

DOI:10.3969/j.issn.1001-4551.2021.03.010

基于注意力机-多任务网络的液压系统多 状态监测识别方法研究*

黄鹏程,李海艳*,林景亮,梁桂铭
(广东工业大学 机电工程学院,广东 广州 510006)

摘要:针对在复杂的多状态条件下,液压系统状态监测方法监测性能不高的问题,对多任务学习和注意力机制方法进行了研究,结合多任务与注意力机制,提出了一种基于注意力机多任务网络的液压系统监测方法。首先,利用注意力机制,根据不同传感器信号对任务贡献程度的大小,赋予了各个传感器不同的权重;其次,使用卷积网络(CNN)构建了自适应特征提取器,从赋予权重的多个传感器信号中提取了深度特征;最后,建立了多任务的特征共享诊断网络,实现了对液压系统多个状态的同时监测。研究结果表明:与以往的方法相比,所提出的方法监测性能更优,能更有效地对复杂的多状态条件下的液压系统的各种状态进行监测,且其平均精度达到 99.3%。

关键词:液压系统多状态监测;监测性能;注意力机;多任务网络

中图分类号:TH137

文献标识码:A

文章编号:1001-4551(2021)03-0331-06

State monitoring method of hydraulic system based on attention machine multi-task network

HUANG Peng-cheng, LI Hai-yan, LIN Jing-liang, LIANG Gui-ming

(School of Mechanical and Electrical Engineering, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: Aiming at the poor monitoring performance of the current hydraulic system state monitoring methods under complex multi-state conditions, the multi-task learning and attention mechanism methods were studied. Combining with the multi-task and attention mechanism, a multi-task network-based monitoring method for hydraulic system was proposed. Firstly, the attention mechanism was used to assign different weights to each sensor according to the degree of contribution of the sensor signals to the task. Secondly, a convolutional network (CNN) was used to construct an adaptive feature extractor to extract depth features from multiple sensor signals with weights. Finally, a multi-task feature sharing diagnostic network was established to realize simultaneous monitoring of multiple states. The results indicate that the proposed method is superior to the previous method, and can effectively monitor the various states of the hydraulic system, with an average accuracy of 99.3%.

Key words: state monitoring of hydraulic system; monitoring performance; attention machine; multi-tasking network

0 引言

液压系统作为重要的传动系统,被广泛应用于工业领域^[1,2]。因此,确保液压系统安全有效的运行非

常重要,准确地估计液压系统状况可以避免突发状况,降低维护的成本。为了确保整个液压系统的正常运行,一种可靠、准确的液压系统状态监测方法是必不可少的。

目前,已有的液压系统状态检测方法主要都是

收稿日期:2020-07-31

基金项目:国家自然科学基金资助项目(5177050476)

作者简介:黄鹏程(1994-),男,广东梅州人,硕士研究生,主要从事机械状态检测及故障诊断方面的研究。E-mail: 895399270@qq.com

通信联系人:李海艳,女,副教授,硕士生导师。E-mail: Cathlyhy@gdut.edu.cn

基于传统的机器学习的单一状态监测。HELWIG N 等人^[3]先通过皮尔逊相关系数方法从原始传感器数据中提取特征,然后利用线性判别分析(LDA)将这些特征值转移到一个较低维的判别空间,从而对故障状态和严重程度进行了分类。考虑到使用单一分类器有时无法获得较高精度的缺点,GUO P 等人^[4]提出了一种基于集成支持向量机的液压系统健康状态监测方法,该方法先从多传感器信号中提取统计特征来描述液压系统的健康状态特征;然后,利用皮尔逊相关系数对提取的特征进行了选择;最后,利用集成支持向量机和叠加方法实现了系统的健康状态识别。随着神经网络的发展,姜保军等人^[5]把自编码器应用于液压系统监测,他们先用希尔伯特-黄和小波变化对传感器信号进行了特征提取,然后利用堆栈稀疏自编码器来预测液压泵的状态。

虽然上述方法取得了一定效果,但同时存在以下不足:

(1) 这些传统方法往往需要丰富的液压系统知识经验来选择特征提取和分类的方法。然而,液压系统在复杂的环境下工作,很难通过知识经验选取特征提取和分类方法;

(2) 对单一状态进行监测,分离了各个状态之间的相关性,丢失了各种状态之间潜在的相关特征^[6]。对于液压系统中复杂的任务,其泛化力差;

