

基于LSTM-DHMM的MOSFET器件健康状态识别与故障时间预测

张明宇¹, 王琦^{1,2}, 于洋¹

(1. 沈阳工业大学信息科学与工程学院, 辽宁沈阳 110870; 2. 辽宁工业大学, 辽宁锦州 121001)

摘要: 针对MOSFET(Metal-Oxide-Semiconductor Field-Effect Transistor)器件故障预测与健康管理工作, 提出了一种长短时记忆(Long Short-Term Memory, LSTM)算法与离散隐马尔可夫模型(Discrete Hidden Markov Model, DHMM)相结合的故障预测新方法. 该方法利用LSTM算法预测器件状态发展趋势; 用自回归(AutoRegressive, AR)模型提取故障信息特征; 以DHMM建立特征向量和退化等级之间的映射关系; 在LSTM-DHMM模型预测结果的基础上, 结合失效阈值排除虚警并预测故障时间, 预测误差小于10%, 精度较高. 与GRU-DHMM(Gated Recurrent Unit Discrete Hidden Markov Model)、GRU-SVM(Gated Recurrent Unit Support Vector Machine)、LSTM-SVM(Long Short-Term Memory Support Vector Machine)方法进行对比分析, 结果表明, LSTM-DHMM的预测准确率高于其他三种方案, 能有效识别实验器件健康状态、较好预测故障时间, 具有有效性和优越性.

关键词: 故障预测与健康管理工作; MOSFET(Metal-Oxide-Semiconductor Field-Effect Transistor); 长短时序列; 离散隐马尔可夫模型; 自回归模型; 故障时间

中图分类号: TH165+3; TN386.1 文献标识码: A 文章编号: 0372-2112(2022)03-0643-09

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20210047

Health Status Identification and Fault Time Prediction of MOSFET Device Based on LSTM-DHMM

ZHANG Ming-yu¹, WANG Qi^{1,2}, YU Yang¹

(1. School of Information Science and Engineering, Shenyang University of Technology, Shenyang, Liaoning 110870, China;

2. Liaoning University of Technology, Jinzhou, Liaoning 121001, China)

Abstract: Aiming at the problem of MOSFET (Metal-Oxide-Semiconductor Field-Effect Transistor) device prognostic and health management, a fault prediction method combining long short term memory(LSTM) algorithm and discrete hidden Markov model(DHMM) is proposed to identify the health status and predict the fault time of MOSFET devices. In this method, LSTM algorithm is used to predict the development trend of device state; autoregressive(AR) model is used as the feature extraction method; DHMM is used to establish the mapping relationship between feature vector and degradation level; based on the prediction results of LSTM-DHMM model, false alarm is eliminated and fault time is predicted by combining with the failure threshold. The prediction error is less than 10% and the accuracy is high. Compared with single-stress GRU-DHMM(Gated Recurrent Unit Discrete Hidden Markov Model)、GRU-SVM(Gated Recurrent Unit Support Vector Machine) and LSTM-SVM(Long Short-Term Memory Support Vector Machine), the proposed method is superior to the other four schemes in prediction accuracy and rationality, the results show that the prediction accuracy of the proposed method is higher than that of the other three schemes, and the proposed method can effectively identify the health state of the experimental devices and predict the fault time well, which is effective and superior.

Key words: prognostic and health management; MOSFET (Metal-Oxide-Semiconductor Field-Effect Transistor); long short-term memory; discrete hidden Markov model; autoregressive model; fault time

1 引言

半导体器件作为现代电子设备的关键零部件,被广泛应用于军工、通信、自动化和航空等领域,其健康状况直接影响着设备的运行性能和运行精度.传统的依照可靠性手册对半导体器件进行评估鉴定,是基于“正常”和“失效”的二元判定,已经不能满足当前发展对寿命评估的要求,开展半导体器件的故障预测和健康管理(Prognostic and Health Management, PHM)研究、建立产品使用寿命与故障机理之间的关系是十分必要的.

国内外主要从故障诊断^[1,2]、状态评估^[3-5]和寿命预测^[6-9]三个方面开展 PHM 技术研究,取得了较好的成果.考虑到现有研究方法主要集中于对单一监测变量进行分析,且少有将状态评估和寿命预测结合起来研究,存在退化因素考虑不全和信息挖掘不充分的问题,本文面向电子领域 PHM 技术,提出了一种基于 LSTM-DHMM 的 MOSFET 器件故障时间预测方法,该方法可对器件状态进行预估并预测故障时间,为科学评估器件健康状态、最大限度地降低故障影响奠定基础.

2 基于 LSTM-DHMM 方法的健康状态识别与故障时间预测模型

2.1 预测流程

LSTM 算法是一种深度学习理论,能够学习数据中暗含的复杂规则,其具备的长期记忆能力,使之处理半导体器件性能退化这种较长距离的时序依赖关系时更具优势;而半导体器件在故障演化过程中经历的衰退状态在现实中是观测不到的,只能根据状态观测值表现出来的征兆去感知器件的衰退状态, DHMM 可根据观测值反映研究对象内在状态,具有较强的状态描述特性与自学习能力,正适合处理半导体器件健康状态识别的问题.

