

## Temperature Error Compensation Method of MEMS Gyroscope Under Deep Learning\*

SONG Yiping, LIU Ning\*, LIU Fuchao, LEI Ming, QI Wenhao

(Beijing Key Laboratory of High Dynamic Navigation Technology, Beijing Information Science and Technology University, Beijing 100192, China)

**Abstract:** For MEMS gyroscopes, the output data is affected by temperature due to differences in material characteristics and manufacturing processes. On the basis of traditional temperature error compensation, this paper proposes to combine deep learning with neural network, and perform temperature error compensation through LSTM neural network, thereby reducing the temperature drift of the gyro caused by temperature changes. The temperature characteristics of the MEMS gyroscope are analyzed, and on the basis of the RNN neural network model, a multilayer LSTM neural network model is established, and the LSTM network is trained using the ADAM-based optimization algorithm and the time back propagation BPTT algorithm. The trained network model is implanted into the STM32 hardware to realize real-time temperature compensation for the output of the MEMS gyroscope. Experiments show that, compared with the RBF temperature compensation model, the LSTM model has improved performance indicators such as bias stability, bias instability, and angle random walk after gyroscope compensation by more than 90%.

**Key words:** temperature compensation; deep learning; LSTM neural network; MEMS gyroscope

EEACC: 7210; 7230; 2575

doi: 10.3969/j.issn.1004-1699.2022.01.013

## 深度学习下 MEMS 陀螺温度误差补偿方法\*

宋一平, 刘 宁\*, 刘福朝, 雷明, 戚文昊

(北京信息科技大学高动态导航技术北京市重点实验室, 北京 100192)

**摘 要:** 针对 MEMS 陀螺仪因材质特性, 制造工艺等差异导致输出数据受温度影响的问题。本文在传统温度误差补偿的基础上, 提出将深度学习与神经网络相结合, 通过 LSTM 神经网络进行温度误差补偿, 从而减小温度变化引起的陀螺的温度漂移。分析了 MEMS 陀螺仪的温度特性, 并在 RNN 神经网络模型的基础上, 建立多层 LSTM 神经网络模型, 利用基于 ADAM 的优化算法和时间反向传播 BPTT 算法对 LSTM 网络进行训练。将训练好的网络模型植入到 STM32 硬件中, 进而实现对 MEMS 陀螺仪输出的实时温度补偿。实验表明, LSTM 模型与 RBF 温度补偿模型相比, 陀螺仪补偿后的零偏稳定性、零偏不稳定性 and 角度随机游走等性能指标, 以及 MAE、MSE、RMSE 三个模型评价指标提高了 90% 以上。

**关键词:** 温度补偿; 深度学习; LSTM 神经网络; MEMS 陀螺仪

中图分类号: TH701; TN306

文献标识码: A

文章编号: 1004-1699(2022)01-0092-07

MEMS (Micro-Electro-Mechanical System) 陀螺仪是一种成本低、体积小、可靠性好的微机械陀螺仪<sup>[1]</sup>。MEMS 陀螺仪不同于传统陀螺仪的工作原理, 它是通过科里奥利力来实现的。MEMS 陀螺仪以其体积小、性能好、价格低等优点在微惯性导航系统、军事、汽车、消费电子、移动应用、机器人、工业、医疗等领域得到广泛的应用<sup>[1]</sup>。

由于 MEMS 陀螺仪的材质特性, 其数据输出受

温度影响十分显著, 这使 MEMS 陀螺仪的精度达不到要求, 限制了它的进一步应用<sup>[2]</sup>。为解决该问题, 需要对 MEMS 陀螺仪进行温度补偿, 现有的温度补偿方法有三种: 温度控制、器件设计和算法补偿<sup>[2]</sup>。本文研究的内容是算法补偿, 算法补偿的核心思想是通过构造温度误差模型, 使陀螺仪的输出误差得到补偿。构造温度误差模型的方法有以下两种: 一是最小二乘多项式法, 二是神经网络算法<sup>[3]</sup>。

