

控制与决策

Control and Decision

基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断

王进花, 岳亮辉, 曹洁, 马佳林

引用本文:

王进花, 岳亮辉, 曹洁, 马佳林. 基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断[J]. *控制与决策*, 2023, 38(4): 1015–1021.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.1527>

您可能感兴趣的其他文章

Articles you may be interested in

[基于改进的胶囊网络的行星齿轮箱故障诊断方法](#)

Fault diagnosis method of planetary gearbox based on enhanced capsule network
控制与决策. 2023, 38(3): 661–669 <https://doi.org/10.13195/j.kzyjc.2021.1440>

[基于改进SSA优化MDS-SVM的变压器故障诊断方法](#)

Transformer fault diagnosis method based on improved SSA optimized MDS-SVM
控制与决策. 2023, 38(2): 459–467 <https://doi.org/10.13195/j.kzyjc.2021.1437>

[基于W-DenseNet的减压阀不平衡样本故障诊断模型](#)

W-DenseNet-based fault diagnosis model of pressure-reducing valve with unbalanced samples
控制与决策. 2022, 37(6): 1513–1520 <https://doi.org/10.13195/j.kzyjc.2020.1708>

[基于鲸鱼算法优化LSSVM的滚动轴承故障诊断](#)

Fault diagnosis method of rolling bearing based on LSSVM optimized by whale optimization algorithm
控制与决策. 2022, 37(1): 230–236 <https://doi.org/10.13195/j.kzyjc.2020.1147>

[基于径向基神经网络的新型齿轮故障诊断方法](#)

Novel gear fault diagnosis method based on RBF neural network
控制与决策. 2022, 37(2): 409–416 <https://doi.org/10.13195/j.kzyjc.2020.0836>

基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断

王进花^{1,2,3†}, 岳亮辉¹, 曹洁^{1,4}, 马佳林⁴

- (1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050;
2. 甘肃工业过程先进控制重点实验室, 兰州 730050;
3. 兰州理工大学 电气与控制工程国家实验教学中心, 兰州 730050;
4. 兰州理工大学 计算机与通信学院, 兰州 730050)

摘要: 近年来,许多基于深度学习的方法被用于故障诊断领域,并且取得了良好的效果,但是发电机故障样本数据难以获取,在数据量较少的情况下,基于深度学习的方法存在过拟合现象,导致模型泛化能力差、诊断精度不高.为了解决这一问题,提出一种基于随机变分推理贝叶斯神经网络的故障诊断方法.该方法以贝叶斯推理与随机变分推理为基础,可以根据少量数据得到较为可靠的模型,获得网络各层参数的概率分布,有效解决过拟合的问题.采用证据下限(evidence lower bound, ELBO)派生类函数 TraceGraph ELBO 进行随机变分推理,解决派生类函数 Trace ELBO 诊断精度较低的问题.将所提方法应用于发电机轴承的故障诊断,并与其他方法对比,结果表明,所提方法在故障样本数据量较少的情况下具有较高的诊断性能.

关键词: 发电机轴承; 故障诊断; 深度学习; 贝叶斯神经网络; 随机变分推理

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.1527

引用格式: 王进花,岳亮辉,曹洁,等.基于随机变分推理贝叶斯神经网络的发电机轴承故障诊断[J].控制与决策,2023,38(4): 1015-1021.

Fault diagnosis of generator bearing based on stochastic variational inference Bayesian neural network

WANG Jin-hua^{1,2,3†}, YUE Liang-hui¹, CAO Jie^{1,4}, MA Jia-lin⁴

- (1. School of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
2. Gansu Key Laboratory of Advanced Industrial Process Control, Lanzhou 730050, China;
3. National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, China;
4. School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: In recent years, many deep learning-based methods have been used in the field of fault diagnosis and have achieved good results. However, it is difficult to obtain generator fault sample data. In a case of a small amount of data, deep learning-based methods have over-fitting phenomenon, resulting in poor model generalization ability and low diagnostic accuracy. In order to solve this problem, this paper proposes a fault diagnosis method based on the random variational inference Bayesian neural network. This method is based on Bayesian inference and random variational inference, which can obtain a more reliable model based on a small amount of data. Obtaining the probability distribution of the parameters of each layer of the network can effectively solve the problem of overfitting. The evidence lower bound derived function TraceGraph ELBO is used to carry out random variational inference, which solves the problem of low diagnostic accuracy of the derived function Trace ELBO. This method is applied to the fault diagnosis of generator bearings and compared with other methods. The results show that the proposed method has higher diagnostic performance when the amount of fault sample data is small.