基于 LSTM-DHMM 的 MOSFET 器件故障时间预测流程如图 1 所示.首先,对原始数据进行预处理;其次,采用 LSTM 算法对二维离散时域信号进行时间序列回归预测;再次,利用 AR 模型对得到的时间序列进行故障特征信息提取;接着,利用 DHMM 算法构建健康状态识别分类器,建立特征向量与退化等级间的映射关系,实现 MOSFET 器件退化状态的识别;最后,根据识别结果,结合失效阈值,进行虚警排除并实现 MOSFET 器件的故障时间预测.

2.2 数据预处理

由于原始时域监测信号中存在的干扰因素,会影响模型输出结果的真实性和精确度.因此,在预测前需进行数据预处理.

数据预处理包括去噪、数据压缩和归一化.

首先,使用加权滑动平均滤波法滤除训练集和测试

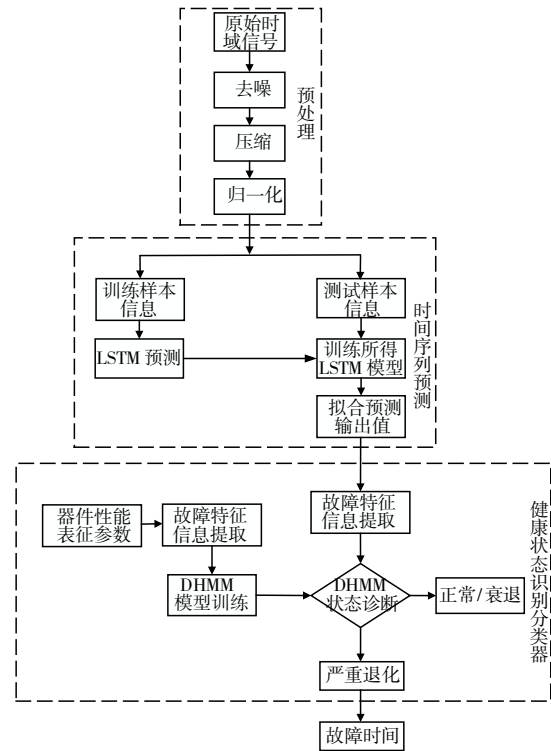


图1 LSTM-DHMM 预测流程

集中的高低频噪音.加权滑动平均滤波法如式(1)所示.

$$\bar{y}_i = \frac{\sum_{k=1}^N w_k y_{i+k}}{\sum_{k=1}^N w_k} \quad (1)$$

式(1)中, y_i 为原始时域数据; \bar{y}_i 为滤波后的数据; w_k 为线性权系数,其表达式如式(2)所示.

$$w_k = N + 1 - k \quad (2)$$

半导体器件状态的变化是极其缓慢的过程,当对半导体器件全寿命周期进行监测时,数据量将呈爆炸式增长.为加快模型收敛,减少预测耗费的时间,需对滤波后的数据进行压缩处理.本文选用一阶预测器数据压缩算法剔除重复、冗余数据.具体操作如下:

$$\Delta x(t_2) = x(t_2) - x(t_1) \quad (3)$$

$$\hat{x}(t_3) = x(t_2) + \Delta x(t_2) \quad (4)$$

$$k_L = \frac{x(t_2) - x(t_1)}{t_2 - t_1} \quad (5)$$

式(3)~(5)中, $x(t_1)$ 、 $x(t_2)$ 为样本中相邻点, k_L 为 $x(t_1)$ 和 $x(t_2)$ 定义的直线的斜率.设置一个可变阈值,如果 t_3 时刻的采样点在阈值范围内,则去除,反之则留用.以“MOSFET Thermal Overstress Aging Data Set”14号实验器件第五次实验数据为例,数据压缩前后对比见图2.

在时间序列预测阶段,采用二维离散时域信号作为样本输入,而二维离散时域信号具有不同的量纲和

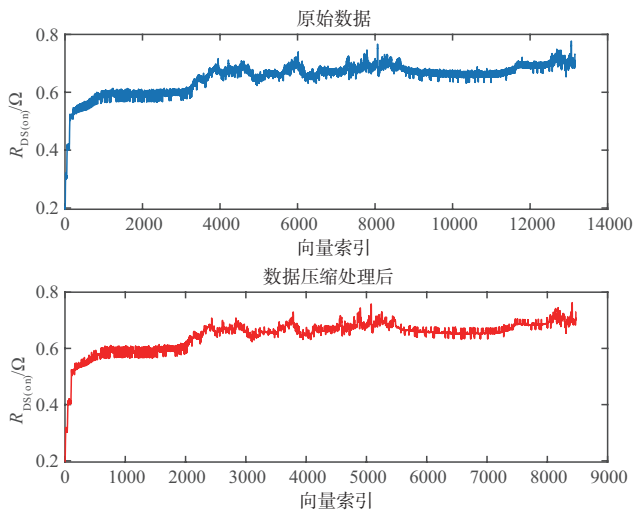


图2 数据压缩前后对比图

数量级,为消除量纲和数量级对模型训练结果的干扰,同时加快模型收敛,需进行压缩后数据的归一化处理.具体见式(6).

$$\hat{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

式(6)中, \hat{x} 为归一化值, x 为原始监测数据, x_{\min} 和 x_{\max} 为监测数据中的最小值和最大值.