多项式模型不足以模拟突然变化的小范围温度间隔和传感器滞后的偏差趋势。针对多项式模型的不足, 李士心等学者提出了一种基于灰色模型和 RBF 神经网络的 MEMS 陀螺温度补偿方法<sup>[4]</sup>。为了更快速准确的对陀螺仪进行温度补偿, 进一步提出了 CMAC 小脑神经网络模型, 它在解决了非线性问题的同时还具有结构简单以及快速的学习收敛性的优点。ZENG L J 和 MIN F 采用 Elman 神经网络, 直接补偿陀螺输出误差, 实验结果表明, 该方法可以显著降低温度变化引起的陀螺漂移<sup>[5]</sup>。Yang Yuan 提出了一种基于遗传算法的支持向量机优化方法来补偿陀螺仪的零位漂移<sup>[6]</sup>。Li Dinghua, Zhou Jun 等人采用递归神经网络与卡尔曼滤波器结合的方法补偿 MEMS 陀螺的零位漂移<sup>[7]</sup>。李鲁明等人通过改进卡尔曼滤波的陀螺仪误差补偿算法, 阻抑陀螺仪的随机误差<sup>[8]</sup>。

在上述补偿方法中存在如下不足: RBF 神经网络的泛化性能不佳, 存在拟合不足和拟合过度的问题; CMAC 小脑神经网络模型的工作机理是利用一种非线性映射的查表机制。由于它的运算特性, 占用了大量的存储空间, 并且存在局部收敛的缺点; MEMS 陀螺仪的零位漂移用支持向量机补偿法进行补偿的缺点在于特征向量和模型参数选取的过程非常复杂; Kalman 滤波的局限性在于, 当系统模型和噪声统计特性存在不确定性的情况下应用受到限制<sup>[9]</sup>。

为了优化 MEMS 陀螺仪的温度补偿方法, 本文对 MEMS 陀螺仪进行温度误差机理分析, 将深度学习与神经网络相结合。通过对深层非线性网络结构的学习, 改进了温度误差模型的缺陷, 提高其优越性, 抑制了 MEMS 陀螺仪的温度漂移。

### 1 温度误差机理分析

温度变化引起的漂移是 MEMS 陀螺仪主要的误差之一, 温度通过改变陀螺的谐振频率和驱动振幅来影响陀螺的性能<sup>[10-11]</sup>。由于 MEMS 陀螺仪是由硅制成的, 硅是一种热敏材料, 当环境温度发生变化, 弹性模量会随之改变, 陀螺仪刚度在弹性模量的影响下, 使谐振频率发生改变, 导致 MEMS 陀螺仪的漂移加剧, 陀螺精度大幅下降<sup>[11]</sup>, MEMS 陀螺仪的刚度与环境温度的关系可表示为:

$$K = K_0 - C_E K_0 (T - T_0) \quad (1)$$

式中:  $K$  和  $K_0$  分别是在温度  $T$  和  $T_0$  下陀螺仪的刚度。陀螺仪谐振频率与环境温度的关系式如下:

$$f(T) = \sqrt{K/m} = \sqrt{[K_0 - C_E K_0 (T - T_0)]/m} =$$

$$f_0 \sqrt{1 - C_E (T - T_0)} \quad (2)$$

式中:  $f(T)$  和  $f_0$  分别是谐振子在温度为  $T$  和  $T_0$  时的谐振频率。

由式(2)可以看出, 陀螺仪的谐振频率与温度变化有关, 温度对 MEMS 陀螺仪的影响较大, 使陀螺输出精度降低。通过分析 MEMS 惯性器件的温度影响机理, 对 MEMS 温度误差补偿方法进行研究。

## 2 深度学习下的神经网络模型搭建

### 2.1 RNN 神经网络

深度学习的过程是从信号中提取特征, 然后映射到特征值, 其中特征是由网络自己选择的。深度学习下的神经网络层级不同于传统的神经网络, 如图 1 中 RNN 神经网络结构图所示。




