

基于 DTL 与 DC-ResNet 的非侵入式多标签负荷识别方法^①

潘国兵^② 王振涛 欧阳静 王杰 高亚栋 尹康

(浙江工业大学特种装备制造与先进加工技术教育部/浙江省重点实验室 杭州 310014)

摘要 针对目前负荷识别中存在的人工挖掘特征困难的问题,同时为了进一步提升识别精度,提出了一种基于深度转换学习(DTL)与双通道深度残差神经网络(DC-ResNet)的非侵入式多标签负荷识别方法。首先运用改进的 DTL 从原始的负荷数据中自动提取有效的负荷特征,可以达到降维的效果。然后将负荷数据按时间滑窗生成特征图作为 DC-ResNet 的输入,利用卷积核自动提取时间尺度上的有效特征。DC-ResNet 的一条通道用于提取大类特征预测负荷的开关状态,另一条通道用于提取小类特征预测负荷的运行模式,综合两条通道的输出可以得到最后的多标签分类结果。实验结果表明,经 DTL 提取后的负荷数据更易被识别,DC-ResNet 在总体和单一设备的识别上都具有更好的效果,而且模型所需的训练时间较短。

关键词 双通道深度残差神经网络(DC-ResNet); 深度转换学习(DTL); 非侵入式负荷识别; 多标签分类

0 引言

建设泛在电力物联网作为“三型两网,世界一流”战略的重要组成部分,通过连接电力用户及其设备、电网企业及其设备、发电企业及其设备、供应商及其设备以及人和物,搭建了一个以电网为枢纽的数据共享平台^[1-2]。实现电力负荷的分类识别有助于了解电力系统的负荷组成、优化电力系统的规划调度,更有助于加强电网、用户、设备三者之间的泛在联系,对于泛在电力物联网的发展具有重要意义。

现有的负荷识别方法主要分为侵入式和非侵入式两类^[3]。相较于传统的侵入式识别方法,非侵入式识别方法具有硬件成本低、安装维护方便等优势,近年来受到了人们的广泛关注,并取得了诸多研究成果。文献[4]提出了一种基于改进隐式马尔科夫(hidden Markov model,HMM)的负荷识别方法,利用

人工免疫算法和增量学习对 HMM 模型进行双重优化。文献[5]提出了一种基于改进支持向量机(support vector machine,SVM)的负荷识别方法,以高斯动态弯曲(Gaussian dynamic time warping,GDTW)核作为 SVM 模型的核函数。上述文献都对机器学习算法进行了改进,使其在负荷识别中能有更好的表现,但使用人工方式提取的负荷特征会限制模型的识别效果,特别是在负载情况相对复杂的场景中。随着深度学习的发展,神经网络开始用于电力负荷的分解与识别当中。文献[6]利用广义回归神经网络(general regression neural network,GRNN)对暂态数据进行特征提取与负荷识别。文献[7]利用深度置信网络(deep belief network,DBN)提取负荷数据中的高级特征,并对电力负荷进行分类识别。文献[8]将典型家电的电流数据转换为图片形式,使用卷积神经网络(convolutional neural network,CNN)提取其中的图像特征并进行负荷辨识。文

① 国家重点研发计划(2017YFA0700301)和浙江省重点研发计划(2018C01081)资助项目。

② 男,1978 年生,博士,教授;研究方向:分布式新能源并网,电力负荷识别与分解;联系人,E-mail: WangZT_47@163.com
(收稿日期:2020-06-28)

献[9]从高频的采样数据中提取 V-I 轨迹图像特征与功率数值特征, 分别使用 CNN 与 BP 神经网络对图像特征与数值特征进行高级特征提取, 融合两类特征输入 BP 神经网络进行负荷辨识。上述文献通过深度学习的方法充分提取了负荷数据中的有效特征, 但缺少对数据时间相关性的考虑, 需要人为添加时间特征来确保识别效果。随着电网中负荷种类与设备数量的不断增加, 部分学者开始研究多种设备同时运行下的识别方法。文献[10]将负荷识别看作是一个多标签分类问题, 采用以支持向量机和决策树为基础分类器的算法, 充分考虑了多种设备并行时的情况, 但对于训练集中未出现过的负荷组合没有辨识能力。文献[11]使用基于 K 近邻(K-nearest neighbours, K-NN)改进的 ML-KNN 多标签分类算法, 进一步提高了识别的准确率。文献[12]利用有功功率、无功功率、视在功率、电流和谐波特征构造负荷分解的目标函数, 并通过多目标进化(multi-objective evolutionary algorithm, MOEA)与多准则决策算法进行求解, 对于并行负荷的识别率较高, 但模型的使用条件过于苛刻。