2.3 模型搭建

MOSFET 器件的健康状态识别与故障时间预测模型分为时间序列预测和健康状态识别两部分. 时间序列预测部分拟合应力作用下器件故障特征向量的变化趋势,健康状态识别部分建立故障特征向量和退化等级之间的映射关系,结合两者的预测结果,判断器件健康状态、预测器件发生故障的时间. 时间序列预测部分采用堆叠结构,由 LSTM 单元、Dropout 层、全连接层和回归层组成. 健康状态识别部分包括特征提取、建立模式库、模式匹配与状态识别四个子部分. 模型架构如图 3 所示,图中 X^t 表示 t 时刻的样本输入, Dense 代表全连接层, Regression 代表回归层.

在时间序列预测阶段,由二维离散时域信号构成关于同一器件不同参数的时间序列训练集 X^t ,将多个器件的训练集分别代入 LSTM 单元,经 LSTM 单元处理后将输出导入全连接层,其中, t 时刻 X^t 的训练标签为 $t+1$ 时刻的输入 X^{t+1} . 为防止过拟合现象,在全连接层前加入 Dropout 层. 全连接层的输出为后续回归层的输入,回归层的输出即为时间序列预测结果. 在模型训练过程中,采用 BPTT 算法和模型权重优化算法调整模型参数,选用的模型权重优化算法将在 3.2 节中进行介绍. 选取均方根误差 (Root Mean Square Error, RMSE) 作为时间序列预测模型精确度的评价标准,其计算式为:

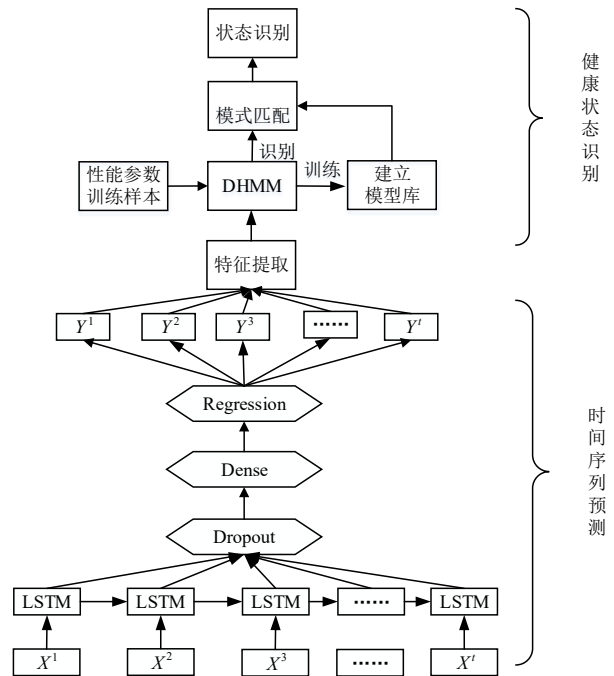


图3 LSTM-DHMM 模型框架

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N (\hat{y}_k - y_k)^2} \quad (7)$$

式(7)中, N 为预测的时间序列中数据的个数, \hat{y}_k 为预测值, y_k 为目标值. RMSE 数值越小,表示预测的时间序列效果越好.

在状态识别前,为找出时域信号的本质特征,需要提取时序序列的特征参数. 常用的平稳时间序列模型有自回归模型、移动平均 (Moving Average, MA) 模型和自回归滑动平均 (AutoRegressive Moving Average, ARMA) 模型. 根据序列的自相关函数 (AutoCorrelation Function, ACF) 和偏自相关系数函数 (Partial Autocorrelation Coefficient Function, PACF) 确定三种模型的使用场合: 自相关系数拖尾, 偏自相关系数截尾, 则选用 AR 模型; 自相关系数截尾, 偏自相关系数拖尾, 则选用 MA 模型; 自相关系数和偏自相关系数都拖尾, 选用 ARMA 模型^[10,11]. 根据选用的模型类型,确定相关算法提取模型特征参数.

观察特征参数变化趋势,根据特征参数的特点,将半导体器件的寿命周期划分为若干阶段: 器件在有效寿命期间发生故障的概率很小,为偶发故障,此阶段特征参数变化较平稳,前后幅值相差不大,设此阶段为正常损耗期;当器件的性能开始退化时,特征参数较正常损耗期会有较大起伏,设此阶段为衰退期;当退化逐步累积,器件在此阶段发生故障的概率增加,特征向量前后会有较大变化,设此阶段为严重退化期.

根据特征值变化趋势将器件寿命周期划分为正常

损耗期、衰退期和严重退化期后,便可进入状态识别阶段. 由于DHMM的观测矢量需要在有限的离散符号集合内,因此,在状态识别阶段,使用通讯领域信源编码技术中的Lloyds算法将提取到的故障特征信息转为离散码本,再利用式(8)将码本化为观察值序号序列.

$$\text{index}(x) = \begin{cases} 1, & x \leq \text{partition}(1) \\ i, & \text{partition}(i) < x \leq \text{partition}(i+1) \\ N, & \text{partition}(N-1) < x \end{cases} \quad (8)$$

式(8)中,partition为标量量化参数,index(x)为量化索引. 此时,便可利用DHMM算法训练样本序列,建立状态识别模型库.

在健康状态识别阶段,将码本化的故障特征信息值作为观测值序列输入到初始模型中,利用Baum-Welch算法可求得一组新的参数,同时获得新的模型,观测序列在新模型下的输出概率要大于在初始模型的输出概率. 重复此过程,逐步优化DHMM模型参数直到输出概率满足预设的收敛条件,此时的模型便是所求的DHMM状态识别模型.

