

[变压器]

基于神经网络的变压器负载率预测方法

文/黄丞远
广东电网有限责任公司珠海供电局

随着光伏大规模并网、各行业用电量的持续走高，对配电网设备带来巨大冲击。配电变压器作为整个配电网中的关键设备，其稳定运行也随之受到挑战。为保障稳定可靠的电力供应，提出一种基于神经网络的变压器负载率预测方法，能够针对具有海量高维特性的变压器运行数据进行处理，结合XGboost智能算法构建特征选择模型，以实现海量高维运行数据的降维处理。并在此基础上，引入遗传算法对传统反向传播神经网络进行参数优化，利用优化后的神经网络构建变压器负载率预测模型。

在当前光伏大规模并网、居民用电量持续走高的情况下，变压器的稳定运行面临巨大挑战，如何及时掌握变压器的负载率以避免重过载已成为必须面对的问题。

目前，有不少学者为及时掌握变压器的负载率，开展一系列研究，主要从两方面入手，一是通过传统计算方法进行改进并基于优化算法构建物理模型对变压器的运行状况进行评估分析。文献[1]基于热电类比原理，建立温度估算模型，对变压器的负载能力进行评估。文献[2]基于有限元与有限体积法的油浸式电力变压器温度场计算方法，建立油浸式电力变压器温度场与流场模型，实现对变压器负载率的评估。另一种研究思路则是结合人工智能技术，对变压器的运行数据开展数据挖掘，通过运行数据背后的逻辑关系建立模型以实现对变压器的负载能力进行分析。文献[3-4]基于大数据人工智能技术，结合温度计算模型，将多参量纳入考虑范畴，对变压器的过载能力进行预测评估研究，通过数据仿真证明方法的可行性。文献[6]通过将变压器本体特性数据、电网运行状况数据、地理气象状况数据等与变压器相关的全景数据纳入变压器负载能力评

估参量体系，对变压器的负载能力进行评估预测，其有效性通过实例得到验证。

相比第一种研究方法，采用大数据挖掘技术展开变压器负载率评估分析一般会取得更精准的结果。但是，上述采用数据挖掘评估预测变压器负载率时，少有将变压器运行数据特性纳入考虑范畴。变压器运行数据具有海量高维特性，这一数据特性不仅将加大算力消耗，同时将影响最终分析结果。本文提出一种改进的神经网络变压器负载率预测模型，能够针对性处理海量高维特性的变压器运行数据，并实现智能化的变压器负载率预测。结合某省实际变压器运行数据，证明所提方法的可行性。

基于XGboost的变压器运行数据特征选择模型

考虑到历史变压器运行数据具有海量高维特性，难以避免会存在数据冗余、噪声等现象，这将会直接影响最终的预测准确度。因此，在开展变压器运行数据挖掘工作前，有必要对变压器运行数据进行特征选择，以实现高维数据的降维处理。特征选择作为一种常用的数据降维方法，能够在不破坏

原始数据空间结构的情况下降低原始数据维度，有助于减小算力损耗、提升预测模型准确度。XGboost具有高准确性以及出色的并行处理数据能力，通过XGboost构建特征选择模型，则可以实现高准确度数据分类任务的同时极大加快数据训练，假设XGboost特征选择模型中回归树的数量为 k ，则模型可表示为

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in D \quad (1)$$

式中， $\hat{y}_i$ 为 y_i 预测值； f_k 为单棵回归树， D 为对应所有回归树的集合； $f_k(x_i)$ 为第 k 棵树所对应数据集中第 i 个样本的得分。

此时模型的目标函数为

$$O_b = \sum_{i=1}^m l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2)$$

式中， l 为表现模型拟合训练样本的误差函数。

同时，为避免模型训练结果过拟合，通过设置正则化项 $\Omega(f_k)$ 以惩罚复杂模型，表达式为

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \|w\|^2 = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (3)$$

式中， γ 和 λ 为模型惩罚系数； T 和 w 分别为第 k 棵树的叶子数及对应权重。

由于原始模型为加法树，目标函数可以通过前向分步算法实现，经过 t 次迭代后，样本 i 的预测值为 $\hat{y}_i^{(t)}$ ，目标函数的最优化可以通过引入 f_t 实现

$$O_b^{(t)} = \sum_{i=1}^m l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega f(t) \quad (4)$$

式中， $l(y_i, \hat{y}_i^{(t-1)})$ 为损失函数； $f_t(x_i)$ 为第 t 棵树的预测值； $\Omega f(t)$ 为第 t 棵树的模型复杂程度。

对式（4）中目标函数进行二阶泰勒展开，去除常数项可得

$$O_b^{(t)} = \sum_{i=1}^m [g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2] + \Omega(f_t) \quad (5)$$