负荷数据属于典型的时间序列数据, 它在时间尺度上的变化规律往往可以体现不同设备之间的差异性, 这种差异在设备投切的暂态阶段尤为明显。目前大部分识别方法还是以设备的瞬时特征作为主要的分类依据, 少部分识别方法虽然通过人为的方式添加了时间特征, 但是无法体现完整的时序信息。针对现有方法的不足, 文中提出了一种基于深度转换学习(deeping transform learning, DTL)与双通道深度残差神经网络(double channel-deep residual neural network, DC-ResNet)的非侵入式多标签负荷识别方法。为了进一步提升识别效果, 同时简化识别网络, 文中提出了一种基于改进 DTL 的特征提取算法, 可以从原始的负荷数据中自动提取有效的特征信息, 并且能够达到降维的效果。为了自动提取时间尺度上的有效特征, 文中提出了一种基于 DC-ResNet 的多标签负荷识别算法, 将降维后的负荷数据按时间滑窗生成连续的特征图, 分别输入两个通道 Channel 01 与 Channel 02。前者用于提取大类特征, 预测负荷的开关状态, 后者用于提取小类特征, 预测负荷的

运行模式。综合两条通道的输出可以获得不同设备处在每种运行模式下的概率, 进而得到最后的多标签分类结果。实验结果表明, 经 DTL 提取和降维后的负荷数据更易识别, DC-ResNet 无论是在总体的多标签识别上, 还是在单一设备的多类别识别上均优于其他方法, 而且模型所需的训练时间较短。

1 基于深度转换学习的特征提取

随着电力设备传感技术与非侵入式监测技术的发展, 能够采集到的负荷特征正在不断增加。但不是所有的特征都有利于识别, 过高的维度会增加模型的计算量, 所以在负荷识别前对原始特征进行筛选或者降维变得尤为重要。常见的方法包括主成分分析(principal components analysis, PCA)、线性判别分析(linear discriminant analysis, LDA)、堆叠自动编码器(stacked autoencoder, SAE)和深度置信网络(DBN)等。

转换学习(transform learning, TL)作为字典学习的一种衍生算法, 已在信号处理、图像降噪、特征提取等领域取得了广泛应用, 其主要思想是通过一个优化的转换矩阵 T , 将原始数据 X 解析成系数矩阵 Z , 即 $TX \cong Z$ 。学习指定大小的转换矩阵可以达到降维的效果, 并且能够在一定程度上挖掘特征中的隐含信息。文献[13]在单层 TL 模型的基础上, 提出了一种深度转换学习(DTL)算法, 通过增加转换矩阵的数量, 进一步提升了模型对特征的提取和降维能力, 效果优于 SAE、DBN 等方法^[13]。但 DTL 目标函数的不同惩罚项之间可能存在数量级上的差异, 系数的取值范围较广难以调优。本文针对上述问题, 提出了一种改进的深度转换学习算法, 修改了目标函数的各项系数与负对数正定惩罚项, 并对转换矩阵的更新公式做出了相应的调整。

深度转换学习的模型结构类似于人工神经网络, 如图 1 所示, 通过多个转换矩阵 $T_1 \sim T_D$, 将原始数据 X 逐层解析至最终的系数矩阵 Z , 即 $T_D \varphi(\cdots T_{2\varphi}(T_1 X)) \cong Z$ 。其中, $\varphi(\cdot)$ 表示激活函数, 能够在确保转换矩阵相互独立的同时增加模型的非线性, 为了获得较快的收敛速度文中取 tanh 函数。

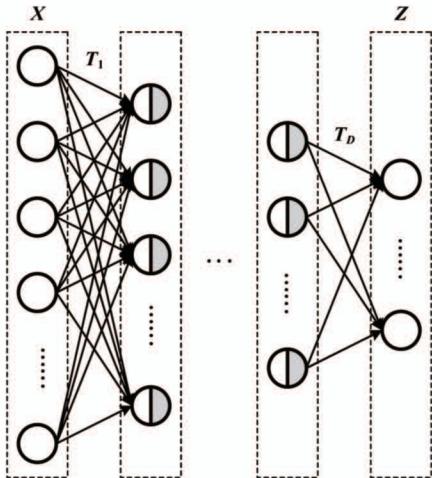


图 1 深度转换学习示意图

DTL 算法的目标函数可以表示为

$$\min_{T_1, \dots, T_D, Z} \|T_D \varphi(\cdots T_d \cdots \varphi(T_1 X)) - Z\|_F^2 \quad (1)$$

式中, X 表示原始的训练数据矩阵, $X \in \Re^{M_0 \times N}$, M_0 表示原始的特征维度, N 表示样本数量; T_d 表示第 d 个转换矩阵, $T_d \in \Re^{M_d \times M_{d-1}}$, M_d 表示 X 经过 $T_1 \sim T_d$ 转换后的特征维度; $d = 1, 2, \dots, D$, D 表示转换矩阵的数量, 即 DTL 模型的深度; Z 表示最终的系数矩阵, $Z \in \Re^{M_D \times N}$ 。

上述目标函数属于一个多变量优化问题, 通常使用梯度法来进行求解, 但变量 $T_1 \sim T_D$ 所对应的子问题并不属于最小二乘问题, 无法直接给出解析形式的解。因此文献[13]引入了中间变量 $Z_0 \sim Z_D$, 如式(2)所示, 采用贪婪算法每次只计算一层的转换矩阵与系数矩阵, 并且将得到的系数矩阵作为下一层的输入, 以此类推, 可以获得全部的变量矩阵。

$$\begin{cases} Z_0 = X & d = 0 \\ Z_d = \varphi(T_d Z_{d-1}) & 0 < d < D \\ Z_D = Z & d = D \end{cases} \quad (2)$$

