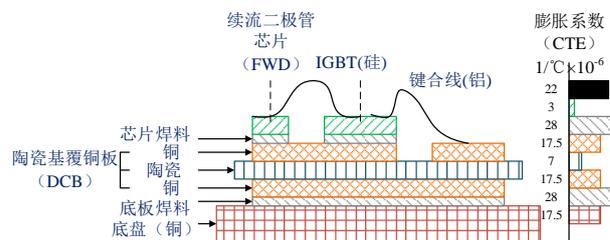


图 3 IGBT 封装结构

Fig.3 IGBT encapsulation structure

焊料层最易出现的是空洞和裂纹。在 IGBT 的焊接过程中，表面可能会出现油污，这些油污会造成焊料层间不同形状的空洞，在制造过程中出现工艺问题导致材料不同程度剥脱也会出现空洞。焊料层的空洞会减小模块各层的接触面积并增加接触热阻，循环往复，在时间的积累下，热阻的增大导致 IGBT 芯片在运行过程中产生的热量不能充分释放，最终引起结温升高<sup>[16]</sup>，导致器件的失效。

铝键合线连接着芯片与芯片或者芯片与陶瓷基覆铜板，起到引出电流的作用。由于焊接点面积非常小而且各层热膨胀系数不同，这种差异令硅芯片与铝之间拉伸与压缩应力互不一致，导致键合线连接处松动。那么在电流长期冲击下，此种现象越来越严重，最后便会引起铝键合线彻底脱落。同样，铝金属重构是材料不同热膨胀系数加上在长期热循环冲击下，铝线表面变得粗糙，不光滑，接触面积减小导致的热阻增大，最终导致器件的失效。

### 1.2 芯片相关失效

与芯片相关的失效是 IGBT 模块失效的重要原因，其和与封装相关的老化失效不同，它是一种瞬变失效，由于电应力的作用，器件内部可能发生短路或者断路的情况，造成不可挽回的异变。与芯片相关的失效主要包括：电气过应力、静电荷放电、闩锁效应和寄生晶体管的触发、离子污染、热载流子注入、电迁徙和热激发<sup>[17]</sup>等，在实际复杂的工作环境中，几种失效形式通常一齐发生，导致器件加速失效。

电气过应力详细来说分为两种：过电压应力和过电流应力<sup>[18]</sup>。当 IGBT 处于过电压情况下，栅-集、栅-射间的寄生电容会发生耦合效应，从而产生过大电流导致器件发热损坏。电流过应力是指器件工作的电流超过了安全电流值，导致器件严重发热而损坏。净电荷放电问题会导致栅极氧化层击穿，从而造成短路事故。可以通过测量栅极的充电时间来检查是否出现净电荷放电现象，为了避免此现象

发生，可添加栅极保护电路<sup>[19]</sup>。

总而言之，IGBT 老化损坏或故障会导致其物理和化学特性的变化<sup>[20]</sup>，也就是 IGBT 器件参数的一些变化。铝键合线的断开会导致 IGBT 器件的导通电阻上升，而焊料层疲劳会导致散热问题的发生，从引起模块热阻增大。电迁移和铝金属重构也可能引起接触电阻或者表面电阻的上升，净电荷放电、离子污染以及热载流子注入可能引起栅极衰退。简单来说，IGBT 的故障模式可划分为瞬变故障与缓变故障，针对前者，应研究故障诊断与冗余容错控制技术；针对后者，应先提取其老化失效特征因子，再进行故障预测或剩余寿命估计进而评估其可靠性。

## 2 IGBT 退化实验及数据分析

本文中使用的 IGBT 退化数据来自 Nishad Patil 等人<sup>[21]</sup>的电阻负载下的 NPT-IGBT 加速老化实验，总的来说，实验装置由栅极驱动板、主板和电源调节板组成。主板上有用 IGBT 器件的终端块和连接到终端块的输出端口，每个端口分别用于栅极-发射极电压 ( $V_{GE}$ )、集电极-发射极电压 ( $V_{CE}$ ) 和集电极-发射极电流 ( $I_{CE}$ ) 信号，用示波器测量。主板还装有一个 200kHz 霍尔效应电流传感器，最大电流额定值为 100A，用于测量  $I_{CE}$ 。