图 1 RNN 神经网络结构图

其中,  $x$  表示输入层的值,  $s$  表示隐藏层的值,  $o$  表示输出层的值。  $U$  是输出层到隐藏层的权重矩阵,  $V$  是隐藏层到输出层的权重矩阵,  $W$  代表的是各时间点之间的权重矩阵。RNN 循环神经网络隐藏层的值  $s$  不仅取决于当前的输入  $x$ , 还与上一隐藏层的值  $s$  有关。将图 1 循环层按时间线展开, 如图 2 所示。




图 2 RNN 循环层时间线展开图

随着模型深度不断增加, RNN 循环神经网络会面临梯度消失的问题, 不能很好地处理长距离的依赖。为此引入了 LSTM 长短时记忆神经网络。

### 2.2 LSTM 神经网络

LSTM 神经网络是基于 RNN 循环神经网络的衍生网络, 它是一种能够捕捉长时依赖的特殊循环神经网络<sup>[12]</sup>。它能够解决训练过程中 RNN 循环神

神经网络梯度消失的问题,并克服只能短时学习的缺点<sup>[13]</sup>。LSTM 的核心概念在于细胞状态以及“门”结构。细胞状态是传递有关信息的途径,它将序列中的有关信息传递下去。“门”结构的作用是在训练过程中负责学习信息的去留问题。LSTM 单元中有三种类型的门控,分别为:输入门、遗忘门和输出门。LSTM 神经网络对有关信息保存筛选的操作是由这三种门控实现的。如图 3 所示。




图 3 LSTM 结构模型图

门控是由 sigmoid 函数和点乘运算实现。本文采用的门控的形式表示为:

$$g(x) = \sigma(Wx+b) \quad (3)$$

式中: $\sigma(x) = 1/[1 + \exp(-x)]$ ,称为 Sigmoid 函数,它是一种常用的非线性激活函数,通过将一个数值映射到区间 0~1 内,来确定信息是否被顺利传递到下一步。当门的输出值为 0,表示信息被拦截,当值为 1 则表示信息顺利通过。分别使用  $i_f$  和  $o$  来表示输入门、遗忘门和输出门的输出值, $\odot$ 代表对应元素相乘, $W$  和  $b$  表示网络的权重矩阵和偏置向量。LSTM 的前向计算过程可以表示为:

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (4)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (5)$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (6)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (7)$$

$$h_t = o_t \odot \tanh(c_t) \quad (8)$$

LSTM 神经网络的运行模式与 RNN 神经网络的无太大差异,不同之处在于,LSTM 神经网络经由一个更确切的内部处置单元有效地存储和更新信息。LSTM 神经网络将 sigmoid 函数映射到 [0,1] 区间上,以便剔除或保留相关信息。通过这种方式,存储单元可以同时捕捉短期和长期的时间序列特征,解决 RNN 神经网络梯度消失的问题<sup>[14]</sup>。

### 2.3 LSTM 神经网络建模

本文基于多层的 LSTM 神经网络模型进行构建,该算法模型按照以下步骤进行设计:

步骤 1 设计 LSTM 网络模型层级。采用 3 层 LSTM 网络,一层扁平化网络,一层全连接网络。通

过 flatten 层把输入信息扁平化,将多维输入转变为一维输入。经由一个全连接层将 LSTM 输出的向量转换成标签向量的维度。网络结构图如图 4 所示。

步骤 2 LSTM 单元用 128 个神经元进行训练。选用 32 360 样本数据集为训练集,32 360 样本为测试集。输入维度为 2,滑动窗口大小为 100。然后需要调节的主要参数有存储单元数目、结构和训练集时间窗口大小。对每种情况训练 100 次,监测网络模型指标。

步骤 3 评估训练后的 LSTM 神经网络性能。通过平均绝对误差(MAE)、均方误差(MSE)、均方根误差(RMSE)这三个评价指标判定 LSTM 网络模型的预测能力。MAE 的值越小表示预测模型的精度越高。MSE 和 RMSE 的值越小表示模型的预测效果越稳定。