Keywords: generator bearing; fault diagnosis; deep learning; Bayesian neural network; random variational reasoning

0 引言

随着社会的发展,发电机的规模逐渐扩大,发电机的密封保护受到制约,许多发电机长期运行于电磁环境中,容易发生故障^[1].据统计,在发电机的所有

故障中,轴承的故障率为40%,定子的故障率为38%,转子的故障率为10%,其他故障为12%^[2].因此,针对电机轴承等关键零部件的故障诊断与监测一直是电机装置故障诊断研究的热点.近年来,基于深度

收稿日期: 2021-08-30; 录用日期: 2022-01-11.

基金项目: 国家自然科学基金项目(62063020,61763028); 甘肃省自然科学基金项目(20JR5RA463).

†通讯作者. E-mail: wjh0615@lut.edu.cn.

学习的智能故障诊断方法^[3-5]已被成功应用于电机轴承故障诊断中,并取得了不错的诊断效果.文献[6]使用一维卷积神经网络(CNN)来快速、精准地检测电机的轴承故障,达到了很高的准确率;文献[7]提出了一种通用的轴承故障诊断模型,该模型由著名的Alexnet模型转换而来,只需要替换最后一个完全连通的层;文献[8]使用从振动数据中提取的统计特征作为模型输入,并开发了用于轴承故障分类的2D CNN;文献[9]采用了一种比普通神经网络具有更高稳定性和准确性的模型,获得了很好的诊断效果;文献[10]从原始振动信号和声学信号中提取特征,并利用基于1D-CNN的网络进行融合;文献[11]提出了基于卷积神经网络的隐马尔可夫模型对机械系统中的轴承故障进行分类.基于深度学习的诊断方法不需要对数据作处理,可以通过自身模型直接实现特征提取与分类,由原始数据就可以得到很高的诊断精度.基于深度学习的智能故障诊断算法往往需要大量的故障数据才能得到好的诊断效果,而电机故障诊断领域都存在故障样本数据难以获取的问题.在数据较少的情况下,大多基于深度学习的智能故障诊断算法存在过拟合现象,导致了诊断结果不高、模型泛化能力差的问题.

贝叶斯神经网络提供网络权值的不确定表示,对权值的后验分布进行估计和决策,因此在小样本分类问题中有较好的泛化能力^[12].在过去几十年里,贝叶斯神经网络得到了很好的发展,Neal^[13]提出神经网络的贝叶斯学习;Gal等^[14]使用概率的思维解释机器学习中的原理,从贝叶斯的角度解释了dropout为什么可以为神经网络带来防止过拟合的效果.存在的问题是,在神经网络中执行贝叶斯推理时,很难求得参数的后验分布.因此,最近几年贝叶斯方法的核心目标之一就是使用各种方法去近似难以计算的后验概率,Graves^[15]为大多数的神经网络提出了一个变分推理的方法,该方法能够有效近似后验分布;Fortunat等^[16]成功将贝叶斯方法应用到了循环神经网络中,用变分推理近似后验分布,取得了不错的效果.贝叶斯方法将先验知识融入到现有的深度学习结构中,使用高斯分布的形式表示网络权重参数,可以避免过拟合现象;使用近似变分后验去近似真实的后验概率分布,将近似的问题转换成对函数的优化问题,解决了真实后验概率难以计算的问题.但是在变分推理中,常用推导方法只适用于共轭分布,不适用于不易分析的概率分布,因此引入随机梯度下降法去解决此问题.

基于以上分析,本文提出基于随机变分推理贝叶斯神经网络故障诊断方法.为了降低模型复杂度,采用只有一层隐藏层的网络结构;针对实验数据样

本特性,增加隐藏层神经元的个数,提高网络提取故障特征的能力;与传统的采用固定权值的神经网络不同,通过引入与条件概率分布相关的权值,贝叶斯神经网络能够解决经典神经网络中常见的过拟合问题;选择ELBO的派生类函数TraceGraph ELBO进行随机变分推理,解决派生类函数Trace ELBO诊断精度较低的问题;使用随机变分推理的方法可以在数据量较少的情况下学习,获得近似后验分布,并根据近似后验分布进行分类决策,从而得到较为准确的诊断结果.

1 贝叶斯神经网络

1.1 网络模型

神经网络都可以被认为是一般的回归模型,并且这些模型被训练成将一系列输入 $X = [X_1, X_2, \dots, X_N]$ 与它们相应的输出 $Y = [Y_1, Y_1, \dots, Y_N]$ 相关联.假设有一个表示为 $f^w(\cdot)$ 的神经网络^[17],其中 f 表示神经网络的结构(例如,层数和隐藏单元,激活函数的选择), w 是要估计的模型参数(神经元权重)的集合.在贝叶斯方法中,需要实现的目标是推断最有可能生成观测数据 X 和 Y 的模型参数 w 的后验分布.该方法中,在模型参数 $P(w)$ 的空间上分配先验分布表示生成观测数据时对每个候选模型参数的先验信念,然后构造似然函数 $p(Y_1|X_1, w)$ ($w \in \mathbf{w}$)表征给定模型参数 w 时生成观测数据的概率.贝叶斯推理旨在计算模型参数 w 上的后验分布 $p(w|X, Y)$,如下所示:

$$P(w|X, Y) = \frac{P(Y|X, w)P(w)}{P(Y|X)}. \quad (1)$$

一旦有了完全后验分布 $P(w|X, Y)$,新数据点 X^* 上的预测分布可以通过在 w 上积分得到,如下所示:

$$P(Y^*|X^*, X, Y) = \int P(Y^*|X^*, w)P(w|X, Y)dw, \quad (2)$$

其中 $P(w|X, Y)$ 表示 w 的后验分布.在实践中,每次从后验分布 $P(w|X, Y)$ 中抽取一个样本 w ,并获得给定 w 的新数据点 X^* 上的点估计 Y^* .上述操作被重复多次,由此可以获得新数据点 X^* 的分布估计.贝叶斯神经网络得到的是各层参数的分布,从而得到模型参数 w 上的后验分布 $P(w|X, Y)$,因此在故障样本数据较少时,可以有效解决过拟合的问题.

1.2 变分推理

就神经网络而言,定义先验分布的一种流行方法是在神经元权重上放置高斯分布 $p(w) = N(0, I)$.为了简单起见,偏置向量通常被假设为点估计.困难的是,由于深度神经网络中的非线性和非共轭性,用经典的蒙特卡罗马尔可夫链(MCMC)采样算法进行贝

叶斯推理在计算上是难以处理的. 这是由于激活函数本身的非线性以及它们在多个隐藏层上的组合, 导致了神经网络的高度非线性行为. 另外, 神经网络的复杂结构导致共轭先验的缺乏, 当在神经网络中执行贝叶斯推理时, 不可能以封闭形式导出后验分布 $P(w|X, Y)$. 已有学者提出了近似推理技术(例如变分推理)来减轻计算负担, 而不是推断精确的后验分布.

变分推理的核心思想是用变分参数分布来逼近后验分布 $P(w|X, Y)$. Gal等^[14]的研究表明, Monte Carlo (MC) dropout的目标实际上最小化了近似分布 $q_\theta(w)$ 和后验分布 $P(w|X, Y)$ 之间的Kulback-Leibler散度, 可以用于近似深层神经网络中的贝叶斯推理. 以下简要描述该方法的数学细节.

考虑近似分布 $q_\theta(w)$, 通过最小化近似分布 $q_\theta(w)$ 和真实后验分布 $P(w|X, Y)$ 之间的Kulback-Leibler (KL) 散度, 以确定最佳参数分布来近似实际的后验分布, 如下所示:

$$\begin{aligned} \text{KL}(q_\theta(w)||p(w|X, Y)) &= \int q_\theta(w) \log \frac{q_\theta(w)}{p(w|X, Y)} dw = \\ &= \int q_\theta(w) \log \frac{q_\theta(w)p(X, Y)}{p(w, X, Y)} dw = \\ &= \log p(X, Y) - \int q_\theta(w) \log \frac{p(w, X, Y)}{q_\theta(w)} dw. \end{aligned} \quad (3)$$

由于 $p(Y|X)$ 是一个常数, 最小化KL散度相当于最大化 θ 的对数证据下界 (ELBO), 如下所示:

$$L_{\text{ELBO}}(\theta) = \int q_\theta(w) \log p(Y|X) dw - \text{KL}(q_\theta(w)||p(w)). \quad (4)$$

其中: 第1项测量从变分分布 $q_\theta(w)$ 采样的参数值生成观测数据的可能性; 第2项是变分密度和先验之间的负散度, 越接近先验分布越好. θ 使式(4)中的目标函数最大化将导致变分分布 q_θ 可以很好地近似后验 $p(w|X, Y)$, 同时仍然接近先验 $p(w)$.

式(4)中的积分在计算上对所有 q 都是困难的, 因此执行蒙特卡罗积分来近似这个量. 具体而言, 首先从 $q_\theta(w)$ 中采样 \hat{w} , 然后针对 θ 执行一步优化, 以最大化下式中的目标函数:

$$L(\hat{\theta}) = \log p(Y|X, \hat{w}) - \text{KL}(q_\theta(w)||p(w)). \quad (5)$$

接下来, 更新 $q_\theta(w)$, 并从更新后的 $q_\theta(w)$ 中抽取一个新样本 \hat{w} . 通过重复这样做, 最终收敛到一个最接近真实后验分布 $p(w|X, Y)$ 的 θ .