由于直接使用式(2)容易出现退化问题, 因此需要增加约束条件, 以确保变量矩阵在迭代过程中获得稳定的非平凡解^[14]。文中还对所有惩罚项进行了均值处理, 将它们缩放到同一个数量级上, 更有助于系数的调优。各层变量矩阵的求解方法类似, 在得出第 $d-1$ 层的系数矩阵 Z_{d-1} 后, 第 d 层的目标函数可以表示为

$$\min_{T_d, Z_d} \frac{1}{NM_d} \|T_d Z_{d-1} - \varphi^{-1}(Z_d)\|_F^2$$

$$+ \frac{\xi}{M_d M_{d-1}} \|T_d\|_F^2 - \frac{\lambda}{M_d^2} \log(|\det(T_d T_d^T)|) \quad (3)$$

式中, $\|\cdot\|_F^2$ 表示稳定性惩罚项, 能够避免精确稀疏表示时发生“尺度模糊”^[15]; $-\log(|\det(T_d T_d^T)|)$ 表示改进后的负对数正定惩罚项。文献[13]中该项为 $-\log(\det(T_d))$, 由于 T_d 并非方阵无法对其求行列式, 而且 \log 函数的输入可能为负数, 因此文中对 T_d 右乘自身转置将其变回方阵, 同时对行列式取绝对值以保证 \log 函数输入的非负性。采用梯度法可以将式(3)拆分成以下两个子问题, 交替更新进行求解。

$$\begin{aligned} \min_{Z_d} & \|T_d Z_{d-1} - \varphi^{-1}(Z_d)\|_F^2 \\ \min_{T_d} & \frac{1}{NM_d} \|T_d Z_{d-1} - \varphi^{-1}(Z_d)\|_F^2 \\ & + \frac{\xi}{M_d M_{d-1}} \|T_d\|_F^2 - \frac{\lambda}{M_d^2} \log(|\det(T_d T_d^T)|) \end{aligned} \quad (4)$$

其中, Z_d 的更新公式较为简单, 即 $Z_d^* = \varphi(T_d Z_{d-1})$; T_d 的更新公式可以通过非线性共轭梯度法^[16]求得:

$$\begin{cases} Z_{d-1} Z_{d-1}^T + \frac{\xi}{M_d M_{d-1}} E = L_d L_d^T \\ L_d^{-1} Z_{d-1} Z_d^T = U_d \Sigma_d V_d^T \\ T_d^* = \frac{V_d}{2} (\Sigma_d + (\Sigma_d \cdot \Sigma_d + \frac{4\lambda}{M_{d-1}^2} E')^{1/2})^T U_d^T L_d^{-1} \end{cases} \quad (5)$$

其中, L_d 表示 Cholesky 分解所得的实对称正定矩阵; Σ_d 表示 SVD 分解所得的奇异值矩阵, U_d, V_d 分别表示对应的左、右奇异矩阵; E 表示单位矩阵; E' 表示 E 根据 Σ_d 的大小进行补零后的矩阵, 即 $E' = [E, \mathbf{0}]$ 。

对于新输入的测试数据 x , 经过 DTL 模型提取和降维后的特征数据 z 可以表示为 $z = T_{D\varphi}(\cdots T_{2\varphi}(T_1 x))$ 。

2 基于双通道深度残差神经网络的多标签负荷识别

2.1 深度残差神经网络

卷积神经网络通过局部连接和共享权值的方

式,利用卷积层和池化层直接从原始数据中获取信息,自动提取数据的局部特征,并建立完备的特征向量。

从理论上来说,增加网络深度有助于获得更多的特征信息,提升模型的准确率,然而过深的网络容易出现退化的问题。文献[17]在卷积神经网络的基础上提出了深度残差神经网络(deep residual network, ResNet),改善了模型的退化问题,进一步提升了准确率。

典型 ResNet 的残差单元如图 2 所示,输入 x 经过两个卷积层的变换得到 $F(x)$,同时也直接连接至两层之后,则残差单元输出 $H(x) = F(x) + x$ 。如果某一个卷积层的输出已经较好地拟合了期望结果,那么多加入一个卷积层不会使得模型变得更差,因为该层的输出将被直接短接至两层之后,相当于直接学习了一个恒等映射,而跳过的两层只需要拟合上个卷积层的输出与目标之间的残差即可。

