

深度学习辅助水成膜泡沫灭火剂低温预警

张建成¹, 吴刘锁¹, 张美琪¹, 石泽耀¹, 张放为²

¹北京南瑞怡和环保科技有限公司, 北京

²上海纳米技术及应用国家工程研究中心有限公司, 上海

收稿日期: 2023年11月16日; 录用日期: 2024年1月7日; 发布日期: 2024年1月16日

摘要

为了避免水成膜灭火剂落入过低的储存温度, 需要对其在未来一日内可达到的最低温度做出预报。通过假设下一日最低储存温度与当日相同, 在此基础上再输入两个罐体温度传感器和当地天气预报数据, 引入一个高度简化的三层BP神经网络处理数据以预测下一日最低罐温。实验表明, 以经典的二阶回归算法评判, 引入神经网络显著改善了预测精度; 以python3代码实现模型, 在多种自主可控平台CPU上单线程运行可在10 min内得到预测结果, 表明其具有较高的可移植性和执行效率。

关键词

水成膜泡沫灭火剂, 人工神经网络, 低温, 预警

Deep Learning Assisted Early Warning for Low Temperature of Aqueous Film Forming Fire Extinguishing Agent

Jiancheng Zhang¹, Liusuo Wu¹, Meiqi Zhang¹, Zeyao Shi¹, Fangwei Zhang²

¹Beijing Nari Yihe Environmental Technology Co., Ltd., Beijing

²Shanghai Nanotechnology and Application National Engineering Research Center Co., Ltd., Shanghai

Received: Nov. 16th, 2023; accepted: Jan. 7th, 2024; published: Jan. 16th, 2024

Abstract

In order to prevent the aqueous film forming fire extinguishing agent (AFFF) from falling into low storage temperatures, it is necessary to predict the minimum temperature that they can reach in the next day. By assuming that the lowest storage temperature for the next day is the same as that of the current day, two tank temperature sensors and local weather forecast data are input, and a

highly simplified three-layer BP neural network is introduced to process the data to predict the lowest tank temperature for the next day. Experiments have shown that the introduction of neural networks significantly improves prediction accuracy based on classical second-order regression algorithms; Using Python 3 code to implement the model, single-threaded running on multiple autonomous and controllable CPU platforms can obtain prediction results within 10 minutes, indicating its high portability and execution efficiency.

Keywords

Aqueous Film Forming Fire Extinguishing Agent, Artificial Neural Network, Low Temperature, Early Warning

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

水成膜泡沫灭火剂(AFFF)是一类广泛用于扑灭油脂火灾的泡沫灭火剂[1]。在自动化的灭火系统中,其一般以原液的形式储存于不锈钢罐中,使用先将其与大量水混合,然后鼓入大量空气即可形成能够覆盖油脂表面并隔绝空气的灭火泡沫。水成膜原液就决定了最终灭火泡沫的性能。尚祖政等[2]曾检测国内3家石化企业配备的泡沫原液,发现有部分灭火剂原液在保质期内已经失效,而其他一些原液虽已过保质期但还能保有足够的灭火性能。显然经过长期存放的原液的有效性与其储存状态也有关,袁余斌等人通过实验证明,泡沫原液的储存寿命与储存温度的关系符合阿龙尼乌斯公式,即储存寿命随储存温度成指数下降[3]。根据上述公式,储存温度越低,对应的储存寿命越长,然而水成膜泡沫灭火剂本质是一种高浓度溶胶水溶液,其温度接近凝固点时,容易发生失稳分层或沉降;温度达到凝固点时,将发生相变以致完全失效,即使温度重新回升至凝固点以上也难以复原。实验表明,AFFF灭火剂在不锈钢储罐中随昼夜交替温度周期性变化,一天中最低温度总是出现在夜间或清晨,不利于人工干预,而对于负责在全寿命范围内监控水成膜泡沫灭火剂有效性的系统而言,为了干预过低温,则须自动装定加热时间、功率等参数,不但需要具备持续收集其温度的能力,也需要对接近凝固点的低温状况做出前瞻性估计。