3 实验与分析

3.1 数据集描述及分析

本文利用NASA Ames Research Center提供的“MOSFET Thermal Overstress Aging Data Set”作为实验数据对基于LSTM-DHMM的MOSFET器件健康状态识别与故障时间预测模型进行分析. 该数据集中包含栅-源电压、漏-源电压、漏电流和壳温等参数的监测数据.

半导体器件的健康状态在运行中很难直接观测,只能通过器件表现出的信号征兆判断半导体器件的状态. 为了便于观测实验器件状态随温度的变化趋势,本文选用单一退化特征向量作为状态观测值,通过计算数据集中漏-源电压与漏极电流的比值求出实验器件的漏-源导通电阻 $R_{\text{DS(on)}}$,以 $R_{\text{DS(on)}}$ 参数作为监测量反应实验器件的状态. 五次实验的 $R_{\text{DS(on)}}$ 随实验条件的变化如图4所示.




图4 五次实验 $R_{\text{DS(on)}}$ 变化趋势图

图4(a)显示,在前四次实验中,器件的 $R_{\text{DS(on)}}$ 随壳温的降低而下降;而图4(b)显示,在壳温低于第4次实验的情况下,第5次实验的 $R_{\text{DS(on)}}$ 要高于第4次实验. 综上所述,可知 $R_{\text{DS(on)}}$ 参数同时受壳温和加速老化累计时长的影响.

在时间序列预测阶段,本文选取壳温及加速老化累计时长作为样本输入,预测器件 $R_{\text{DS(on)}}$ 值.

3.2 模型训练

选取数据集中8号、11号、12号、14号器件五次实验的全寿命数据作为训练集,9号器件五次实验的全寿命数据作为测试集进行模型验证.

划分好训练集和测试集后,利用LSTM算法进行时间序列预测. 预测前使用2.2节介绍的方法对原始时域监测信号进行预处理,去除信号中存在的干扰因素. 超参数的设置直接影响着模型的训练结果,在时间序列预测阶段,LSTM模型的初始参数在均值为0、方差为 $2/(m+n)$ 的均匀分布中抽取,其中, m 为输入数量, n 为输出数量. 常用的模型权重优化算法有Adam、SGDM和RMSProp三种^[15]. 五次实验,三种优化算法训练的模型均方根误差见表1所示. 可见,三种优化算法中,Adam作为自适应优化算法的预测误差最小,五次实验预测误差均小于1%,因此,本文使用Adam优化器进行梯度优化,训练得到最优的模型参数,具体步骤参见文献[12].

表1 三种优化算法的均方根误差

实验序号	优化算法		
	Adam	SGDM	RMSProp
1	0.00814	0.00832	0.00951
2	0.00912	0.02174	0.01846
3	0.00898	0.01944	0.01633
4	0.00665	0.00741	0.00786
5	0.00814	0.00997	0.01021

在模型测试阶段,以9号实验器件的实验数据为例,将壳温和实验累计时长作为输入向量输入到已训练好的LSTM时间序列预测模型中,预测9号实验器件的 $R_{\text{DS(on)}}$ 值. 五次实验的模型预测值与模型目标值(实验器件实际 $R_{\text{DS(on)}}$ 值)的拟合结果如图5所示,绿色曲线代表模型预测值,红色曲线代表模型目标值.

从图5中可以看出,模型较好地拟合了样本参数的变化趋势,输出结果和目标值较吻合,模型计算结果作为预测值可信度高.

将9号实验器件的预测值留取待用,待完成DHMM健康状态识别分类器的训练后,将9号实验器件预测值中的故障特征信息作为DHMM模型的输入值.

