

基于 LSTM 网络的综合射频模块温度的预测研究

陈卫卫¹, 李鑫¹, 时林林², 俞鹏飞²

(1. 中国电子科技集团公司电子科学研究院 一体化保障系统研究所, 北京 100041;

2. 工业和信息化部电子第五研究所 电子元器件可靠性物理及应用技术重点实验室, 广州 510610)

摘要: 随着电子产品及集成电路的快速发展, 其电子产品的故障预测研究引起了高度重视, 但准确预测其使用寿命难度还是很大, 目前针对电子产品主要采用状态监控和健康管理, 从而实现状态的预测。以此为出发点, 构建综合射频模块温度的状态预测模型, 该预测模型首先将设备的时域特征数据转换为有监督的样本数据集, 然后建立原始参数集、预测模型的训练集和测试集, 接着建立 LSTM 深度学习网络结构, 进行参数调整设置并运行模型, 最后获得预测值和观测值的误差曲线; 采用该方法在某典型任务场景中进行了应用验证, 获得综合射频模块的温度预测的准确率为 98.7%, 达到了较好的预测效果和精度。

关键词: 综合射频模块; 温度; LSTM 模型; 预测样本; 预测准确度

Research on Integrated RF Module Temperature Prediction Based on LSTM Network

CHEN Weiwei¹, LI Xin¹, SHI Linlin², YU Pengfei²

(1. Institute of Integrated support Systems, China Academic of Electronics and Information Technology, Beijing 100041, China;

2. No. 5 Electronics Research Institute, Key Laboratory of Science and Technology on Reliability Physics and Application of Electronics Components, Ministry of Industry and Information Technology, Guangzhou 510610, China)

Abstract: With the rapid development of electronic products and integrated circuits, the fault prediction research on electronics has attracted great attention. However, it is still very difficult to accurately predict the service life of electronics. At present, the main implementation is state monitoring and health management. A state prediction model for integrated radio frequency (RF) module temperature based on long short-term memory network (LSTM) neural network is constructed in this paper. Firstly, the time-domain data of device is converted into supervised sample dataset. Then the original parameter set, training and test sets for prediction model are established. Next the LSTM deep learning network is constructed and run with parameters adjustment. Finally, the error curves of the predicted and observed values are obtained. The model is proved to achieve the good prediction effect and forecast precision with an accuracy of 98.7% by predicting the integrated RF module temperature in a typical task.

Keywords: integrated RF module; temperature; LSTM model; forecast sample; forecast accuracy

0 引言

故障预测与健康管理 (PHM, prognostic and health management) 现已成为军事系统实现高效系统级维护和降低寿命周期成本的关键因素之一。早在 20 世纪 70 年代, 美军就开始关注到武器装备的故障诊断和预测的重要军事意义, 并大力推广基于状态的维修 (CBM, condition based maintenance), 即“视情维修”。他们强调要在武器装备的研制初期就要充分考虑装备的测试性和维修性, 要求装备研制与故障诊断和预测能力同步设计, 然后通过获取武器

装备的技术状态信息作为对装备进行保障的决策依据。2002 年 11 月, 负责后勤和物资准备的美国国防部副部长发布了一项名为“基于状态的维修增强” (CBM+) 的政策。CBM+ 代表了将新系统和旧系统的非计划修复性设备维护转变为基于必要证据安排预防性维护和预测性维护的努力。2005 年, 一项对 11 个 CBM 项目的调查突出了将“电子产品故障预测”作为最需要的维修相关特性或应用之一, 而不考虑成本, 这一观点也得到了航空电子行业的认同。美国国防部 5000.2 《国防采办政策文件》规定, “项目经理应

收稿日期: 2022-05-18; 修回日期: 2022-05-30。

基金项目: 国防科工局“十三五”技术基础科研项目 (JSZL2018210C003)。

作者简介: 陈卫卫 (1982-), 女, 江苏启东人, 博士, 高级工程师, 主要从事测试性及 PHM 领域方向的研究。

李鑫 (1979-), 男, 内蒙古通辽人, 大学本科, 高级工程师, 主要从事综合保障领域方向的研究。

引用格式: 陈卫卫, 李鑫, 时林林, 等. 基于 LSTM 网络的综合射频模块温度的预测研究[J]. 计算机测量与控制, 2022, 30(7): 84-90.