对于式（5）中二阶泰勒展开的目标函数，有

$$\begin{cases} g_i = \partial_{y_i} l(y_i, \hat{y}_i^{(t-1)}) \\ h_i = \partial_{y_i}^2 l(y_i, \hat{y}_i^{(t-1)}) \end{cases} \quad (6)$$

式中， g_i 和 h_i 分别为损失函数的一阶、二阶导数。

此时，可将目标函数进一步改写为

$$\begin{aligned} O_b^{(t)} &= \sum_{i=1}^m [g_i f_t(x_i) + \frac{1}{2} h_i f_t(x_i)^2] + \gamma T + \|w\|^2 \\ &= \sum_{j=1}^T [(\sum_{i \in I_j} g_i) w_j + \frac{1}{2} (\sum_{i \in I_j} h_i + \lambda) w_j^2] + \gamma T \end{aligned} \quad (7)$$

式中， $I_j = \{i | q(x_i = j)\}$ 表示叶子 j 的样本集合。

此时，目标函数就转换为一个关于 w_j 的方程组求解最小值问题。树结构 q 不变，则对应叶子 j 的最优权重为

$$w_j^* = -\frac{G_j}{H_j + \lambda} \quad (8)$$

式中， $G_j = \sum_{i \in I_j} g_i$ ， $H_j = \sum_{i \in I_j} h_i$ ，分别表示对损失函数的一阶、二阶导数求和； λ 为模型惩罚系数。

此时，可得对应最优目标值为

$$O_b^{(t)} = -\frac{1}{2} \sum_{j=1}^T \frac{G_j^2}{H_j + \lambda} + \lambda T \quad (9)$$

式中， $O_b^{(t)}$ 作为衡量树的结构分数，一般情况下取值大小与树的结构性能成反比。

对于树的所有结构，进行完全列举是不现实的，所以结合贪心算法对当前节点的子树进行划分，对已有叶节点引入分割点，并将所有可行的分割点进行列举，在其中选择函数最小而增益最大的划分，其中增益公式为

$$\text{Gain} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + \lambda + H_R} \right] - \gamma \quad (10)$$

式中， $G_L = \sum_{i \in I_j} g_i$ ， $G_R = \sum_{i \in I_n} g_i$ ； $H_L = \sum_{i \in I_L} h_i$ ， $H_R = \sum_{i \in I_n} h_i$ ； I_L 和 I_R 分别为分类后的左子树和右子树样本集。

增益公式能够对分类效果进行评分，在实际预测时，将会基于“Gain最大”的叶节点进行分类。

基于上述XGboost特征构建变压器运行数据特征选择模型，模型的具体选择流程如图1所示。




图1 基于XGboost的特征选择模型

基于神经网络的变压器负载率预测模型

经过上述XGboost特征选择模型, 输出得到最优特征子集, 子集中为与变压器负载率呈高关联性特征。将最优特征子集作为输入, 构建神经网络预测模型, 考虑到传统反向传播神经网络存在收敛速率慢、易陷入局部最小值的问题, 结合遗传算法对反向传播神经网络的参数部分进行优化。通过迭代寻优的方式搜寻到最优中间层参数, 设定 x_i 为输入数据, y_n 为输出数据, w_n 为输入信号, 则此时信号强度为

$$N_{et,j} = \sum w_{ij}x_i \quad (11)$$

式中, w_{ij} 为第 i 个神经元作用于第 j 个神经元的权重; x_i 为输入信号。

将反向传播神经网络预测模型的阈值设定为 θ , 当 $N_{et,j} > \theta$ 时, 则激活该神经元, 模型的表达式为

$$yj = f(\sum_i w_{ij}x_i - \theta) \quad (12)$$

此时利用遗传算法对反向传播神经网络预测模型的权重及阈值进行优化, 通过初始化种群产生一个随机种群 $X_{m \times n}$, 其中神经网络的初始权重分布由个体 $X_{1 \times n}$ 表示, 单个连接权重及阈值由单值表示, 此时神经网络的权重与阈值个数和等于个体长度

$$n = r \times s_1 + r \times s_2 + s_1 + s_2 \quad (13)$$

式中, n 为个体长度; r 为输入层神经元数; s_1 为隐含层神经元数; s_2 为输出层神经元数。

结合适应度函数评价每个个体, 反向传播神经网络预测模型的输入由所有个体解码得到, 适应度函数为

$$f = \sum_{i=1}^n |E_n| \quad (14)$$

式中, E_n 为输出误差值。

通过计算得到适应度最大的个体将进入到下一代种群中。

采用轮盘赌法^[10]对算子进行选择, 假设第 i 个个体的适应度为 f_i , 则选中该算子的概率为

$$p_i = f_i / \sum_{i=1}^j f_i \quad (15)$$

式中, j 为种群数量。

利用算术交叉选择交叉算子, 计算式为

$$\begin{cases} X_i(k+1) = \alpha X_i(k) + \beta X_{i+1}(k) \\ X_{i+1}(k+1) = \alpha X_{i+1}(k) + \beta X_i(k) \end{cases} \quad (16)$$