在状态识别阶段,根据器件状态退化单向前进演变的特点,DHMM模型采用左右型马尔科夫链. 随着现代半导体设计、制造工艺和控制过程技术的发展,半导

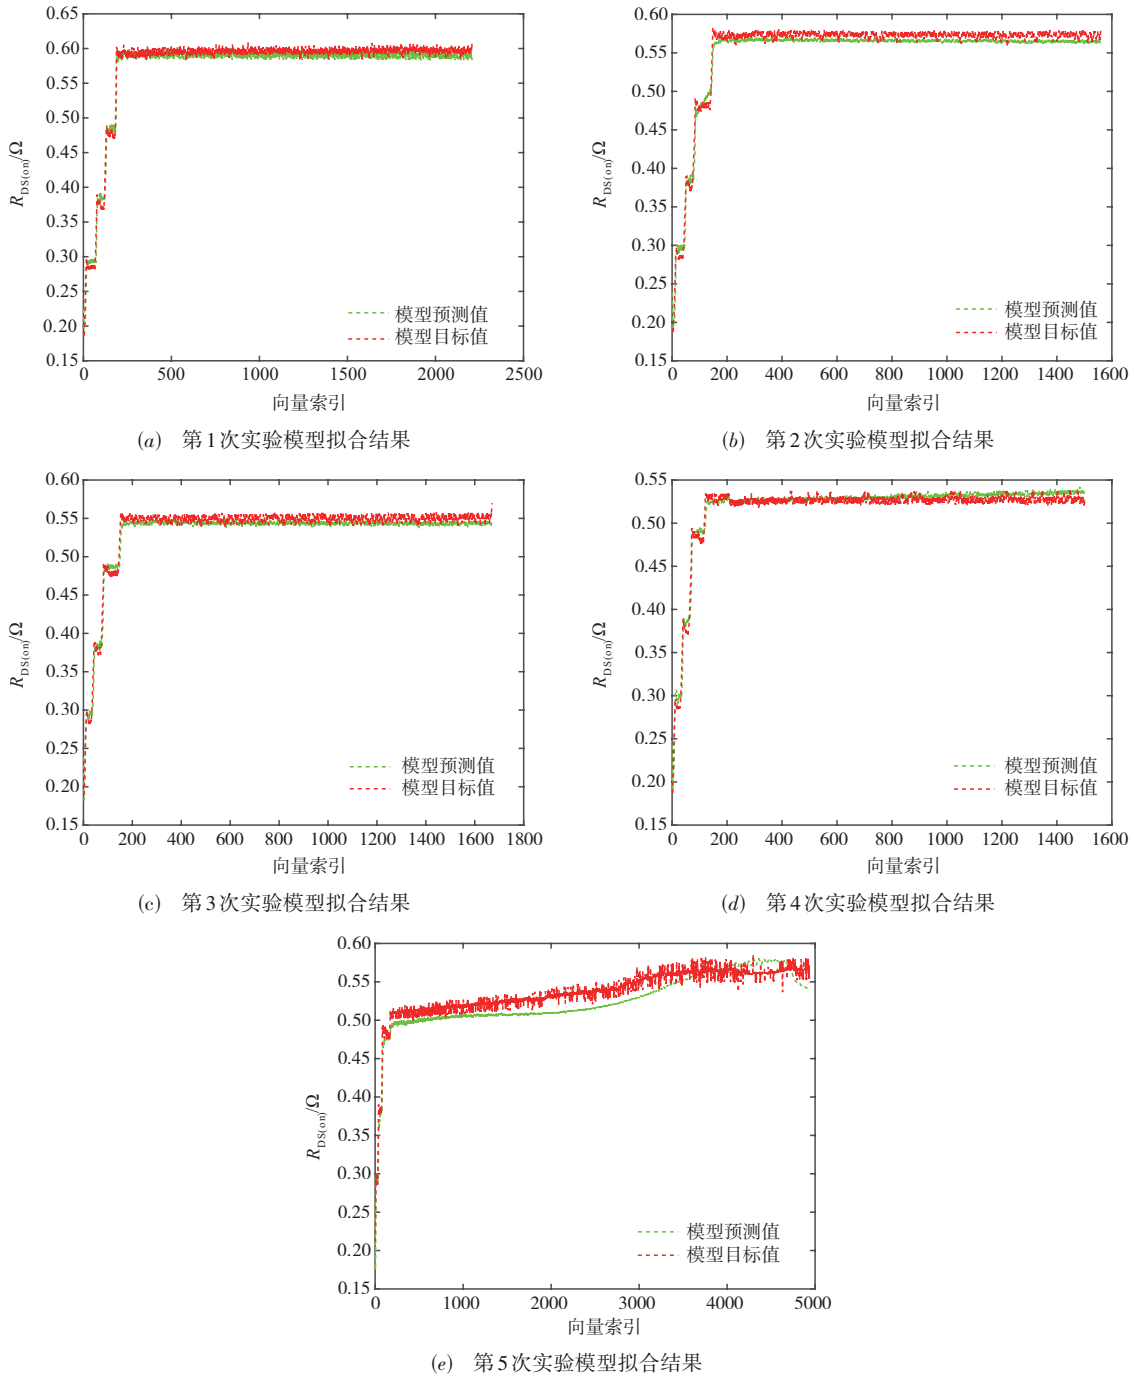


图5 模型拟合结果

体器件的早期失效率和偶然失效率已接近于零,可保证器件在初始工作时刻状态是正常的,因此,把初始概率分布 π 设为 $(1, 0, 0)$. 前文已将半导体器件的寿命周期划分为正常损耗阶段、衰退阶段和严重退化阶段. 那么,状态数 N 可确定为 3, 状态所对应的观测值的数目 M 由故障特征信息提取情况确定.

以9号实验器件第一次实验数据为例,计算序列的 ACF 与 PACF,判断序列的模型类型. 计算结果见表2所示.

从表2中可以看出,此序列 ACF 拖尾, PACF 截尾. 由前节所述可知,此种情况适合选用 AR 模型. AR 模型可探究时域信号复杂的内在结构,具有良好的时频分辨率,其表达式为:

$$x(n) = - \sum_{k=1}^p a_k x(n-k) + \varepsilon_n \quad (9)$$

式(9)中, $x(n)$ 表示时间序列; a_k 、 p 分别为模型的参数和阶次; ε_n 为白噪声.

表2 ACF与PACF值

ACF	PACF	ACF	PACF
0.990	0.990	0.854	-0.004
0.980	0.020	0.848	-0.010
0.972	0.070	0.842	-0.002
0.964	-0.006	0.836	-0.009
0.953	-0.113	0.831	0.008
0.943	0.010	0.825	-0.006
0.935	0.048	0.819	-0.003
0.926	0.022	0.813	0.009
0.917	-0.022	0.807	0.000
0.909	0.024	0.801	-0.009
0.901	0.038	0.796	0.008
0.894	0.018	0.790	-0.004
0.887	0.005	0.784	0.002
0.881	0.041	0.778	-0.013
0.875	0.016	0.773	0.006
0.870	0.013	0.767	-0.012
0.864	0.002	0.761	0.006
0.859	0.005	0.755	-0.014

时间序列类型确定后,便可采用与序列类型相关的特征提取方法提取故障特征值.由于五次实验 $R_{DS(on)}$ 参数幅值很小,为更显著的反映温度环境应力及实验累计时长对 $R_{DS(on)}$ 参数的影响,采用趋势分析法,提取 $R_{DS(on)}$ 针对上一时刻的变化量,再利用Burg算法对AR模型提取参数,Burg算法具体求解步骤见文献[13].