在神经网络中, 将 q 定义为跨所有层 $[i = 1, 2, \dots, N]$ 的权重矩阵 W_i 的因子分解, 如下所示:

$$q_\theta(w) = \prod_i q_{M_i}(W_i). \quad (6)$$

其中每个 W_i 的 q 定义为平均权重矩阵 $M_i (M_i =$

$\text{mean}(W_i))$ 与每个持有伯努利变量的 q 的对角矩阵的乘积, 表示为

$$q_{M_i}(W_i) = M_i \cdot \text{diag}([Z_{i,j}]), \quad (7)$$

$$Z_{i,j} \sim \text{Bernoulli}(p_i), \quad (8)$$

$$W_{i,j} \sim q_{M_i}(W_i). \quad (9)$$

如式(8)所示, 从伯努利分布中抽样对角线元素 Z 与随机将神经网络的相应单元设置为零是相同的. 因此, Monte Carlo dropout可以用来逼近深度神经网络中的贝叶斯推理.

2 随机梯度优化

变分推理的目标是用更简单的分布 $q_\theta(w)$ 来近似复杂分布 $p(w|D)$. 这是通过调整 $q_\theta(w)$ 的参数 θ 以最大化函数 $L(\theta)$ 来完成的, 通常由KL散度给出, 如下所示:

$$\begin{aligned} \text{KL}(q_\theta(w)||p(w|D)) &= \\ &= \int q_\theta(w) \log \frac{q_\theta(w)}{p(w|D)} dw = \\ &= \log p(D) + \int q_\theta(w) \log \frac{q_\theta(w)}{p(w)p(D|w)} dw = \\ &= \log p(D) - L(\theta). \end{aligned} \quad (10)$$

其中

$$L(\theta) \triangleq \int q_\theta(w) \log \frac{p(w)p(D|w)}{q_\theta(w)} dw. \quad (11)$$

最小化式(10)通常通过解析计算导数, 将它们设置为零, 求解一组耦合的非线性方程, 并推导迭代坐标下降算法来完成. 然而, 这种方法只适用于共轭分布, 不适用于高度结构化的分布(例如由概率程序表示的分布), 这些分布在分析上是不可处理的.

解决这个问题的一个方法是在 $L(\theta)$ 上的随机梯度下降^[18]. 根据下列公式估计梯度:

$$-\nabla_\theta L(\theta) = \int \nabla_\theta \left(q_\theta(w) \log \frac{q_\theta(w)}{p(w)p(D|w)} \right) dw = \quad (12)$$

$$\int \nabla_\theta q_\theta(w) \log \frac{q_\theta(w)}{p(w)p(D|w)} dw + \int q_\theta(w) (\nabla_\theta \log q_\theta(w)) dw = \quad (13)$$

$$\int \nabla_\theta q_\theta(w) \left(\log \left(\frac{q_\theta(w)}{p(w)p(D|w)} \right) \right) dw = \quad (14)$$

$$\int q_\theta(w) \nabla_\theta (\log q_\theta(w)) \cdot \left(\log \left(\frac{q_\theta(w)}{p(w)p(D|w)} \right) \right) dw = \quad (15)$$

$$\int q_\theta(w) \nabla_\theta (\log q_\theta(w)) \cdot \left(\log \left(\frac{q_\theta(w)}{p(w)p(D|w)} \right) + K \right) dw = \quad (16)$$

$$\frac{1}{N} \sum_{w^j} \nabla_\theta \log q_\theta(w^j) \cdot \left(\log \left(\frac{q_\theta(w^j)}{p(w^j)p(D|w^j)} \right) + K \right). \quad (17)$$

当 $w^j \sim q_\theta(w)$ 时, $j = 1, \dots, N$ 和 K 是任意常数. 为了得到方程(14)~(16), 反复使用如下公式:

$$\nabla \log q_\theta(w) = \frac{\nabla_\theta q_\theta(w)}{q_\theta(w)}. \quad (18)$$

此外, 对于等式(14)和(16), 使用如下公式:

$$\int q_\theta(w) \nabla \log q_\theta(w) dw = \int \nabla_\theta q_\theta(w) dw = \nabla_\theta \int q_\theta(w) dw = \nabla_\theta 1 = 0. \quad (19)$$

添加常数 K 的目的是近似估计(最佳基线) K 的值, 使得式(16)的蒙特卡罗估计(17)的方差最小化.

3 随机变分推理贝叶斯神经网络故障诊断模型

3.1 网络结构

在贝叶斯神经网络中, 由于使用高斯分布为每个权重参数做先验概率分布, 传统神经网络中的单点估计扩展成了由均值 μ 和方差 δ^2 共同组成的高斯分布形式. 这种方式的缺点之一就是成倍增长的参数量, 贝叶斯神经网络中的参数可以表示为 $\theta = [\mu, \delta^2]$.

相同结构的贝叶斯神经网络与神经网络相比较, 由于贝叶斯神经网络的网络参数服从高斯分布, 需要同时优化参数分布的均值和方差, 所以贝叶斯神经网络的参数量是神经网络参数量的二倍, 这会增加模型的参数量、运算时间以及运算复杂度. 针对该问题, 使用减少网络隐含层的方式来减少模型的复杂度. 本文选择一层隐含层的简单神经网络结构, 从而达到减少网络参数量, 减少运算时间以及降低模型复杂度的目的. 因此, 本文构建的随机变分推理贝叶斯神经网络为一个输入层以及一个隐含层以及一个输出层的简单结构.

