第49卷 第22期 2025年11月25日
DOI：10.7500/AEPS20241117002
电力系统自动化
Automation of Electric Power Systems
Vol. 49 No. 22 Nov. 25，2025

基于变权值神经网络的低压配电网弱关联型计量异常识别

金阳忻，徐永进，汪金荣
（国网浙江省电力有限公司营销服务中心（计量中心），浙江省杭州市 310000）

摘要：电能表作为低压配电网重要的数据源，其计量异常的治理关系到电力交易的公平性。因此，以电能表功率、电压冻结值及部分档案信息作为输入，设计了一种基于变权值神经网络的低压配电网线损弱关联型计量异常识别模型。该模型的主体部分是用于推算计量异常指数的残差神经网络。首先，针对输入信息不完备引起的精度退化，提出了神经网络变权值算法，即不再认为网络权值训练后均保持恒定，转而将其中一部分视作若干本征权值叠加而成的可变权值层。然后，利用无法直接作为网络输入的节点间关联状态，通过分维度的合成密度矩阵合并计算叠加系数，显著提升了模型准确度。最后，将增广样本集用于训练和测试，对比验证了变权值残差神经网络识别模型的有效性，再将该模型试点应用于中国浙江省某市电网高损台区治理，进一步检验了其在实际工况中的检测效果。

关键词：配电网；电能表；计量异常；残差神经网络；变权值算法

0 引言

在电力交易市场化的背景下，低压配电网非技术线损治理成为保障交易公平和维护供电秩序的重要基础，而电能表计量异常是非技术线损的主要来源[1]。计量异常是指电能表对功率或电量的测得值大幅偏离真值的现象，其来源包括用户窃电、设备故障以及接线差错等，其中，异常用户抄见电量无显著特征且与台区线损不存在直接关联的部分可称为弱关联型计量异常，反之则称为强关联型。

传统计量异常治理大多以现场稽查的形式开展，耗费大量人工成本且效率低下。随着高级量测体系（advanced metering infrastructure，AMI）[2]逐步推广，数据驱动的计量异常识别在海量用电数据基础上得到迅猛发展[3-4]。现有常用的数据驱动类计量异常检测方法，包括基于聚类的识别方式[5-7]、基于序列统计特征的识别方式[8-10]，以及基于博弈论的识别方式[11-12]等，依赖计量异常用户的抄见电量、功率自身的特征，如负荷异常跌落、尖峰电量等，或依赖抄见电量、功率与线损的关联[13]。因此，以上识别方式适用于强关联型计量异常。

随着低压台区计量环境的日趋复杂，弱关联型计量异常的案例数呈上升态势：绕越法窃电、电能表停走等计量异常频繁发生，且由于近几年反窃查违力度的加大，一些用户开始采用部分绕越或在被绕越电能表后加装低值负载等方式模拟正常用户[10-13]。因此，弱关联型计量异常很难被前面几种识别方式定位。近年来出现的计量异常识别模型开始引入电量、功率或线损率以外的信息，主要包括：

1）基于网络状态量的识别方式：由于配电网各节点的电压和注入功率等状态量服从潮流方程约束，理论上可利用同相节点的测量结果估计目标用户的电压、功率等状态量[14]，通过对比识别计量异常。这种基于网络潮流计算的检测方式通常对节点间测量同时性要求极高[15]，还需要详细的配电网拓扑结构和线路阻抗等参数[16]。而目前低压配电网的测量同时性至多可达到亚秒级，且线路阻抗难以被准确估计[2]。

2）基于机器学习的识别方式：通过监督学习方法，可训练k近邻（k-nearest neighbor，kNN）模型[17]、支持向量机（support vector machine，SVM）[18]、卷积神经网络（convolutional neural network，CNN）[19]及长短期记忆（long short-term memory，LSTM）网络[20]等计量正常/异常分类器。这种非解析的机器学习算法能较好地提取输入序列的非线性映射信息，但也面临原始数据信息密度较低，且正面与负面样本数量不平衡等问题[21]。文献[22-23]采用Bagging、XGboost等异质集成学习算法实现多个模型的优势互补，但可能导致少数正确识别结果被

收稿日期：2024-11-17；修回日期：2025-03-17。
上网日期：2025-10-15。
国家重点研发计划资助项目（2023YFC3807100）。

淹没。

针对现有弱关联型计量异常识别方法的不足，本文融合基于网络状态和机器学习的计量异常检测方法，提出了一种变权值残差神经网络识别模型，远程定位低压配电网弱关联型计量异常，并进行了算例对比验证。

1　问题描述

本章主要讨论可用于判定线损弱关联型计量异常的低压配电网特征信息，并据此形成识别模型的输入及输出架构。

1.1　弱关联型计量异常的检测原理

在中国，公变台区是低压配电网覆盖范围最广、用户最多的供电形式，通常线损管理以台区为单元，一次部分由配电变压器与其低压侧母线、线路与其分支点（包括分支箱和计量箱），以及用户（三相用户可视作三个单相用户）组成；二次部分则包括用户侧电能表和台区总表、互感器，以及配套的用电信息采集系统[3]。根据定义，台区统计线损E_{L}等于总表累积电能与台区内各用户节点累积电能总和的差值，如式（1）所示。

$$E_{\mathrm{L}}=\int_0^t\left[P_{\mathrm{T}}-\sum P_{\mathrm{m}n}\right]\mathrm{d}\tau=\int_0^t\left[P_{\mathrm{T}}-\sum(P_{cn}+P_{en})\right]\mathrm{d}\tau \tag{1}$$

式中：n为节点序号；下标m表示测量值；P_{T}为配电变压器低压侧关口电能表所测得的功率；$P_{\mathrm{m}n}$为用户节点n电能表所测得的功率；P_{cn}为用户节点n的实际有功功率；P_{en}为用户节点n电能表所测得的功率$P_{\mathrm{m}n}$与真实值P_n之差。

若$P_{en}\neq 0$且$P_{\mathrm{m}n}$和P_{en}相互独立，则可判定存在线损弱关联型计量异常。结合历年查获的案例，这种极具迷惑性的计量异常可归纳为3类工况：

1）$P_{\mathrm{m}n}=0$，即用户绕越法窃电、电能表故障停走或错接线等工况；

2）$P_{\mathrm{m}n}$等于一个较小的常数，即用户在采用绕越法窃电的基础上，以一个低值负载模拟正常用户的工况；

3）P_{en}等于一个较大的负常数，即用户采用部分绕越法窃电的工况。

对于以上工况，仅依靠电量或功率信息判断计量异常容易和某些正常用电行为混淆，从而造成误报。因此，需要在其他信息维度上寻找特征。

理论上，若配电网各节点电压相量及网络导纳矩阵已知，可用潮流法计算各用户电压相量的分布[14]，再将视在功率计算值与测量值进行比较，即可判定计量失准的位置。但在实际工程中，低压配电网由于用户众多、隐蔽布线复杂，且存在频繁改、扩接操作，而表箱至配电变压器的拓扑关系尚无可靠识别方法，且线路、空气开关等部件的阻抗难以准确测量，因而网络导纳矩阵无从计算；另一方面，低压配电网各节点电气量的测量同时性依赖于电能表时钟精度，目前至多可达到亚秒级，且单相电能表不计量无功功率。综上，潮流计算方法不能直接应用于低压配电网，但电压和功率的相关关系特征仍可用于识别。

若已知线路阻抗，可写出直接相连节点间的电压降与线路功率的关系，如式（2）所示。

$$\dot{U}_{\mathrm{b}\tau(n)}=Z_n\frac{S_{cn}}{\dot{U}_{cn}}+\dot{U}_{cn} \tag{2}$$