图6(a)~(e)依次代表第1次~第5次实验的AR模型参数.根据前文对器件寿命周期的划分,结合器件 $R_{DS(on)}$ 参数在前三次实验中改变较小且在第5次实验中陆续失效的结果,将前三次实验归为一类,设定为正常损耗期,设定器件在第四次实验中处于衰退期,第五次实验中的器件处于严重退化期.

规定了DHMM模型参数的初始值、划分好器件状态后,便可使用Baum-Welch算法对模型参数不断迭代重估,构建健康状态识别分类器,反映特征向量和退化等级之间的关系.DHMM训练迭代曲线如图7所示.

由图7的迭代曲线可以看出,DHMM模型具有很强的学习能力.虽然衰退期与严重退化期的迭代曲线距离较近,但三种退化状态依然具有不同的收敛值.

MOSFET器件退化DHMM库建好后,便可以用来识别器件所处的状态.识别方法为使用前向-后向算法计算测试集数据在各模型下的输出概率值,选取输出最大概率值的模型作为实验器件所处的状态.Baum-Welch算法和前向-后向算法的具体计算步骤见文献[14].三种MOSFET器件退化状态在DHMM分类器下的输出对数似然概率与识别结果见表3所示.

从表3可以看出,按照前文已划分的器件退化状




图6 五次实验AR模型参数




图7 三种状态的DHMM迭代曲线

态,DHMM健康状态识别分类器正确识别出第2~第5次实验的结果,识别准确率为80%.

表3 DHMM分类器下三种状态的对数似然概率与识别结果

实验序号	三种退化状态DHMM输出的对数似然概率			识别结果
	正常损耗期	衰退期	严重退化期	
1	-54.41	-45.42	-33.04	严重退化期
2	-129.05	-133.25	-173.86	正常损耗期
3	-78.91	-79.17	-145.01	正常损耗期
4	-116.78	-116.39	-167.30	衰退期
5	-178.76	-186.99	-137.32	严重退化期

3.3 LSTM-DHMM模型与常用识别方法对比分析

为了进一步验证本文提出的LSTM-DHMM预测方法的有效性和优越性,设置其他方案与本文所提预测方法进行对比分析,以增强比较效果.

GRU引入更新门和重置门控制信息的更新,是一种比LSTM网络更加简单的循环神经网络,和LSTM网络一样,通常也用于时间序列的预测.本文使用GRU网络和单以温度环境应力为输入的LSTM网络作为时

间序列预测模型 LSTM 的对比方案。

由于数据驱动类算法存在多次预测不稳定的问题,本文引入均方差作为模型稳定性的对比指标.均方差用来衡量数据的波动性.均方差越大,说明模型预测数据偏离期望的程度越大;其值越小,说明模型预测数据波动性越小,预测算法的稳定性越好^[15].均方差计算公式见(10)所示.

$$\sigma = \sqrt{\frac{\sum_{k=1}^N (\hat{y}_k - E)^2}{N-1}} \quad (10)$$

式(10)中, N 为预测的时间序列中数据的个数, \hat{y}_k 为模型预测值, E 为预测时间序列的期望.三种时间序列预测方法的均方差如表4所示.

表4 三种时间序列预测方法的均方差

实验序号	预测方法		
	二维离散时域信号 GRU 网络	单应力 LSTM	二维离散时域信号 LSTM
1	0.06352	0.06678	0.06576
2	0.05785	0.05790	0.05367
3	0.04751	0.04932	0.04750
4	0.04483	0.04572	0.04452
5	0.03267	0.02984	0.03690

从表4可以看出,以二维离散时域信号建模的 GRU 网络和 LSTM 网络除第五次实验的均方差大于单应力 LSTM 网络外,其余四次实验两者的均方差均小于单应力 LSTM 网络.可以说,就整体预测而言,二维离散时域信号 GRU 网络与二维离散时域信号 LSTM 网络的模型稳定性要优于单应力 LSTM 网络.

接下来对比二维离散时域信号 LSTM 网络与二维离散时域信号 GRU 网络的稳定性.除第1次、第5次实验 LSTM 网络的均方差要略大于 GRU 网络外,其余三次实验 LSTM 网络的均方差均小于 GRU 网络,但相差不大.综合分析,就单次实验而言,二维离散时域信号 LSTM 网络与二维离散时域信号 GRU 网络的稳定性各有优劣,但二维离散时域信号 LSTM 网络的模型整体稳定性要比二维离散时域信号 GRU 网络略胜一筹.

对比完三种时间序列预测方法的稳定性后,再对比三种方法的预测精确性.采用均方根误差作为模型预测精确性的对比指标.均方根误差越大,模型预测精确度越低;均方根误差越小,模型预测精确度越高.三种方法的均方根误差如表5所示.