本文的实验数据来自德国帕德伯恩大学的轴承数据集, 该数据集在 64 kHz 的采样频率下采集得到, 采样频率是指对模拟信号进行 A/D 采样时, 每秒钟对信号采样的点数. 采样频率与原始信号频率之间有一定的关系, 根据奈奎斯特理论, 只有采样频率高于原始信号最高频率的两倍时, 才能将数字信号表示的信号还原成为原来的信号. 因此, 信号频率越高, 它对应的采样频率也越高. 采样频率越高, 说明在相同时间内, 采集到的样本点数量越多.

单位时间内采集的数据量越多, 意味着出现的特殊情况越多, 也就需要更多的神经元来捕捉这种特殊情况, 除非是数据形态非常固定, 不然数据越多反而影响结果, 出现过拟合现象. 为了解决这一问题, 本文增加了隐藏层神经元的个数, 以提取更多的故障特征, 降低因采样频率过高而对结果造成的影响. 而对于低频信号, 相对来说它单位时间内采样点会少很多, 因此所需隐藏层的神经元会少很多.

最终, 本文构建的贝叶斯神经网络模型是一个输

入层为 1200 个神经元, 隐藏层为 10000 个神经元, 输出层为 3 个神经元的结构, 如图 1 所示.

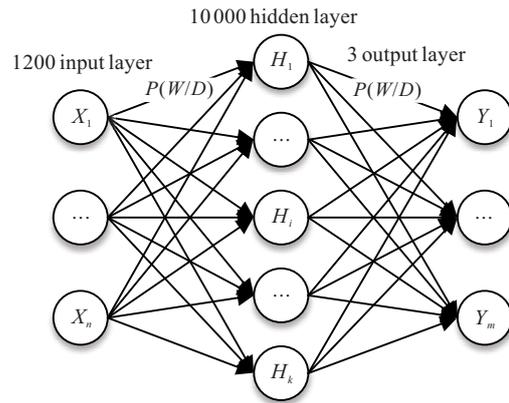


图 1 贝叶斯神经网络结构

3.2 随机变分推理优化函数

通过优化 ELBO 来使近似分布和真实分布的 KL 散度最小, 从而使它们更接近. 但是在编程中, 大多数用户不会直接与这个基类 ELBO 交互, 而是创建派生类的实例. 本文选择了 TraceGraph ELBO 和 Trace ELBO 函数来进行实验, 通过实验结果来比较两个函数对模型的影响.

1) Trace ELBO: 基于 ELBO 的 SVI (随机变分推理) 的跟踪实现是按照文献 [18] 和文献 [19] 构造的估计量, 对模型的依赖结构没有任何限制. 梯度估计包含部分 Rao-Blackwellization 以减小估计量的方差, Rao-Blackwellization 的详细介绍参见文献 [19]. Rao-Blackwellization 是局部的, 因为它只使用由上下文标记的条件独立信息.

2) TraceGraph ELBO: 基于 ELBO 的 SVI 的 TraceGraph 实现, 有更细粒度的 Rao-Blackwellization. 梯度估计器是按照专门针对 ELBO 情况的参考文献 [20] 构造的, 它支持模型和指南的任意依赖结构. 在可能的情况下, 使用记录中的条件依赖性信息来减少梯度估计器的方差.

3.3 基于随机变分推理贝叶斯神经网络的构建

对于未知的事物, 贝叶斯方法假设一个先验知识, 并且通过采样等方法修改先验知识, 逐渐地逼近真实的后验概率分布, 算法流程如图 2 所示, 具体步骤如下.

step 1: 准备数据集, 为每类故障数据标记相应的标签.

step 2: 根据划分好的故障数据集定义网络模型.

step 3: 使用正态分布初始化网络参数.

step 4: 用 p 函数表示数据的真实分布, q 函数表示数据的近似分布, 即 p 的近似分布. 用 p 和 q 的 KL 散度描述两个分布的逼近效果, 由 KL 散度推导出 ELBO.

step 5: 进行变分推理,用随机梯度优化证据下限.

step 6: 调整参数,改变近似分布,使其逼近真实分布,判断两个分布的KL散度,若KL散度没有达到最优,则返回step 5继续执行,直到KL散度最优为止.

step 7: 故障诊断,网络输出为发生每类故障的可能性大小,选择概率最大的一类为所发生的故障.