通过负担得起的集成的嵌入式诊断和预测、嵌入式培训和测试、序列化物资管理、自动识别技术和迭代技术更新, 优化战备状态”。因此, 任何出售给美国国防部的系统都需要具备故障预测能力^[1]。

故障预测与健康管理的健康管理, 是指通过传感器、内建自测试 (BIT) 等方式监测各种参数, 并实时评估和预测产品或装备在实际环境中的可靠性。它包括两层含义: 1) 参数监测, 即对装备的性能参数或工作载荷的在线/离线监测; 2) 健康评估, 即持续评估装备是否存在退化以及退化状态, 确定装备能正常工作的时间。健康状态的实时感知代表了一种方法的转变, 即借助各种先进传感与监测技术, 实现装备状态参数信息的全面感知, 并基于失效物理分析、智能推理算法等方法完成对装备健康状态的评估和预测, 从而一方面促进装备从传统的基于事件的维修向基于状态 (视情) 维修的转变, 另一方面促进装备的智能化。

PHM 技术的第一个成功案例是美国 F-35 飞机的自主式保障系统。该系统通过对健康状态参数的监控, 在低虚警率的故障预测技术的支持下实现了故障隔离、健康趋势预测和维修决策辅助, 大幅提高了飞机的战略值勤能力, 并降低了维护维修成本。经过前期大量的基础研究和应用推广, 目前故障预测与健康管理系统已经从方案设计阶段发展到工程验证阶段。从国内外公开发表的资料看, 故障预测与健康管理系统应用已经遍及航空、航天、舰船、汽车、桥梁、重型机械、工业过程、半导体制造、核电站、大型水坝等众多领域。

1 故障预测方法

故障预测是 PHM 技术的重点和难点。故障预测模型是基于相关敏感参数的时间相关数据, 通过拟合、回归、预测等方式, 结合故障/失效阈值, 预测故障/失效的发生趋势。如果可以评估电子设备相对于预期正常工作状态时的偏离或退化程度, 则能够利用这些此信息来实现以下目标, 即 (a) 提供故障预警; (b) 减少非计划维修, 延长维护周期, 并通过及时维护来保持效能; (c) 通过降低检查成本、停机时间和库存备件来降低设备的寿命周期成本; (d) 提高质量, 并协助对已部署和未来新研系统设计和后勤保障。

故障预测从基本技术路径上可分为基于模型的故障预测和基于数据驱动的故障预测 (不含融合方法)^[2]。基于模型的故障预测是将失效物理结合起来, 并量化各种负载和运行条件下的退化过程特征。基于物理的健康评估方法可以分为 PoF 方法和系统建模方法两种。通常, PoF 模型是特定于系统/组件的, 例如裂纹扩展模型、旋转机械模型、磨损模型、气体路径模型和电化学模型。PoF 方法核心是监测可能导致性能或物理退化的寿命周期载荷和相关的系统响应, 然后从退化特征变量中提取特征, 使用 PoF 模型进行损伤评估和 RUL 计算。系统建模方法假设系统可以由一个模型来描述, 该模型可以说明系统过度退化的随机行为。例如状态空间模型可以将一个物理系统转化为一组与

一阶微分方程相关的输入、输出和状态变量。在失效评估数学模型可用的情况下, 估计和滤波技术是系统建模方法中使用的主要工具, 例如 Kalman 滤波器 (KF)、扩展 Kalman 滤波器 (EKF)、集合 Kalman 滤波器、无损 Kalman 滤波器 (UKF)、粒子滤波器 (PF) 和基于状态观测器的方法等。基于物理方法 (包括 PoF 方法和系统建模方法) 的局限性主要在于模型通常是特定于某个对象的, 因此其可重用性是有限的。数据驱动方法用于识别当前退化状态的特征, 并在很少的物理理解可用时, 使用可用的历史数据 (监测数据) 预测未来健康状态。目前, 基于数据驱动的方法主要分为机器学习 (ML) /人工智能 (AI) 和统计建模两种。其中, 机器学习作为计算机科学和人工智能的一个分支, 旨在建立能够从数据中学习的系统, 而不是显式的程序设计结构。而统计建模是数学的一个分支, 它用来发现变量之间的关系以评估结果。数据驱动方法的特点是直接从可用数据导出模型, 依赖于统计特征, 相当于“黑盒模型”。因此, 识别这些特征是开发数据驱动方法的关键过程。基于数据驱动的方法有两个主要优点: 第一个是获取方便, 这些模型可以简单地量化时间和退化状态之间的关系, 而不需要或只需要极少关于系统的知识, 实现成本低。另一个是性能的提高, 通过使用强大的机器学习技术, 数据驱动方法可以在很大程度上减少模型错误。有时, 这些模型会拓宽认知复杂性退化过程。