从表5中可以看出,在五次实验中,单应力 LSTM 的均方根误差最大,即三种时间序列预测方法中,单应力 LSTM 网络法的模型预测精确度最差.可见相对于单应力时间序列预测模型,使用二维离散时域信号建模,能够充分考虑影响器件的退化因素,可更好地拟合

表5 三种时间序列预测方法的均方根误差

实验序号	预测方法		
	二维离散时域信号 GRU 网络	单应力 LSTM	二维离散时域信号 LSTM
1	0.00797	0.00822	0.00814
2	0.00771	0.01092	0.00912
3	0.00806	0.01082	0.00898
4	0.00862	0.00867	0.00665
5	0.01672	0.02230	0.00814

器件的变化趋势.

对于同样以二维离散时域信号建模的 GRU 网络和 LSTM 网络,在前三次实验中,虽然 GRU 网络的预测误差要略小于 LSTM 网络,但相差不大.对于第4次、第5次实验,GRU 网络的预测误差要远大于 LSTM 网络,尤其是在第五次实验中,GRU 网络的预测误差是 LSTM 网络预测误差的2倍之多.综上,对于五次实验,GRU 网络与 LSTM 网络的预测精确度各有优劣,但于整体预测而言,LSTM 网络更具优势.

通过三种时间序列预测方法的均方差、均方根误差的对比分析可知,单以温度环境应力为输入的 LSTM 网络法在模型稳定性、预测误差方面都要逊色于二维离散时域信号 GRU 网络法.因此,选用 GRU 网络法作为时间序列预测方法,选择识别领域内研究较充分且常用的 SVM 方法进行健康状态识别,组成对比方案,以验证 LSTM-DHMM 模型在本学习任务中的优势.对比方案具体构成见表6.

表6 对比方案构成与本文所提预测方法

预测方法	时间序列预测	健康状态识别
方案1	二维离散时域信号 GRU 网络	DHMM
方案2	二维离散时域信号 GRU 网络	SVM
方案3	二维离散时域信号 LSTM	SVM
本文	二维离散时域信号 LSTM	DHMM

按照本文所提二维离散时域信号 LSTM-DHMM 方法的预测流程,计算对比方案的预测结果,结果见表7.

从表7中可以看出,GRU-SVM 模型的识别率最低,仅为40%.虽然 GRU-DHMM 模型和 LSTM-SVM 模型的识别率能达到60%,但相较于 LSTM-DHMM 模型80%的识别率,仍然偏低.对比结果表明,LSTM-DHMM 模型相较于 GRU-DHMM 模型、GRU-SVM 模型和 LSTM-SVM 模型,识别准确率更高,更适用于本学习任务.

综合本节的分析可知,二维离散时域信号 LSTM 网络法在模型稳定性、预测准确性方面均要优于单应力 LSTM 网络法.就整体预测而言,二维离散时域信号 LSTM 网络法的稳定性、准确性也要略胜于二维离散时域信号 GRU 网络法.引入 GRU-DHMM、GRU-SVM、LSTM-SVM 与 LSTM-DHMM 方法相比较,结果表明 LSTM-DHMM 方法

表7 对比方案的识别结果

实验序号	识别结果			真实状态
	二维离散时域信号 GRU-DHMM	二维离散时域信号 GRU-SVM	二维离散时域信号 LSTM-SVM	
1	衰退期	正常损耗期	严重退化期	正常损耗期
2	正常损耗期	衰减阶段	正常损耗期	正常损耗期
3	正常损耗期	正常损耗期	正常损耗期	正常损耗期
4	衰退期	正常损耗期	正常损耗期	衰退期
5	衰退期	正常损耗期	严重退化期	严重退化期
识别准确率	60%	40%	60%	—

识别率更高。因此,本文所提方法在模型稳定性、预测准确性和识别率方面均表现良好,具有优越性。

3.4 故障时间预测

按照 LSTM-DHMM 预测流程,当 DHMM 预测器件处于严重退化阶段时,应结合失效阈值,预测器件的故障时间。选取壳温稳定后 $R_{DS(on)}$ 参数 20% 的漂移作为器件故障阈值^[16]。计算表 4 中第 1 次和第 5 次实验 $R_{DS(on)}$ 参数的漂移量,见表 8 所示。

表8 $R_{DS(on)}$ 参数漂移百分比

实验序号	1	5
漂移百分比	1.46%	21.41%

第 1 次实验的 $R_{DS(on)}$ 参数预测值漂移量低于故障阈值,可判断器件并没有发生故障,此次预警为虚警,器件可以正常工作,不需更换,继续进行监测便可;第 5 次实验的 $R_{DS(on)}$ 参数漂移量超过故障阈值,计算其故障发生时间,如表 9 所示。

表9 预测故障时间与实际故障时间

预测故障时间	实际故障时间	相对误差
257 min	263 min	2.3%

由此可见,LSTM-DHMM 模型能够提前预测故障的发生,模型预测误差小于 10%,具有较高的预测精度。

在应用 LSTM-DHMM 模型时,如经健康状态识别分类器判断,器件处于正常损耗期,证明器件处于整个寿命周期的早期,性能参数缓慢下降,但不影响正常工作,器件可以放心使用,继续监测器件状态即可;如果判断器件处于衰减期,此时器件性能参数下降速度加剧,需加强对器件的关注,并采取降温等措施,减缓材料老化、延长器件使用时间;如果判断器件处于严重退化阶段,代表器件材料已经严重老化,器件已濒临失效,根据故障阈值计算器件故障时间,以便提前更换器件,最大限度降低器件突然失效造成的损失。