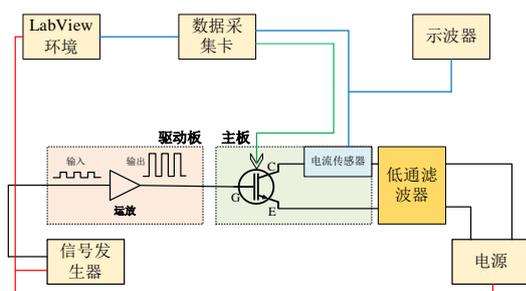


图 4 IGBT 的功率循环实验装置图

Fig.4 Experimental setup for power cycling of IGBTs

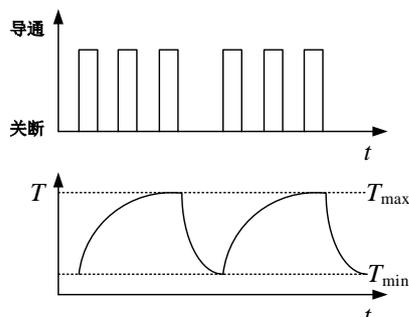


图 5 温度和开关测试图

Fig.5 Schematic of temperature and switching test

在 IGBT 上进行了电-热应力的加速老化实验，实验条件是占空比为 50%，门电压为 15V，频率为 1KHz，集电极-发射极电压为 9V。器件在设置的最高壳温  $T_{max}=200^{\circ}C$  和最低壳温  $T_{min}=100^{\circ}C$ （平均温度为  $150^{\circ}C$ ）之间进行循环导通，达到老化的目的。实验中使用热电偶贴于器件的 TO-220A 型封装的散热片上来得到温度数据，待老化 IGBT 不停地进行导通关断操作直至监测到的壳温上升至  $T_{max}$ ，接着 IGBT 关断冷却，直至温度下降至  $T_{min}$ ，然后再再次进行导通关断操作，循环往复，一直持续到设备故障。其过程如图 5 所示。

IGBT 的老化失效问题会一定程度地在其外部参数上面表现出来，因此我们在进行 IGBT 的失效分析后，基于实验数据，便可选择最能代表其健康状态的老化特征因子结合数据驱动算法来进行故障预测。文献<sup>[22]</sup>表明可用作 IGBT 的老化特征参数有：门极导通阈值电压、跨导、集电极-发射极饱和压降等。随着老化进程的加剧，典型特征参数的变化有：1) 集电极-发射极饱和压降上升；2) 门极导通阈值电压上升；3) 跨导上升；4) 器件关断时间变长；5) 关断瞬时尖峰电压下降。本文的研究中，选取集电极-发射极饱和压降  $V_{CE(ON)}$  作为老化特征参数且认为其值上升至原来的 20% 为故障阈值。

## 3 IGBT 故障预测

通过上一节数据分析，选定集电极发射极导通压降  $V_{CE(ON)}$  作为老化特征参数， $V_{CE(ON)}$  随着 IGBT 退化进程的加剧，存在上升趋势。图 6 显示了 IGBT 器件的老化特征参数  $V_{CE(ON)}$  随时间的变化趋势，可以看出，老化特征参数  $V_{CE(ON)}$  呈现出一个分阶段上升的特点，在 10 小时以前为退化初期，其进程较为缓慢，随着时间推移，后期呈现出加速退化的趋势，目前的单一预测算法往往只能满足一个阶段的预测需求，而对于两个阶段不能很好的进行学习和预测，因此，结合文献中的实验数据，采用一种灰色 Verhulst 模型和无迹卡尔曼粒子滤波的组合型算法对 IGBT 的全寿命周期进行退化预测，基本思想如图 7 所示。下面分别对灰色 Verhulst 模型和无迹卡尔曼粒子滤波的应用进行介绍。

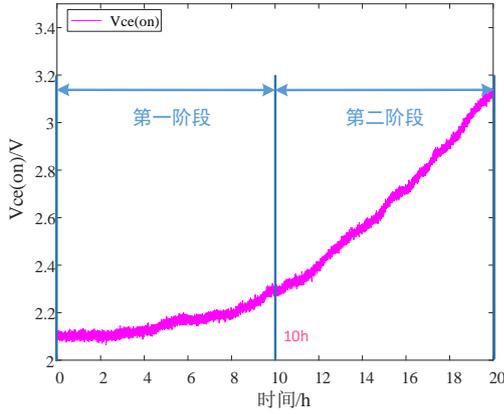


图 6 IGBT 器件的老化特征参数  $V_{CE(ON)}$  随时间的变化趋势

Fig.6 IGBT device aging characteristic parameters  $V_{CE(ON)}$  change trend with time

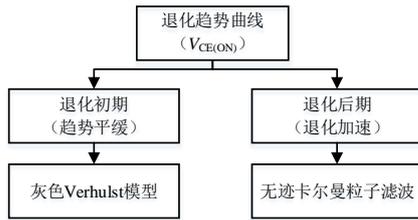


图 7 组合型算法运用在预测中

Fig.7 Combined algorithm used in prediction

### 3.1 灰色 Verhulst 模型(GVM)

灰色模型 (Grey Models, GM) 即是通过少量的、不完全的信息, 建立灰色微分预测模型, 对事物发展规律作出模糊性的长期描述。灰色 Verhulst 模型为灰色模型中的一种, 用来描述具有 S 型趋势的曲线。