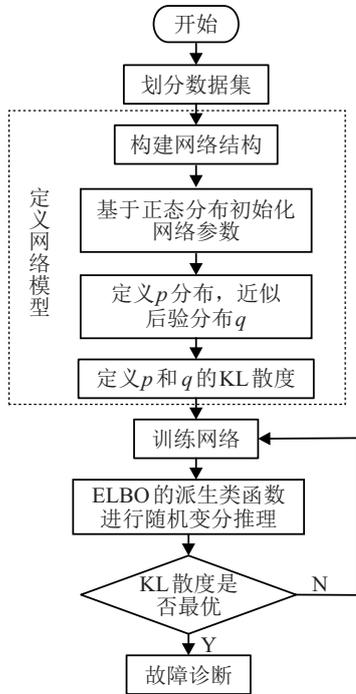


图2 基于随机变分推理贝叶斯神经网络流程

3.4 整体框架

故障诊断方法的框图如图3所示,总体上由数据收集、模型构建和故障诊断3个部分组成. 首先收集数据制作数据集,将数据划分为训练集和测试集. 然后用训练集训练网络,使用随机变分推理构建参数分布,构建贝叶斯神经网络,并按参数优化策略设置相应参数. 最后判断KL散度,若不满足性能要求,则继续训练网络;若满足性能要求,则终止训练,得到诊断模型,使用测试集对模型性能进行测试.

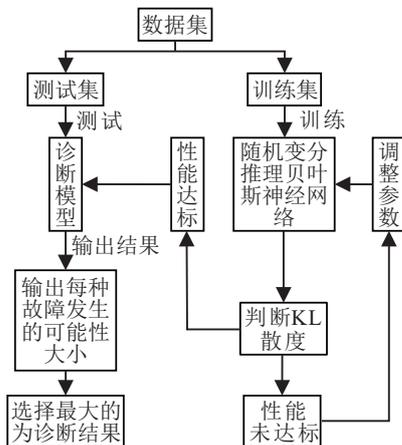


图3 故障诊断框

4 实验结果分析

4.1 数据集

对提出的贝叶斯神经网络模型故障诊断方法进行分析,实验数据来自德国帕德伯恩大学提出的用于滚动轴承状态监测的基准数据集. 试验台由5个模块组成:电机、扭矩测量轴、滚动轴承测试模块、飞轮和负载电机,见图4. 将不同损伤类型的轴承安装在轴承测试模块中,以生成实验数据.



图4 模块化试验台

实验数据集在 64 kHz 采样频率下采集得到,在所有的信号采集实验中,温度保持在 45 °C ~ 50 °C. 通过改变驱动系统的转速测试轴承上的径向力以及驱动系统上的负载转矩,得到包含 4 种不同工况下的数据集,4 种工况的运行条件如表 1 所示.

表 1 4 种工况的运行参数

	转速 / rpm	负载转矩 / N · m	径向力 / N
0	1 500	0.7	1 000
1	900	0.7	1 000
2	1 500	0.1	1 000
3	1 500	0.7	400

本文采用工况 1 下(转速为 900 rpm, 负载转矩为 0.7 N · m, 径向力为 1 000 N)的数据. 选中数据集中的一部分进行训练和测试,在数据集中有人为损伤和真实损伤(加速寿命的实验所产生). 实验采用真实损伤情况下的数据,包括 2 种故障类型和 1 种正常类型. 其中:外圈的损伤包括点蚀单一损伤 1 级 KA04、点蚀重复损伤 2 级 KA16、点蚀单一损伤 1 级 KA22;内圈的损伤包括点蚀重复损伤 1 级 KI17、点蚀单一损伤 2 级 KI18、点蚀单一损伤 1 级 KI21;正常情况 K003.

不对数据作处理,直接使用原始数据对网络性能进行测试. 在进行网络训练前,通过窗口切割将轴承信号分割为每个数据段作为样本. 本文采用无重叠的形式分割样本,如图 5 所示. 无重叠的分割方式保证了数据间的无重复性,并且采用无重叠分割的方法可以避免样本间的相关性.

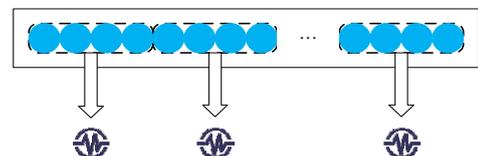


图5 无重叠数据分割示意图

每1200个采样点无重叠分割后,每种类型各得到2133组样本,共6399组样本.使用最简单的随机拆分方法划分训练集和测试集,拆为80%训练集和20%测试集.首先使用训练集训练,然后使用测试集测试模型效果.

4.2 不同ELBO函数对诊断结果的影响

选择ELBO函数的派生类实例Trace ELBO和TraceGraph ELBO,分别进行贝叶斯神经网络中的随机变分推理.为了确保实验的准确性,分别对Trace ELBO和TraceGraph ELBO进行10次实验,并求取其诊断结果的平均值. BNN的超参数batch size = 1500, lr = 0.05. 诊断结果如表2所示,可以看出,在贝叶斯神经网络中使用TraceGraph ELBO所得的诊断结果要高于Trace ELBO. 这是因为TraceGraph ELBO中,记录的有条件依赖性信息可以用于减小梯度估计器的方差,还有更细粒度的Rao-Blackwellization. 因此,在贝叶斯神经网络中,使用TraceGraph ELBO作随机变分推理所得网络的诊断效果更好.