目前在故障预测体系架构、故障模型、故障预测方法、PHM 系统集成等方面都取得了一些研究成果, 不少研究成果已经得到不同程度的工程应用。但在电子设备的故障预测方面, 想要准确预测其使用寿命难度还是很大, 目前针对电子产品主要采用状态监控和健康管理, 主要实现状态的预测, 随着工业部门开始关注零部件故障模式与机理分析, 并积累大量失效数据后, 对故障的预测能力将会大大增强。

通过对国内外文献调研, 常用的预测方法包括时间序列法、灰色模型 (G11 和 G21)、自回归滑动平均模型 AR-MA、指数模型、LSTM (long short-term memory network, 长短时记忆网络)、高阶回归、线性模型、二次模型、多参数融合模型、循环神经网络、深度前馈神经网络、门控单元网络等^[3-6]。针对分析对象的复杂性, 也有混合算法模型, 包括 LSTM-BP 网络模型^[7], BP-LM-PSO-GA^[8]模型, LSSVM-HMM^[9]等, 不同算法特点不同, 适用的信号类型也不同。

在分析大规模数据时, 相比于支持向量机模型和 BP 神经网络模型, 具有记忆功能的人工递归/循环神经网络 (如长短时记忆神经网络) 具有较大的优势^[10], 因此本文采用长短时记忆网络 (LSTM, long short-term memory network) 对综合射频模块的温度进行状态预测, 并给出预测的准确度。

2 长短时记忆网络 (LSTM)

LSTM 是改进版的循环神经网络, 通过在隐含层增加

三个控制开关分别是来克服常规循环神经网络 (RNN, recurrent neural network) 处理较长序列时的梯度爆炸或梯度消失的问题 [11-12]。因此利用循环神经网络, 基于时域监测数据进行的复杂故障预测具有一定的优势 [13]。长短时记忆网络是一种特殊结构的 RNN, 可以实现学习长时间的依赖 [14]。使用 LSTM 网络, 可以轻松实现当任务仅需要查看当前时间点信息的时候, 就不需要额外提供其他时间点的信息, 这样就能够当预测的目标点与其相关的上文信息的点的间隔较小的时候, RNN 网络可以有效的利用过去的知识。

图 1 为 LSTM 结构图 [15], LSTM 与 RNN 具有一致的链式结构, 但其重复的模块却有着明显不同。LSTM 关键位置在于单元, 顺着传递线从起始到末尾运行, 中间存在线性的交互, 信息可以直接顺着它传递而不改变。LSTM 利用门 (gate) 的结构来对每个单元添加或丢弃信息。LSTM 网络的单元具有三种类型的门: 遗忘门、输入门和状态门。其中最关键的就是遗忘门, 这三个门通过下面的三个函数来控制信息的流入和流出 (或者说是通过和不通过)。

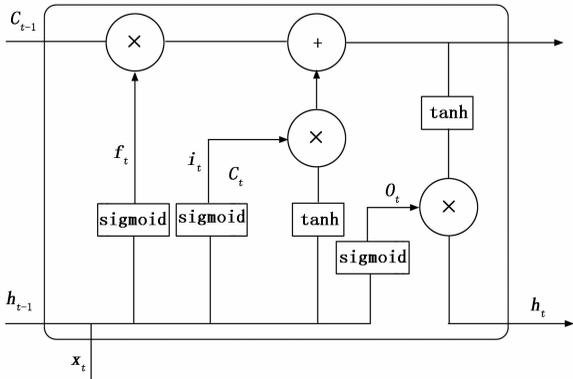


图 1 LSTM 结构图

$$\begin{aligned}
 f_t &= \sigma(W_f X_t + b_f) \\
 i_t &= \sigma(W_i X_t + b_i) \\
 o_t &= \sigma(W_o X_t + b_o)
 \end{aligned} \tag{1}$$

其中: $\sigma(\cdot)$ 为网络的输出 sigmoid 激活函数。激活函数选用 sigmoid 使得趋近于 0 的时候无法正常通过, 而接近 1 时则可以通过该门, 因此网络的输出取决于当前信息本身。

设当前时刻为 t , 则状态 $S_t = f_t S_{t-1} + i_t X_t$ 与传统的 RNN: $s_t = W_x \cdot x_t + W_s \cdot s_{t-1} + b_t$ 相似, 将 LSTM 网络的状态表达式展开后可以得到:

$$S_t = \sigma(W_f X_t + b_f) S_{t-1} + \sigma(W_i X_t + b_i) X_t \tag{2}$$

经过激活函数之后, 有:

$$S_t = \tanh[\sigma(W_f X_t + b_f) S_{t-1} + \sigma(W_i X_t + b_i) X_t] \tag{3}$$