(3) 在实际操作中,每个任务对各个传感器信号会有不同的依赖程度,而多个传感器信号笼统地直接输入,使得网络无法获取更为重要的信息,易出现网络信息过载的问题,降低了准确性。

针对以上方法存在的问题,本文结合注意力机和多任务学习,提出一种基于注意力机的多任务网络的液压系统多状态监测方法,利用卷积网络(CNN)自动地从多个原始传感器信号中提取深度特征,并在网络中加入注意力机,然后建立多任务的特征共享诊断网络,实现对多个状态的同时监测,利用各状态之间的相关性,提取更泛化的特征,提高任务准确性。

1 理论基础

1.1 卷积神经网络

卷积神经网络是一种典型的前馈神经网络,主要是由输入层、卷积层、池化层、全连接层和输出层组成。通过对输入层进行逐层卷积和池化,层层提取输入数

据的特征,随着层数的加深,不断提取更加抽象的特征,最终得到具有平移旋转不变性的鲁棒特征。因其具有强大的非线性映射能力,近年来在图像识别^[7]、语言识别^[8]等方面被广泛应用。

此处由于输入的特征是多变量时间序列,笔者使用一维卷积^[9-11]构建网络。

卷积层通过用多个卷积核对前一层输出特征进行卷积操作,然后利用非线性激活函数构造出新的特征,其数学公式为:

$$X_j^l = f\left(\sum_{i \in M_j} X_i^{l-1} \cdot w_{ij}^l + b_j^l\right) \quad (1)$$

式中: M_j —第 $l-1$ 层第 j 个卷积区域; w —卷积核的权重; b —网络偏置; X_j^l —第 l 层输出; X_i^{l-1} —上一层的输入; $f(\cdot)$ — $Relu$ 非线性激活函数。

池化层也叫下采样层,对上一层的卷积特征进行缩放映射,保留主要特征的同时减少参数和计算量,防止过拟合,提高模型泛化能力。

常采用的是最大池化,即取局部的最大值,其数学公式为:

$$X_{m,n}^d = \max_{i \in R_{m,n}^d} (x_i) \quad (2)$$

式中: x_i —区域 $R_{m,n}^d$ 内神经元激活后的值。

全连接层将前面卷积池化得到的高维数据铺平以作为输入,进行一些非线性变换,然后将结果输入到它后面的输出层 $softmax$ 函数。全连接层数学表达式为:

$$y^l = g(w^l x^{l-1} + b^l) \quad (3)$$

式中: l —网络层的序号; y^l —全连接层的输出; x^{l-1} —平铺后的一维特征向量; w^l —权重系数; $g(\cdot)$ — $softmax$ 非线性激活函数。

$Softmax$ 函数,将输出各值化作(0,1)之间,以用于分类。其数学公式为:

$$\sigma(z_j) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (4)$$

式中: j —输出层第 j 个特征; K —输出层特征总数。

1.2 注意力机制

2014 年谷歌 DeepMind^[12]提出了注意力机(Attention),并将其应用于图像识别领域,解决了图片处理时计算量巨大的问题。同年,BENGIO Y^[13]把注意力机应用于机器翻译,解决了机器翻译中不同长度的源语言对齐问题。

上述两个注意力机应用均取得了不错的效果,随后注意力机在深度学习任务中蓬勃发展。深度学习中的注意力机从本质上讲是和人类视觉机制类似,核心

任务都是用来捕获当前目标更为关键的信息,而忽视无关信息。

采用注意力机通常有两个目的:(1)降低数据的维度,减少计算量;(2)选择输入数据中与当前输出更加相关的有用信息,提高输出的质量。

常用的注意力机分为软注意力和硬注意力。其中,软注意力更关注区域或者通道,且因为注意力是确定性的,其可微分,可以通过反向传播来学习它的参数;而硬注意力更加关注点,且注意力是一个随机预测过程,动态变化,导致了其不可微分。

由于软注意力是可微分的,可以利用反向传播进行训练,求它的参数,并方便地嵌入网络框架中,比较常用。因此,本文选择了软注意力机,其数学公式为:

$$\alpha_i = p(z = i | X, q) = \text{softmax}(s(x_i, q)) = \frac{\exp(s(x_i, q))}{\sum_{j=1}^N \exp(s(x_j, q))} \quad (5)$$

式中: α_i —注意力分布; $s(x_i, q)$ —注意力打分模型; q —和任务相关的查询向量; $X = [x_1, \dots, x_N]$ — N 组输入信息; x_i —第 i 个向量。