水成膜泡沫灭火剂一般储存在避光的方形不锈钢罐体中,其内部温度跟随附近大气温度变化,而附近大气温度不但受到当地气象条件影响,也与附近的人员、机器的活动有关。为了通过罐体温度传感器数据结合当地天气预报预测可能出现的过低原液温度,就需要建立合适的数学模型,因为上述各种影响因素经常发生变化(例如,因为进入冬天,工作人员关上了附近的窗户等),所以对应的数学模型也必须具备“学习”能力,自动装定模型中各项参数的值。另外考虑到在这样一个旨在预测的系统中,输入系统的数据又庞大而繁杂,为了高效处理数据,可利用人工神经网络(ANN)将其中的有效信息抽离为特征值,并通过多层网络进行数据加工。反向传播神经网络(BP神经网络)是一种常见的预测机器学习模型,它使用梯度下降法调整网络的权重值,对于非线性而连续变化的量具有较好的拟合能力[4]。在本课题中,即实现并调优了一个BP网络以处理由2个传感器和本地天气预报产生的大量数据。本研究建立合适的学习模型并根据数日内实际测温数据优化其参数,在模拟实验中,预测最大偏差为0.99℃。

2. 实验方法

整个实验系统由4个部分组成,包括缩尺寸方形管廊模型、油池火源系统、液氮输送系统和数据采

集系统,如图1所示。

由北京南瑞怡和环保科技有限公司提供水成膜泡沫灭火剂并灌装至容积为10 L的双层不锈钢罐体中作为模拟实验平台。在线监测系统由微控制器(MCU)、本地节点、本地核心节点和云端服务器组成。本地气象预报由上海市气象局网络站点提供。全系统概况如图1所示。

模拟实验收集数据分为两段,每段20个数据,其中第一段对应2022年1月8日至1月27日,第二段对应2022年2月18日至3月9日。用于预测实验的数据也分为两段,每段6个,分别对应1月22日至1月28日和3月4日至3月9日。其他数据点则用于训练模型。

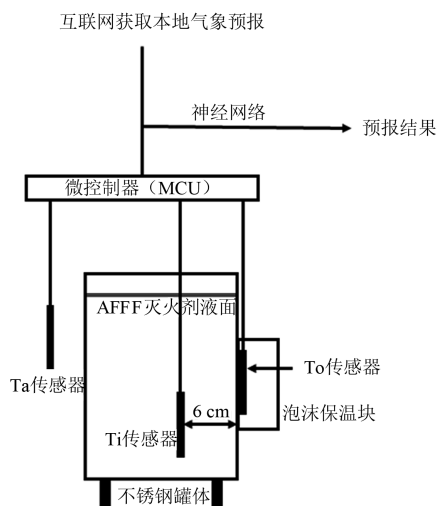


Figure 1. A demonstration of the experiment setup
图 1. 实验装置示意

3. 结果与讨论

在一个位于上海市闵行区的总容积为10 L的模拟不锈钢槽罐内灌满水成膜泡沫灭火剂,并分别在罐体中央、罐体表面和罐体周围空气中设置温度传感器,与微控制器(MCU)、本地服务器和云端服务器相连形成在线监测系统,并由云端负责收集气象数据用于预测罐体最低温度。系统中数据的流动如图1所示,其中罐体内温(Ti)、罐体表面温度(To)和罐体周围空气温度(Ta)的数据收集周期为10分钟,而气象预报今日最低气温(F_{min})和今日最高气温(F_{max})、明日最低气温(F_{next_min})和明日最高气温(F_{next_max})均为每日12时收集一次。在模拟实验中,我们首先连续收集了2021年1月8日至1月27日共20天间的数据,如图1所示。从图中可知在此期间,气象预报曾两度突破 0°C (1月11日和1月13日)接近灭火剂最低储存温度 -3°C ,但代表罐内水成膜泡沫灭火剂原液温度的To和Ti均还保持在 9°C 以上,这就表明周围储存环境对最低温度也具有重要的影响。根据图1中Ta、To和Ti条曲线的波动规律,在每一天温度的周期变化中Ta波动范围最大,Ti波动范围最小,而To曲线夹在两者之间。考虑到不锈钢罐体具有很好的导热性能,可认为罐体本身达到的最低温度就是临近罐壁处的灭火剂原液所承受的最低温度。若我们将3条温度曲线以每日15时为界分割为时间长度24 h的时间片段,可见在任意片段中,To最小值总是低于Ti最小值,即任意一日内临近罐壁处的灭火剂原液达到的最低温度总是低于罐体中部,因此To最小值就可标志罐内灭火剂所达到的最低温度,本研究中我们将其定为模型学习目标。每日To温度水平随气象预报数据波动且具有一定的滞后性,因此除了需要向模型提供下一日的气象预报气温最高值和最低值外,还需提供当日的气象预报高低值。我们将日期分界点定为每日的15时,这是为了保