求偏导数, 可以知道, LSTM 网络具有与上文中类似 RNN 的一项, 但在 LSTM 中该项为:

$$\prod_{j=k+1}^t \frac{\partial S_j}{\partial S_{j-1}} = \prod_{j=k+1}^t \tanh' \sigma(W_f X_j + b_f) \tag{4}$$

令 $H = \tanh'(x) \sigma(y)$, 那么 H 的函数图像如图 2 所示。

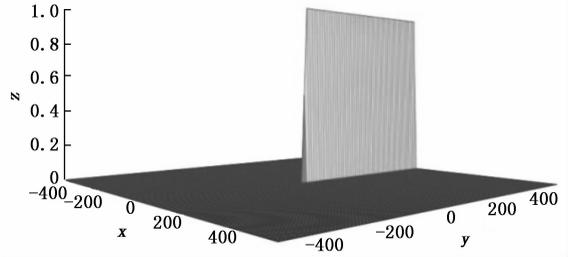


图 2 H 函数图像

从图 2 显而易见, 这个函数值基本上只有 0 和 1, 而正因为这个偏导数的乘积只会分布在 0 和 1 上, LSTM 可以就此解决了传统 RNN 中梯度消失的问题。

3 预测样本的构造

机器学习分为有监督学习 (supervised learning)、无监督学习、半监督学习等类型。有监督学习是指从给定的训练数据集中学习出一个函数 (模型参数), 当新的数据到来时, 可以根据这个函数预测结果 [16-17]。有监督学习的训练集要求包括输入输出, 也可以说是特征和目标。训练集中的目标是由人标注的。LSTM 是一种有监督学习 [18]。就处理时间序列而言, 可以将 LSTM 用于 1 对于 1, 多对 1 和多对多等场景。为利用 LSTM 的在时间序列的记忆特性, 本文采用多对 1 的方式对设备的时域特征数据进行建模。设备的时域特征信号在数据上表现为一列或一行和时间变量相关的时序参数集, 表面上看和有监督学习的处理方式有一定差距。所以在利用设备的故障数据特征建立 LSTM 模型之前, 需要将设备的时域特征数据转换为有监督的样本数据集。以时滞 Δt 个时间单位为例, 设备的特征时间序列构建以 $t + \Delta t$ 的数据为一个 feature, 作为模型的输入值, 而下一时刻 t' 数据为 label 作为预测值, 可形成一个故障特征的时间序列窗口。而后, 此窗口每向后滑动一个时间单位, 如从 t 到 $t + 1$ 就形成一个新的特征时间序列记录。在该记录中, 模型的 feature 是 $t + \Delta t + 1$ 内的数据, label 是 $t' + 1$ 的数据, 按此机制构建设备的故障表征参数的时间序列, 即可形成用于设备 LSTM 建模的有监督的样本数据集。假定 $\Delta t = 6$, 样本集中样本的个数为 11, 图 3 描述设备 LSTM 预测参数建模样本构造过程。

4 预测模型的建立

将时间序列样本集作为监测参数的原始参数集, 将原始参数集分为训练集和测试集, 一部分为训练数据, 一部分为预测数据。

建立 LSTM 深度学习网络结构, LSTM 网络架构包含 1 个输入特征维数和 1 个输出特征维数, 该深度学习模型的网络结构由输入层、lstm 层、全连接层和回归层共四层网络构成。其中 lstm 隐含层包含 200 个神经网络单元。

