

AI 深度学习及应用在空压系统中的策略优化研究

曹轶¹ 陆炜¹ 徐亮² 郑铁君² 肖俊³

1. 上海大众祥源动力供应有限公司；2. 宁波杭州湾新区祥源动力供应有限公司；
3. 上海龙乾电气科技有限公司

摘要：本文旨在探讨AI深度学习在空压系统策略优化中的应用，通过构建深度学习模型，实现对空压系统参数的精准预测和优化，以提高空压系统的运行效率，降低成本。实验结果表明，对比机理模型和线性回归模型，本文所提出的卷积神经网络建模的方法具有更好的模型训练效果，并结合遗传算法为控制参数提供优化，此方法为汽车工业节能提供了新思路。

关键词：空压系统；AI深度学习；节能减排

0 前言

在汽车制造过程中，空压机是不可或缺的关键设备之一，广泛应用于涂装、焊接和冲压等各个生产环节，而且自动化水平越高的生产线对压缩空气的需求量和品质要求也就越高。但空压机的高能耗问题一直是汽车企业面临的一大挑战。如何降低空压机的能耗，提高能源利用效率，已成为当前工业尤其是汽车工业节能领域亟待解决的问题。

传统的空压机能耗优化方法主要依赖于经验调整或固定参数的优化，虽然在一定程度上能够降低能耗，但效果有限且难以适应复杂多变的工业环境。

在空压机深度学习建模的应用方面，研究者们已经取得了一些初步的成果，但对于工业场景的空压机性能的建模以及优化控制目前还较少有人研究。因此，研究一种新型的建模方法，实现对空压系统的精准控制和优化，具有重要的现实意义和应用价值。

1 建立 AI 深度学习空压机模型

1.1 数据采集与预处理

在空压机建模过程中，数据收集与处理是至关重要的一步。数据质量直接影响到模型的准确性和泛化能力。因此，我们对空压机运行数据进行了细致的收集和整理。针对空压机建模，将表1的变量纳入模型中。

在数据收集完成后，我们进行了数据清洗工作，

表1 空压机采集变量

序号	变量	含义	备注
1	T_db	环境干球温度	
2	T_cdOut	冷却水出口水温度	
3	T_cdIn	冷却水进口水温度	
4	T_cdIO	冷却水进出口水温差	
5	P_cd	冷却水压力	
6	T_bearing	轴承温度	
7	P_Out	压缩机出口压力	
8	P_env	环境大气压力	
9	P_oil	油压	
10	T_oil	油温	
11	F	空压机出口流量	
12	T_1cOut	一级压缩出口温度	多级压缩会增加对应测点
13	T_2cIn	二级压缩进口温度	
14	T_2cOut	二级压缩出口温度	
15	P_dfilter	空气过滤器压差	
16	T_Out	压缩机出口温度	
17	State	空压机开启状态	
18	E	空压机功率	

以去除异常值和重复数据。异常值可能是由于传感器故障、数据传输错误等原因产生的，它们会对模型的训练产生干扰，因此需要被识别并剔除。此处我们使用四分位法，并使用标准的1.5倍IQR值作为阈值，将超出正常范围的数据标记为异常值，并在后续的数据处理中将其排除。同时使用滑动窗口滤波方法，以5

个样本作为窗口长度，计算出滑动平均值，对于超出平均值 20% 的原始样本标记为异常并在后续的处理中将其排除。重复数据则可能是由于数据采集系统的问题而产生的，我们需要去除这些冗余数据，以避免对模型训练造成不必要的负担，我们将一组数据全部为重复的数据和空压机功率数据重复的数据标记为异常，并在后续的数据处理中将其排除。

1.2 多种方法建模对比

(1) 机理模型

机理建模使用如下公式：

$$P = 8.314 \times \frac{k}{k-1} \times \frac{T_{dischg} - T_{suct}}{M} \times Q_m \quad (1)$$