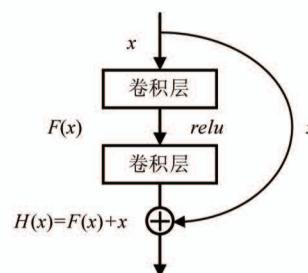


图 2 残差单元

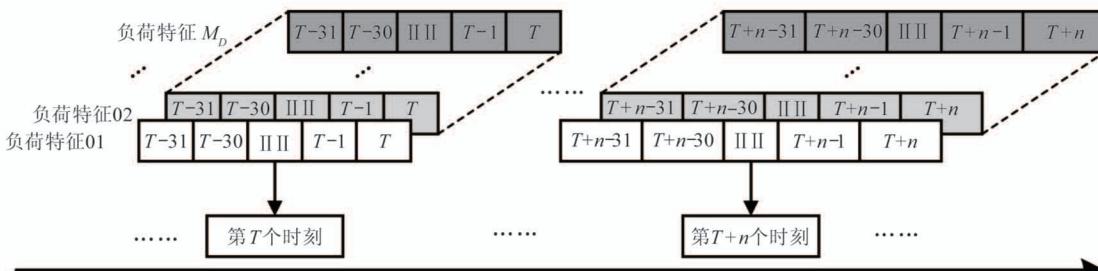


图 3 多通道的时间序列负荷特征图

文中提出的基于 DC-ResNet 的多标签负荷识别模型主要由两个通道 Channel 01 与 Channel 02 组成,如图 4 所示。两者前半部分的网络结构相同,在训练时可以共享权值。不同之处在于前者的输出为所有负荷的大类概率,用于识别负荷是否处于开启状态,而后的输出为所有负荷的小类概率,用于识别负荷处于哪种运行模式。综合两条通道的输出可

2.2 基于 DC-ResNet 的多标签负荷识别

由于负荷数据在时间尺度上的变化规律往往可以体现不同设备之间的差异,仅通过人工的方式很难充分挖掘出其中的规律,因此文中提出了一种基于双通道深度残差神经网络(DC-ResNet)的多标签负荷识别算法,以多通道的负荷特征图作为输入,通过 ResNet 自动提取负荷数据中的时序信息,利用卷积核深入挖掘特征图中非连续数据之间的潜在关系。随着网络的加深,感受野变大,能够提取的时间范围更宽,语义信息更加丰富。

不同于一般卷积神经网络输入的二维图像数据,负荷数据本质上属于一维的时间序列数据,需要采用特殊的手法生成适用于卷积神经网络的特征图。为了能够更好地耦合特征信息,文中借鉴了二维图像的数据结构,将同一时刻不同特征的负荷数据串联成多个通道,类似于图像中的 3 个原色通道,进而形成一个全新的多通道时间序列数据。然后运用滑动窗口的方式依次提取特征图,为了方便后续网络的计算,设置滑动窗口的长度为 64,步长为 1,则单位特征图的尺寸为 $1 \times 64 \times M_D$,生成的特征图也按时间 t 进行排列,如图 3 所示。图中 T 表示监测设备采样的某一个具体时刻; $T+n$ 表示 T 时刻往后 n 个采样点所对应的时刻。

以得到最后的多标签分类结果。由于需要预测的负荷种类与运行模式较多,若直接使用单通道的 ResNet 预测小类概率,网络的复杂度过高,因此文中使用两条通道,相对复杂的通道用于预测大类概率,而相对简单的通道用于预测小类概率,这样能够减少网络的计算量。DC-ResNet 的损失函数由两部分组成,相比于单通道的 ResNet,可以更好地监督网络训