式中：$\dot{U}_{cn}$、S_{cn}分别为用户节点n的电压相量、视在功率；$\dot{U}_{\mathrm{b}\tau(n)}$为次级节点$\tau(n)$的电压相量，次级节点是指与用户节点直接相连的分支点；$\tau(\cdot)$为节点n向其直接相连的上级节点的映射函数；Z_n为用户节点n和其次级节点的互阻抗，一般为未知量。

考虑到低压配电网中线路阻抗的电阻成分远大于电抗成分，式（2）可简化为式（3），即

$$U_{\mathrm{b}\tau(n)}\approx U_{cn}+\frac{R_nP_{cn}}{U_{cn}} \tag{3}$$

式中：U_{cn}为用户节点n的电压有效值；$U_{\mathrm{b}\tau(n)}$为次级节点$\tau(n)$的电压有效值；R_n为用户节点n与节点$\tau(n)$之间的线路电阻。

进一步地，将中间节点$\tau^{k-1}(n)$与其相连的用户节点视为一个虚拟用户，利用式（3）可得到从配电网拓扑中第$k-1$层到第k层中间节点的电压关系式为：

$$U_{\mathrm{b}\tau^k(n)}\approx U_{\mathrm{b}\tau^{k-1}(n)}+\frac{R_{\tau^{k-1}(n)}P_{\mathrm{b}\tau^{k-1}(n)}}{U_{\mathrm{b}\tau^{k-1}(n)}} \tag{4}$$

式中：$U_{\mathrm{b}\tau^{k-1}(n)}$、$P_{\mathrm{b}\tau^{k-1}(n)}$、$R_{\tau^{k-1}(n)}$分别为第$k-1$层中间节点的电压有效值、虚拟用户有功功率、线路电阻。

反复使用式（4），即可递推至根节点电压U_{T}。因此，用户节点n上的有功功率P_{cn}对节点链$n\rightarrow\tau(n)\rightarrow\cdots\rightarrow\tau^k(n)\rightarrow\cdots\rightarrow\Gamma(n)$上所有节点间的电压差都有影响（$\Gamma(\cdot)$为节点$n$向所属相别根节点的映射，记$U_{\mathrm{T}\Gamma(n)}$为根节点电压）。$P_{cn}$与电压差$U_{\mathrm{T}\Gamma(n)}-U_{\mathrm{b}\tau(n)}$、$U_{\mathrm{b}\tau(n)}-U_{cn}$存在正相关关系，将$P_{cn}$拆分为$P_{\mathrm{m}n}$和$P_{en}$，写出$[U_{\mathrm{T}\Gamma(n)}-U_{\mathrm{b}\tau(n)},U_{\mathrm{b}\tau(n)}-U_{cn}]$和$[P_{\mathrm{m}n},P_{en}]$的相关矩阵$\boldsymbol{C}_{\mathrm{PU}}$，如式（5）所示。

$$\boldsymbol{C}_{\mathrm{PU}}=\begin{bmatrix}P_{\mathrm{m}n}\\P_{en}\end{bmatrix}[U_{\mathrm{T}\Gamma(n)}-U_{\mathrm{b}\tau(n)}\quad U_{\mathrm{b}\tau(n)}-U_{cn}]=\begin{bmatrix}C_{\mathrm{PU}}(1,1)&C_{\mathrm{PU}}(1,2)\\C_{\mathrm{PU}}(2,1)&C_{\mathrm{PU}}(2,2)\end{bmatrix} \tag{5}$$

若节点n计量正常且与异常节点分属不同计量箱，则$\boldsymbol{C}_{\mathrm{PU}}$的元素$C_{\mathrm{PU}}(1,1)$、$C_{\mathrm{PU}}(1,2)$占主导；若节

点n计量正常但与异常节点同属一个计量箱，则元素$C_{\mathrm{PU}}(2,1)$、$C_{\mathrm{PU}}(1,2)$占主导；若节点n计量异常，则元素$C_{\mathrm{PU}}(2,1)$、$C_{\mathrm{PU}}(2,2)$占主导。虽然$\boldsymbol{C}_{\mathrm{PU}}$无法直接计算，但由上面的讨论可知，序列$[U_{\mathrm{T}\tau(n)}-U_{\mathrm{b}\tau(n)}, U_{\mathrm{b}\tau(n)}-U_{cn}]$和$[P_{\mathrm{m}n}, P_{en}]$包含了节点$n$是否计量异常的信息。

1.2　模型输入及输出层结构

AMI中用户侧的电能表和配变侧的台区总表已全量实现了有功功率、电压等用电数据的实时采集及定时冻结；同时，台区户变关系和箱表关系在营销系统中均有留档，且目前已有一些台区拓扑识别手段作为补充。因此，本文采用以下数据组成辨识弱关联型计量异常辨识模型的数据源。

1)用户节点n的电压和有功功率的时域序列$\boldsymbol{P}_{\mathrm{m}n}$、$\boldsymbol{U}_{\mathrm{m}n}$如式(6)所示。

$$\begin{cases}\boldsymbol{U}_{\mathrm{m}n}=[U_{\mathrm{m}n1}, U_{\mathrm{m}n2}, \cdots, U_{\mathrm{m}nt}, \cdots, U_{\mathrm{m}nN_t}]\\ \boldsymbol{P}_{\mathrm{m}n}=[P_{\mathrm{m}n1}, P_{\mathrm{m}n2}, \cdots, P_{\mathrm{m}nt}, \cdots, P_{\mathrm{m}nN_t}]\end{cases} \tag{6}$$

式中：$U_{\mathrm{m}nt}$为用户节点n在t时刻的电压测量值；$P_{\mathrm{m}nt}$为用户节点n在t时刻的有功功率测量值；$N_t=4\times96$，为4 d内电压和有功功率分钟冻结的采样点数。

在测量前需对台区内所有电能表进行精准校时，使电能表时钟偏差控制在5 s以内，以保证各冻结值的相对同时性。

2)节点n对应的配变低压侧$\Gamma(n)$相电压和有功功率的时域序列$\boldsymbol{U}_{\mathrm{T}\Gamma(n)}$、$\boldsymbol{P}_{\mathrm{T}\Gamma(n)}$如式(7)所示。

$$\begin{cases}\boldsymbol{U}_{\mathrm{T}\Gamma(n)}=[U_{\mathrm{T}\Gamma(n)1}, U_{\mathrm{T}\Gamma(n)2}, \cdots, U_{\mathrm{T}\Gamma(n)t}, \cdots, U_{\mathrm{T}\Gamma(n)N_t}]\\ \boldsymbol{P}_{\mathrm{T}\Gamma(n)}=[P_{\mathrm{T}\Gamma(n)1}, P_{\mathrm{T}\Gamma(n)2}, \cdots, P_{\mathrm{T}\Gamma(n)t}, \cdots, P_{\mathrm{T}\Gamma(n)N_t}]\end{cases} \tag{7}$$

式中：$U_{\mathrm{T}\Gamma(n)t}$为用户节点n所属相别根节点在t时刻的电压测量值；$P_{\mathrm{T}\Gamma(n)t}$为用户节点n所属相别根节点在t时刻的有功功率测量值。