式中, $X_i(k)$ 和 $X_{i+1}(k)$ 分别为第 i 和第 $i+1$ 个个体在第 k 位子上的基础; $\alpha, \beta \in [0, 1]$

通过均匀变异算子, 对所有基因值进行变异率 P_m 的基因域内部随机替换: $X_i = X_i(p) + r \times q + X_i(n - p - 1)$, 其中, q 为第 $p+1$ 基因值对应的阈值宽度, r, n 为常数。

最后, 计算适应度函数, 达到满足条件或最大遗传次数后, 输出最优个体, 即最终预测结果。

预测流程如图2所示。




图2 基于改进反向传播神经网络的预测流程

算例验证

通过选取某地2023年变压器运行数据作为测试数据, 以原始反向传播神经网络构建预测模型与本文模型进行分析, 通过二者的预测结果对比, 校验本文提出基于神经网络预测模型的有效性。

首先采用原始反向传播神经网络构建预测模型, 将原始变压器运行数据作为输入集合 x , 以负载率作为输出 y , 得到的预测结果见表1。

在测试的20个变压器样本数据上, 原始反向传播神经网络预测模型通过对变压器运行数据进行分析所得到的预测负载率与实际负载率的平均偏差为10%, 而最大偏差达到15.34%。较大的偏差表明原始反向传播神经网络预测模型在针对变压器负载率进行预测时难以起到良好的预测效果。

表1 原始反向传播神经网络预测结果

样本编号	实际负载率 (%)	预测负载率 (%)	偏差 (%)
1	13.37	24.84	11.47
2	16.35	29.86	13.51
3	14.57	3.16	11.41
4	28.15	17.84	10.31
5	10.59	19.64	9.05
6	20.28	29.91	9.63
7	5.84	14.33	8.49
8	9.02	19.25	10.23
9	6.17	14.33	8.16
10	37.95	28.26	9.69
11	4.09	12.86	8.77
12	5.10	14.37	9.27
13	36.80	46.57	9.77
14	41.86	53.28	11.42
15	57.74	48.46	9.28
16	31.76	22.68	9.08
17	44.79	33.83	10.96
18	15.69	8.45	7.24
19	34.70	44.57	9.87
20	47.28	31.94	15.34

利用本文提出的改进神经网络预测模型进行校验，通过将原始变压器运行数据输入到图1中所示的XGboost特征选择模型，输出得到最优特征子集后，将最优特征子集输入图2中改进后的神经网络预测模型，得到预测结果见表2。

表2 改进神经网络预测结果

样本编号	实际负载率 (%)	预测负载率 (%)	偏差 (%)
1	25.67	29.55	3.88
2	19.42	14.87	4.55
3	44.57	49.88	5.31
4	67.25	63.31	3.94
5	36.73	41.12	4.39
6	27.64	31.63	3.99
7	17.85	21.98	4.13
8	34.56	31.22	3.34
9	17.92	14.32	3.6
10	9.84	5.31	4.53
11	55.41	51.49	3.92
12	58.69	62.25	3.56
13	34.27	30.18	4.09
14	15.83	24.51	8.68
15	37.36	42.61	5.25
16	14.59	17.92	3.33
17	52.40	58.94	6.54
18	34.29	39.51	5.22
19	6.54	12.77	6.23
20	19.66	23.51	3.85

通过表2分析，本文提出的神经网络预测模型，针对20个测试变压器样本数据的预测结果的平均偏差在4.6%，最大偏差为8.68%。与表1中原始反向传播神经网络预测模型对比，偏差度有明显降低，预测准确度有一定提升，证明本文所提方法的有效性。

结束语

本文所研究的基于神经网络的变压器负载率预测模型能够对变压器负载率实现精准的评估，针对性解决海量高维特性的变压器运行数据导致的“过拟合”问题。相比传统反向传播神经网络预测模型，本文所提方法的预测准确度提高5%左右，具有广阔的工程应用前景，对实际工作具有指导意义。EA

(收稿日期：2024-10-09)

参考文献

[1] 周则儒,陈斌,李应光,等.基于热电类比原理的变压器负载能力评估模型[J].广东电力,2021,34(4):101-107.

[2] 岳国良.油浸式电力变压器负载能力在线评估及冷却控制策略研究[D].北京:华北电力大学,2016.

[3] 王兴勋,王月香,倪康婷,等.基于深度学习的变压器负载能力评估与应用[J].电工技术,2022(15):42-45+55.

[4] 何文林,邵先军.电力变压器负载能力深度挖掘技术研究[J].浙江电力,2022,41(11):68-72.

[5] 贺川双.基于全景数据融合分析的变压器负载能力评估与预测[D].上海:上海交通大学,2019.