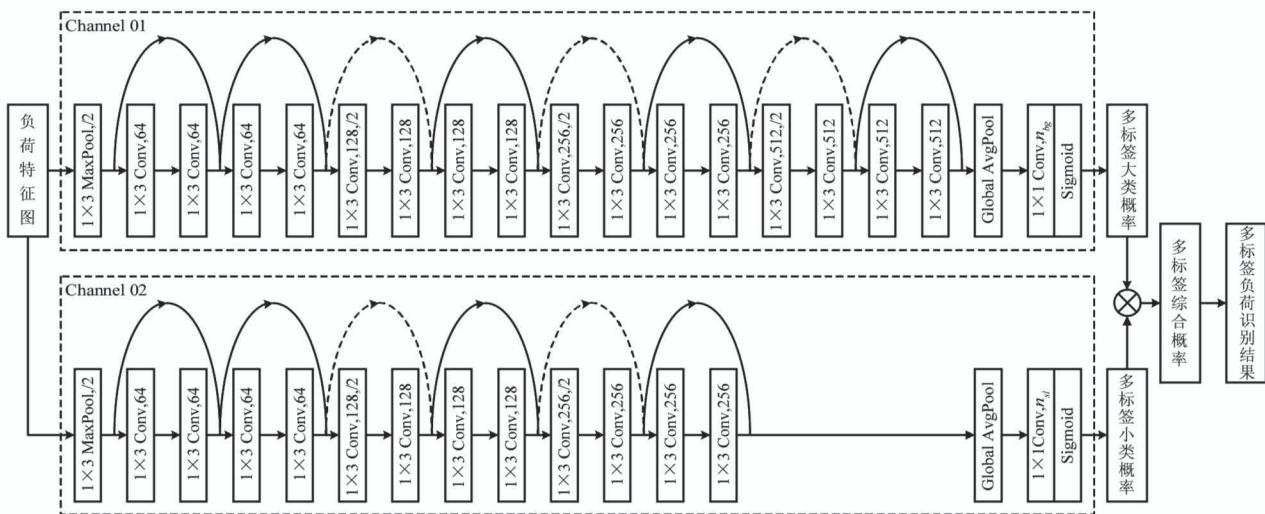


图 4 基于 DC-ResNet 的多标签负荷识别的模型结构

练,进而加快网络收敛,并且能够在一定程度上缓解梯度消失带来的影响。

Channel 01 的网络结构参考 ResNet18,共设计有 4 个阶段(stage),每个阶段内包含 2 个残差单元,每个单元由 2 个卷积核数量相等的卷积层(Conv)组成。从第 2 个阶段开始,设置每个阶段的第一个卷积层的步长为 2,这样可以在计算过程中缩小特征图的尺寸,减轻网络的计算量。为了防止信息量丢失过多,需要在特征图缩小的同时增加通道数量,故 4 个阶段的卷积核数量依次为 64、128、256 和 512。为了充分利用现有的负荷数据,文中设置残差单元内的卷积核大小均为 1×3 。由于需要连接不同卷积核数量的残差单元,因此有些单元不能直接使用恒等映射,图中实线箭头表示恒等映射,而虚线箭头表示经过卷积核大小为 1×1 、步长为 2 的卷积层。模型中使用的池化层包括最大池(Max-Pool)与全局平均池(GlobalAvgPool)。最大池化层的大小为 1×3 ,步长为 2,用于筛选重要特征和剔除冗余特征;全局平均池化层的大小与处理的特征图大小相同,用于综合利用特征信息。经过卷积、池化和残差操作后,能够得到一个 512 维的向量,即为该通道自动提取的大类特征。之后将上述特征输入一个卷积核大小为 1×1 、数量为大类类别数 n_{bg} 的卷积层,并设置激活函数为 sigmoid 函数,能够输出所有负荷开关状态的预测概率。

Channel 02 的结构与 Channel 01 类似,省略了

卷积核数量为 512 的阶段,并把最后一个卷积层的卷积核数量改为小类的类别数 n_{sl} 。 n_{sl} 与 n_{bg} 之间的关系为 $n_{sl} = \sum_{b=1}^{n_{bg}} n_{sl}^b$, 其中 n_{sl}^b 表示第 b 种负荷的运行模式数量。Channel 02 用于自动提取小类特征,输出所有负荷运行模式的预测概率。

最后融合两条通道的输出结果,将大类概率 P_{bg} 与其所对应的小类概率 P_{sl} 分别相乘,以获得所有负荷运行模式的综合预测概率 P ,如图 5 所示。当预测概率大于 0.5 时,则认为该负荷正处于当前预测的运行模式之下,反之则没有。如果在同一个负荷中,存在多种运行模式的预测概率都大于 0.5 的情况,那么选取其中概率最大的运行模式作为该负荷最终的预测状态。

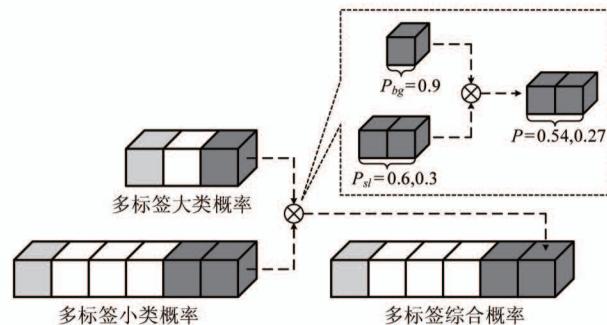


图 5 基于双通道的多标签综合概率

3 算例分析

本算例中使用的数据来自实验室搭建的模拟平

台,识别对象包括 11 种常见的家用电器,即电风扇、微波炉、热水壶、白炽灯、节能灯、饮水机、电吹风、电视机、变频空调、打印机和笔记本电脑。为验证文中方法的科学性与可靠性,大部分电器都包含了不同的运行模式,并加入了运行过程中特征会明显变化的变频空调,以增加识别难度。实验平台的采样周期为 1 s,采集的负荷特征包括电流、电压、有功功率、无功功率、功率因数以及电压电流的 51 次谐波数据,共计 107 维。采集的负荷数据先使用 DTL 进行特征提取和降维,再使用 DC-ResNet 进行多标签负荷识别。最后将实验结果与参数调优的 ResNet、BP-ML、BR-SVM 和 ML-KNN 的结果进行对比分析。

3.1 评价指标

传统二分类问题的输出结果只有正类和负类两种。混淆矩阵作为评估二分类器可信度的一个基本工具^[18],如表 1 所示,结果分为 4 类:真阳性(true positive, TP),将正类预测为正类数;伪阳性(false positive, FP),将负类预测为正类数;真阴性(true negative, TN),将负类预测为负类数;伪阴性(false negative, FN),将正类预测为负类数。

表 1 混淆矩阵

真实状态	预测状态	
	正类	负类
正类	TP	FN
负类	FP	TN

在混淆矩阵的基础上可以推导出二分类器常用的评价指标,即 F1 分数(F1-Score)。

$$\begin{cases} P(TP, FP) = \frac{TP}{TP + FP} \\ R(TP, FN) = \frac{TP}{TP + FN} \\ F1(P, R) = \frac{2 \times P \times R}{P + R} \end{cases} \quad (6)$$