通常,打分模型 $s(x_i, q)$ 针对每个 x_i 计算出一个 s 。而打分的依据就是 x_i 与注意力机所关注的对象的相关程度;它们越相关,所得元素分数值越大。利用 softmax 对上面的得分进行数值转换,一方面进行归一化,使得所有分数之和为1;另一方面也可以更加突出重要元素的权重。

本文注意力机模型如图1所示。




图1 注意力机模型

图1中,用一个全连接层作为 $s(x_i, q)$ 函数,来学习不同传感器特征与任务的相关程度,其中神经元数

为传感器个数。

2 注意力机多任务网络

本文的研究对象是液压系统的冷却器、阀门、内部泵及液压蓄能器状态,具有4个状态监测的任务。因此,本文使用多任务学习的方式来构建网络。

多任务学习可以提取多个任务的共享特征,共享特征具有较强的抽象能力,可以适应多个不同但相关的任务,通常可以使网络获得更好的泛化力;且由于输入的是多个传感器信号,考虑到实际任务会对各个传感器信号有不同的依赖程度,笔者使用注意力机来赋予各传感器不同的关注程度,让网络关注更加有用的传感器信息,以减低对其他信息的关注度,提高网络的监测效率。

结合注意力机与多任务网络,笔者构建注意力机多任务网络,如图2所示。

图2中,网络由输入层、注意力层、特征提取层、多任务层构成。其总体状态监测步骤如下:

(1)对多个传感器数据进行归一化处理,构建输入特征矩阵 χ ;

(2)输入特征 χ 输入到注意力层,通过将注意力模型得到的特征权重 α 与输入特征 χ 做矩阵乘法,得到注意力特征 χ_{att} ;

(3)注意力特征 χ_{att} 共享层,使用多个卷积层来提取4个任务的共享特征;

(4)共享特征输入到任务层,共有4个任务,其损失函数为各个任务损失函数的线性加权,即联合损失函数,其数学表达式为:

$$L = \lambda_1 L_1 + \lambda_2 L_2 + \lambda_3 L_3 + \lambda_4 L_4 \quad (6)$$

式中: L_1 —冷却器状态; L_2 —阀门状态; L_3 —内部泵状态; L_4 —液压蓄能器状态; $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ —对应任务的权重,文中均取0.25。

而 L_i 损失函数为交叉熵损失函数,其表达式为:

$$L_i = -\frac{1}{N} \left[\sum_{n=1}^N \sum_{k=1}^K 1\{y^n = k\} \log(\hat{y}_k^n) \right] \quad (7)$$

式中: N —样本数; K —样本类别数; y^n —第 n 个样本真实类别; $\hat{y}_k^n$ —第 n 个样本对应的第 k 个输出神经元的激活值; $1\{*\}$ —指示性函数;

(5)采用反向传播算法^[14]对网络参数进行更新。




图2 注意力多任务网络

本文利用深度学习框架 pytorch 构建模型,训练优化器为 Adam,批量为 32,学习率初始设置为 0.001,迭代次数为 550。

网络结构参数如表 1 所示。

表1 网络结构参数

层名	参数	特征维度
Input		(60,17)
Attention	(17,1)	(60,17)
Conv1d	(17,50,10)	(50,51)
Conv1d	(50,50,10)	(50,42)
Maxpooling	(2,2)	(50,21)
Conv1d	(50,100,10)	(100,12)
Conv1d	(100,100,10)	(100,3)
Avgpooling	(3,3)	(100,1)
FC_S	(100,100)	(100,1)
FC1	(100,3)	(3,1)
FC2	(100,4)	(4,1)
FC3	(100,3)	(3,1)
FC4	(100,4)	(4,1)

表1中,根据一维卷积参考文献的网络结构,适当调整参数大小,构建网络共享层,并在共享层前面加入注意力模型,其参数为输入传感器的个数;在共享层后面加入多任务模型,其参数为各任务状态个数,构成整体网络结构。

3 实验与分析

3.1 数据描述

此处采用 UCI 网站中的液压系统状态监测数据^[15]进行实验,实验数据通过一个液压实验台获得。该试验台以 60 s 为 1 周期进行恒定负载循环,通过测量压力、流量等 17 个传感器的值,来监测 4 个液压组件(冷却器、阀门、泵和蓄能器)的状态定量变化;共有 2 205 组模拟数据,每个组包含了 17 个传感器数据和 4 个组件的运行状况。