在提取了 IGBT 的老化特征参数之后, 即可根据数据来实现基于灰色 Verhulst 模型的 IGBT 故障预测: 在 IGBT 器件运行的过程中, 采集获取器件的老化特征参数, 并将其数据的部分历史量作为已知信息从而建立灰色预测模型, 来预测在未来某个时刻器件老化特征参数的大小, 以此来反应 IGBT 的老化发展程度, 实现 IGBT 器件未来健康状态的预测。

灰色预测模型首先采用累加生成算子 (AGO) 产生目标状态的累加生成序列以减小状态的随机性, 并通过灰色微分方程预测未来的累加值, 然后对累加数据进行一阶微分的求解, 通过最小二乘法确定解中的未知参数, 最后采用逆累加生成算子 (IAGO) 并作用于累加值的预测值, 从而得到目标状态的预测值。其具体实现过程如下<sup>[23]</sup>:

步骤一: 设原始时间序列为

$$x^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\} \quad (1)$$

其中,  $x^{(0)}(k) \geq 0, k=1, 2, \dots, n$ ;  $x^{(1)}$  为  $x^{(0)}$  的 1-AGO 序列, 即

$$x^{(1)} = \{x^{(1)}(1), x^{(1)}(2), \dots, x^{(1)}(n)\} = \{x^{(0)}(1), x^{(0)}(1) + x^{(0)}(2), \dots, x^{(0)}(1) + \dots + x^{(0)}(n)\} \quad (2)$$

其中,  $x^{(1)}(k) = \sum_{i=1}^k x^{(0)}(i), k=1, 2, \dots, n$ 。

步骤二: 生成  $x^{(1)}$  的紧邻均值生成序列  $z^{(1)}$

$$z^{(1)} = \{z^{(1)}(2), z^{(1)}(3), \dots, z^{(1)}(n)\} \quad (3)$$

$$z^{(1)}(k) = 0.5(x^{(1)}(k) + x^{(1)}(k-1)), k=2, 3, \dots, n \quad (4)$$

步骤三: 建立灰色 Verhulst 模型

$$x^{(0)} + az^{(1)} = b(z^{(1)})^2 \quad (5)$$

其中,  $a$  和  $b$  为方程参数。并称

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = b(x^{(1)})^2 \quad (6)$$

为白化方程,  $t$  为时间。

步骤四: 如上所述为灰色 Verhulst 模型, 需要确定时间响应式中的参数  $a$  和参数  $b$  才可以具体求出预测值。 $\hat{a} = (a, b)^T$  为参数序列, 且

$$B = \begin{bmatrix} -z_2^{(1)} & (z_2^{(1)})^2 \\ -z_3^{(1)} & (z_3^{(1)})^2 \\ \vdots & \vdots \\ -z_n^{(1)} & (z_n^{(1)})^2 \end{bmatrix}, Y = \begin{bmatrix} x_2^{(0)} \\ x_3^{(0)} \\ \vdots \\ x_n^{(0)} \end{bmatrix} \quad (8)$$

则参数列  $\hat{a}$  的最小二乘满足  $\hat{a} = (B^T B)^{-1} B^T Y$ 。

步骤五: 灰色 Verhulst 模型白化方程的解 (时间响应函数) 为

$$x^{(1)}(t) = \frac{ax_0^{(1)}}{bx_0^{(1)} + (a - bx_0^{(1)})e^{at}} \quad (9)$$

则, 灰色 Verhulst 模型的时间响应序列为

$$\hat{x}^{(1)}(k+1) = \frac{ax^{(1)}(0)}{bx^{(1)}(0) + (a - bx^{(1)}(0))e^{ak}} \quad (10)$$

可将  $x^{(1)}(0)$  取为  $x^{(0)}(1)$ , 则上式变为

$$\hat{x}^{(1)}(k+1) = \frac{ax^{(0)}(1)}{bx^{(0)}(1) + (a-bx^{(0)}(1))e^{ak}} \quad (11)$$

步骤六：对上式作累减还原，则原始数据序列的灰色 Verhulst 模型预测结果为

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k) \quad (12)$$

将灰色 Verhulst 预测算法运用在 IGBT 的故障预测中，需将其特征参数  $V_{CE(ON)}$  的训练值代入为原始时间序列  $x^{(0)}$  并按照上述步骤进行计算。

### 3.2 粒子滤波(PF)

粒子滤波法 (Particle Filter, PF) 是指通过寻找一组在状态空间传播的随机样本对概率密度函数进行近似，以样本均值代替积分运算，从而获得状态最小方差分布的过程。PF 方法假设状态方程可以建模为一阶马尔可夫过程 (Markov Process)，其输出在条件上独立，如图 8 所示。为了分析系统，需要一个描述系统状态随时间变化的模型 (控制输入)，以及一个将测量与系统状态相关联的模型，分别称为状态模型和测量模型，并且以概率状态空间公式表示。时间  $k$  处的系统状态可以描述为公式 (13)， $f_k$  是状态模型，它是历史状态，时间，任何控制输入和  $\omega_k$  (过程噪声) 的函数。使用公式 (14) 中所示的测量模型，在时间  $k$  处的测量与系统状态相关，其中  $h_k$  是测量模型， $v_k$  是测量噪声。

