

文章编号: 2095-2163(2019)03-0184-04

中图分类号: TP393.06

文献标志码: A

基于神经网络的数据中心故障预测方法的研究

李鹏园¹, 黄进¹, 冯涛²

(1 西南交通大学 电气工程学院, 成都 610031; 2 四川自然资源厅信息中心, 成都 610072)

摘要: 数据中心作为信息化社会的 IT 基础设施, 存储管理大量关键数据, 发挥着越来越重要的作用, 因此如何实现数据中心机房的智能化管理越来越得到业内广泛重视。提出一种基于神经网络的数据中心故障预测方法, 根据已有的机房设备日志数据, 提取出关键的设备性能指标作为训练特征, 输入神经网络训练模型, 得到的模型可以根据所提供的设备数据预测出当前设备运行状态。

关键词: 数据中心; 神经网络; 故障预测; TensorFlow; 机房设备

Research on data center error prediction method based on neural network

LI Pengyuan¹, HUANG Jin¹, FENG Tao²

(1 School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2 Information Center, Department of Natural Resources of Sichuan Province, Chengdu 610072, China)

[Abstract] As the IT infrastructure of the information society, the data center plays an increasingly important role in the storage and management of a large number of key data. Therefore, more and more attention has been paid to realize the intelligent management of the data center in the industry. This paper proposes a method based on neural network to predict the data center error. According to the existing log data of the data center, the key equipment performance indicators are extracted as training characteristics, which will be fed into the neural network for training. The obtained model can predict the current equipment running state according to the provided device data.

[Key words] data center; neural network; error prediction; TensorFlow; computer room equipment

0 引言

随着现代科技的迅猛发展, 为适应数据中心长期稳定运营的实际需要, 实现智能化管理已是大势所趋。以前, 大多是依靠经验丰富的专业运维人员通过计算机自动化来监管机房设备各项指标, 运维人员每天需对设备做出多次重复检查, 这一工作不仅耗时, 而且繁琐。已有研究成果表明, 若能结合深度学习、人工智能技术对数据中心进行智能化管理, 将可有效提高数据中心的智能化运维水平, 而其中涉及的数据中心智能预警的分析设计也就随即成为与智能化管理研究密切相关的基础重要内容。

目前, 国内外已有相当数量的专家学者针对数据中心机房设备故障诊断方面展开了一些研究, 取得了一定进展。这些研究主要是利用机器学习的方法进行故障预测, 而基于深度学习的同类研发技术应用却才是刚刚起步。文献[1]采用 nProbe 工具对数据中心大规模网络进行被动测量, 该方法结合历史数据得到正常连接率、吞吐率、设备响应时间的偏

离度, 能够在一定程度上反映设备的性能好坏, 但是作为评估参数的 TCP flags 在 TCP 连接超时后, 发生 TCP 重传, 从而提高 TCP 连接的比率, 可能会造成评估值增大, 影响性能评估效果, 无法如实反映设备技术性能; 文献[2]主要分析了不同事件与网络设备性能之间的关联, 考虑的影响因素较多, 由于网络设备各个性能指标之间存在着较为复杂的关系, 若仅是考虑某一种因素的作用影响, 并不能科学准确地判断设备性能, 同时还会增加系统复杂度; 利用深度学习神经网络, 通过向神经网络中输入数据, 设置参数进行训练, 可以综合分析设备状态和性能。

1 模型的研究与设计

数据中心机房设备类型众多, 且引发故障的原因也错综复杂。本文选取了较为常见的机房故障类型展开故障预测方法的研究。

深度学习神经网络在分类预测方面表现出较好的性能, 采用 TensorFlow 搭建神经网络模型, 将采集到的机房日志经过数据归一化处理, 提取特征, 送入

基金项目: 四川自然资源厅(原来四川国土厅)国土资源数据中心智能化监管技术研究(KJ-2018-16)项目资助。

作者简介: 李鹏园(1996-), 女, 本科生, 主要研究方向: 深度学习、数据挖掘。

收稿日期: 2019-03-12

神经网络训练模型, 实现利用设备运行日志数据预测出设备可能发生的状态。

1.1 特征数据预处理

服务器、交换机、路由器是数据中心机房的重要基础设施, 而对应设备的性能优劣将直接影响数据中心网络的运行效率。网络设备的性能参数主要包括 CPU 利用率、内存利用率以及设备响应时间等, 这些参数能够反映出网络的运行状态。

因此, 研究在采集机房设备日志数据时, 选取上述能够反映设备性能的关键指标参数, 主要包含: CPU 使用率、内存利用率、设备响应时间、接收 IP 报文速率、设备当前时间, 利用所选取的各项指标数据就可综合评价设备状态。

由于采集到的日志数据存在无效数据以及冗余数据, 因此需要对采集到的原始数据进行预处理加工, 处理流程如图 1 所示。按照采集时样本数据当前对应的设备状态, 分类标注“正常”和“故障”数

据, 得到训练集和测试集数据, 并保存为.csv 格式。



图 1 数据集制作流程

Fig. 1 Data set production process

本文基于四川省自然资源厅数据中心机房设备数据进行测试和验证, 在研究中利用主动轮询的方式, 按照预先选取的性能指标采集数据中心设备性能参数数据。总共整理了 20 000 条样本数据作为数据集。

如前所述, 数据中心机房设备类型众多, 造成机房设备性能故障的原因较为复杂, 这里选取了较为典型的机房设备故障类型作为故障样本数据集数据, 详见表 1。表 1 中包含了设备正常状态下、由于 CPU 利用率过高以及内存利用率过高导致设备出现故障的部分数据。此外, 数据集中还包含了设备响应时间过长、传输报文速率过低等引起的设备故障。