等价公式为：

$$P = \frac{8.314}{M} \times \frac{k \times T_{suct}}{k-1} \times \left[\left(\frac{P_1}{P_2} \right)^{(k-1)/k} - 1 \right] \times Q_m \quad (2)$$

式中， P 为压缩机功率，对应表 1 中的变量 18； T_{suct} 为空压机进口温度（K），对应变数 1； T_{dischg} 为空压机出口温度（K），对应变数 14； M 为空气摩尔质量（g/mol）28.96； Q_m 为空压机流量（kg/s），对应变数 11； k 为空气等熵系数 1.4； P_2 为空压机出口压力，对应变数 7； P_1 为空压机进口压力，对应变数 8。

(2) 线性回归建模

线性回归的目标是找到一个最佳的直线（在多变量情况下是平面），使得这个直线（平面）与数据点之间的距离最小化。这个距离通常是欧几里得距离，即垂直距离。通过最小二乘法，可以求解线性回归模型的参数，从而实现连续型变量的预测。

线性回归模型可以表示为：

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \cdots + \beta_n X_n \quad (3)$$

式中， Y 是因变量； $X_1, X_2, \cdots, X_n$ 是自变量； $\beta_0, \beta_1, \beta_2, \cdots, \beta_n$ 是模型的参数。本文中，将表 1 中 1 ~ 17 号变量作为输入，18 号变量作为输出，并使用最小二乘法求解。

(3) 卷积神经网络建模

卷积神经网络（CNN）是一种专门用于处理具有网格结构数据的神经网络，如图像数据。它通过卷积操作提取输入数据的局部特征，并通过层次化的网络结构逐步抽象出更高级的特征表示。CNN 在图像识别、目标检测等领域取得了显著的成功。CNN 模型通常由卷积层、池化层及全连接层等组成。卷积层负责提取输入数据的局部特征，通过卷积核与输入数据的卷积运算生成特征图。池化层则负责对特征图进行下采样，

减少数据的维度和计算量，同时保留重要的特征信息。全连接层则负责将提取的特征映射到输出空间，实现分类或回归等任务。

本文使用两层 3*1 大小的卷积层、一层 3*1 大小的池化层和三层全连接层，每层之间均设置激活层，激活层均使用 RELU 函数。模型输入为表 1 中 1 ~ 17 号变量，模型输出为 18 号变量。

(4) 建模结果对比

本次建模中，共对 5 台空压机进行建模测试，对比上述 3 种建模方法，模型训练从 3 个指标进行评价（训练结果指标如表 2 所示），分别是 R_2 拟合系数， R_2 定义为：

$$R^2(Y, \hat{Y}) = 1 - \frac{\sum_i^m (\hat{y}_i - y_i)^2}{\sum_i^m (\bar{y}_i - y_i)^2} \quad (4)$$

MAE 平均绝对误差，定义为：

$$MAE(Y, \hat{Y}) = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \quad (5)$$

MAPE 平均绝对误差百分比，定义为：

$$MAPE(Y, \hat{Y}) = \frac{1}{m} \sum_{i=1}^m |(y_i - \hat{y}_i)/y_i| \quad (6)$$

由表 2 可以得知，CNN 模型在 5 台空压机的建模中，在 R_2 、MAE、MAPE 这三个指标中均取得了最佳的结果。同时根据图 1 所示的 5 号空压机建模结果，机理建模方法仅对少量工况起到了较好的拟合效果，在 900 kW 功率和 1000 kW 功率附近均出现了较多的预测偏离样本。线性回归和 CNN 模型均有较好的拟合结果，但从

