

基于多维融合特征和卷积神经网络的多任务用户短期负荷预测

臧海祥, 许瑞琦, 刘璟璇, 陈玉伟, 卫志农, 孙国强
(河海大学能源与电气学院, 江苏省南京市 211100)

摘要: 针对海量用户负荷预测场景下,应用单任务用户负荷预测法所导致的运行效率低以及无法学习相关任务间关联关系等问题,提出一种基于多维融合特征和卷积神经网络的多任务用户短期负荷预测方法。首先,基于聚类技术实现多任务学习中相关任务的选择;其次,为每一类用户群构建多维融合输入,合理有序容纳多个任务的特征,避免维度爆炸和信息混乱;最后,分别为每一类用户建立以卷积神经网络为共享层的多任务预测模型,学习共享特征,并行输出相应类中全部用户的负荷预测值。基于爱尔兰能源监管委员会提供的智能电表实测数据进行算例分析,结果表明,该方法在提高整体运行效率和平均预测精度方面均取得良好成效。

关键词: 海量用户; 负荷预测; 多任务学习; 多维融合特征; 卷积神经网络

0 引言

随着售电侧改革的不断深入,售电公司这一新兴市场主体应时而生^[1]。准确掌握用户用电需求是这类企业开展购售电业务的前提和提高经济收益的关键。然而,传统的系统级负荷预测技术无法支撑售电公司应对偏差电量考核^[2],用户级负荷预测技术的重要性日益彰显。不同于系统级负荷,用户级负荷由于缺乏平滑效应,呈现出更强的波动性和随机性,预测难度更大^[3]。此外,高级量测体系的逐步完善和智能电表的愈发普及,使得海量用户用电数据可以被获取^[4]。一方面,这为电力企业分析用户用电行为提供了数据基础;另一方面,也对电力企业提出了预测海量用户负荷的要求。因此,有必要研究高效精准的适用于海量用户的负荷预测技术^[5]。

迄今为止,国内外学者在研究过程中已产生了丰富的单任务学习负荷预测理论研究成果^[6]。文献[7-9]分别从时空特征提取或多时间尺度相似性分析的角度,研究提升单个用户负荷预测精度的方法。单任务学习负荷预测法,即一次仅对单个用户的负荷进行预测,将一个用户的负荷预测看作一项任务,单个任务享有独立的模型空间,不同任务的模型间没有连接。因此,单任务学习的显著不足表现为无法获取不同任务间的相关性,一定程度上限制

了负荷预测精度的提升。此外,若待测用户的数量较少,可以不过多考虑计算内存和运行时间,但若待测用户数量庞大,则不得不考虑其运行效率^[10]。

多任务学习作为一种侧重领域间知识共享性的学习范式,可以弥补分散学习各个任务过程中丢失相关信息的不足。近年来,多任务学习逐渐受到负荷预测领域研究人员的广泛青睐^[11]。文献[12]探讨了基于核的多任务学习应用,把网络的多点电力需求预测问题描述成多任务学习问题,并说明了利用联合学习以及多组负荷数据间相似性进行多点负荷预测的可行性和有效性。文献[13]考虑到同一小区内用户间负荷存在相似性,将多任务学习用于预测被挑选出的2个相似用户。文献[14]对两个社区60户居民建立基于多任务贝叶斯的时空高斯过程负荷预测模型,以捕捉不同社区用户间的关联性。文献[15]通过多任务学习提取多点间的共享低维表示,对上海地区4个楼宇的用电负荷进行联合预测,并指出若基于时间序列相似度筛选多任务源,可进一步提高预测准确性。目前,多任务学习在海量用户负荷预测方面的应用尚未得到充分研究,且现有文献通常未对多任务学习中相关任务进行选择,同时,也忽视了对多任务模型的输入特征进行研究,无法充分发挥多任务学习的优势^[16]。