液压试验台使用的传感器如表 2 所示。

表2 液压试验台使用的传感器

传感器	物理量	单位	采样频率/Hz
PS1-PS6	压力	bar	100
EPS1	电机功率	W	100
FS1,FS2	体积流量	l/min	10
TS1-TS4	温度	℃	1
VS1	振动	mm/s	1
CE	冷却效率(虚拟)	%	1
CP	冷却功率(虚拟)	kW	1
SE	效率系数	%	1

表2中,CE、CP 和 SE 是表示计算值的虚拟传感器,其余传感器是液压回路中的物理传感器。

液压组件状态变量如表 3 所示。

表3 液压组件状态变量

组件	变量(单位)	值	状态
冷却器	%	10 020	全效率
		3	效率不足
			故障
阀门	%	100	最佳的切换行为
		90	小滞后
		80	重度滞后
		73	接近完全失效
内部泵	\	0	无泄漏
		1	弱泄漏
		2	严重泄漏
液压蓄能器	Pa	130	最佳压力
		115	压力偏低
		100	压力过低
		90	故障

表3中给出了4个液压组件所存在各种的状态。

其中,冷却器与内部泵存在3种状态,阀门与液压蓄能器存在4种状态。

3.2 数据处理

由于传感器采样频率不一样,导致相同周期内不同传感器时序点个数不同,如压力传感器100 Hz,60 s内有6 000个时序点,而温度传感器1 Hz,60 s内只有60个时序点,为了输入到网络中,需要对数据进行简单的平均处理,使得每个传感器时序点数均为60。

处理后得到输入特征图如图3所示。




图3 输入特征图

图3中,输入特征图是由17个传感器堆叠构成的特征图,其维度为(17,60)。其中,行是每个传感器时序点数,列是传感器数。

将2205组数据样本按照6:2:2比例,划分为训练集、验证集和测试集。在训练集上训练网络内部参数,通过验证集调节网络迭代次数、学习率等超参数,使训练集上得到的网络能在测试集上有更好的效果。

3.3 评价指标

为了量化网络诊断的性能,此处使用指标准确率,其计算公式为:

$$acc(t) = \frac{1}{N} \sum_{n=1}^N l(f(x_n) = y_n) \quad (8)$$

式中: $acc(t)$ —第 t 个任务准确率; N —样本数; $f(x_n)$ —预测值; y_n —真实值; $1\{\ast\}$ —指示性函数。

3.4 实验结果与分析

为验证该方法的监测性能,此处训练集与验证集以交叉验证的方式进行训练,最后在测试集上验证精度;并将其与现有的传统方法LDA、人工神经网络(ANN)、集成SVM进行对比。模型在训练过程中,由于权重的初始化是随机的,为了避免实验结果受到其影响,对训练数据重复做5次实验,然后取平均值。

该方法与传统方法结果比较如表4所示。

表4 与传统方法结果比较 %

组件	LDA	ANN	集成 SVM	注意力机 + 多任务
冷却器	100	100	100	100
阀门	100	100	100	100
内部泵	73.6	80.0	98.6	99.0
液压蓄能器	54.0	50.4	56.1	98.0
平均	81.9	82.6	88.7	99.3

从表4中可以看出:本文提出的注意力多任务方法可以让液压系统状态获得更好的监测效果;它比最新的传统方法平均精度提高了10.6%,特别在液压蓄能器方面的提高了42.9%。

为了验证多任务和注意力机的有效性,此处将该方法与有相同网络层的单任务CNN与多任务CNN进行了比较,其结果比较如表5所示。

表5 与CNN方法结果比较 %

组件	单任务 CNN	多任务 CNN	注意力机 + 多任务
冷却器	100	100	100
阀门	100	100	100
内部泵	99.0	98.0	99.0
液压蓄能器	89.1	97.0	98.0
平均	97.0	98.8	99.3

从表5中可以看出:多任务CNN精度相比单任务平均精度提高1.8%,验证了多任务网络可以通过各个任务之间的相互辅助,有效地提取了各个任务之间潜在的特征,提高了监测的精度;而加入的注意力机,会根据各个传感器对任务的重要程度,给与相关的权重,缓解了网络的信息过载,使得内部泵和液压蓄能器任务精度均提高了1%,进一步提升了网络的监测精度(达到了99.3%)。