3)配电网台区的部分档案信息包括：用户的相别，即户变关系，以及用户接入的线路分支(表箱或分支箱)序号，即箱表关系。

式(5)中$U_{\mathrm{T}\Gamma(n)}$、U_{cn}和$P_{\mathrm{m}n}$可从数据源直接得到，而$U_{\mathrm{b}\tau(n)}$和P_{en}通常未知，故分别以平均电压和瞬时线损$P_{\mathrm{L}t}$近似替代，如式(8)所示。

$$\begin{cases}\bar{U}_{\tau(n)t}=\dfrac{1}{o(N_{\mathrm{b}\tau(n)})}\displaystyle\sum_{n_1\in N_{\mathrm{b}\tau(n)}}U_{\mathrm{m}\tau(n)t}\\ P_{\mathrm{L}t}=P_{\mathrm{T}\Gamma(n)t}-\displaystyle\sum_{n}P_{\mathrm{m}nt}\end{cases} \tag{8}$$

式中：$N_{\mathrm{b}\tau(n)}=\{n_1|\tau(n_1)=\tau(n)\}$，为与$n$连接至同一次级节点的用户节点集；$o(\cdot)$为集合基数；$P_{\mathrm{L}t}$为台区某相总功率与该相用户功率测得值之差，即瞬时线损，而P_{en}为其中一个重要分量。

另外，以上测量值需要计及测量误差的影响，包括系统误差和随机误差。系统误差在一定时间内具有稳定性；而随机误差是一种时变的系统小干扰，通常较系统误差小1个数量级[24]。电能表是用于电能结算的计量器具，使用前必须经过全检验收，根据相关标准[25]，电网公司安装的电能表测量功率时系统误差可以控制在±1%以内，随机误差取±0.1%；测量电压时系统误差可以控制在±0.5%(±1 V)以内，随机误差一般在±0.1 V以内。另外，台区总表准确度远高于用户电能表，其测量误差可以忽略。

考虑到模型可移植性，对网络的输入特征应进行归一化处理以排除台区规模特征的影响。因此，把神经网络的输入层$\boldsymbol{X}_0$写为式(9)。

$$\boldsymbol{X}_0=\begin{bmatrix}\dfrac{\boldsymbol{U}_{\mathrm{T}\Gamma(n)}-[\bar{U}_{\tau(n)t}]_{1\times N_t}}{\max(\boldsymbol{U}_{\mathrm{T}\Gamma(n)}-\boldsymbol{U}_{\mathrm{m}n})}\\ \dfrac{[\bar{U}_{\tau(n)t}]_{1\times N_t}-\boldsymbol{U}_{\mathrm{m}n}}{\max(\boldsymbol{U}_{\mathrm{T}\Gamma(n)}-\boldsymbol{U}_{\mathrm{m}n})}\\ \dfrac{\boldsymbol{P}_{\mathrm{m}n}}{\max\boldsymbol{P}_{\mathrm{T}\Gamma(n)}}\\ \dfrac{[P_{\mathrm{L}t}]_{1\times N_t}}{\max\boldsymbol{P}_{\mathrm{T}\Gamma(n)}}\end{bmatrix} \tag{9}$$

输出方面，神经网络应当输出用户节点n的计量异常指数Y_m(m为节点n在样本集中的序号)，若超出异常指数阈值Y_{th}，即可认为存在弱关联型计量异常嫌疑，此时应派出计量现场作业人员前往核查。

1.3　样本数据的获取和增强

为提升模型准确性，样本的收集应尽可能全面，但为了增加训练的针对性，收集原始数据集后应首先剔除几类明显的非弱关联型计量异常。

1)飞走/停走，即电能表冻结功率正常但电能变化量很大或停止走字。其判据为功率测量值$P_{\mathrm{m}nt}$和电量测量值E_{m}不匹配，如式(10)所示。

$$E_{\mathrm{m}}\neq\int P_{\mathrm{m}nt}\mathrm{d}t\approx\lim_{\Delta T\to0}\sum P_{\mathrm{m}nt}\Delta T \tag{10}$$

式中：ΔT为有功功率冻结周期。

2)失压，即电能表测得的端电压值明显小于额定值220 V，此时，电能表内失压事件将被触发。其判据为电能表电压测得值长期显著低于同台区其他电能表，如式(11)所示。

$$U_{\mathrm{m}nt}\leqslant(1-\varepsilon)\max_{\Gamma(n_1)=\Gamma(n)}U_{\mathrm{m}n_1t} \tag{11}$$

式中：ε为电能表失压事件触发阈值，一般定为0.2。

3)强关联异常，通常为用户采用欠流法等方式窃电或电压/电流线反接等，此时，台区线损与电能表冻结功率具有较大关联甚至线性相关，可利用目前常用的几种反窃电技术加以甄别[5-6,9-10]。

为了避免神经网络的训练陷入局部极小值或过拟合，正常、异常样本比例应大致相当，但在实际反窃查违工作中，发现的计量异常用户远少于计量正常用户，导致样本比例严重失衡，故引入数据增强技术扩张训练集[26]。在全省范围内收集近几个月的弱关联型计量异常，从中总结几种常见类型，归纳其功率测得值与真实值的映射关系（以方程P_{mnt}形式写出）[5]，如表1所示。表中：P_{cBn}为用户n的用电容量；η_B为固定系数，通常取值为0～0.6；$\eta(t)$为时变系数；$t\in T_e$，T_e为计量异常时段，通常分为全时段异常和高峰时段异常，后者仅在用户窃电的情形下出现。

在计量正常台区的样本集中添加“人为异常”模拟异常样本[7,21]，即取正常用户的电压、功率数据，利用表1中各类型计量异常的映射关系计算发生相应计量异常时功率P_{mnt}的取值。将异常样本代入式(6)—式(9)，并加入增广训练集，可以促使网络在训练中学习样本集数据的深层特征[26]，从而抑制过拟合。

表1　弱关联型计量异常特征
Table 1　Weakly-correlated measurement anomaly feature

序号	P_{mnt}	序号	P_{mnt}
1	0	4	$\max(0,P_{cnt}-\eta_B P_{cBn})$
2	$\eta_B P_{cBn}$		
3	$\eta(t)P_{cBn}$	5	$\max(0,P_{cnt}-\eta(t)P_{cBn})$

2　计量异常识别模型

本文采用的残差神经网络是CNN[26-27]的一种改进分支，通过权值共享和跨层直连克服梯度消失问题[28-29]，结构如图1所示。

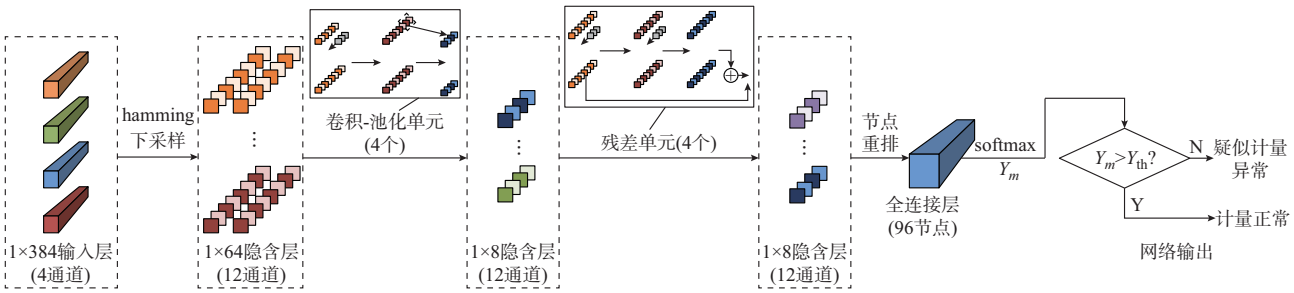

图1　残差神经网络总体结构
Fig. 1　Overall structure of residual neural network

为兼顾网络模型的计算效率和表达能力，该神经网络包含4个卷积-池化单元（由交替的卷积层和池化层组成，独立卷积层可视为与池化宽度为1的池化层配对）、4个残差单元（由带旁路的2个卷积层构成），以及1个全连接层。