设置 LSTM 训练参数, 包括参数最大迭代次数、梯度

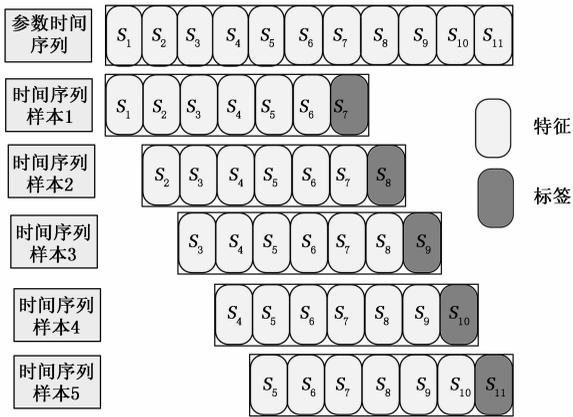


图 3 LSTM 寿命参数建模样本构造示意图

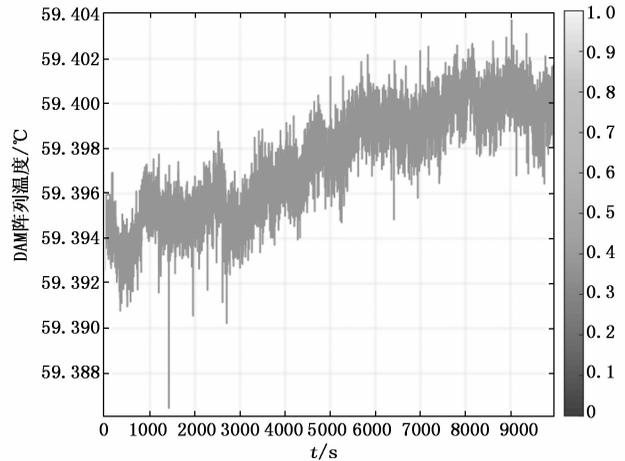


图 4 DAM 阵列温度变化

阈值、初始学习率、学习率框架设置、学习率衰落周期、衰落因子等。

基于前述步骤设置的网络结构和训练参数, 开始 LSTM 网络训练, 得到用于综合射频模块温度时间序列预测的 LSTM 模型。

用预测集进行验证, 采用公式 5 计算预测的总体误差, 并获得预测值与观测值误差曲线。

$$Error = \text{mean} \frac{\text{abs}(YPred - YTest)}{YTest} \quad (5)$$

5 预测应用与分析

依托某核心电子系统的验证与应用项目, 开展某大型信息系统的状态监控集成联试, 涵盖芯片, 模块及系统。

本案例中以雷达综合射频的数字阵列模块 (DAM, digital array module) 作为研究对象, DAM 的温度作为敏感参数, 其阵列的温度变化可反映出其 FPGA 芯片的退化情况。以温度的时间序列为例, 建立机器学习模型对其温度的状态变化过程进行预测, 判断温度的变化趋势, 预测未来一段时间内 DAM 阵列温度的变化规律。

实时监控其温度参数, 该样本数据呈现随机振荡但总体趋势为递升, 以此规律进行数据模拟, 获得原始数据集共计 10 000 条。图 4 为 DAM 阵列温度的 10 000 条样本数据的变化曲线图, 将模型训练数据设置为 95% 的序列长度, 即包含 9 500 个数据样本, 模型预测集的长度为 500 个数据样本。从而根据 DAM 阵列温度的时间序列长度, 预测未来 500 个时间单位的 DAM 阵列温度值。

为建立正确的 LSTM 网络的模型, 需要熟悉 LSTM 网络的一些主要模型参数。LSTM 是一种特殊的循环神经网络 (RNN)。一般的循环神经网络 RNN 容易出现梯度爆炸/梯度消失问题。在神经网络的反向传播过程中, 工作原理是从输出层到输入层, 并在此过程中传播误差梯度。一旦算法计算出代价函数相对于网络中每个参数的梯度, 就可以使用这些梯度以梯度下降步骤来更新每个参数^[19]。这种方式在用链式求导规律计算各层梯度时涉及一些联合操作。随着算法向下传播到较低层, 梯度通常会越来越小。结果

梯度下降更新使较低层的连接权重保持不变, 训练不能收敛到一个好的最优解, 由此导致梯度消失问题。在某些情况下, 可能会出现相反的情况: 梯度可能会越来越大, 各层需要更新很大的权重直到算法发散为止, 这是梯度爆炸问题。和 RNN 相比, 之所以 LSTM 能够克服梯度消失/爆炸问题, 主要是因为 LSTM 的递归求导公式中包含加法, 使得导数值可以在 1 上下跳动, 这些通过 LSTM 中的梯度阈值设置来实现^[20]。另外, 深度学习训练参数中 Epoch 对模型的训练起到很重要的作用。在深度学习的训练中, 一个 epoch 表示所有的数据送入网络中, 完成了一次前向计算和反向传播的过程。由于 epoch 一般比较大, 可把它分成几个小的 batch。因为将所有数据迭代训练一次是不够的, 故需要反复多次才能拟合、收敛。在实际训练时, 将所有数据分成多个 batch, 每次送入一部分数据。实际中, 往往使用单个 epoch 更新权重不够, 所以通常采用多个 epoch 进行训练。随着 epoch 数量的增加, 权重更新迭代的次数增多, 曲线从最开始的不拟合状态, 进入优化拟合状态, 最终模型会进入过拟合。epoch 的大小与数据集的多样化程度有关, 多样化程度越强, epoch 可设置越大。其次, 学习率也是训练神经网络的重要超参数之一, 它代表在每一次迭代中梯度向损失函数最优解移动的步长, 通常用 η 表示。它的大小决定网络学习速度的快慢。在网络训练过程中, 模型通过样本数据给出预测值, 计算代价函数并通过反向传播来调整参数。重复上述过程, 使得模型参数逐步趋于最优解从而获得最优模型。在这个过程中, 学习率负责控制每一步参数更新的步长。合适的学习率可以使代价函数以合适的速度收敛到最小值。除此之外, LSTM 还提供学习率格式、学习率衰落周期等参数。