表 1 部分样本数据

Tab.1 Partial sample data

CPU/%	Memory Usage/%	Re message rate/(datagrams/s)	Response time/ms	Device Statement
1.93	60.14	1.56	0.77	normal
2.08	60.46	4.99	0.26	normal
90.44	60.68	3.06	0.11	breakdown
84.20	61.90	5.48	0.13	breakdown
78.91	92.63	1.18	0.76	breakdown

不同的特征往往具有不同的量纲和量纲单位, 这样的情况会影响到数据分析的结果, 为了消除指标之间的量纲影响, 需要再次进行数据标准化处理。在此过程后, 各指标处于同一数量级, 适合进行综合对比评价。研究中, 采用 Z-score 均方差的方法将数据做到归一化处理。研究推得数学公式可表示为:

$$z = \frac{x_i - \mu}{\delta} \tag{1}$$

其中, x_i 表示样本数据; μ 表示总体平均值; δ 表示总体标准差。

归一化处理后的数据符合均值为 0, 方差为 1 的正态分布曲线, 经过归一化处理后的各数据指标处于同一数量级, 适于后续的综合对比评价研究。

1.2 神经网络模型的设计

神经网络在分类预测方面表现出良好的性能, 神经网络模型结构在整体上包含 3 层: 输入层、隐藏层、输出层, 通过全连接的方法, 可将多个隐藏层连

接起来, 从而扩充神经网络模型的深度来解决较为复杂的问题。由于数据中心机房设备性能数据关系复杂, 通常为非线性关系, 本文搭建多层神经网络来进行故障预测。对此可做研究阐述如下。

1.2.1 模型结构

在实验中, 利用 TensorFlow 框架搭建了一个简单的神经网络模型用于故障训练和预测, 模型结构设计如图 2 所示。该结构图中主要包含输入层、输出层、全连接层(隐藏层), 输入层输入数据, 经过全连接层的处理, 从输出层输出分类结果。

该模型的输入层包括 4 部分, 即输入了 4 个特征, 分别是: CPU 利用率 (CPU)、内存利用率 (Memory Usage)、接收报文速率 (Re message rate)、以及设备响应时间 (Response time)。输出层输出 2 种设备状态, 分别是: 设备“故障”或是“正常”, 在实验中, 1 表示设备状态故障, 0 表示设备状态正常。

全连接层的核心操作就是矩阵相乘, 并通过激活函数产生非线性特性, 其输入输出公式为:

$$z = f(W \cdot x + b). \quad (2)$$

其中, x, z 分别为输入输出特征向量; W 为权重矩阵; b 为偏置; $f(\cdot)$ 代表激活函数。在实验中, 设置全连接神经网络共 2 层, 每层的维度分别为 128 和 64。




图 2 神经网络模型结构图

Fig. 2 Structure diagram of neural network model

1.2.2 模型的训练与预测

使用 Softmax 函数作为最终判断设备状态属于哪一种类别的概率计算, 其损失函数为交叉熵, 定义如下:

$$L = - \sum_{j=1}^n \sum_{k=0}^1 p_j(k) \log \hat{p}_j(k), \quad (3)$$

其中, n 表示训练样本个数; $\hat{p}_j(k)$ 表示模型预测样本 j 属于类别 k 的概率; $p_j(k)$ 表示样本 j 的实际概率; 如果样本 j 属于 k , 则取值为 1, 否则为 0。

在训练过程中, 加入正则化项, 尽量防止过拟合现象的发生。对此, 可将公式写作如下形式:

$$L = - \sum_{j=1}^n \sum_{k=0}^1 p_j(k) \log \hat{p}_j(k) + \alpha \| \omega \|^2. \quad (4)$$

1.2.3 评价指标

本次研究是针对数据中心机房故障进行预测, 本质上是对机房设备状态进行分类判断, 属于二分类问题, 因此使用损失变化和分类准确率作为评测指标。在实验中, 利用梯度下降法来最小化损失。

表 2 预测当前设备状态

Tab. 2 Prediction of current device status

样本数据				真实值	预测值
CPU/%	Memory Usage/%	Re message rate/(datagrams/s)	Response time/ms		
98.3	60.3	0.10	0.15	1	1
91.6	61.2	0.08	0.09	1	1
60.1	60.3	0.20	0.13	0	0
0.2	75.6	0.10	0.08	0	0
1.5	61.5	0.15	0.10	0	0

假设设备实际状态标签为 y , 模型输出分类为 \hat{y} , 则准确率取值为:

$$accuracy(y, \hat{y}) = \frac{1}{n} \sum_{i=0}^n (y_i - \hat{y}_i). \quad (5)$$

1.3 实验结果与分析

设置学习率为 0.01, 采用梯度下降法最小化损失, 在实验中一共训练了 1 000 轮。运行后绘制得到的损失曲线图和准确率曲线图分别如图 3、图 4 所示。由图 3 可以看出, 随着迭代次数的增加, 训练出的模型损失曲线呈收敛趋势, 最终在 800 步之后趋于稳定。由图 4 可以看出, 随着迭代次数的增加, 准确率逐渐增加, 最终稳定在 0.99, 输入测试数据, 可以较为准确地预测出数据所对应的设备状态。




图 3 损失曲线图

Fig. 3 Loss curve




图 4 准确率曲线图

Fig. 4 Accuracy curve

输入部分样本数据, 调用模型预测, 预测后的结果数据见表 2。由表 2 可以看到, 基本可以准确预测出当前设备状态。表 2 中, 1 表示设备状态故障, 0 表示设备状态正常。