表2 不同派生类函数的准确性

	Trace	TraceGraph
accuracy	0.98	0.99

4.3 不同诊断方法对比

为了验证本文方法的轴承故障诊断效果,将此方法与现有其他轴承故障诊断方法比较. 本文选择CNN、LSTM、SAE作为对比模型进行实验,3个模型采用与BNN相同的数据集. SAE(stacked auto encoder)由3个自编码器堆叠而成,其中间层的神经元数量分别为800、200、50. SAE的超参数lr = 0.005, batch size = 128. LSTM的输入维度为(128, 1200, 1),得到(128, 1200, 32)的时序特征,经过压平,输入到全连接层,得到(128, 32)特征,最后经过softmax和全连接层得到分类结果. LSTM的超参数lr = 0.01, batch size = 256. CNN模型输入(128, 1200, 1)维数据到两层1D-CNN中,经过softmax激活函数和池化,得到(128, 38, 16)特征,再通过平铺、drop操作和全连接层得到分类结果. CNN的超参数lr = 0.01, batch size = 128. 诊断结果如图6所示.

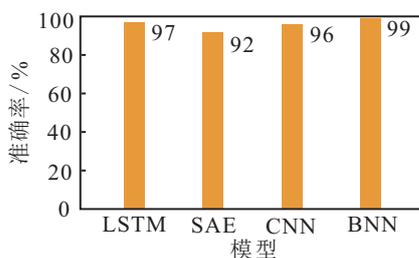


图6 不同模型故障诊断精度

从图6可以看出,与其他3种模型相比,使用贝叶斯神经网络的诊断效果有一定的改善,在故障诊断领域有一定的优势. 说明贝叶斯神经网络模型可以从原始信号中提取高效的故障判别特征,使用随机变分推理的方法使其可以从数据中学习有效的模型.

4.4 不同样本数量下的诊断结果对比

为了验证本文提出的BNN模型在数据量较少的情况下仍能获得较高的诊断精度,分别取原来样本数量的50%、60%、70%进行实验. 对BNN、CNN、SAE与LSTM在不同样本数量下进行实验,模型参数保持不变,诊断结果如表3所示.

表3 数据量较少情况下的诊断结果

	BNN	LSTM	CNN	SAE
50%	0.94	0.92	0.90	0.88
60%	0.96	0.94	0.91	0.90
70%	0.97	0.95	0.93	0.91

表3中的数据代表诊断准确率. 从表3可以看出,在分别取原样本数量的50%、60%及70%的情况下,本文所提出BNN模型仍能得到较高的诊断精度,且高于CNN、SAE以及LSTM. 通过实验说明,在数据量较少的情况下,本文所提BNN模型,仍能达到较高的诊断准确率,且高于其他网络,可见随机变分推理的方法可以学习到更有效的网络模型.

为了更加精确地表示所提网络的诊断性能,在给出诊断准确率的基础上,给出均方误差(MSE)如表4所示. MSE是指参数估计值与参数真实值之差平方的期望值, MSE的值越小,说明预测模型描述实验数据具有越好的精确度. 从表4可以看出,在数据量较少时, BNN模型的MSE值均小于其他模型. 说明当数据量较少时, BNN模型更能拟合训练数据.

表4 数据量较少情况下各模型的MSE

	BNN	LSTM	CNN	SAE
50%	0.806	0.954	1.015	1.243
60%	0.664	0.811	0.967	1.026
70%	0.602	0.723	0.893	0.963

5 结论

本文针对深度学习在故障样本数量较少情况下,存在过拟合现象,导致模型泛化能力差、诊断精度不高的问题,提出基于随机变分推理的贝叶斯神经网络故障诊断方法. 用德国帕德伯恩轴承数据集对所提方法进行了验证,并与其他方法进行了对比.

1) 通过引入与条件概率分布相关的权值,以及使用随机变分推理的方法,使贝叶斯神经网络可以在数据量较少的情况下学习,并根据后验分布进行分类决策,从而得到较高的诊断结果,可以有效解决故障样

本较少情况下诊断精度不高的问题. 在不同故障样本数据量下, 与CNN、LSTM、SAE模型进行对比实验, 本文模型的诊断精度、MSE均优于这三种方法. 说明所提出的基于随机变分推理贝叶斯神经网络模型可以从原始信号中提取高效的判别特征, 在数据量较少情况下, 更能拟合训练数据, 得到较高诊断精度.

2) 加入随机梯度优化方法, 解决了变分推理难以处理程序中概率分布的问题. 用ELBO的派生类函数TraceGraph ELBO作随机变分推理, 所得的诊断结果要高于派生类函数Trace ELBO. 说明在贝叶斯神经网络中, 使用TraceGraph ELBO作随机变分推理所得网络的诊断效果更好.