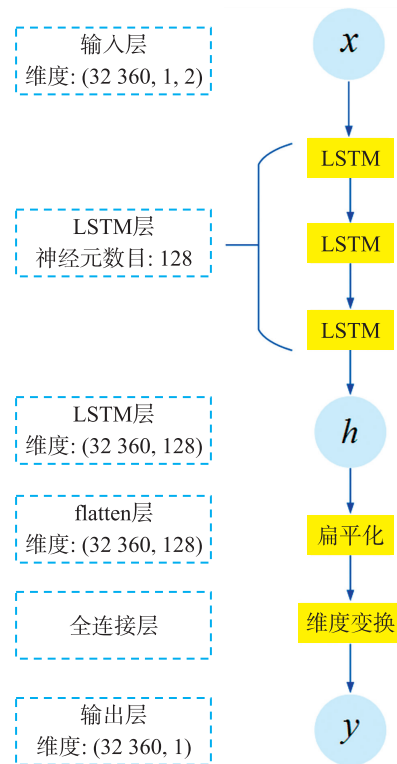


图 4 网络结构图

## 3 LSTM 神经网络训练

本文研究的 LSTM 神经网络算法包括训练数据和测试数据两大方面。训练结果和测试结果的准确性往往取决于数据的选择、数据量的大小和模型参数的设定三个方面。初步完成神经网络模型搭建之后,需要测试模型的补偿效果,根据测试后得到的评价指标进而调整模型的参数、特征或者算法,以达到满意的结果。LSTM 神经网络的训练算法是一种反

向传播算法, 主要分为以下三个步骤:

步骤 1 计算每个神经元的正向传播参数。计算 LSTM 神经网络中  $f_t, i_t, C_t, o_t$  和  $h_t$  这五个向量的值。

步骤 2 计算每个神经元的误差值  $\delta$ 。LSTM 神经网络误差项的反向传播包括两个方向: 一个是沿时间方向的反向传播, 通过当前时间  $t$  计算每一时刻的误差项; 另一个是沿着上一层的反向传播。

步骤 3 计算每个权重的梯度, 然后使用 ADAM 优化算法和时间反向传播 BPTT 算法更新权重。

为了减少训练模型的误差, 避免陷入局部最优解, 首先对时间序列进行反向传播和归一化, 然后对各层权值和学习率进行初始化, 最后采用基于 ADAM 的优化算法和时间反向传播 BPTT 算法对 LSTM 网络进行进一步训练。具体网络训练流程如图 5 所示。

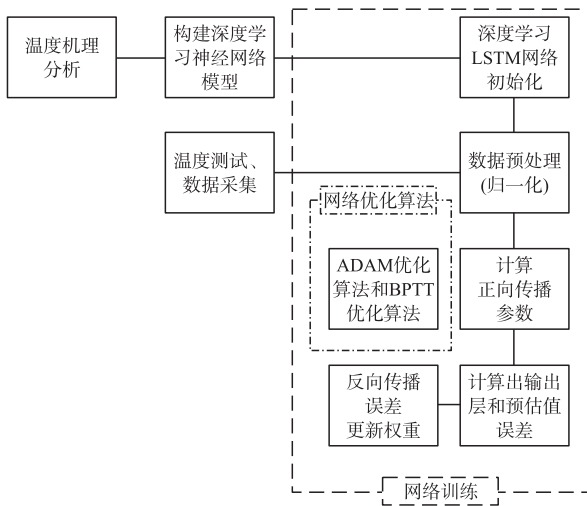


图 5 LSTM 网络训练流程

本文选用的评价指标是平均绝对误差、均方误差、均方根误差, 通过这三个指标来评估 LSTM 网络模型的预测能力<sup>[13]</sup>:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (9)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (10)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (11)$$