4 结论

本文提出了一种面向半导体 PHM 技术的二维离散时域信号驱动 MOSFET 器件故障时间预测方法,通过

LSTM 算法拟合应力作用下器件故障特征向量的变化趋势,采用 DHMM 算法反映特征向量与退化等级间的映射关系,结合故障阈值排除虚警,最终实现故障发生时间的预测。将本文所提方法与多种不同方法进行对比分析,结果显示,本文所提方法在预测准确性、预测精确性和识别准确率方面均取得了较好的效果。在今后的工作中,我们将优化模型结构,进一步深入分析多种信号特征融合策略,以提高模型的判别能力。

参考文献

- [1] 樊浩,李兴文,苏海博,等.基于主成分分析-支持向量机优化模型的断路器故障诊断方法研究[J].高压电器,2020,56(6):143-151.
- [2] 刘磊,龙兵,刘震.两种多故障诊断算法的性能比较研究[J].电子测量与仪器学报,2011,25(1):75-80.
- [3] KALGREN P W, BAYBUTT M, GINART A, et al. Application of prognostic health management in digital electronic systems[C]//2007 IEEE Aerospace Conference. Big Sky, MT, USA: IEEE, 2007: 1-9.
- [4] MENON S, JIN X, CHOW T W S, et al. Evaluating covariance in prognostic and system health management applications [J]. Mechanical Systems & Signal Processing, 2015, 58-59(6): 206-217.
- [5] VASAN A S S, PECHT M. Electronic circuit health estimation through kernel learning[J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1585-1594.
- [6] RAMAKRISHNAN A, PECHT M. A life consumption monitoring methodology for electronic systems[J]. IEEE Transactions on Components and Packaging Technologies,


2003, 26(3): 625-634.

- [7] 陈颖,高蕾,康锐.基于故障物理的电子产品可靠性仿真分析方法[J].中国电子科学研究院学报,2013,8(5):444-448.
CHEN Ying, GAO Lei, KANG Rui. Research on reliability simulation prediction of electronic product based on physics of failure method[J]. Journal of CAEIT, 2013, 8(5):444-448. (in Chinese)
- [8] TSUI K L, CHEN N, ZHOU Q, et al. Prognostics and health management: a review on data driven approaches[J]. Mathematical Problems in Engineering, 2015, 2015(6): 1-17.
- [9] 杨立峰,吕卫民,肖阳.基于故障机理和伪失效寿命的电子产品剩余寿命预测[J].海军航空工程学院学报,2017,32(2):246-250.
YANG Li-feng, Wei-min LÜ, XIAO Yang. Residual life prediction for electronic products based on fault mechanism and pseudo-failure data[J]. Journal of Naval Aeronautical and Astronautical University, 2017, 32(2): 246-250. (in Chinese)
- [10] 周永道,王会琦,吕王勇.时间序列分析及应用[M].北京:高等教育出版,2015.
ZHOU Yong-dao, WANG Hui-qi, Wang-yong LÜ. Time Series Analysis and Application[M]. Beijing: Higher Education Press,2015. (in Chinese)
- [11] 郝俊虎,胡毅.基于 XGBoost 和自回归模型的轴承故障诊断和预警方法研究[J].组合机床与自动化加工技术,2020,552(2):140-142,157.
HAO Jun-hu, HU Yi. Research on bearing fault diagnosis and warning based on XGBoost and autoregressive algorithm[J]. Modular Machine Tool & Automatic Manufacturing Technique, 2020, 552(2):140-142,157. (in Chinese)
- [12] 伊恩·古德费洛,约书亚·本吉奥,亚伦·库维尔.深度学习[M].北京:人民邮电出版社,2017.187-190.
Goodfellow Ian, Bengio Yoshua, Courville Aaron. Deep Learning[M]. Beijing: Posts&Telecom Press Co,Ltd, 2017. 187-190. (in Chinese)
- [13] 张峰,王东,石现峰.振动信号 Burg 谱估计算法的性能优化研究[J].计算机仿真,2017,34(4):262-266.
ZHANG Fen, WANG Dong, SHI Xian-feng. Study on performance optimization of vibration signal burg spectral estimation algorithm[J]. Computer Simulation, 2017, 34(4): 262-266. (in Chinese)
- [14] RABINER L R. A tutorial on hidden Markov models and selected applications in speech recognition[J]. Proceedings of the IEEE, 1989, 77(2): 257-286.
- [15] 于劲松,刘浩,张平等.故障预测算法稳定性实时评估方法[J].北京航空航天大学学报,2014,40(9):1208-1212.
YU Jin-song, Liu Hao, Zhang ping, et al. Real-time evalu-

ation method for stability of fault prognostic algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2014, 40(9): 1208-1212.

- [16] TESTA A, CARO S D, PANARELLO S, et al. Stress analysis and lifetime estimation on power MOSFETs for automotive ABS systems[C]//Power Electronics Specialists Conference. Rhodes, Greece: IEEE Press, 2008: 1169-1175.

作者简介



张明宇 女,1987年生于辽宁沈阳.博士研究生.主要研究方向为故障诊断技术、健康监测.
E-mail: jiabingde@126.com



王琦 男,1965年生于吉林梅河口.教授、博士生导师.主要研究方向为计算机技术在环境监测管理中的应用、装备状态监测及故障诊断、航空发动机污染与测试技术.
E-mail: wangqi@lnut.edu.cn



于洋 女,1967年生于辽宁沈阳.博士、教授、博士生导师.主要研究方向为装备故障监测与健康管理.
E-mail: yuy@sut.edu.cn