参考文献(References)

- [1] 陈雪峰, 李继猛, 程航, 等. 风力发电机状态监测和故障诊断技术的研究与进展[J]. 机械工程学报, 2011, 47(9): 45-52.
(Chen X F, Li J M, Cheng H, et al. Research and application of condition monitoring and fault diagnosis technology in wind turbines[J]. Journal of Mechanical Engineering, 2011, 47(9): 45-52.)
- [2] Popa L M, Jensen B B, Ritchie E, et al. Condition monitoring of wind generators[C]. The 38th IAS Annual Meeting on Conference Record of the Industry Applications Conference. Salt Lake City, 2003: 1839-1846.
- [3] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. 仪器仪表学报, 2018, 39(7): 134-143.
(Qu J L, Yu L, Yuan T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network[J]. Chinese Journal of Scientific Instrument, 2018, 39(7): 134-143.)
- [4] 咎涛, 王辉, 刘智豪, 等. 基于多输入层卷积神经网络的滚动轴承故障诊断模型[J]. 振动与冲击, 2020, 39(12): 142-149.
(Zan T, Wang H, Liu Z H, et al. A fault diagnosis model for rolling bearings based on a multi-input layer convolutional neural network[J]. Journal of Vibration and Shock, 2020, 39(12): 142-149.)
- [5] Chen Z Y, Mauricio A, Li W H, et al. A deep learning method for bearing fault diagnosis based on cyclic spectral coherence and convolutional neural networks[J]. Mechanical Systems and Signal Processing, 2020, 140: 106683.
- [6] Eren L. Bearing fault detection by one-dimensional convolutional neural networks[J]. Mathematical Problems in Engineering, 2017, 2017: 8617315.
- [7] Wang J Y, Mo Z L, Zhang H, et al. A deep learning method for bearing fault diagnosis based on time-frequency image[J]. IEEE Access, 2019, 7: 42373-42383.
- [8] Hoang D T, Kang H J. A motor current signal-based bearing fault diagnosis using deep learning and information fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(6): 3325-3333.
- [9] Han S, Jeong J. An weighted CNN ensemble model with small amount of data for bearing fault diagnosis[J]. Procedia Computer Science, 2020, 175: 88-95.
- [10] Wang X, Mao D X, Li X D. Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network[J]. Measurement, 2021, 173: 108518.
- [11] Wang S H, Xiang J W, Zhong Y T, et al. Convolutional neural network-based hidden Markov models for rolling element bearing fault identification[J]. Knowledge-Based Systems, 2018, 144: 65-76.
- [12] 王新琪. 基于宽度贝叶斯神经网络的分类方法研究[D]. 大连: 大连理工大学控制科学与控制工程学院, 2019.
(Wang X Q. Classification methods based on broad Bayesian neural networks[D]. Dalian: School of Control Science and Control Engineering, Dalian University of Technology, 2019.)
- [13] Neal R M. Monte Carlo implementation of Gaussian process models for Bayesian regression and classification[R]. Toronto: University of Toronto, 1997.
- [14] Gal Y, Ghahramani Z. Dropout as a Bayesian approximation: Representing model uncertainty in deep learning[C]. International Conference on Machine Learning. PMLR, 2016: 1050-1059.
- [15] Graves A. Practical variational inference for neural networks[C]. Advances in neural information processing systems. Granada, 2011: 2348-2356.
- [16] Fortunato M, Blundell C, Vinyals O. Bayesian recurrent neural networks[J/OL]. 2017, arXiv: 1704.02798.
- [17] Zhang X G, Mahadevan S. Bayesian neural networks for flight trajectory prediction and safety assessment[J]. Decision Support Systems, 2020, 131: 113246.
- [18] Wingate D, Weber T. Automated variational inference in probabilistic programming[J/OL]. 2013, arXiv: 1301.1299.
- [19] Ranganath R, Gerrish S, Blei D M. Black box variational inference[J]. Journal of Machine Learning Research, 2014, 33: 814-822.
- [20] Schulman J, Heess N, Weber T, et al. Gradient estimation using stochastic computation graphs[J/OL]. 2015, arXiv: 1506.05254.

作者简介

王进花(1979—), 女, 副教授, 博士, 从事智能信息处理、多源信息融合等研究, E-mail: wjh0615@lut.edu.cn;

岳亮辉(1994—), 男, 硕士生, 从事故障诊断、信息融合的研究, E-mail: 739698482@qq.com;

曹洁(1966—), 女, 教授, 博士生导师, 从事信息融合理论及应用、智能信息处理等研究, E-mail: caoj@lut.edu.cn;

马佳林(1995—), 男, 硕士生, 从事故障诊断、强化学习的研究, E-mail: jialinm@lut.edu.cn.