式中:  $y_i$  为  $t$  时刻的实际输出,  $\hat{y}_i$  为  $t$  时刻的预测输出。

由表 1 可以看出, MAE 的值随着反向传播次数的增加逐渐减小, 这说明预测模型的精度逐渐提高。MSE 和 RMSE 的值越小, 说明模型的预测效果越

稳定。

表 1 LSTM 网络训练模型指标

$n$	MAE	MSE	RMSE
1	0.243 1	0.005 4	0.073 7
2	0.244 1	0.005 6	0.074 5
4	0.249 3	0.006 3	0.077 6
8	0.237 1	0.004 9	0.070 3
10	0.231 5	0.004 5	0.067 2
12	0.229 9	0.004 4	0.066 3

## 4 实验分析

### 4.1 数据采集与预处理

实验中使用的设备有 MEMS 陀螺仪(由高动态导航北京市重点实验室自制)、一台双轴转台高低温试验箱和一台计算机。设计 MEMS 陀螺仪的硬件结构, 制作出如图 6 所示的 MEMS 陀螺样机。在采集数据前需要对陀螺仪设备进行校准, 然后通过双轴转台高低温试验箱实现 MEMS 陀螺仪的温度变化, 最后利用由实验室制作的 hdntCenter 上位机软件记录陀螺仪的输出数据以及温度数据。具体过程如下。

将带有型号为 ADXRS646 的陀螺仪的 MENS 器件放置于温箱内, 如图 7 所示。打开测试设备电源, 设置温箱程序, 设定温度为  $-40\text{ }^{\circ}\text{C} \sim 60\text{ }^{\circ}\text{C}$ 。在测试过程中, 温度是唯一环境量, 通过热阻得到 MEMS 陀螺仪金属外壳内部的实时温度, 其值与 MEMS 陀螺仪输出同步<sup>[15]</sup>。温箱温度初始值设置为  $-40\text{ }^{\circ}\text{C}$ , 待温度到达  $-40\text{ }^{\circ}\text{C}$  后, 保温 15 min, 打开 hdntCenter 上位机软件开始记录数据。温箱温度在  $-40\text{ }^{\circ}\text{C}$  保持 1 h 后将温度变化速率调至  $0.5\text{ }^{\circ}\text{C}/\text{min}$ , 当温箱温度升高至  $60\text{ }^{\circ}\text{C}$  后保持 1 h, 以确保 MEMS 陀螺仪外壳内部的温度与温箱温度保持一致, 随后停止记录, 保存数据并关闭温箱。




图 6 MEMS 陀螺仪

在温度区间内进行数据采集, 得到陀螺零位漂移-温度的关系图, 如图 8 所示。由于原始的 MEMS 陀螺仪零位漂移与温度关系的数据过多, 使得图像不精准。为了得到更精准的 MEMS 陀螺仪零位漂移与温度关系的曲线图, 需要每  $0.1\text{ }^{\circ}\text{C}$  在原始陀螺

零位漂移-温度的关系曲线上取前后 100 个样本的平均值作为新的陀螺零位漂移-温度关系曲线的样本点,如图 9 所示。



图 7 双轴转台高低温试验箱




图 8 MEMS 陀螺仪的零位漂移-温度关系




图 9 取平均值后 MEMS 陀螺仪的零位漂移-温度关系

#### 4.2 实验结果及分析

采集数据的前 70%作为训练样本,剩下的 30%作为测试样本。本文对 LSTM 网络进行了 50 次迭代训练,滑动窗口大小为 1,所有采集到的数据在使用前进行相应的处理。训练完成后,将训练好的网络参数存储到测试数据集中,测试 LSTM 网络模型的性能。图 10 表明了随着迭代次数的增加 LSTM 网络的误差变化。可以看出,经过 50 次训练后,LSTM 网络的损失函数下降趋于稳定。

为了显示出 LSTM 神经网络的优越性,本文与传统多项式模型、RBF 神经网络模型、CMAC 小脑模型作对比。利用同一测试集检验几种模型的预测精度,表 2 列出了不同模型的预测能力和补偿效果的