2.1　神经网络的单元设计

为方便讨论，在网络的第k层，按层类型对网络基本参数作以下规定：对于全连接层，以N_k表示输出神经元个数，以w_{kij}和b_{ki}分别表示第i个神经元的输入中第j个权值和该神经元的偏置，以x_{ki}表示第i个像素值；对于卷积层，以N_k表示特征面个数，以N_{pixk}表示特征面的像素数，以N_c表示卷积核尺度，以w_{kijc}和b_{ki}分别表示第i个特征面的输入中第j个特征面的卷积核上坐标为c的权值和该特征面的偏置，其中$c\in N_c=\{(-1),(0),(1)\}$；以$x_{kie}$表示该特征面坐标为$e$的像素值，以$N_{pixk}=\{e_1,e_2,\cdots\}$表示特征面的像素集合，特征面的边缘以0填充，即像素坐标$e\notin N_{pixk}$的像素值$x_{kie}=0$。对于合并层，以N_{sk}表示需要合并的层所属序号集合。

为叙述简洁，将权值写为下列向量形式：

$$\begin{cases}\boldsymbol{W}_{kij}=[w_{kijc}] \quad c\in N_c\\ \boldsymbol{W}_k=\begin{bmatrix}\boldsymbol{W}_{k11} & \boldsymbol{W}_{k12} & \cdots & \boldsymbol{W}_{k1N_{k-1}} & b_{k1}\\ \boldsymbol{W}_{k21} & \boldsymbol{W}_{k22} & \cdots & \boldsymbol{W}_{k2N_{k-1}} & b_{k2}\\ \vdots & \vdots & & \vdots & \vdots\\ \boldsymbol{W}_{kN_k1} & \boldsymbol{W}_{kN_k2} & \cdots & \boldsymbol{W}_{kN_kN_{k-1}} & b_{kN_k}\end{bmatrix}\\ \boldsymbol{W}=[\boldsymbol{W}_1,\boldsymbol{W}_2,\cdots,\boldsymbol{W}_{N_l}]\end{cases} \tag{12}$$

式中：N_l为网络深度；$\boldsymbol{W}$为全网络权值。

在卷积层中，每个特征面在卷积运算后参与形成下一层的特征面，递推关系如式(13)所示。

$$\begin{cases}\boldsymbol{\Sigma}_{ki}=[\sigma_{kie}]=\left[\sum_{j=1}^{N_k}\sum_{c}x_{kj(e+c)}w_{kijc}+b_{ki}\right]=\\ \qquad\sum_{j=1}^{N_k}\boldsymbol{W}_{kij}*\boldsymbol{X}_{kj}+b_{ki}\boldsymbol{I}\\ \boldsymbol{X}_{k+1}=\begin{bmatrix}\boldsymbol{X}_{(k+1)1}\\ \boldsymbol{X}_{(k+1)2}\\ \vdots\\ \boldsymbol{X}_{(k+1)N_k}\end{bmatrix}=[x_{(k+1)ie}]=[f_k(\sigma_{kie})]=f_k\left(\begin{bmatrix}\boldsymbol{\Sigma}_{k1}\\ \boldsymbol{\Sigma}_{k2}\\ \vdots\\ \boldsymbol{\Sigma}_{kN_k}\end{bmatrix}\right)\end{cases} \tag{13}$$

式中：$\boldsymbol{I}$为单位矩阵；*表示卷积运算；$\boldsymbol{X}_{ki}$为第k层第i个特征面像素矩阵；σ_{kie}为其第e个像素的激励；$f_k(\cdot)$为第k层网络采用的激活函数。输出层采用softmax函数，其他采用线性整流函数以抑制梯度弥散。

这种卷积核的权值共享机制减少了神经元间的连接数，提升了网络的泛化能力。

在池化层中，每个特征面按照最大池化方式计算输出特征面的像素，具体可参照文献[26]。

在合并层中，递推式如式(14)所示。

$$x_{(k+1)ie}=\sum_{k\in N_{sk}}x_{kie} \tag{14}$$

2.2　神经网络的训练

考虑到神经网络的作用为分类器，训练目标以铰链函数定义，如式(15)所示。

$$f_{\mathrm{h}}(Y_m|Y_{tm})=\begin{cases}\max(0,1-Y_m) & Y_{tm}=1\\ \max(0,Y_m) & Y_{tm}=0\end{cases} \tag{15}$$

式中：Y_{tm}为训练集第m个样本的目标；m为样本号；Y_m为网络前馈输出的计量异常指数，反映训练过程中的动态变化。

下面利用变量上标(v)表示第v轮训练。例如，$\boldsymbol{W}_k^{(v)}$为第v轮训练后的第k层权值向量。

残差神经网络的训练基于误差反向传播原理[30]，采用梯度共轭法(L-M方法)确定第v轮训练中权值向量的变化量[31]，如式(16)所示。

$$\Delta\boldsymbol{W}^{(v)}=-\mu(\boldsymbol{J}_{\boldsymbol{W}}\boldsymbol{J}_{\boldsymbol{W}}^{\mathrm{T}}+\eta\boldsymbol{I})^{-1}\boldsymbol{J}_{\boldsymbol{W}}^{\mathrm{T}}f_{\mathrm{h}}'-f_z'(\boldsymbol{W}^{(v)}) \tag{16}$$

式中：f_{h}'为铰链函数的导数；η为超参数，用于保持黑塞矩阵$\boldsymbol{J}_{\boldsymbol{W}}\boldsymbol{J}_{\boldsymbol{W}}^{\mathrm{T}}+\eta\boldsymbol{I}$满秩；$\mu$为网络学习速率；$f_z(\cdot)$为正则函数，用于平衡网络的精度和泛化能力；$\boldsymbol{J}_{\boldsymbol{W}}$为$\boldsymbol{W}$的雅可比矩阵，网络训练的关键即在于求解$\boldsymbol{J}_{\boldsymbol{W}}$的各个元素。

以第k个卷积层为例，对于第m个训练样本，该层第i个特征面输入中，第j个卷积核上第c个权值w_{kijcm}对应的$\boldsymbol{J}_{\boldsymbol{W}}$元素如式(17)所示。

$$J_{kijcm}=\frac{\partial y_m}{\partial w_{kijc}}=\sum_{e\in N_{pixk}}\delta_{(k+1)iem}x_{kj(e+c)m}\frac{\partial f_k(\sigma_{kie})}{\partial\sigma_{kie}} \tag{17}$$

式中：$\delta_{(k+1)iem}$为像素值$x_{(k+1)iem}$的梯度，可以由式(18)得到。

$$\delta_{kiem}=\sum_{i=1}^{N_{k+1}}[\delta_{(k+1)i(e-c)m}]*\boldsymbol{W}_{kij}\frac{\partial f_k(\sigma_{kie})}{\partial\sigma_{kie}} \tag{18}$$

另外，偏置b_{kim}可视为输入“1”的权值，代入式(17)即可得到b_{kim}对应的$\boldsymbol{J}_{\boldsymbol{W}}$元素。

若第k层为池化层或合并层，则无可训练权值，梯度δ_{kiem}的递推式参照文献[26,28-29]计算。

2.3　变权值神经网络

直接按照以上方法训练网络权值，在5%～10%之间出现了训练精度提升的瓶颈(如附录D图D1(a)所示)，即使采用随机小批量梯度下降[30]、批归一化[32]等方法也无明显改善。通过分析错分样本分布发现，精度退化的主因是模型输入信息不完备，仅包含用户节点自身的电压、功率信息，而缺失了同样影响显著的节点间关联状态信息，导致神经网络无法正确地学习一些分类特征。这些信息包括台区拓扑类型、节点在台区中所处层级等，通常不被台区档案所记录且数据结构并非序列形式，无法直接输入神经网络。