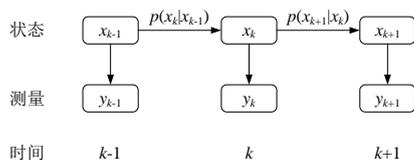


图 8 状态空间模型

Fig.8 State-space model

$$x_k = f_k(x_{k-1}, \omega_{k-1}) \quad (13)$$

$$y_k = h_k(x_k, v_k) \quad (14)$$

在当前的研究中，PF 预测是基于导通状态的电阻值变化量 ( $V_{CE(ON)}$ )。状态模型和测量模型指的是：

$$\begin{aligned} V_{CE(ON),k} &= \\ V_{CE(ON),k-1} + 2at_k(t_k - t_{k-1}) + b(t_k - t_{k-1}) + \omega_{k-1} & \quad (15) \\ z_k = V_{CE(ON),k} + v_k & \end{aligned}$$

$z_k$  是  $V_{CE(ON)}$  的测量值。

粒子滤波算法主要包含两个过程：训练过程和

预测过程。训练过程是通过健康数据实现粒子的优胜劣汰。具体步骤如下：

步骤一：参数初始化；

步骤二：重要性采样；

$$x_k^i = \pi(x_k | x_{0:k-1}^i, y_{0:k}) \quad (14)$$

步骤三：计算重要性权重；

$$\begin{aligned} \omega_k^i &= \omega_{k-1}^i \frac{p(y_k | x_k) p(x_k | x_{k-1})}{\pi(x_k | x_{0:k-1}, y_{0:k})} \\ \tilde{\omega}_k^i &= \frac{\omega_k^i}{\sum_{i=1}^n \omega_k^i} \end{aligned} \quad (15)$$

步骤四：重采样；

$$\hat{N}_{eff} = \frac{1}{\sum_{i=1}^N (\tilde{\omega}_k^i)^2} \quad (16)$$

步骤五：状态估计。

$$x_{0:k}^{est} = \sum_{i=1}^n x_{0:k}^i \tilde{\omega}_k^i \quad (17)$$

在上述步骤中，实现粒子更新的重要方法是重采样。重采样用于避免粒子退化的问题，即，避免除了一个粒子重要性权重以外的所有其他重要性权重都接近零的情况。正确选择重采样方法也会影响算法的性能。在研究中选用系统重采样方法。

#### 3.2.1 无迹卡尔曼粒子滤波(UPF)

UPF 是改进重要性密度函数的一种很好的方法，用于减少粒子退化问题的影响。使用无迹卡尔曼滤波 (UKF) 方法改进粒子滤波的算法称为无迹卡尔曼粒子滤波 (UPF)。UPF 算法使用 UKF 算法生成建议分布  $N(\bar{x}_k^i, \hat{p}_k^i)$ ，并从其中进行抽样。然后，结合当前的观测结果，可以有效地使用最新的测量信息。

UKF 摒弃了对非线性函数进行线性化的传统做法，而是采用卡尔曼线性滤波框架，对于一步预测方程，使用无迹变换 (Unscented Transform, UT) 来处理均值和协方差的非线性传递问题。UKF 算法是对非线性函数的概率密度分布进行近似，用一系列确定样本来逼近状态的后验概率分布，而不是对非线性函数进行近似，不需要对雅可比矩阵进行求导。UKF 没有忽略高阶项，因此对于非线性分布的统计量有较高的计算精度。

UT 的基本原理如下。设置一个非线性变换  $y = f(x)$ 。状态向量  $x$  是  $n$  维随机变量，并且其平均值和

方差是已知的。然后，可以通过 UT 获得  $2n+1$  个 sigma 点  $X$  和相应的权重  $\omega$  来计算  $y$  的统计特性。

步骤一：计算  $2n+1$  个 sigma 点，即样本点。这里  $n$  是状态的维数。

$$\begin{cases} X^{(0)} = \bar{X}, i=0 \\ X^{(i)} = \bar{X} + (\sqrt{(n+\lambda)P})_i, i=1, \dots, n \\ X^{(i)} = \bar{X} - (\sqrt{(n+\lambda)P})_i, i=n+1, \dots, 2n \end{cases} \quad (18)$$

公式中， $(\sqrt{P})^T (\sqrt{P}) = P, (\sqrt{P})_i$  代表代表矩阵平方根的第  $i$  列。

步骤二：计算这些采样点的相应权重。

$$\begin{cases} \omega_m^{(0)} = \frac{\lambda}{n+\lambda} \\ \omega_c^{(0)} = \frac{\lambda}{n+\lambda} + (1-a^2 + \beta) \\ \omega_m^{(i)} = \omega_c^{(i)} = \frac{\lambda}{2(n+\lambda)}, i=1, \dots, 2n \end{cases} \quad (19)$$