图 10 LSTM 神经网络训练周期与误差的关系

评价指标。与其他模型相比 LSTM 神经网络模型的 MAE、MSE 和 RMSE 的值更小,这表明预测模型的精度高,稳定性好。表 3 为陀螺仪的性能指标,对比其他模型,LSTM 网络模型的性能指标的优越性十分显著。从图 11 可以更直观的看出,LSTM 神经网络模型的补偿效果优于其他模型。

表 2 不同模型的评价指标

模型	MAE	MSE	RMSE
多项式	0.414 3	0.040 4	0.201 0
RBF	0.346 9	0.024 2	0.155 7
CMAC	0.318 4	0.023 6	0.153 6
LSTM	0.009 2	0.000 1	0.011 6

表 3 陀螺仪的性能指标

模型	零偏稳定性 /(°/h)	零偏不稳定性 /(°/h)	角度随机游走 /(°/√h)
多项式	456.306 6	174.615 7	4.171 4
RBF	313.976 1	66.642 8	4.171 4
CMAC	305.969 1	61.179 8	3.933 9
LSTM	13.352 7	1.025 6	0.191 9




图 11 不同模型的补偿效果

#### 4.3 LSTM 神经网络模型的验证

使用相同型号的另一组陀螺仪进行实验,在 -40 °C ~60 °C 温度区间内采集 7 组数据。采用 LSTM 网络模型对 MEMS 陀螺仪输出进行温度补偿,补偿后的模型评价指标如表 4 所示,7 组均方误差、绝对值均差、均方根误差这三指标值上下波动不大,且数值较小,说明模型预测精度高,补偿效果稳定。

表 4 LSTM 网络的评价指标

序号	MAE	MSE	RMSE
1	0.008 5	0.000 1	0.010 6
2	0.009 2	0.000 1	0.011 5
3	0.015 8	0.000 4	0.018 9
4	0.008 7	0.000 1	0.010 9
5	0.009 5	0.000 1	0.010 8
6	0.009 9	0.000 2	0.015 4
7	0.011 5	0.000 4	0.015 5

经过数据预处理,计算出陀螺的各项指标。表 5 列举了 MEMS 陀螺仪温度补偿前的各项指标,表 6 为通过 LSTM 网络补偿后的陀螺仪指标。对比可知,补偿后的陀螺仪零偏稳定性、零偏不稳定性、角度随机游走数值大幅度减小,证明了稳定补偿模型的准确性。

表 5 温度补偿前 MEMS 陀螺仪的各项指标

序号	零偏稳定性 /(°/h)	零偏不稳定性 /(°/h)	角度随机游走 /(°/√h)
1	649.59	185.95	2.602 8
2	708.18	158.66	2.203 1
3	706.65	154.88	2.054 3
4	701.01	179.43	2.530 8
5	749.91	171.00	2.434 1
6	703.01	164.024 1	2.234 2
7	674.52	163.032 1	2.577 1

表 6 温度补偿后 MEMS 陀螺仪的各项指标

序号	零偏稳定性 /(°/h)	零偏不稳定性 /(°/h)	角度随机游走 /(°/√h)
1	11.192 9	2.379 1	0.174 4
2	24.046 0	5.199 3	0.195 6
3	35.164 7	3.776 9	0.167 1
4	17.962 3	1.697 6	0.179 8
5	20.135 4	4.197 7	0.190 0
6	24.463 1	1.948 4	0.182 0
7	19.157 2	3.846 1	0.178 4

### 4.4 硬件实现

利用训练好的模型实现 MEMS 陀螺仪输出的温度补偿,具体流程如图 12 所示。对于本文提出的深度学习下的多层 LSTM 网络,需要通过 Cube.ai 在 STM32 上实现。利用 Cube.ai 部署多层 LSTM 网络的具体步骤如下:

步骤 1 利用上文 4.1 节中方法利用 hdntCenter 上位机软件采集陀螺仪温度数据和原始输出数据,重复测试 2 组。

步骤 2 利用 Python 将两组数据在每 0.1 °C 取前后 100 个陀螺仪输出的平均值作为网络训练样本

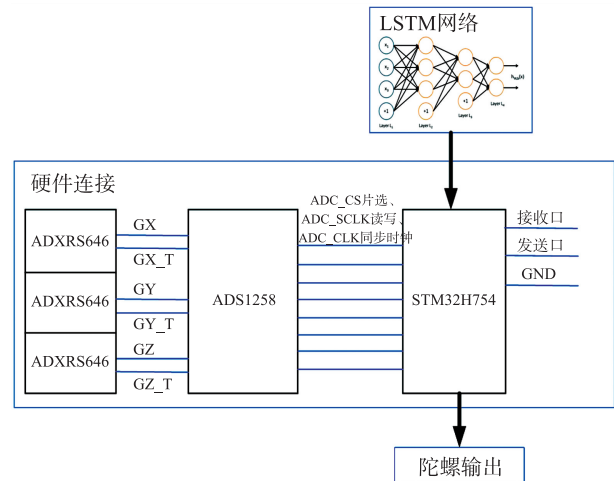


图 12 系统组成图

和测试样本,并将训练样本和测试样本逐一打上标签(标签为陀螺仪零偏)。

步骤 3 训练深度学习下的多层 LSTM 网络模型。利用 Python 的 Keras 深度学习框架构建本文深度学习网络结构。将陀螺的输出数据和对应的温度数据作为 LSTM 深度学习网络的输入,步骤 2 中的标签作为深度学习网络的输出。应用 3 种不同的损失函数进行网络训练,通过短时间内多次迭代,使得网络的输出可以最小化期望的误差标准。

步骤 4 将深度学习下的多层 LSTM 网络转换为 STM32 的优化代码。把训练好的深度学习模型的.h5 文件输入到 CubeMX 软件中,借助 STM32 CubeMX 软件中 Cube.ai 工具箱优化代码,将网络转化成 STM32 可以运行的 Keil 工程文件,并使工程复杂度和内存需求最小化。随后下载到 STM32 中。

步骤 5 使用训练后的网络处理和分析实时数据。

## 5 结论

本文将深度学习与神经网络相结合,提出了一种在 LSTM 神经网络的作用下能抑制 MEMS 陀螺仪受温度影响产生零位漂移的方法。该方法将网络层级部分进行了优化,利用其特有的网络层级对有限样本进行数据训练,使网络对非线性函数输出具有预测能力。LSTM 神经网络通过学习一种深层非线性网络结构,模拟更加复杂的函数,从而提高补偿模型的准确性,为后续的温度误差补偿奠定了基础。为了验证 LSTM 神经网络模型的优越性和有效性有效性,本文将 LSTM 模型与其他模型进行对比试验,经过 LSTM 神经网络模型补偿的效果图更趋近于一条水平直线。对比几种模型的预测能力和补偿效果评价指标,实验表明,LSTM 模型与 RBF 温度补偿模

型相比,陀螺仪补偿后的零偏稳定性、零偏不稳定性和角度随机游走等性能指标,以及 MAE、MSE、RMSE 三个模型评价指标提高了 90% 以上。并且 LSTM 神经网络模型的 MAE、MSE、RMSE 值最小,这说明 LSTM 神经网络预测模型的精度高,效果稳定。后续对 LSTM 神经网络模型的可行性和准确性也进行了进一步的验证。实验结果表明,基于 LSTM 神经网络模型补偿后的陀螺输出精度显著提高,补偿效果明显,具有一定的工程应用价值。