由于增加了初始学习率和 epoch, 建立的 LSTM 模型的收敛比较充分。

首先, 将 LSTM 训练参数设置如下: 最大迭代次数为 60, 梯度阈值为 1, 防止梯度爆炸。初始学习率设置为 0.000 1, 学习率框架设置为分段形式, 学习率衰落周期为

125, 衰落因子为 0.2, 如表 1 所示。

表 1 预测网络训练参数设置

参数名称	参数设置	参数说明
目标函数优化器	adam	自适应矩估计
Max Epochs	60	最大迭代次数
Gradient Threshold	1	梯度阈值
Initial Learn Rate	0.000 1	初始学习率
Learn Rate Schedule	piecewise	学习率格式
Learn Rate Drop Period	125	学习率衰落周期
Learn Rate Drop Factor	0.2	学习率衰减因子
Learn Rate Drop Factor	0.2	学习率衰减因子

设置好以上网络的参数, 对模型进行训练。训练过程的误差收敛和损失曲线如图 5 所示, 整个训练过程持续时间为 3 分 7 秒, 从而得到训练完成的 LSTM 模型。从图 5 中的模型训练误差收敛情况来看, 收模型的误差收敛速度较慢, 在训练 50 个 epoch 之后, 误差收敛的趋势才开始显现。可以预见, 在上述的模型参数设置下, 本模型的收敛状态不佳, 造成模型的收敛不充分。

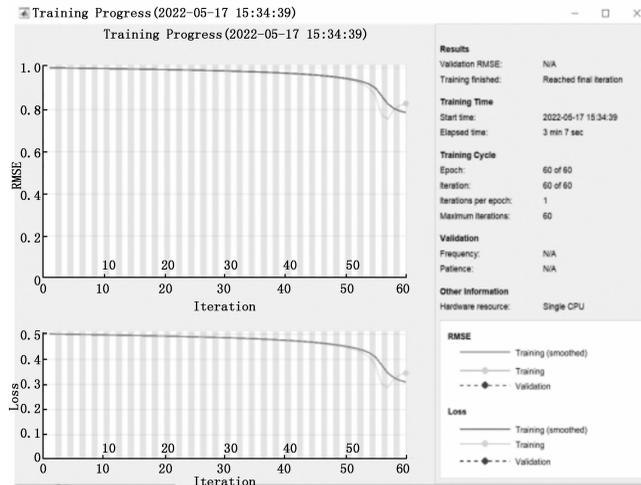


图 5 LSTM 模型的训练误差收敛和损失曲线 (epoch=60)

采用训练完的模型, 对未来 500 个时间步的 DAM 阵列温度数据进行预测, 如图 6 所示。由于模型收敛不充分, 可以发现 LSTM 对于 DAM 阵列温度预测具有较大的误差。预测 500 个时间步的 DAM 阵列温度数据与原有的数据趋势不吻合, 呈现一条直线状。进一步, 画出预测值与观测值误差曲线见图 7 所示。可以看出, 由于上述 LSTM 模型对 500 步的预测值和真实值的差异比较明显, RMSE 误差为 0.002 25。

LSTM 模型的网络参数设置可能会对模型的精度产生较大影响。最大迭代次数和初始学习率是影响网络收敛的两个主要参数。这里主要更改网络模型参数的最大迭代次数和初始学习率, 训练参数设置如下: 最大迭代次数为 120, 梯度阈值为 1, 防止梯度爆炸。初始学习率设置为