其中, $F1(\cdot)$ 表示 F1 分数, $P(\cdot)$ 表示查准率, $R(\cdot)$ 表示查全率。F1 分数其实是基于查准率与查全率的调和平均,能同时兼顾二分类器的精确率与召回率。对于多标签和多类别分类器,文中采用“宏 F1”(Macro-F1)分数和“微 F1”(Micro-F1)分数作为评价指标,分别从宏观与微观的角度对不同负

荷的 F1 分数进行平均。

$$\begin{cases} P_{mac} = \frac{1}{n_{bg}} \sum_{b=1}^{n_{bg}} \frac{1}{n_{sl}} \sum_{s=1}^{n_{sl}^b} P(TP_{bs}, FP_{bs}) \\ R_{mac} = \frac{1}{n_{bg}} \sum_{b=1}^{n_{bg}} \frac{1}{n_{sl}} \sum_{s=1}^{n_{sl}^b} R(TP_{bs}, FN_{bs}) \\ F1_{mac} = F1(P_{mac}, R_{mac}) \end{cases} \quad (7)$$

$$\begin{cases} P_{mic} = P\left(\frac{1}{n_{bg}} \sum_{b=1}^{n_{bg}} \frac{1}{n_{sl}} \sum_{s=1}^{n_{sl}^b} TP_{bs}, \frac{1}{n_{bg}} \sum_{b=1}^{n_{bg}} \frac{1}{n_{sl}} \sum_{s=1}^{n_{sl}^b} FP_{bs}\right) \\ R_{mic} = R\left(\frac{1}{n_{bg}} \sum_{b=1}^{n_{bg}} \frac{1}{n_{sl}} \sum_{s=1}^{n_{sl}^b} TP_{bs}, \frac{1}{n_{bg}} \sum_{b=1}^{n_{bg}} \frac{1}{n_{sl}} \sum_{s=1}^{n_{sl}^b} FN_{bs}\right) \\ F1_{mic} = F1(P_{mic}, R_{mic}) \end{cases} \quad (8)$$

其中, $F1_{mac}$ 和 $F1_{mic}$ 表示 Macro-F1 与 Micro-F1 分数; P_{mac} 和 R_{mac} 表示 $F1_{mac}$ 对应的查准率与查全率; P_{mic} 和 R_{mic} 表示 $F1_{mic}$ 对应的查准率与查全率; TP_{bs} 、 FP_{bs} 和 FN_{bs} 分别表示第 b 种负荷的第 s 种运行模式的真阳性、假阳性和假阴性。如果 $F1_{mac}$ 与 $F1_{mic}$ 的分数越高,说明分类器的分类效果越好,对应负荷识别算法的辨识性能越佳。

3.2 数据处理

(1) 数据标准化

采用最大-最小标准化方法对原始的负荷数据进行线性变换,将数据大小约束在 [0, 1] 区间。对于第 m_0 项负荷特征而言,则有:

$$x_{m_0n}^* = \frac{x_{m_0n} - x_{m_0}^{\min}}{x_{m_0}^{\max} - x_{m_0}^{\min}} \quad (9)$$

式中, $x_{m_0n}^*$ 表示该特征标准化后的数值; $x_{m_0}^{\max}$ 表示该特征数据的最大值; $x_{m_0}^{\min}$ 表示该特征数据的最小值。

(2) 数据集划分

对于标准化后的负荷数据,取其中的 70% 作为训练集,剩下的 30% 作为测试集,并保证两个数据集中的多标签分布相近。

3.3 实验结果分析

(1) 负荷特征的提取与降维

采用控制变量法对 DTL 模型进行逐步调优,在固定分类器不变的条件下,测试不同惩罚系数与模型层数对识别效果的影响。多标签分类器选用基础的 BP-ML,以尽量突出 DTL 模型的特征提取能力。对于不同深度的 DTL 模型采用网格搜索法寻找最

优的参数组合,参数包括稳定性系数 ξ 与负对数正定系数 λ ,取值范围为 [0,1],网格间隔为 0.05,对比结果如表 2 所示。

表 2 DTL 模型不同参数与结构的对比结果

层数	维度	最优 λ	最优 ξ	Macro-F1	Micro-F1
0	105			0.80506	0.86802
1	100	0.95	0.9	0.80597	0.86829
2	90	0.6	1	0.81065	0.87202
3	80	1	0.95	0.82147	0.88166
4	70	0.85	0.8	0.79801	0.85953
5	60	0.9	0.95	0.79060	0.85287
6	50	0.65	0.75	0.77540	0.83883

从表 2 可以看出,不同深度的 DTL 模型有着各自对应的最优参数组合。适当增加模型深度,可以逐步提取更深层次的有效特征,有助于提升多分类器的识别能力,同时降低特征维度。但是当模型的深度增加至 4 层时,多分类器的识别效果开始下降,说明过度压缩维度会导致数据中原有的重要信息丢失。实验表明对于本算例中的负荷数据,3 层 DTL 模型的提取效果相对较好,降维后的 80 维特征数据更易于后续网络的分类识别。