表 2 不同建模方法结果对比

设备	指标	机理模型	线性回归模型	卷积神经网络模型
1 号空压机	R_2	0.320	0.8600	0.98000
	MAE	35.140	10.6900	4.24000
	MAPE	0.138	0.0421	0.01570
2 号空压机	R_2	0.260	0.8500	0.97000
	MAE	103.700	38.1000	5.54000
	MAPE	0.130	0.0468	0.00770
3 号空压机	R_2	0.150	0.8800	0.97000
	MAE	114.900	30.9000	3.99000
	MAPE	0.143	0.0395	0.00530
4 号空压机	R_2	0.290	0.8700	0.98000
	MAE	136.750	52.3000	3.64000
	MAPE	0.139	0.0567	0.00363
5 号空压机	R_2	0.210	0.8700	0.98000
	MAE	129.020	47.1000	2.52000
	MAPE	0.131	0.0402	0.00256




图1 机理模型空压机功率真实值与模型预测值对比




图2 线性回归模型空压机功率真实值与模型预测值对比




图3 卷积神经网络模型空压机功率真实值与模型预测值对比

模型指标上看 CNN 模型的误差更小。综上所述, CNN 网络取得了最佳的训练效果, 故使用此模型作为优化的基础。

2 优化目标及优化算法选择

根据压缩机变量特征和工艺流程分析, 空压系统模型的输入为每个空压机模型输入, 输出为 5 个空压

机模型输出电功率之和, 即:

$$E = f_1(P_{env-1}, F_1, \dots) + \dots + f_5(P_{env-5}, F_5, \dots) \quad (7)$$

式中, $f_1 \sim f_5$ 为 5 台空压机模型, 优化目标为公式 (6) 的总功率 E 最小, 即空压系统能耗最低。

遗传算法 (Genetic Algorithm, GA) 是一种模拟自然选择和遗传机制的优化算法。它借鉴了生物进化过程中的自然选择和遗传学原理, 通过模拟种群的进化过程来搜索问题的最优解。遗传算法的基本思想是将问题的求解过程转化为类似生物进化中的染色体基因的交叉、变异等过程。在求解过程中, 遗传算法通过逐代进化来搜索越来越好的近似解, 每一代都根据问题域中个体的适应度大小选择个体, 并借助于自然遗传学的遗传算子进行组合交叉和变异, 产生出代表新的解集的种群。这个过程将导致种群像自然进化一样的后代种群比前代更加适应环境, 末代种群中的最优个体经过解码, 可以作为问题近似最优解。遗传算法的基本步骤如下。

(1) 编码: 将问题的解空间转化为遗传算法能够处理的搜索空间, 即把问题的可能解从其解空间转换到遗传算法所能处理的搜索空间的转换方法。

(2) 初始种群生成: 随机生成一组个体作为初始种群, 这些个体代表问题的可能解。

(3) 适应度评估: 根据问题的目标函数, 计算每个个体的适应度值, 评估其优劣。

(4) 选择: 根据个体的适应度值, 选择一部分优秀个体进入下一代, 保证优秀基因得以传递。

(5) 交叉(也称“杂交”): 将选择出的个体进行配对, 并按照一定的概率交换部分基因, 生成新的个体。

(6) 变异: 对交叉产生的个体按照一定的概率改变某些基因的值, 以增加种群的多样性。

(7) 终止条件判断: 若满足终止条件(如达到最大迭代次数、找到满意解等), 则算法结束, 输出最优解。否则, 返回步骤 (3) 继续迭代。

故使用遗传算法对空压系统模型的输入参数进行寻优, 使得系统总功率最低的输入参数, 即为最佳控制参数。本文中, 使用表 1 输入变量中 7 空压机出口压力、11 空压机出口流量、17 空压机开启状态作为可变量, 其余输入参数为固定常数取当前实时值, 变量 18 空压机总功率作为寻优目标, 同时约束空压系统总供气流量在优化后不能低于当前实际值。种群个数设置为 100, 初始种群完全随机生成, 迭代次数为 300 次,

无其他迭代停止条件。

3 算法验证

空压机 CNN 模型训练完成后，使用两个月的新数据对模型进行测试，所有空压机模型指标 *MAE* 和 *MAPE* 均未超过模型训练时 *MAE* 和 *MAPE*，测试集 R_2 指标不低于训练时 R_2 ，说明 CNN 模型表现比较稳定。本文所提到的 5 台空压机参数见表 3。