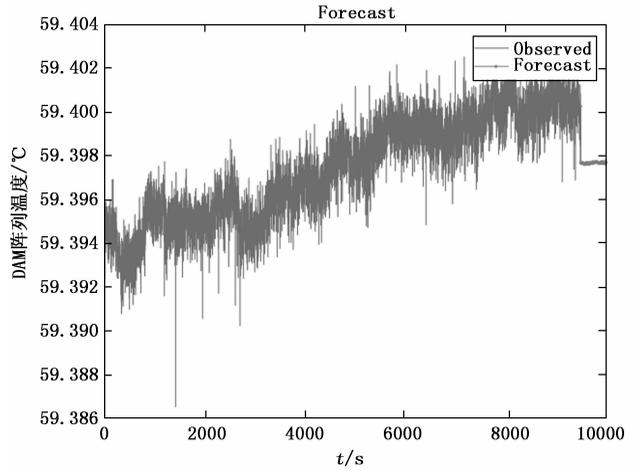


图 6 预测未来 500 步温度值

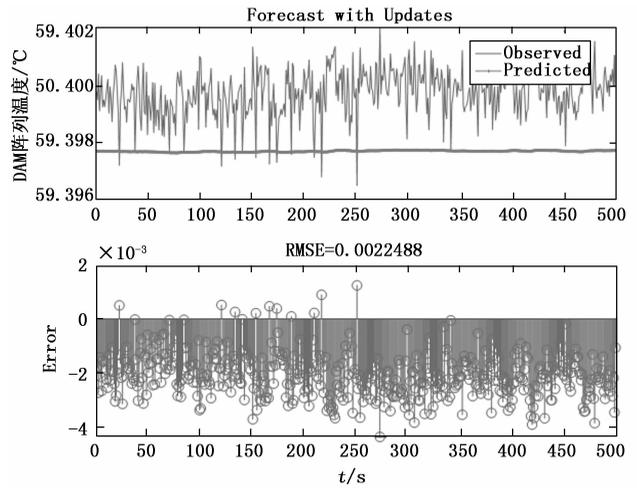


图 7 预测值与观测值误差曲线

0.005, 学习率框架设置为分段形式, 学习率衰落周期为 125, 衰落因子为 0.2, 如表 2 所示。

表 2 预测网络训练参数设置

参数名称	参数设置	参数说明
目标函数优化器	adam	自适应矩估计
Max Epochs	120	最大迭代次数
Gradient Threshold	1	梯度阈值
Initial Learn Rate	0.005	初始学习率
Learn Rate Schedule	piecewise	学习率格式
Learn Rate DropPeriod	125	学习率衰落周期
Learn Rate DropFactor	0.2	学习率衰减因子

为了获得较好的拟合并防止训练发散, 这里将训练数据标准化为具有零均值和单位方差。在预测时, 采用与训练数据相同的参数来标准化测试数据。

在设置好相关的网络参数基础上, 开始启动 LSTM 网络训练进程, 训练过程的误差收敛和损失曲线如图 8 所示, 整个训练过程持续时间为 6 分 34 秒, 从而得到训练完成的

LSTM 模型。由于训练的 epoch 数增大了 1 倍, 造成训练时间比第 1 次的训练模型增加。由于增加了初始学习率和 epoch, 建立的 LSTM 模型的收敛比较充分。

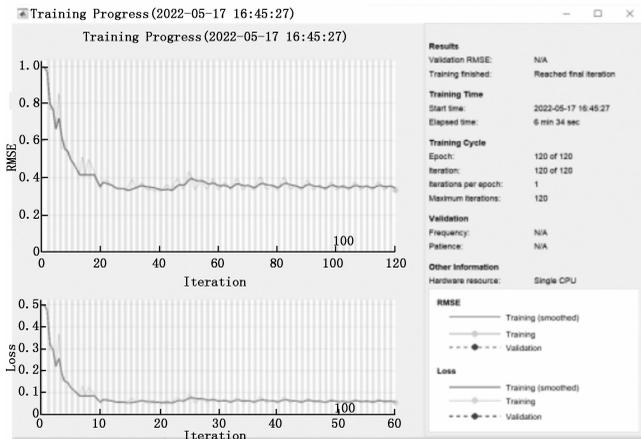


图 8 LSTM 模型的训练误差收敛和损失曲线

采用训练完的模型, 对未来 500 个时间步的 DAM 阵列温度数据进行预测, 如图 9 所示, 可以发现 LSTM 对于 DAM 阵列温度预测具有比较高的准确率, 图 10 为雷达小面阵系统 FPGA 基于 DAM 阵列温度的 LSTM 模型预测预测值与观测值误差曲线。可以看出, 模型的精度可达到 $1e^{-3}$ 至 $1e^{-2}$ 之间的精度。