(2) 多标签负荷识别

将降维后的负荷数据生成特征图,分别输入 DC-ResNet 与 ResNet 进行训练,同时将降维后的负

荷数据直接输入 BR-SVM、ML-KNN 与 BP-ML 进行训练。完成后对测试集数据进行负荷识别,计算评价指标并进行比较分析,如表 3 所示。

表 3 总体的多标签识别结果

模型名称	Macro-F1	Micro-F1
DC-ResNet	0.91721	0.96241
ResNet	0.89209	0.94606
BP-ML	0.82147	0.88166
BR-SVM	0.84675	0.90472
ML-KNN	0.83463	0.89481

从表 3 中可以看出,本文方法的总体评价指标高于其他模型,Macro-F1 与 Micro-F1 分数分别为 0.91721 和 0.96241, 高于分数次之的 ResNet 约 2%。表 4 为不同设备的识别效果汇总表。

从表 4 中可以看出,本文方法对于单一设备的评价指标也基本高于其他模型,对于较难识别的变频空调,其 Macro-F1 与 Micro-F1 分数达到了 0.86012 和 0.89363。双通道的 DC-ResNet 相比于单通道的 ResNet 具有更好的识别效果。由于 DC-ResNet 可以提取时间尺度上的特征信息,因此最后的评价指标明显高于仅使用瞬时特征的 BR-SVM、ML-KNN 与 BP-ML, 特别是对于变频空调这种负荷特征存在周期性变化的设备。图 6 为 3 种神经网络的损失函数

表 4 单一设备的多类别识别结果

负荷名称	DC-ResNet		ResNet		BP-ML		BR-SVM		ML-KNN	
	Macro-F1	Micro-F1	Macro-F1	Micro-F1	Macro-F1	Micro-F1	Macro-F1	Micro-F1	Macro-F1	Micro-F1
电风扇	0.96317	0.96800	0.92544	0.93446	0.85373	0.86753	0.82827	0.84987	0.82381	0.83623
微波炉	0.94859	0.96811	0.93143	0.93720	0.86607	0.91325	0.85927	0.91748	0.85035	0.91497
热水壶	0.94876	0.96496	0.92937	0.94229	0.86646	0.91415	0.78715	0.86341	0.77603	0.84033
白炽灯	0.94515	0.97156	0.87822	0.95732	0.82783	0.95211	0.79435	0.92830	0.79122	0.92710
节能灯	0.88744	0.81947	0.82114	0.88376	0.83354	0.85852	0.86225	0.80898	0.80714	0.80461
饮水机	0.88920	0.94893	0.83015	0.90235	0.85598	0.86878	0.85892	0.86940	0.84170	0.85775
电吹风	0.93166	0.95777	0.85388	0.94212	0.83153	0.91676	0.84246	0.87716	0.84173	0.85552
电视机	0.94286	0.96884	0.95337	0.98250	0.89885	0.95283	0.83570	0.96548	0.82790	0.95910
变频空调	0.86012	0.89363	0.83025	0.85384	0.81593	0.81520	0.76358	0.77635	0.76024	0.76422
打印机	0.91970	0.93663	0.88742	0.94729	0.88857	0.93865	0.83784	0.87557	0.81370	0.86151
笔记本电脑	0.89005	0.97737	0.88796	0.96831	0.86608	0.94443	0.84402	0.95492	0.78849	0.93800

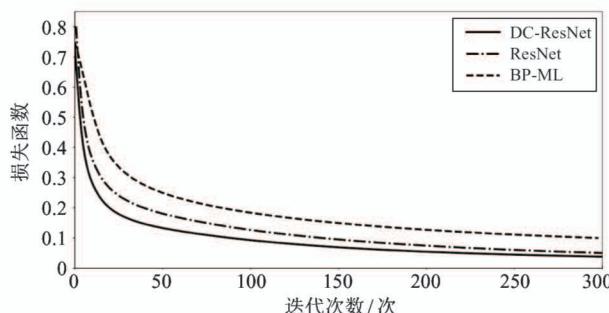


图 6 神经网络损失函数的变化对比图

变化对比图。因为 DC-ResNet 的部分网络共享权值, 所以每轮迭代的计算量不会因为双通道而变为 ResNet 的两倍。

从图中可以看出 DC-ResNet 的训练时间更短, 大约在 200 轮迭代之后率先趋于收敛, 说明 DC-ResNet 的双通道结构可以更好地监督网络训练, 加快网络收敛。

4 结 论

针对目前负荷识别中存在人工挖掘时序特征困难的问题, 本文提出了一种基于 DC-ResNet 的多标签负荷识别算法。将负荷数据按时间滑窗生成特征图作为输入, Channel 01 用于提取大类特征, 预测负荷的开关状态, Channel 02 用于提取小类特征, 预测负荷的运行模式, 综合两条通道的输出可以得到最后的多标签分类结果。为了进一步提升识别精度, 本文提出了一种基于改进 DTL 的特征提取算法, 从原始的负荷数据中自动提取有效的负荷特征, 并且可以达到降维的效果。实验结果表明, 经 DTL 提取和降维后的负荷数据更易识别, DC-ResNet 相比于其他 4 种模型具有更好的识别效果, 并且模型所需的训练时间较短。