针对该情况，一个自然的解决方法是为每类关联状态分别训练权值，但这种训练方式需要巨大的样本量及网络存储规模。为了低成本地计及节点间关联状态，本文提出一种变权值算法，即改变原先所有网络权值一经训练即保持不变的做法，将网络部分层级改为变权值层，样本m的权值$\boldsymbol{W}_{km}$视为多个本征权值的叠加，具体如下。

考虑到对节点间关联状态φ_m(第m个样本)进行的估计具有一定模糊性，将其写为本征态ψ_{12}依概率的线性叠加，通过映射T将每个本征态对应至一个本征权值$\boldsymbol{W}_{k\psi12}$，并将φ_m投影至变权值层的网络权值$\boldsymbol{W}_{km}$，如式(19)所示。

$$\begin{cases}T:\mathbf{R}^4\xrightarrow{T}\mathrm{FL}(N_{k+1}\times N_k)\\ T(\varphi_m)=\boldsymbol{W}_{km}\\ \varphi_m=\sum\rho_{m\psi12}\psi_{12}\\ \boldsymbol{W}_{km}=\sum\rho_{m\psi12}^2\boldsymbol{W}_{k\psi_{12}}\\ \psi_{12}=\psi_1\otimes\psi_2\in\{|00\rangle,|01\rangle,|10\rangle,|11\rangle\}\end{cases} \tag{19}$$

式中：$\mathbf{R}^4$表示4维实向量空间；$\mathrm{FL}(N_{k+1}\times N_k)$表示$N_{k+1}\times N_k$(即权值$\boldsymbol{W}_{km}$的维数)矩阵空间；$\psi_{12}$的两个维度中，$\psi_1$为台区拓扑结构分维度对应的本征态分量，$\psi_2$为节点层级分维度对应的本征态分量；$\otimes$表示直积运算；$\rho_{m\psi12}$为第$m$个样本在各本征态的概率密度投影，根据概率归一化要求，各$\rho_{m\psi12}$的平方和应为1。

概率密度投影$\rho_{m\psi12}$需要计及节点间关系状态中台区拓扑结构和节点层级两个分维度上的合成密度矩阵$\boldsymbol{\rho}_{\mathrm{tpm}}$、$\boldsymbol{\rho}_{\mathrm{locm}}$，具体计算方法见附录A。

因为辐射型拓扑中几乎不可能存在高拓扑层级的节点，本征态$|01\rangle$的系数$\rho_{m|01\rangle}$应为0。其他本征态概率密度的计算方法如式(20)所示。

$$\begin{cases}\varphi_m=\sum\limits_{\psi_{12}}\rho_{m\psi_{12}}\psi_{12}\\ \rho_{m|00\rangle}=\rho_{\mathrm{tp}00}\\ \rho_{m|01\rangle}=0\\ \rho_{m|10\rangle}=\rho_{\mathrm{tp}11}\rho_{\mathrm{loc}00}\\ \rho_{m|11\rangle}=\rho_{\mathrm{tp}11}\rho_{\mathrm{loc}11}\end{cases}\tag{20}$$

式中：$\rho_{\mathrm{tp}00}$、$\rho_{\mathrm{tp}11}$为$\boldsymbol{\rho}_{\mathrm{tp}m}$的对角元素，表示台区拓扑结构分维度上两个本征态的概率；$\rho_{\mathrm{loc}00}$、$\rho_{\mathrm{loc}11}$为$\boldsymbol{\rho}_{\mathrm{loc}m}$的对角元素，表示节点层级分维度上两个本征态的概率。

将$\rho_{m\psi12}$作为补充信息，代入式(19)可得到变权值层$\boldsymbol{W}_{km}$的叠加系数，如式(21)所示。

$$\boldsymbol{W}_{km}=|\rho_{\mathrm{tp}00}|^2\boldsymbol{W}_{k|00\rangle}+|\rho_{\mathrm{tp}11}\rho_{\mathrm{loc}00}|^2\boldsymbol{W}_{k|10\rangle}+|\rho_{\mathrm{tp}11}\rho_{\mathrm{loc}11}|^2\boldsymbol{W}_{k|11\rangle}\tag{21}$$

得到$\boldsymbol{W}_{km}$后，代入式(13)即可得到变权值层的前馈运算递推式，如式(22)所示。

$$\begin{cases}\boldsymbol{X}_{(k+1)m}=f_k\left(\begin{bmatrix}\boldsymbol{\Sigma}_{k1m}\\ \boldsymbol{\Sigma}_{k2m}\\ \vdots\\ \boldsymbol{\Sigma}_{kN_km}\end{bmatrix}\right)\\ \boldsymbol{\Sigma}_{kim}=\sum\limits_{j=1}^{N_k}\boldsymbol{W}_{kijm}*\boldsymbol{X}_{kjm}+b_{kim}\boldsymbol{I}\\ \boldsymbol{W}_{km}=\begin{bmatrix}\boldsymbol{W}_{k11m}&\cdots&\boldsymbol{W}_{k1N_{k-1}m}&b_{k1m}\\ \boldsymbol{W}_{k21m}&\cdots&\boldsymbol{W}_{k2N_{k-1}m}&b_{k2m}\\ \vdots&&\vdots&\vdots\\ \boldsymbol{W}_{kN_k1m}&\cdots&\boldsymbol{W}_{kN_kN_{k-1}m}&b_{kN_km}\end{bmatrix}\end{cases}\tag{22}$$

由于变权值层各样本不再共享权值，式(21)中以下标m加以区分，变权值神经网络用于识别的具体流程如图2所示。

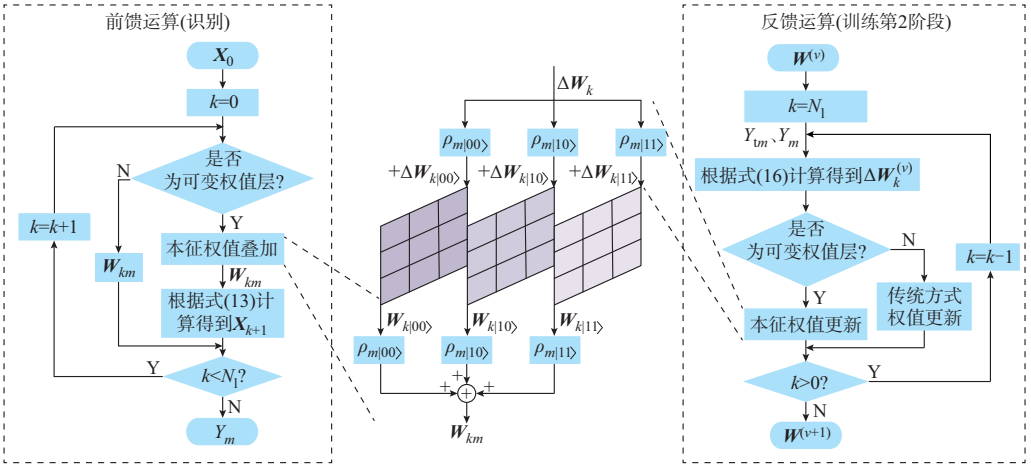

图2　变权值神经网络的识别与训练

Fig. 2　Recognition and training of neural network with variable weights

变权值神经网络的训练可分为两个阶段：

1)假定变权值层每个本征权值相等，此时，神经网络各层权值的训练方法与2.2节完全一致；

2)按式(20)计算训练集每个样本的本征态概率密度，单独训练可变权值层的每个本征权值，如图2所示，将式(18)中权重$\boldsymbol{W}_{kij}$以$\boldsymbol{W}_{kijm}$替代，且按式(16)得到变权值层权值向量的总变化量后，结合叠加系数更新每个本征权值$\boldsymbol{W}_{k\psi_{12}}^{(v)}$，如式(23)所示。

$$\boldsymbol{W}_{k\psi_{12}}^{(v)}=\boldsymbol{W}_{k\psi_{12}}^{(v-1)}+|\rho_{m\psi_{12}}|^2\Delta\boldsymbol{W}_k^{(v)}\tag{23}$$