公式中，下标  $m$  为平均值， $c$  为协方差，上标为第几个采样点。参数  $\lambda = a^2(n+\kappa) - n$  是一个缩放比例参数，用来降低总的预测误差， $a$  的选取控制了采样点的分布状态， $\kappa$  为待选参数，其具体取值虽然没有界限，但是通常应确定矩阵  $(n+\lambda)P$  为半正定矩阵。待选参数  $\beta \geq 0$  是一个非负的权系数，它可以合并方程中高阶项的动差，这样就可以把高阶项的影响包含在内。

UKF 算法的实现步骤如下。

步骤一：利用式(18)和(19)获得一组采样点（称为 Sigma 点集）及其对应权值。

$$\begin{aligned} X^{(i)}(k|k) &= [\hat{X}(k|k), \\ &\hat{X}(k|k) + \sqrt{(n+\lambda)P(k|k)}, \\ &\hat{X}(k|k) - \sqrt{(n+\lambda)P(k|k)}] \end{aligned} \quad (20)$$

步骤二：计算  $2n+1$  个 Sigma 点集的一步预测， $i=1,2,3,\dots,2n+1$ 。

$$X^{(i)}(k+1|k) = f[k, X^{(i)}(k|k)] \quad (21)$$

步骤三：计算系统状态量的一步预测以及协方差矩阵，它由 Sigma 点集的预测值加权求和得到，其中权值  $\omega^{(i)}$  通过公式(19)得到。

$$\hat{X}(k+1|k) = \sum_{i=0}^{2n} \omega^{(i)} X^{(i)}(k+1|k) \quad (22)$$

$$P(k+1|k) = \sum_{i=0}^{2n} \omega^{(i)} [\hat{X}(k+1|k) - X^{(i)}(k+1|k)] [\hat{X}(k+1|k) - \hat{X}(k+1|k)]^T + Q \quad (23)$$

步骤四：根据一步预测值，再次使用 UT 变换，产生新的 Sigma 点集。

$$\begin{aligned} \hat{X}^{(i)}(k+1|k) &= [\hat{X}(k+1|k), \\ &\hat{X}(k+1|k) + \sqrt{(n+\lambda)P(k+1|k)}, \\ &\hat{X}(k+1|k) - \sqrt{(n+\lambda)P(k+1|k)}] \end{aligned} \quad (24)$$

步骤五：将由步骤四预测的 Sigma 点集代入观测方程，得到预测的观测量， $i=1,2,3,\dots,2n+1$ 。

$$Z^{(i)}(k+1|k) = h[X^{(i)}(k+1|k)] \quad (25)$$

步骤六：由步骤五得到 Sigma 点集的观测预测值，通过加权求和得到系统预测的均值和协方差。

$$\begin{aligned} \bar{Z}(k+1|k) &= \sum_{i=0}^{2n} \omega^{(i)} Z^{(i)}(k+1|k) \\ P_{z_k z_k} &= \sum_{i=0}^{2n} \omega^{(i)} [Z^{(i)}(k+1|k) - \bar{Z}(k+1|k)] [Z^{(i)}(k+1|k) - \bar{Z}(k+1|k)]^T + R \\ P_{x_k z_k} &= \sum_{i=0}^{2n} \omega^{(i)} [X^{(i)}(k+1|k) - \bar{Z}(k+1|k)] [Z^{(i)}(k+1|k) - \bar{Z}(k+1|k)]^T \end{aligned} \quad (26)$$

步骤七：计算卡尔曼增益矩阵。

$$K(k+1) = P_{x_k z_k} P_{z_k z_k}^{-1} \quad (27)$$

步骤八：计算系统的状态更新和协方差更新。

$$\begin{aligned} \hat{X}(k+1|k+1) &= \\ &\hat{X}(k+1|k) + K(k+1) [Z(k+1) - \hat{Z}(k+1|k)] \\ P(k+1|k+1) &= \\ &P(k+1|k) - K(k+1) P_{z_k z_k} K^T(k+1) \end{aligned} \quad (28)$$

由此可以看出，无迹卡尔曼滤波在处理非线性滤波时，并不需要在估计点处做泰勒级数展开，然后再进行前  $n$  阶近似，而是在估计点附近进行 UT 变换，使获得的 Sigma 点集的均值和协方差与原统计特性匹配，再直接对这些 Sigma 点集进行非线性映射，近似得到状态概率密度函数。

## 4 结果与分析

上一节中，分析了作为老化特征参数的  $V_{CE(ON)}$  随老化时间的推移呈现的分阶段的上升趋势，针对这两种阶段，选取不同的预测算法进行故障的预测，并且与使用单一方法进行精确度对比。首先对数据进行滑动平均滤波，如图 9 所示。