#### 参考文献:

- [1] Rita F, Domenico A, Rosario S, et al. MEMS Gyros Temperature Calibration Through Artificial Neural Networks[J]. Sensors and Actuators: A. Physical, 2018, 279: 553-565.
- [2] 徐小婷,沈小林. 基于 RBF 神经网络的 MEMS 陀螺温度漂移补偿[J]. 微纳电子技术, 2018, 55(11): 819-823.
- [3] 刘楠,苏言,童鑫,等. 硅微机械陀螺仪温度补偿方法的研究现状[J]. 微纳电子技术, 2017, 54(6): 395-400.
- [4] 李士心,王晓亮,翁海娜,等. 基于灰色模型和 RBF 神经网络的 MEMS 陀螺仪温度补偿[J]. 中国惯性技术学报, 2010, 018(6): 742-746.
- [5] Zeng L J, Min F. Temperature Drift Compensation of MEMS Gyroscope Array Based on Elman Neural Networks [C]//2019 IEEE 3rd Advanced Information Management, Communicates, Electronic and Automation Control Conference(IMCEC), 2019: 1643-1646.
- [6] Yang Y, Liu Y, Zhao X, et al. Temperature Compensation of MEMS Gyroscope Based on Support Vector Machine Optimized by GA [C]//2019 IEEE Symposium Series on Computational Intelligence (SSCI). Xiamen, 2019: 2989-2994.
- [7] Li D, Zhou J, Liu Y. Recurrent-Neural-Network-Based Unscented Kalman Filter for Estimating and Compensating the Random Drift of MEMS Gyroscopes in Real Time — ScienceDirect[J]. Mechanical Systems and Signal Processing, 2021, 147: 107057.
- [8] 李鲁明,赵鲁阳,唐晓红,等. 基于改进卡尔曼滤波的陀螺仪误差补偿算法[J]. 传感技术学报, 2018, 31(4): 538-544, 550.
- [9] 钱华明,夏全喜,阙兴涛,等. 基于 Kalman 滤波的 MEMS 陀螺仪滤波算法[J]. 哈尔滨工程大学学报, 2010, 31(9): 1217-1221.
- [10] Su Z, Liu N, Li Q. Error Model and Compensation of Bell-Shaped Vibratory Gyro[J]. Sensors, 2015, 15(9): 23684-23705.
- [11] Ga A, Afar S. Characterization and Calibration of MEMS Inertial Sensors for State and Parameter Estimation Applications[J]. Measurement, 2012, 45(5): 1210-1225.
- [12] 李荣冰,鄢俊胜,刘刚,等. 基于 LSTM 深度神经网络的 MEMS-IMU 误差模型及标定方法[J]. 中国惯性技术学报, 2020, 28(2): 165-171.
- [13] Wang Q, Gu Y, Liu J, et al. Deep Speedometer: Vehicle Speed Estimation from Accelerometer and Gyroscope Using LSTM Model [C]//2017 IEEE 20th International Conference on Intelligent Transportation Systems(ITSC), 2017: 1-6.
- [14] Lu S, Zhang Q, Chen G, et al. A Combined Method for Short-Term Traffic Flow Prediction Based on Recurrent Neural Network [J]. AEJ — Alexandria Engineering Journal, 2021, 60(1): 87-94.
- [15] Shen C, Song R, Li J, et al. Temperature Drift Modeling of MEMS Gyroscope Based on Genetic-Elman Neural Network[J]. Mechanical Systems and Signal Processing, 2016, 72-73: 897-905.



宋一平(1997—),女,汉族,现在北京信息科技大学就读研究生,专业为控制工程,研究方向是导航与制导;



刘宁(1986—),男,汉族,现任北京信息科技大学自动化学院高动态导航技术北京市重点实验室副研究员。累计发表 SCI 论文 15 篇、EI 论文 12 篇,授权发明专利 12 项。曾获 2017 年国家技术发明二等奖 1 项、2016 年国防技术发明一等奖 1 项、北京市科学技术二等奖 2 项和三等奖 1 项、吴文俊人工智能科技技术奖二等奖 1 项和三等奖 2 项。获批北京市科技新星计划,获中国仿真学会优秀科技工作者称号,获北京自动化学会“青年科技创新人才”奖。ning.liu@bistu.edu.cn。