为节约算力和存储空间，一般只需将网络后面几个宽度较小的层改为变权值层。采用变权值算法后，神经网络即可利用本征权值的叠加从$\rho_{m\psi_{12}}$获取节点间关联状态信息，从而进一步提升了网络精度。

2.4　网络权值的迭代

神经网络每一次作出识别后，若得到异常样本，应派出计量现场作业人员前往核查，判断是否确为计量异常，若现场检定未发现计量异常，则记录该用户电压和有功功率冻结值，用于更新原始样本集的计量正常部分。对于识别为计量正常但通过其他途径发现实际为计量异常的用户，应将其电压和有功功率冻结值用于更新原始样本集的计量异常部分。整体工作流程如图3所示。

对于式(9)中的网络输入，每次迭代时应将原有数据替换；由于节点间关联状态基本不会变化，式(9)中密度矩阵的更新应计及原有采样结果，以拓扑维度密度矩阵的第V轮迭代(以上标V表示)为例，更新方法如式(24)所示。

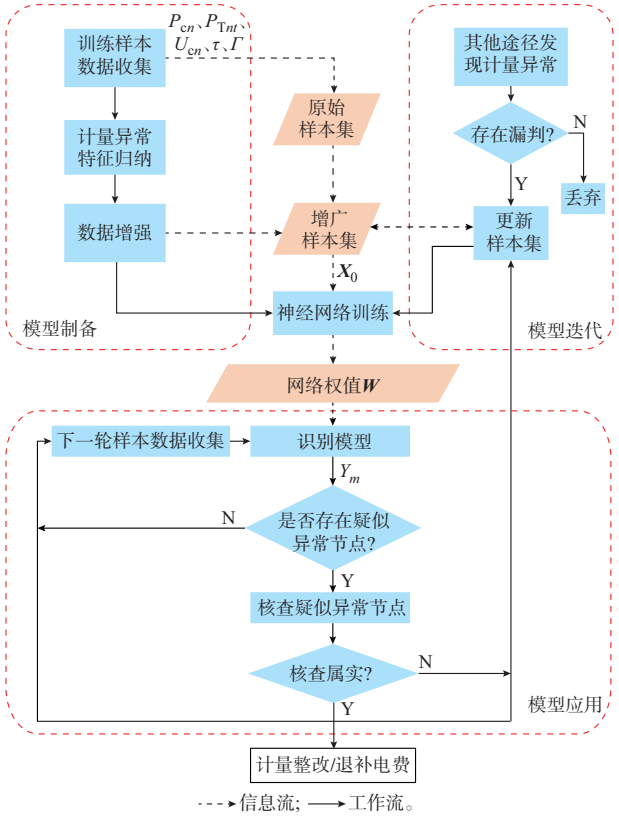

图3　计量异常识别模型的制备、应用及迭代

Fig. 3　Preparation, application and iteration of measurement anomaly recognition model

$$\begin{cases}\bar{\boldsymbol{\rho}}_{\mathrm{tp}m}^{(0)}=\boldsymbol{\rho}_{\mathrm{tp}m}^{(0)}\\ \bar{\boldsymbol{\rho}}_{\mathrm{tp}m}^{(V)}=(1-\beta)\bar{\boldsymbol{\rho}}_{\mathrm{tp}m}^{(V-1)}+\beta\boldsymbol{\rho}_{\mathrm{tp}m}^{(V)}\\ \beta=\dfrac{2|\bar{\rho}_{\mathrm{tp}01}^{(V-1)}|}{|\bar{\rho}_{\mathrm{tp}01}^{(V-1)}|+|\rho_{\mathrm{tp}01}^{(V)}|+|\bar{\rho}_{\mathrm{tp}01}^{(V-1)}+\rho_{\mathrm{tp}01}^{(V)}|}\end{cases}\tag{24}$$

式中：$\boldsymbol{\rho}_{\mathrm{tp}m}^{(V)}$为第$V$轮测得的密度矩阵，$\rho_{\mathrm{tp}01}^{(V)}$为其反对角元素；$\bar{\boldsymbol{\rho}}_{\mathrm{tp}m}^{(V)}$为前$V$轮识别周期的平均密度矩阵，$\bar{\rho}_{\mathrm{tp}01}^{(V)}$为其反对角元素；$\beta$为更新系数。

在样本集更新一定比例后，应重新训练神经网络权值。

3　算例验证

为验证弱关联型计量异常识别模型的准确性，在浙江省电力公司下辖供电所中选择40个典型低压台区（线损率稳定在5%以下，采集成功率为99.9%以上，包含居民小区、农网、写字楼及商场类型各10个），从典型低压台区随机抽取840个用户的电压及有功功率冻结值数据作为计量正常样本，连同原有全省范围收集的80个弱关联计量异常案例，构成原始样本集。再按照1.3节的方法，在实测采集数据的基础上，每个台区随机抽取19个用户模拟计量异常，共计760个计量异常样本，构成增广样本集。从原始样本集＋增广样本集中抽取计量正常/异常样本各720个共同组成模型训练集（具体见附录B），剩余样本作为测试集。

利用MATLAB软件进行本文模型有效性的证验，先验证神经网络结构及参数选择的合理性（见附录D），再与其他常见计量异常识别算法进行对比，最后在试点应用中验证模型在实际工况中的识别准确性。

3.1　识别效果对比测试

为了验证本文识别模型的整体有效性，将其与现有常用的几种窃电或计量异常检测方法进行对比，包括：SVM模型[18]、kNN模型[17]、回归分析模型[9]、Granger归因模型[8]、LSTM模型[20]、随机森林模型[22]。利用受试者测试曲线（ROC）和准确率-召回率曲线对比各模型的识别效果，结果如图4所示。

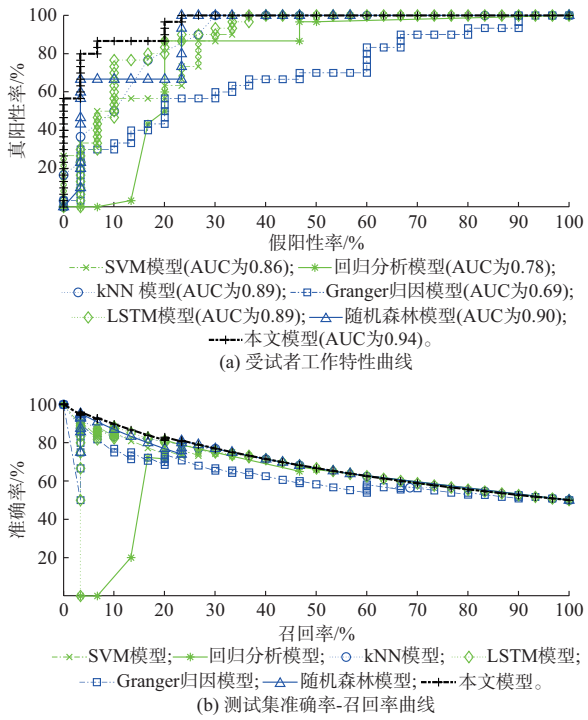

图4　各模型的识别效果对比

Fig. 4　Comparison of recognition effect of various models

图4中各模型识别结果以不同格式的曲线表示。可以发现，在准确率-召回率曲线上，回归分析和LSTM模型在测试集个别计量异常样本点上所得计量异常指数Y_m低于所有计量正常样本点，故近原点处准确率突降为0，Granger归因模型则在召回率30%～60%之间准确率低于其他模型10%左右，而代表本文模型的曲线基本包络现有常用模型。通过ROC曲线包络面积（area under ROC curve，AUC）的定量比较，可以发现只利用功率特征的回