从图 9 可以看出，IGBT 的整个老化时间为 20 小时，12000 个使用周期。生命曲线分为两个阶段。第一阶段大约是 0 到 10h (0 到 6000 个周期)，这是一个缓慢的降解阶段。首先采用 GVM 方法进行预测，选取数据集的前 600 个值作为训练值，将其带入 GVM 的预测方程，得到预测值。图 10 为预测结果。

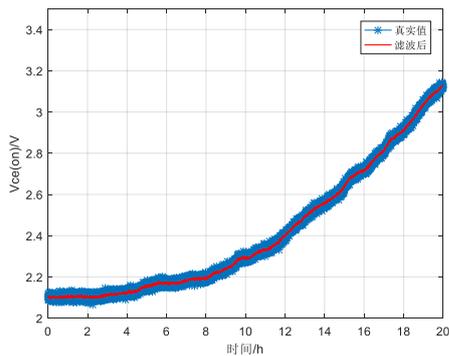


图 9  $V_{CE(ON)}$  的真实值以及滤波后的值

Fig.9 The actual  $V_{CE(ON)}$  value and the value after filtering

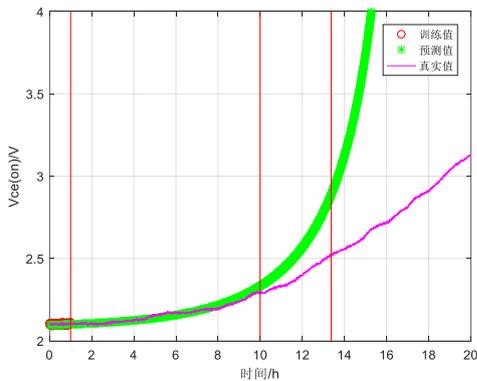


图 10 GVM 方法预测结果

Fig.10 Prediction results of GVM method

从图 10 可以看出，GVM 对第一阶段的预测效果较好。但在第二阶段预测结果不准确。预测结果的绝对误差如图 11 所示。10h 前预测结果的绝对误差在 0.06 以下，是一个较小的误差范围。

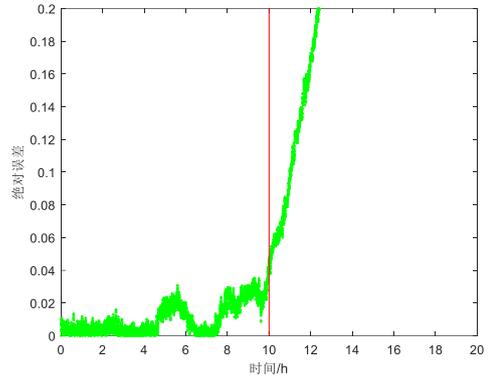


图 11 GVM 方法预测误差

Fig.11 Prediction error of GVM method

接下来采用 UPF 方法进行预测。在 UPF 方法仿真中，重采样方法选择了系统重采样方法。UPF 算法从 1h 开始训练，即在第 601 个采样点之前。

从图 12 可以看出，当  $V_{CE(ON)}$  上升 20% 作为老化预警，则  $V_{CE(ON)}$  的参数老化预警发生在 13.37h。UPF 给出的平均预测失效时间为 12.96h，预测误差为 3.07%。

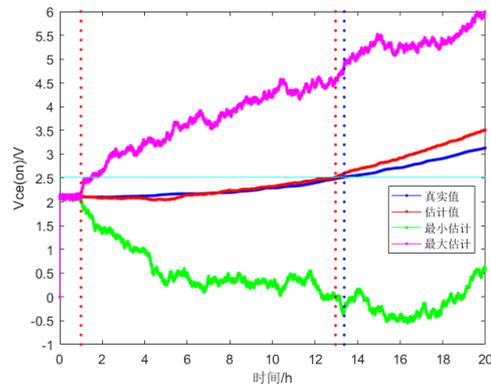


图 12 UPF 方法预测结果

Fig.12 Prediction results of UPF method

预测值与真实值的偏差如图 13 所示。从图中可以看出，使用 UPF 算法预测  $V_{CE(ON)}$  值时，在 0~14h 时绝对误差控制在 0.12 以下，在 10h~14h 时绝对误差控制在 0.02~0.08 之间。在故障时间点，预测值可以保证在真实值之前得到预警。预测误差为 3.07%。