表 3 测试用压缩机参数

设备编号	最大供气量 / (Nm ³ /min)	压缩机最大功率 /kW
1	80	580
2	150	800
3	150	800
4	190	1000
5	190	1000

我们将供气需求量 0 ~ 240 Nm³/min 代入模型进行优化计算得到结果如表 4 所示。

表 4 不同供气需求下最佳机组组合

供气量范围 / (Nm ³ /min)	最佳机组组合
0 ~ 80	1 号
80 ~ 150	3 号
150 ~ 190	4 号
190 ~ 240	1 号 +4 号

经实际测试，在同样的供气量下 CNN 模型结合遗传算法给出的最佳组合对比其他机组组合，具有更低的供气能耗。

4 结论

本文尝试了机理模型、线性回归模型以及 CNN 模型，对比前两种模型，CNN 模型在模型精度上有优势。CNN 模型结合遗传算法进行空压机控制参数优化，可以找到最佳机组组合以及控制参数，对比其他机组组合方式，此方法推理得到的机组组合整体能耗最低。

参考文献

[1] 王宇. 基于数据驱动的空压机故障诊断与性能预测系统研究 [D]. 上海: 上海应用技术大学, 2021.
[2] 马玉宝, 张兴龙, 李霖, 等. 基于数据驱动的空压机健康状态评估 [J]. 石油工程建设, 2023, 49(1): 62-

66, 87. DOI:10.3969/j.issn.1001-2206.2023.01.012.
[3] 侯大立, 王宇, 成凡. 基于数据驱动的空压机集群智能诊断系统 [J]. 机床与液压, 2021, 49(12): 190-195.
HOU Dali, WANG Yu, CHENG Fan. Intelligent Diagnosis System of Air Compressor Cluster Based on Data driven [J]. Machine Tool & Hydraulics, 2021, 49(12): 190-195
[4] M,U,Hameed, I,A.; SUNDLI,K. Health Monitoring of Air Compressors Using Reconstruction-Based Deep Learning for Anomaly Detection with Increased Transparency [J]. Entropy, 2021(23): 83. <https://doi.org/10.3390/e23010083>
[5] 胡欢欢. 基于 HHT 和深度学习的船舶空压机故障诊断 [D]. 福建: 集美大学, 2020.
[6] WUD, BABAK Bi A, ALI R, et al. Air compressor load forecasting using artificial neural network [J]. Expert Systems with Applications, 2021, 168, 114209, ISSN 0957-4174, <https://doi.org/10.1016/j.eswa.2020.114209>.
[7] SAIDUR R, RAHIM N,A, HASANUZZAMAN,M. A review on compressed-air energy use and energy savings [J]. Renewable and Sustainable Energy Reviews, 2010, 14(4): 1135-1153, ISSN 1364-0321, <https://doi.org/10.1016/j.rser.2009.11.013>.
[8] GHORBANIAN,K, GHOLAMREZAEI,M. An artificial neural network approach to compressor performance prediction [J], Applied Energy, 2009, 86, Issues 7-8: 1210-1221, ISSN 0306-2619, <https://doi.org/10.1016/j.apenergy.2008.06.006>.
[9] 孙志军, 薛磊, 许阳明, 等. 深度学习研究综述 [J]. 计算机应用研究, 2012, 29(8): 5. DOI:10.3969/j.issn.1001-3695.2012.08.002.
[10] 邹乐强. 最小二乘法原理及其简单应用 [J]. 科技信息, 2010(23): 2. DOI: CNKI: SUN: KJXX.0.2010-23-209.
[11] 周明, 孙树栋. 遗传算法原理及应用 [M]. 北京: 国防工业出版社, 1999.
[12] 丁建立, 陈增强, 袁著社. 遗传算法与蚂蚁算法的融合 [J]. 计算机研究与发展, 2003, 40(9): 6. DOI: CNKI: SUN: JFYZ.0.2003-09-010.