证当预测模型判断下一日存在 To 过低的可能时, 可以留给工作人员足够的处理时间。

如前所述, Ta 、 To 和 Ti 传感器每日分别产生 144 个温度数据, 需要通过第一层神经网络做“池化”和平均化处理得到其特征值以简化后续学习过程。在模拟实验中我们发现, Ti 传感器受到灭火剂原液腐蚀作用的影响经常损坏, 寿命远低于 Ta 和 To 传感器, 而研究表明, 在一般的 AFFF 灭火剂储存状况下, 当 Ti 值明显偏离 Ta 和 To 时, 可通过 Ta 和 To 序列的线性组合推测得到 Ti 的值。为了节约传感器费用, 我们将 Ti 数据序列从模型中去掉而加入 Ta 和 To 序列在每日最后两个小时中的平均值 Ta_{avg} 和 To_{avg} 用于模拟 Ti 偏离 Ta 和 To 带来的影响。在第一层神经网络中, Ta 和 To 数据序列分别通过“池化”操作取得当日数据的最小值 Ta_{min} 和 To_{min} 。此外, 将每日中 Ta 和 To 序列的初值和终值分别记为 Ta_{start} 、 Ta_{end} 、 To_{start} 和 To_{end} , 也传递至第二层神经网络。第一层神经网络从 Ta 和 To 序列中抽取以上共 8 个特征值, 加上 4 个天气预报数值传递至后两层神经网络。

上述 12 个数值还必须经过进一步处理才适合用于模型优化。以 2022 年 1 月 8 日获得的数据为例, $F_{min} = 276.2 \text{ K}$, $F_{next_min} = 275.2 \text{ K}$, 它们的绝对值较大而使温度的变化不很明显。实验表明, 将形如 276.2 K 这样的绝对温标数据直接输入模型进行机器学习优化的效率非常低下, 模型往往需要上亿次迭代才能达到收敛。一种解决方法是将绝对温标数值相减得到数字小得多的温度差值, 例如将 F_{next_min} 与 F_{min} 相减就得到明日气温相对今日的变化趋势(对于 1 月 8 日, 这个温度差是 -1 K), 将这样的值输入模型就可大幅度提高优化效率。第二层神经网络的核心目标就是将绝对温度数值通过恰当的组合形成温度差值, 使它们的变化幅度更为明显, 利于模型的感知。本层神经网络首先根据 4 个温度预测模式给出 4 种数据组合方式, 然后再加入由实验发现的其他 3 种对改善模型效果明显的温度差值组合, 共 7 个温度差值传递给下一层神经网络。

为了预测明日 To 序列的最低值, 将它的实测值记为 To_{next_min} , 而模型预测值记为 PTo_{next_min} 。不妨首先建立一个极简模型, 即预测明日 To 最低值与今日相同:

$$PTo_{next_min} = Po_{min} \quad (1)$$

我们也将其称为“机械式”预测。为了评价其预测精度, 选择经典的回归算法[5]构建损失函数:

$$L_2 = \frac{1}{2N} \sum (PTo_{next_min} - To_{next_min})^2 \quad (2)$$

其中 N 为参与计算的数据个数。利用 2022 年初收集得到的共 40 天数据($N = 40$)计算得到上述极简模型的损失函数值 $L_2 = 0.245$, 预测最大偏差值为 -1.63°C , 发生于 2022 年 2 月 28 日。我们设想 To 序列的最低值随天气预报的气温最低值改变, 对应的优化权重记为 $W1$:

$$PTo_{next_min} = To_{min} + W1(F_{next_min} - F_{min}) \quad (3)$$

根据(3)式, 若气象局预报今日当地最低气温是 283.2 K , 而明日最低气温上升至 287.2 K , 那么我们预测明日 To 最低值也将上升, 幅度由气温变化值 $+4.0 \text{ K}$ 和权重 $W1$ 的乘积决定, 即 $+4.0 * W1$ 。基于同样的原理, 可以写出其他 3 个预测式, 分别有:

以天气预报气温最高值预测:

$$PTo_{next_min} = To_{min} + W2(F_{next_max} - F_{max}) \quad (4)$$

以 To 序列终温预测:

$$PTo_{next_min} = To_{min} + W3(To_{end} - To_{start}) \quad (5)$$

容易理解, 在此式中 To_{start} 的意义是前一日的 To_{end} 。同样地, 我们也可通过 Ta 序列终温进行预测:

$$PTo_next_min = To_min + W4(Ta_end - Ta_start) \quad (6)$$

在以上 4 个预测模式的基础上, 我们还通过实验发现了其他一些能为模型提供明显改进, 使损失函数 L_2 显著降低的数据差值组合, 分别是当日罐体附近空气的终温与最低温度的差值 $Ta_end - Ta_min$ 、当日最后两小时罐体附近空气温度和罐体温度的差值 $Ta_avg - To_avg$ 以及当日气象预报最高温度与第二日气象预报最低温度的差值 $F_max - F_next_min$, 以上 3 个温度差对应的权重分别记为 $W5$ 、 $W6$ 和 $W7$ 。根据以上研究, 第二层神经网络中共输出 7 个温度差值, 另外引入常数权重输入下一层, 在图 1 中以常数“1”神经元表示, 对应的权重记为 $W0$ 。第三层神经网络则以全连接的形式输出预测结果(图 1)。在本模型中, 作为参考基准的 To_min 总是直接传递至输出端, 而优化模型即是指通过输入数据优化权重 $W0 \sim W7$ 。

编写 python3 程序实现上述学习模型, 输入全部 40 个数据点并通过批梯度下降(Batch Gradient Descent)策略更新参数 $W0 \sim W7$ 以降低 L_2 [6], 学习率定为 0.001。经过 100 万次迭代后得到损失函数变化如图 2 所示。损失函数在约 50 万次学习后停止下降, 极小值为 0.049, 相交“机械式”预测有明显的下降。模型预测值与实测值最大偏差为 -0.78°C , 同样发生于 2 月 28 日。

灭火剂罐储条件总是在不断地变化之中, 如冷空气来袭、附近窗户的开/闭等, 为了提高模型预测能力, 同时节约系统算力, 我们希望训练模型需要的数据集在包含足够信息的前提下尽可能的小, 以便于我们及时抛弃旧数据而使模型更好地适应当前的储存环境。为了讨论最佳的数据集尺寸, 我们分别考察了数据集大小为 5、7、10 和 14 天时, 模型经过 100 万次训练对下一日罐体最低温的预测能力。例如, 对于 20 号数据(对应 2022 年 1 月 27 日), 将 1 月 6 日到 19 日的数据(共 14 天且不包括 20 号数据本身)输入模型并进行 100 万次训练, 然后以完成训练的模型推理 20 号数据本身得到预测值, 并与 1 月 28 日中的实测值比较以评价模型的预测(泛化)能力。




Figure 2. Learning process of model
图 2. 模型的学习过程

将不同数据集尺寸下预测值与实际测量值的差值按式(2)计算损失函数 L_2 , 结果如图 3 所示。其中, 模型训练集尺寸为 1 代表跳过机器学习步骤, 按式(1)进行“机械式”的预测; 而模型训练集尺寸 39 代表传统意义上的泛化性能, 即以不包含当日的其他全部数据作为训练集($N = 39$)优化模型后推理当日数据。显然, $N = 39$ 时绝大部分情况下训练数据集不但包含对当日而言发生于过去的的数据, 也包含发生于未来的数据, 从数学模型的角度是最为理想的训练集, 得到的 L 值也最低。可以认为 $N = 39$ 代表了本模型在传统泛化上能够达到的最高性能, 但现实中当然不可能实现(因为我们无法获得未来的数据)。从图 3 中可知, 随着训练集数据的增加, 损失函数 L 明显低于“机械式”预测并逐步下降, 当 $N = 39$ 时达到最低值

0.039。此外，当 $N = 5$ 和 $N = 7$ 时，模型均存在明显的过拟合(Over Fitting)，模型在训练集上的平均偏差低于预测偏差一个数量级以上， $N = 10$ 时在部分数据点上还存在过拟合。当 $N = 14$ 时，模型在训练集上的平均偏差和预测偏差基本相当，表明过拟合现象基本消失，并且损失函数给出的 L 值也明显降低。