本文提出的改进 DTL 算法具有一定的通用性, 可用于其他数据的特征降维。提出的基于 DC-ResNet 的多标签负荷识别算法, 将非侵入式负荷识别看作是一个多标签分类问题, 利用 ResNet 自动提取有效的时序特征, 为识别复杂的多负荷并行系统提供了一个新的思路和方法。

参 考 文 献

- [1] 周峰, 周晖, 刁瀛龙. 泛在电力物联网智能感知关键技术发展思路[J]. 中国电机工程学报, 2020, 40(1): 70-82
- [2] 杨挺, 翟峰, 赵英杰, 等. 泛在电力物联网释义与研究展望[J]. 电力系统自动化, 2019, 43(13): 9-20
- [3] 程祥, 李林芝, 吴浩, 等. 非侵入式负荷监测与分解研究综述[J]. 电网技术, 2016, 40(10): 3108-3117
- [4] 孙毅, 李昊洋, 刘耀先, 等. 基于改进隐马尔科夫模型的非侵入式家居负荷识别[J]. 电力建设, 2020, 41(4): 73-80
- [5] 牟魁翌, 杨洪耕. 基于 PLA-GDTW 支持向量机的非侵入式负荷监测方法[J]. 电网技术, 2019, 43(11): 4185-4193
- [6] 江帆, 杨洪耕. 基于广义回归神经网络的非侵入式负荷识别方法[J]. 电测与仪表, 2020, 57(3): 1-6
- [7] 徐春华, 陈克绪, 马建, 等. 基于深度置信网络的电力负荷识别[J]. 电工技术学报, 2019, 34(19): 4135-4142
- [8] 张玉天, 邓春宇, 刘沅昆, 等. 基于卷积神经网络的非侵入负荷辨识算法[J]. 电网技术, 2020, 44(6): 2038-2044
- [9] 王守相, 郭陆阳, 陈海文, 等. 基于特征融合与深度学习的非侵入式负荷辨识算法[J]. 电力系统自动化, 2020, 44(9): 103-111
- [10] Basu K, Debusschere V, Bacha S, et al. Nonintrusive load monitoring: a temporal multilabel classification approach[J]. IEEE Transactions on Industrial Informatics, 2015, 11(1): 262-270
- [11] Tabatabaei S M, Dick S, Xu W S. Toward non-intrusive load monitoring via multi-label classification [J]. IEEE Transactions on Smart Grid, 2017, 8(1): 26-40
- [12] 杨立余, 陈昊, 黎明, 等. 非侵入式电力负荷多目标分解框架[J]. 电力系统保护与控制, 2020, 48(6): 100-107
- [13] Maggu J, Majumdar A. Greedy deep transform learning [C] // Proceedings of the 2017 24th IEEE International Conference on Image Processing, Beijing, China, 2017: 1822-1826
- [14] Zhang Q A, Li B X. Discriminative K-SVD for dictionary learning in face recognition [C] // Proceedings of the 2010 IEEE Conference on Computer Vision and Pattern Recognition, San Francisco, USA, 2010: 2691-2698

- [15] Yang M, Zhang L, Yang J, et al. Robust sparse coding for face recognition [C] // Proceedings of the 2011 IEEE Conference on Computer Vision and Pattern Recognition, Colorado Springs, USA, 2011: 625-632
- [16] Ravishankar S, Wen B H, Bresler Y. Online sparsifying transform learning-part I: algorithms [J]. *IEEE Journal of Selected Topics in Signal Processing*, 2015, 9 (4) : 625-636
- [17] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition, Seattle, USA, 2016: 770-778
- [18] Fawcett T. An introduction to ROC analysis [J]. *Pattern Recognition Letters*, 2006, 27(8) : 861-874

Non-intrusive multi-label load identification method based on DTL and DC-ResNet

Pan Guobin, Wang Zhentao, Ouyang Jing, Wang Jie, Gao Yadong, Yin Kang

(Key Laboratory of E&M, Ministry of Education & Zhejiang Province,
Zhejiang University of Technology, Hangzhou 310014)

Abstract

Aiming at the difficulty of manual feature mining in current load recognition and to further heighten the identification accuracy, a double channel-deep residual neural network (DC-ResNet) and deep transform learning (DTL) based recognition method is proposed in this paper. Firstly, the improved DTL is used to automatically extract effective load features from the original load data, and the feature dimension can be reduced. Then, DC-ResNet takes load data as input by constructing a continuous feature map of time sliding window, and uses the convolution kernel to automatically extract effective timing features. One channel of DC-ResNet is used to extract features of large categories to predict the switching state of the device, and the other channel is used to extract the features of small categories to predict the operating mode of the device. The outputs of the two channels are integrated to obtain the final result of multi-label recognition. Experimental results show that the load data processed by DTL is easier to identify, and DC-ResNet has better results and shorter training time in overall and individual load recognition compared to the others.

Key words: double channel-deep residual neural network (DC-ResNet), deep transform learning (DTL), non-intrusive load identification, multi-label classification