归分析模型和Granger归因模型表现欠佳；以kNN为代表的聚类模型和以SVM及LSTM为代表的神经网络模型计及了电压、功率等数据源，整体表现较好；综合多种特征的随机森林法在传统方法中表现最佳；本文方法则在此基础上又提升了约4%。

3.2　试点应用

进一步地，为了检验本文模型在实际工况中的识别准确性，在浙江省某市选择21个经传统线性回归法分析无法找到计量异常用户的高损台区（约含1 500个用户，详见附录C），利用本文变权值残差神经网络输出44个疑似计量异常用户（为尽可能减少漏检，计量异常指数判断阈值定为0.15），派出计量稽查人员对这些用户电能表计量情况进行复核，发现其中19个用户属于假阳性，另外25个确属计量异常的用户则及时纠正；再对剩余未识别出计量异常的高损台区及纠正后仍高损的台区进行现场校验（约200个用户），发现原识别结果为计量正常的用户中有5个属于假阴性，其中，1个绕越法窃电、2个部分（50%以下）负荷绕越法窃电以及2个分流法窃电/接线错误（该类不属于本文讨论范围）。混淆矩阵如图5(a)所示。

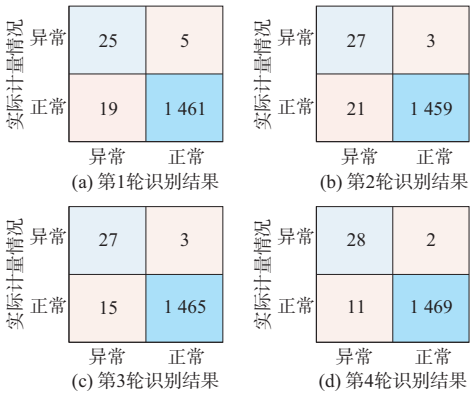

图5　权值迭代中的混淆矩阵演进

Fig. 5　Confusion matrix evolution in weight iteration

按照2.4节的方法在每个识别周期更新权值后，各轮次混淆矩阵如图5(b)至(d)所示。随着权值更新，本文计量异常识别模型的检出率具有上升趋势（5/6→14/15），而误检率也明显下降。

4　结语

为提升低压配电网线损弱关联型计量异常的识别效果，本文分析了该类计量异常的检测特征，设计了一种基于变权值残差神经网络的计量异常系数计算方法。利用算例验证了模型，得到如下结论：

1）在训练集样本量有限的条件下，本文设计的残差神经网络结构参数兼顾了精度和泛化能力的平衡，测试集精度可达94%；在测量误差的最大允许范围内，精度损失不超过5%。

2）本文模型结合了网络状态法和机器学习法的优势：相较网络状态法，本文方法无需线路阻抗、节点电压相角等未知信息作为输入；不同于传统神经网络的权值仅在训练时变化，本文提出的变权值算法在网络识别时也可以灵活调整权值以适配每个样本的节点间关联状态，提高了模型输入信息的完备性。与对照组相比，测试集识别结果的AUC指标提升了约4%。

3）台区试点结果表明，本文模型可有效识别计量现场高损台区的线损弱关联型计量异常，且随着识别轮次的迭代，准确度提升明显，但对其他类型计量异常的识别效率有限，适合与传统反窃电或计量异常识别方法优势互补。

随着台区用电信息采集终端的算力增长，本文模型的识别部分有望下装至采集终端并独立运行，模型的轻量化将是未来的研究方向。

附录见本刊网络版，点击http://www.aeps-info.com/aeps/article/abstract/20241117002，或扫描英文摘要后二维码，可阅读全文。

参 考 文 献

[1] 葛得辉，华定忠，王齐，等．基于虚拟回路阻抗的低压台区异常工况分析方法[J]．电力系统自动化，2022，46(13)：104-111.
GE Dehui，HUA Dingzhong，WANG Qi，et al. Analysis method for abnormal operation condition in low-voltage distribution station area based on virtual circuit impedance [J]. Automation of Electric Power Systems，2022，46(13)：104-111.

[2] JOKAR P，ARIANPOO N，LEUNG V C M. Electricity theft detection in AMI using customers' consumption patterns [J]. IEEE Transactions on Smart Grid，2016，7(1)：216-226.

[3] SHARMA R，JOSHI A M，SAHU C，et al. Detection of false data injection in smart grid using PCA based unsupervised learning[J]. Electrical Engineering，2023，105(4)：2383-2396.

[4] 金晟，苏盛，薛阳，等．数据驱动窃电检测方法综述与低误报率研究展望[J]．电力系统自动化，2022，46(1)：3-14.
JIN Sheng，SU Sheng，XUE Yang，et al. Review on data-driven based electricity theft detection method and research prospect for low false positive rate [J]. Automation of Electric Power Systems，2022，46(1)：3-14.

[5] ZHENG K D，CHEN Q X，WANG Y，et al. A novel combined data-driven approach for electricity theft detection [J]. IEEE Transactions on Industrial Informatics，2019，15(3)：1809-1819.

[6] 刘康，李彬，薛阳，等．基于传递熵密度聚类的用户窃电识别方法[J]．中国电机工程学报，2022，42(20)：7535-7546.
LIU Kang，LI Bin，XUE Yang，et al. User electric theft detection method based on transfer entropy density clustering[J]. Proceedings of the CSEE，2022，42(20)：7535-7546.

[7] ZANETTI M, JAMHOUR E, PELLENZ M, et al. A tunable fraud detection system for advanced metering infrastructure using short-lived patterns [J]. IEEE Transactions on Smart Grid, 2019, 10(1): 830-840.

[8] 金晟,苏盛,曹一家,等.基于格兰杰归因分析的高损台区窃电检测[J].电力系统自动化,2020,44(23):82-89.
JIN Sheng, SU Sheng, CAO Yijia, et al. Electricity-theft detection for high-loss distribution area based on granger causality analysis [J]. Automation of Electric Power Systems, 2020, 44(23): 82-89.

[9] 杨挺,徐嘉成,叶芷杉,等.基于最优变换关联因子和优化平移分裂法的窃电检测[J].电网技术,2023,47(9):3913-3923.
YANG Ting, XU Jiacheng, YE Zhishan, et al. Electricity theft detection based on optimal transform correlation factor and optimized translation splitting method [J]. Power System Technology, 2023, 47(9): 3913-3923.

[10] 殷涛,薛阳,杨艺宁,等.基于向量自回归模型的高损线路窃电检测[J].中国电机工程学报,2022,42(3):1015-1023.
YIN Tao, XUE Yang, YANG Yining, et al. Electricity theft detection of high-loss line with vector autoregression [J]. Proceedings of the CSEE, 2022, 42(3): 1015-1023.

[11] AMIN S, SCHWARTZ G A, CARDENAS A A, et al. Game-theoretic models of electricity theft detection in smart utility networks: providing new capabilities with advanced metering infrastructure [J]. IEEE Control Systems Magazine, 2015, 35(1): 66-81.