Figure 3. Influence of training model size on loss function L_2 (the number at the top of the column is the time required for the cloud server to complete a learning process)

图 3. 训练模型尺寸对损失函数 L_2 的影响(柱线顶部的数字为云端服务器完成一次学习过程需要的时间)

不同数据集尺寸下在线监测系统中各运算单元以单线程完成一次训练(100 万次迭代)所需的时间如表 1 所示，包括作为本地终端机的龙芯@2K1000 单片机、本地核心节点龙芯@3A5000、云端服务器端华为鲲鹏@920，并与常见的家用 CPU INTEL 酷睿@10900X 对比：

Table 1. Training time of the model on multiple CPUs

表 1. 模型在多种 CPU 上的训练时间

CPU	不同模型尺寸用时(s)				
	5 日	7 日	10 日	14 日	39 日
龙芯 2K1000@1.0 GHz	1598	2214	3081	4164	11,072
龙芯 3A5000@2.5 GHz	155	220	314	419	886
鲲鹏 920@2.6 GHz	159	225	325	435	717
酷睿 10900X@3.7 GHz	88	125	175	238	455

大量对照训练数据表明在表 1 所列的各种运行环境下，学习模型程序在百万分之一误差范围内给出完全相同的结果，表明程序可在灭火剂在线监测系统中的各个节点可靠运行，具有较好的可移植性。综合考虑模型的灵活性、精度和训练计算花销，我们认为将训练集尺寸定为 14 天较为合适，除主要负责控制 MCU 单元的龙芯 2K1000 单片机外，在线监测系统中的其他节点均能在 10 min 内完成 1 次模型训练(100 万次迭代)。在此训练集尺寸下，为了预测下一日最低罐体温度，需要向模型输入过去两周时间中温度传感器组和天气预报提供的各项数据。在预测模拟实验中，学习模型在 12 个预测点上的损失函数 L_2 值为 0.086，显著优于“机械式”预测的 L_2 值 0.505，而最大偏差为 -0.99°C ，也低于“机械式”预测的最大偏差 -1.25°C 。随着模拟实验中时间的推移，模型优化得到的 8 个权重系数也有规律地变化(图 2)。特别是对照前 6 与后 6 个预测模型，由于对应的季节从冬转为春，优化后得到的各权重系数明显不同，这就表明本模型具备了一定的自动适应储存环境的能力，为水成膜泡沫灭火剂在线监测系统长期无人值守自主运行提供了坚实的基础。

4. 结论

研究表明, BP 神经网络可用于预测不锈钢罐中水成膜灭火剂在未来一日内的最低温度。通过构建和调优该 BP 网络, 并利用它处理由罐体周围的两只温度传感器和当地的一日内气象预报组成的数据流, 本研究显著地提高了预测精度。在模拟实验中, 模型的预测值偏差 L_2 值从“机械式”预测的 0.505 下降至 0.086。以 python3 代码实现的学习模型程序在水成膜泡沫灭火剂线监测系统本地核心节点和云端服务器上均能可靠运行, 并在 10 分钟内完成 100 万次优化, 具备了较好的实用性, 为在线监测系统长期无人干预运行提供了基础。

参考文献

- [1] 刘大鹏, 王煊军, 夏本立, 等. 水成膜泡沫灭火剂的发展与应用[J]. 化学工程与装备, 2013(2): 139-142.
- [2] 尚祖政, 谈龙妹, 郎需庆, 等. 石化企业现有泡沫灭火剂的质量分析[J]. 消防科学与技术, 2017, 36(2): 230-232.
- [3] 袁余斌, 谢贤俊, 韩永和, 等. 新型水成膜泡沫灭火剂储存寿命测定方法[J]. 消防科学与技术, 2008, 27(5): 347-349.
- [4] Rumelhart, D.E., Hinton, G.E. and Williams, R.J. (1986) Learning Representations by Back Propagating Errors. *Nature*, **323**, 533-536. <https://doi.org/10.1038/323533a0>
- [5] Bowles, M. (2014) Machine Learning in Python: Essential Techniques for Predictive Analysis. John Wiley & Sons, Hoboken.
- [6] Nakama, T. (2009) Theoretical Analysis of Batch and On-Line Training for Gradient Descent Learning in Neural Networks. *Neurocomputing*, **73**, 151-159. <https://doi.org/10.1016/j.neucom.2009.05.017>