各传感器权重分布如图4所示。




图4 各传感器权重分布

从图4可以看出:在没有使用注意力机之前的各个传感器的权重都是相等的,网络对每个传感器的侧

重程度都一样;使用了注意力机之后,各个传感器权重值发生了变化,网络对不同传感器侧重程度不同,有利于提取对网络更有用的传感器信息。

4 结束语

在复杂的多状态条件下,针对液压系统状态监测方法监测性能不高的问题,笔者提出一种基于注意力机的多任务网络的液压系统监测方法。

相比以往的方法,该方法有以下优势:

(1)直接把多传感器信号输入到 CNN,实现了端到端的预测,无需人工提取特征,降低了使用者的操作难度;

(2)利用多任务网络,对多状态同时学习,有利于提取各状态之间存在的潜在特征,可以避免在单状态时,因为过度关注单个状态,而忽视了噪音及泛化性能,使得网络有更好的预测精度;

(3)在网络中加入注意力机,给予了各个传感器一个权重,使得网络可以更多关注于对任务贡献大的输入变量,从而提取更相关的特征,缓解网络信息过载问题,进一步提升网络的预测精度。

但是该方法依然存在不足之处:多任务网络各个任务的权重都是一样的,但是在实验中发现,对于冷却器状态,其收敛的速度快,很快达到了 100%;而对于液压蓄能器状态,其收敛速度慢,精度提升相当慢,所以应该给予各个任务不同的权重比,来帮助网络更快收敛。

所以,笔者下一步的研究重点是设计一个自适应的任务权重选择方法,以提高该方法的运行效率。

参考文献 (References):

- [1] 刘 志,纪爱敏,张 磊,等.剪叉式高空作业平台上车液压系统的稳定性研究[J]. 机电工程,2020,37(6):600-606.
- [2] HIGGS P A, PARKIN R, JACKSON M, et al. A survey on condition monitoring systems in industry[C]. Proceedings of the ASME 7th Biennial Conference on Engineering Systems Design and Analysis. England: ASME, 2004.
- [3] HELWIG N, PIGNANELLI E, SCHÜTZE A. Detecting and compensating sensor faults in a hydraulic condition moni-

ring system[C]. AMA Conferences 2015. Nürnberg: AMA, 2015.

- [4] GUO P, WU J, XU X, et al. Health condition monitoring of hydraulic system based on ensemble support vector machine [C]. 2019 Prognostics and System Health Management Conference. Qingdao: IEEE, 2019.
- [5] 姜保军,王帅杰,董绍江. 基于深度学习的液压监测系统蓄能装置故障诊断[J]. 组合机床与自动化加工技术, 2019(9):89-92.
- [6] 张德明. 连铸机液压系统油液状态监测实例分析[J]. 液压气动与密封,2020(3):74-75.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[J]. **Communications of the ACM**, 2017, 60(6): 84-90.
- [8] SAINATH T N, KINGSBURY B, MOHAMED A R, et al. Improvements to deep convolutional neural networks for LVCSR[C]. 2013 IEEE Workshop on Automatic Speech Recognition and Understanding. Olomouc: IEEE, 2013.
- [9] 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.
- [10] BABU G S, ZHAO P, LI X L. Deep convolutional neural network based regression approach for estimation of remaining useful life[C]. In International Conference on Database Systems for Advance Applications. Online: DASFAA, 2016.
- [11] 杨兰柱,刘文广. 改进的 CNN 网络在轴承故障诊断中的应用[J]. 机电工程技术,2020,49(8):11-13.
- [12] MNIH V, HEES N, GRAVES A. Recurrent models of visual attention[EB/OL]. (2014-06-24)[2020-7-30]. <https://arxiv.org/abs/1406.6247>.
- [13] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate [EB/OL]. (2014-09-01)[2020-7-30]. <https://arxiv.org/abs/1409.0473>.
- [14] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors[J]. **Nature**, 1986, 323(6088): 533-536.
- [15] HELWIG N, PIGNANELLI E, SCHÜTZE A. Condition monitoring of a complex hydraulic system using multivariate statistics [C]. Instrumentation & Measurement Technology Conference. IEEE, 2015.

[编辑:雷 敏]

本文引用格式:

黄鹏程,李海艳,林景亮,等. 基于注意力机-多任务网络的液压系统多状态监测识别方法研究[J]. 机电工程,2021,38(3):331-336.

HUANG Peng-cheng, LI Hai-yan, LIN Jing-liang, et al. State monitoring method of hydraulic system based on attention machine multi-task network[J]. Journal of Mechanical & Electrical Engineering, 2021,38(3):331-336.

《机电工程》杂志:<http://www.meem.com.cn>