[12] CÁRDENAS A A, AMIN S, SCHWARTZ G, et al. A game theory model for electricity theft detection and privacy-aware control in AMI systems [C]// 2012 50th Annual Allerton Conference on Communication, Control, and Computing (Allerton), October 1-5, 2012, Monticello, USA: 1830-1837.

[13] 林振智,崔雪原,金伟超,等.用户侧窃电检测关键技术[J].电力系统自动化,2022,46(5):188-199.
LIN Zhenzhi, CUI Xueyuan, JIN Weichao, et al. Key technologies of electricity theft detection at consumer side [J]. Automation of Electric Power Systems, 2022, 46(5): 188-199.

[14] HUANG S C, LO Y L, LU C N. Non-technical loss detection using state estimation and analysis of variance [J]. IEEE Transactions on Power Systems, 2013, 28(3): 2959-2966.

[15] KRISHNA V B, GUNTER C A, SANDERS W H. Evaluating detectors on optimal attack vectors that enable electricity theft and DER fraud [J]. IEEE Journal of Selected Topics in Signal Processing, 2018, 12(4): 790-805.

[16] 栾文鹏,王兵,周宁,等.基于量测数据的低压配电网精确建模[J].电网技术,2015,39(11):3141-3146.
LUAN Wenpeng, WANG Bing, ZHOU Ning, et al. Modeling of LV distribution network based on metering data [J]. Power System Technology, 2015, 39(11): 3141-3146.

[17] 覃华勤,梁叶,钱奇,等.基于典型窃电用户相似性检索的窃电行为检测方法[J].电力系统自动化,2022,46(6):58-65.
QIN Huaqin, LIANG Ye, QIAN Qi, et al. Detection method of electricity theft behavior based on retrieval of similarity of typical users with electricity theft [J]. Automation of Electric Power Systems, 2022, 46(6): 58-65.

[18] NAGI J, YAP K S, TIONG S K, et al. Nontechnical loss detection for metered customers in power utility using support vector machines [J]. IEEE Transactions on Power Delivery, 2010, 25(2): 1162-1171.

[19] ZHENG Z B, YANG Y T, NIU X D, et al. Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids [J]. IEEE Transactions on Industrial Informatics, 2018, 14(4): 1606-1615.

[20] 邹念,张颖,苏盛,等.基于小时尺度周期特征自编码器的用户窃电识别方法[J]. 电网技术,2023,47(6):2558-2565.
ZOU Nian, ZHANG Ying, SU Sheng, et al. User electric theft detection method based on hour scale periodic feature LSTM-transformer [J]. Power System Technology, 2023, 47(6): 2558-2565.

[21] 卿柏元,陈珏羽,李金瑾,等.基于CNN-LG模型的窃电行为检测方法研究[J].湖南大学学报(自然科学版),2022,49(8):138-148.
QING Boyuan, CHEN Jueyu, LI Jinjin, et al. Research on detection method of electricity theft behavior based on CNN-LG model [J]. Journal of Hunan University (Natural Sciences), 2022, 49(8): 138-148.

[22] 游文霞,申坤,杨楠,等.基于Bagging异质集成学习的窃电检测[J].电力系统自动化,2021,45(2):105-113.
YOU Wenxia, SHEN Kun, YANG Nan, et al. Electricity theft detection based on Bagging heterogeneous ensemble learning [J]. Automation of Electric Power Systems, 2021, 45(2): 105-113.

[23] YAN Z Z, WEN H. Electricity theft detection base on extreme gradient boosting in AMI [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 2504909.

[24] 电测量设备(交流)特殊要求 第21部分:静止式有功电能表:GB/T 17215.321—2021[S].北京:中国标准出版社,2021.
Electricity metering equipment (AC): particular requirements: Part 21: static meters for active energy: GB/T 17215.321—2021[S]. Beijing: Standards Press of China, 2021.

[25] 单相智能电能表技术规范: DL/T 1487—2015[S].北京:中国电力出版社,2015.
Technical specification for single phase smart electricity meters: DL/T 1487—2015[S]. Beijing: China Electric Power Press, 2015.

[26] 金阳忻,徐永进,黄小琼.基于卷积神经网络的电能表测得值置信区间研究[J].中国电机工程学报,2021,41(19):6630-6641.
JIN Yangxin, XU Yongjin, HUANG Xiaoqiong. Confidence coefficient calculation model of the energy meter measurement based on convolutional neural network [J]. Proceedings of the CSEE, 2021, 41(19): 6630-6641.

[27] 郑智聪,王红,齐林海.基于深度学习模型融合的电压暂降源识别方法[J].中国电机工程学报,2019,39(1):97-104.
ZHENG Zhicong, WANG Hong, QI Linhai. Recognition method of voltage sag sources based on deep learning models' fusion[J]. Proceedings of the CSEE, 2019, 39(1): 97-104.

[28] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-

30, 2016, Las Vegas, USA: 770-778.
[29] SHAFIQ M, GU Z Q. Deep residual learning for image recognition: a survey[J]. Applied Sciences, 2022, 12(18): 8972.
[30] 金阳忻.基于模糊神经网络的电能表误差超差风险预测模型[J].电网技术,2019,43(6):1962-1968.
JIN Yangxin. Electrical power meter error overproof calculation model based on fuzzy neural network[J]. Power System Technology, 2019, 43(6): 1962-1968.
[31] DAN FORESEE F, HAGAN M T. Gauss-Newton approximation to Bayesian learning[C]// Proceedings of International Conference on Neural Networks (ICNN'97), June 12-12, 1997, Houston, USA: 1930-1935.
[32] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]// 32nd International Conference on Machine Learning: ICML 2015, July 6-11, 2015, Lile, France.

金阳忻(1991—),男,通信作者,硕士,主要研究方向:电网系统的控制与计量技术。E-mail:1073323678@qq.com
徐永进(1970—),男,正高级工程师,主要研究方向:电力计量技术。E-mail:xuyongjin@yfzx.zj.sgcc.com
汪金荣(1989—),女,硕士,主要研究方向:用电信息采集技术。E-mail:755873699@qq.com

(编辑　冯慧敏)

Weakly-correlated Measurement Anomaly Recognition of Low-voltage Distribution Network Based on Neural Network with Variable Weights

JIN Yangxin, *XU Yongjin*, *WANG Jinrong*
(Marketing Service Center (Metrology Center) of State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310000, China)

Abstract: The electric energy meter, as an important data source in the low-voltage distribution network, plays a crucial role in ensuring the fairness of electricity transactions through the management of measurement anomalies. Therefore, a model of weakly-correlated measurement anomaly recognition of line loss based on neural network with variable weights is designed, whose inputs are freezing values of power and voltage on the electric energy meter, as well as partial archival information. The main part of the model is the residual neural network to calculate the measurement anomaly index. First, aimed at the accuracy degradation caused by insufficient input information, a neural network algorithm with variable weights is proposed, in which the network weights are no longer considered to remain constant after training, instead, some of them are regarded as variable weight layers formed by the superposition of several eigenstate weights. Then, through the node correlation state that is not able to be directly used as network input, the superimposing coefficients are calculated via composite density matrices with dimensions, which significantly improves the model accuracy. Finally, by using the augmented sample set for training and testing, the validity of the residual neural network recognition model with variable weights is comparatively verified. Furthermore, the model is tested and applied to the control of a high-loss distribution station area in a city in Zhejiang Province of China to confirm its detection effect in actual working conditions.

This work is supported by National Key R&D Program of China (No. 2023YFC3807100).

Key words: distribution network; electric energy meter; measurement anomaly; residual neural network; variable weight algorithm