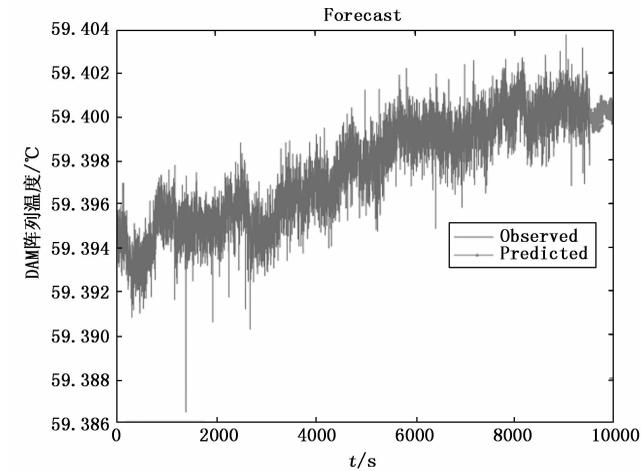


图 9 预测未来 500 步温度值

为进一步计算该模型的精度和误差值, 基于该模型对未来 500 个时间步的 DAM 阵列温度的预测值, 计算 LSTM 对于 FPGA 退化的 DAM 阵列温度预测的总体误差。经程序计算, LSTM 对未来 500 步的总误差为 0.013, 可计算 LSTM 的预测的准确率为 98.7%。

6 结束语

通过计算误差率, 可获得 LSTM 对未来 500 步的总误差为 0.013, 预测的准确率为 98.7%, 因此在该典型任务模式下, 采用长短时记忆网络对综合射频模块的温度做退化预测, 具有比较好的预测效果和精度。由于小面阵系统 FP-

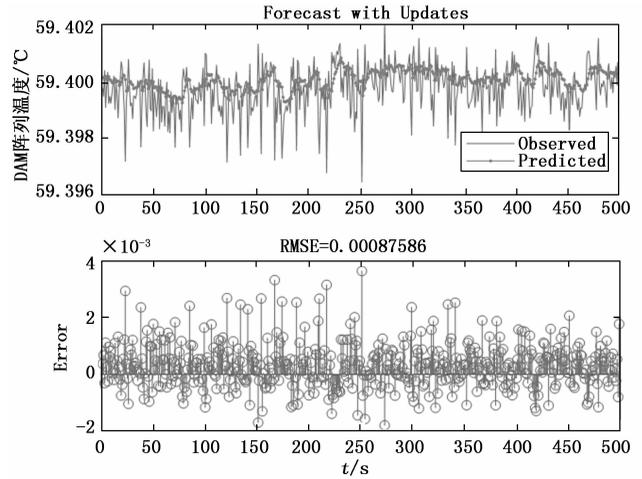


图 10 预测值与观测值误差曲线

GA 退化与 DAM 温度的退化高度关联, 因此下一步工作重点在建立 FPGA 功能性能退化参数和 DAM 温度之间的关系模型。

参考文献:

- [1] 张连超. 美国国防采办系统的运行—美国国防部 5000.2 号指示 [J]. 军用标准化, 2001 (3): 11.
- [2] 吴立金, 夏 冉, 詹红燕, 等. 基于深度学习的故障预测技术研究 [J]. 计算机测量与控制, 2018, 26 (2): 9-12.
- [3] 王振龙. 时间序列分析 [M]. 北京: 中国统计出版社, 2003.
- [4] 邓聚龙. 灰色预测与决策 [M]. 武昌: 华中理工大学出版社, 1986.
- [5] B LENNOX, P RUTHERFORD, G A Montague and C Haugh inAnovel fault prediction technique using model degradation analysis [C] // Proceedings of The American ControlConference, 1995 (6): 3274-3278.
- [6] GF A, SCHMIDHUBERJ, F CUMMINS. Learning to Forget: Continual Prediction with LSTM [C] // IstitutoDalleMolle Di StudiSullIntelligenzaArtificiale. IstitutoDalleMolle Di StudiSullIntelligenzaArtificiale, 1999.
- [7] 上官伟, 孟月月, 杨嘉明, 等. 基于 LSTM-BP 级联网络的列控车载设备故障诊断 [J]. 北京交通大学学报, 2019, 43 (1): 54-62.
- [8] HINTON G, DENG L, YU D, et al. Deep Neural Networks for Acoustic Modeling in Speech Recognition: The Shared Views of Four Research Groups [J]. IEEE Signal Processing Magazine, 2012, 29 (6): 82-97.
- [9] 田沿平, 叶晓慧, 尹 明. 基于状态维修的电子设备故障预测技术研究 [J]. 计算机测量与控制, 2015, 23 (5): 1485-1488.
- [10] 朱乔木, 李弘毅, 王子琪, 等. 基于长短期记忆网络的风电场发电功率超短期预测 [J]. 电网技术, 2017, 41 (12): 3797-3802.
- [11] 代杰杰, 宋 辉, 盛戈皞, 等. 采用 LSTM 网络的电力变压器运行状态预测方法研究 [J]. 高电压技术, 2018, 44 (4):