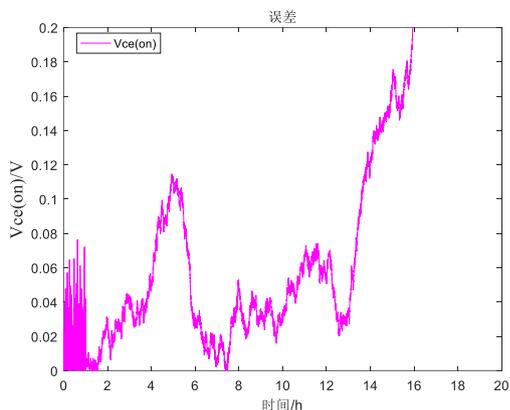


图 13 UPF 方法预测误差

Fig.13 Prediction error of UPF method

与单独使用 UPF 算法进行  $V_{CE(ON)}$  预测相比, 组合算法的预测精度更高。采用灰色 Verhulst 模型和 UPF 算法的预测结果如图 14 所示。UPF 算法从第二阶段即第 10h (第 6000 个采样点) 之前开始训练。将训练数据从第一阶段的预测值中提取。 $V_{CE(ON)}$  的实际故障时间为 13.37h, 而估计故障时间为 13.27h。故障时间预测误差为 0.75%。

组合算法的预测值与真值的偏差如图 15 所示。从图中可以看出, 在 10h 到 14h 之间, 第二阶段使用 UPF 算法的准确率高于整个过程中使用 UPF 算法的准确率, 即 0 到 0.04。因此, 在整个预测过程中, 组合算法的精度要高于单独使用 GVM 或 UPF。算法比较如表 1 所示。

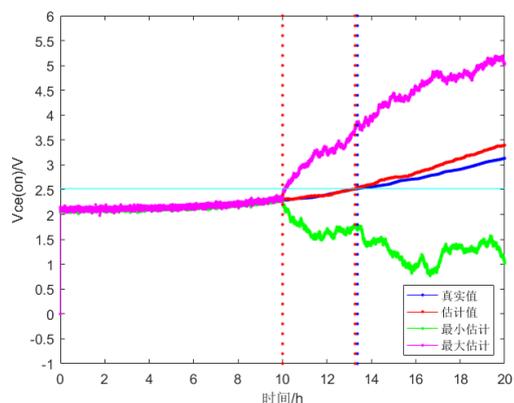


图 14 组合型方法预测结果

Fig.14 Prediction results of combined algorithm

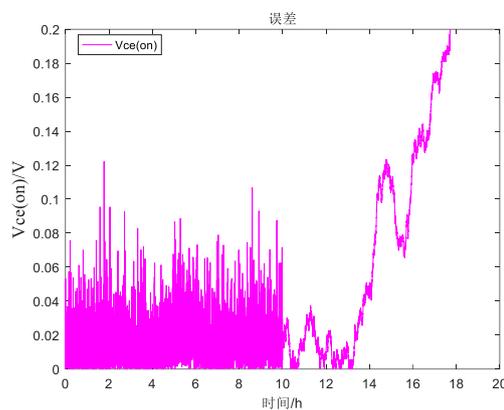


图 15 真实值与预测值之间的误差

Fig.15 The deviation between predicted and true values

表 1 算法比较

Tab.1 Algorithm comparison

	GVM	UPF	GVM+UPF
阶段 1: $V_{CE(ON)}$ 误差 (0-10h)	低于 0.06	低于 0.12	低于 0.06
阶段 2: $V_{CE(ON)}$ 误差 (10-14h)	误差较大	0.02-0.08 之间	0-0.04 之间
真实故障时间	13.37h	13.37h	13.37h
预测故障时间	—	12.96h	13.27h
预测误差	>10%	3.07%	0.75%

## 5 结论

本文在进行 IGBT 失效模式和机理的分析基础上, 研究了一种改进的基于数据驱动 IGBT 故障预测方法。在这种方法中,  $V_{CE(ON)}$  被选为老化特征参数。针对 IGBT 的分级退化状态, 结合灰色 Verhulst 模型和无迹卡尔曼粒子滤波算法对 IGBT 的失效进行预测。并在 IGBT 循环老化实验的数据中进行了算法仿真研究, 结果表明组合型方法取得了较好的效果。

## 参考文献

- [1] S. Yang, A. Bryant, P. Mawby, D. Xiang, L. Ran, and P. Tavner, An Industry-Based Survey of Reliability in Power Electronic Converters [J]. IEEE Transactions on Industry Applications, 2011, 47(3): 1441-1451.
- [2] X. Perpiñà et al. IGBT module failure analysis in railway applications[J]. Microelectronics Reliability, 2008, 48(8-9): 1427-1431.
- [3] 孟冬辉. 牵引变流器的故障预测与健康管理的 PHM 及可靠性评估技术研究[D]. 北京: 北京交通大学,

- 2017.
- Meng Linghui. Research on fault prognostics and health management and reliability assessment of traction converter[D]. Beijing: Beijing Jiaotong University, 2017.
- [4] 彭喜元. 数据驱动的故障预测[M]. 哈尔滨: 哈尔滨工业大学出版社, 2016.
- Peng Xiyuan. Data-driven failure prediction[M]. Harbin: Harbin Institute of Technology Press, 2016.
- [5] Sasaki K, Iwasa N, Kurosu T, et al. Thermal and structural simulation techniques for estimating fatigue life of an IGBT module[C]. International Symposium on Power Semiconductor Devices and Ic's, 2008: 181-184.
- [6] Zhang W, Liu S, Sun B, et al. A cloud model-based method for the analysis of accelerated life test data[J]. Microelectronics Reliability, 2014, 55(1): 123-128.
- [7] Huang H, Mawby P A. A lifetime estimation technique for voltage source inverters[J]. IEEE Transactions on Power Electronics, 2013, 28(8): 4113-4119.
- [8] Batzel T D, Swanson D C. Prognostic health management of aircraft power generators[J]. IEEE Transactions on Aerospace & Electronic Systems, 2009, 45(2): 473-482.
- [9] Wu Y K, Jiang B, Lu N Y, et al. Bayesian network based fault prognosis via bond graph modeling of high-speed railway traction device[J]. Mathematical Problem in Engineering, 2015, 1-11.
- [10] Alghassi A, Samie M, Perinpanayagam S. Stochastic RUL calculation enhanced with TDNN-based IGBT failure modeling[J], 2015, 65(2): 1-16.
- [11] Sutrisno E. Fault detection and prognostics of insulated gate bipolar transistor (IGBT) using a k-nearest neighbor classification algorithm[J]. Dissertations & Theses-gradworks, 2013.
- [12] Marco Rigamonti, Piero Baraldi, Enrico Zio, et al. Identification of the degradation state for condition-based maintenance of insulated gate bipolar transistors: A self-organizing map approach[J]. Microelectronics Reliability, 2016, 60.
- [13] Sreenuch T, Alghassi A, Perinpanayagam S, et al. Probabilistic Monte-Carlo method for modelling and prediction of electronics component life[J]. IJACSA, 2014, 5(1).
- [14] 王宇琦. IGBT 疲劳老化失效剩余使用寿命预测的研究[D]. 西安电子科技大学, 2017.
- Wang Yuqi. Study on prediction of remaining useful life of IGBT fatigue aging[D]. Xidian University, 2017.
- [15] Xiang D, Ran L, Tavner P, et al. Monitoring solder fatigue in a power module using the rise of case-above-ambient temperature[C]. Energy Conversion Congress and Exposition, 2010: 955-962.
- [16] 陈君, 张小玲, 谢雪松, 等. 一种 IGBT 热阻测试系统的研制[J]. 半导体技术, 2015, 40(01): 68-72.
- Chen Jun, Zhang Xiaoling, Xie Xuesong, et al. Development of a thermal resistance testing system for IGBT[J]. Semiconductor Technology, 2015, 40(01): 68-72.
- [17] 周利华. IGBT 的寿命评估方法研究[D]. 淮南: 安徽理工大学, 2017.
- Zhou Lihua. Research on the life evaluation method of IGBT[D]. Huainan: Anhui University of Science & Technology, 2017.
- [18] 刘鹿生. IGBT 及其子器件的几种失效模式[J]. 电力电子, 2006, 5: 42-46.
- Liu Lusheng. Several failure modes of IGBT and its sub-devices[J]. Power Electronics, 2006, 5: 42-46.
- [19] 张学甲. CRH2 牵引变流器故障分析及其诊断方法研究[D]. 长沙: 中南大学, 2014.
- Zhang Xuejia. CRH2 traction converter fault analysis and diagnosis method research[D]. Changsha: Central South University, 2014.
- [20] 李宁. 基于机器学习算法的 IGBT 模块故障预测技术研究[D]. 北京: 北京交通大学, 2017.
- Li Ning. Research on IGBT module fault prediction technology based on machine learning algorithm[D]. Beijing: Beijing Jiaotong University, 2017.
- [21] Nishad Patil, Diganta Das, Michael Pecht. A prognostic approach for non-punch through and field stop IGBTs[J]. Microelectronics Reliability, 2012, 52: 482-488.
- [22] Nishad Patil, Diganta Das, Kai Goebel. Identification of Failure Precursor Parameters for Insulated Gate Bipolar Transistors (IGBTs)[J]. International Conference on Prognostics and Health Management, 2008.

[23] 曹鸿飞, 张铭, 李平. 灰色动态模型群在城市轨道交通客流预测中的应用研究[J]. 铁路计算机应用, 2012, 21(03): 1-3+8.

Cao Hongfei, Zhang Ming, Li Ping. Application research on grey dynamic model group in passenger flow prediction for urban transit[J]. Railway Computer Application, 2012, 21(03): 1-3+8.

---

作者简介

黎白冷 女, 1996年生, 硕士, 研究方向为电力电子与电力传动。

E-mail: 18121453@bjtu.edu.cn

方晓春 男, 1987年生, 讲师, 研究方向为轨道交通电力牵引传动。

E-mail: me330221789@126.com (通信作者)