本文在现有研究的基础上,将多任务学习应用于海量用户负荷预测,提出一种基于多维融合特征和卷积神经网络的多任务用户短期负荷预测方法。首先,基于用户负荷聚类实现多任务学习中相关任务选择;然后,为每一类用户群构建相应的多维融合

收稿日期: 2022-04-27; 修回日期: 2022-10-25。

上网日期: 2023-01-09。

国家自然科学基金资助项目(52077062);已申请国家发明专利(申请号:CN202111134821.0)。

输入;最后,分别对每一类用户群建立基于卷积神经网络的多任务用户负荷预测模型,经训练及预测并行输出相应类中全部用户的负荷预测结果,从而实现兼顾整体运行效率和平均预测精度的海量用户负荷预测。本文基于爱尔兰能源监管委员会提供的实测居民负荷数据进行算例分析,通过多组对比试验,对所提方法提升整体运行效率和预测准确性的有效性进行验证。

1 基于用户负荷聚类的相关任务选择

多任务学习是基于所学任务中至少有部分相关任务的假设,若引入大量显著不相关的任务可能引发严重的负迁移,即从其他任务学到的知识,对当前任务的学习产生了负面的作用^[17]。因此,从海量用户中分析出存在负荷相关性的用户是应用多任务学习的前提。同时,考虑到人为选择多任务学习中的相关任务,不仅将带来巨大的工作量,还可能由于先验知识不足,导致相关性分析存在偏差等情况。因此,本文直接依据对实际负荷数据的分析,采用聚类算法实现相关任务的自适应选择。

聚类分析作为一种寻找统计规律的无监督学习方法,可按照某种标准,视存在相似性或相关性的样本为同一类,将数据集划分为具有不同特性的多个子类,使类内相关性较高,类间相关性较低。通常根据实际应用的聚类对象和聚类需求选择合适的聚类算法。为避免初始聚类中心选择和局部极小的问题,本文采用凝聚型层次聚类算法^[18]。类间邻近度和样本邻近度是决定该算法计算规则的关键参数,本文分别采用 ward linkage 和欧氏距离作为两个类之间和两个样本之间邻近程度的量度指标,具体流程图如附录 A 图 A1 所示。基于凝聚型层次聚类算法对海量用户进行相关任务选择的具体步骤如下。

1) 假设所有用户数为 R , 考虑到负荷的季节特性,分别计算每个用户各个季节的日均负荷序列,并按照春夏秋冬的次序构成向量,作为各用户的聚类特征向量。则第 j 个用户的聚类特征向量 f_j 可表示为:

$$f_j = [\bar{l}_j^{s,1}, \dots, \bar{l}_j^{s,h}, \dots, \bar{l}_j^{s,24}] \quad (1)$$

$$\bar{l}_j^{s,h} = \frac{1}{D_s} \sum_{d=1}^{D_s} l_j^{d,h} \quad (2)$$

式中: j 表示用户的序号, $j=1, 2, \dots, R$; $\bar{l}_j^{s,h}$ 为第 j 个用户、第 s 个季节、第 h 时刻的负荷均值; s 表示季节的序号, $s=1, 2, 3, 4$, 依次分别代表春夏秋冬 4 个季节; h 表示时刻的序号, $h=1, 2, \dots, 24$; $l_j^{d,h}$ 为第 j 个用户、第 s 个季节中第 d 天、第 h 时刻的负荷值; d_s

表示第 s 个季节中天数的序号; D_s 为第 s 个季节的总天数。

构造聚类特征矩阵 F :

$$F = [f_1^T f_2^T \dots f_R^T]^T \quad (3)$$

2) 初始化迭代次数序号, $c=0$, 分别计算每两个样本间的邻近度, 得到初始邻近度矩阵 $P^{(c)}$, 将每个样本看作一个类簇。其中, 第 k 行、第 g 列的元素 $p_{k,g}^{(c)}$ (即第 k 个样本和第 g 个样本间的邻近度) 计算公式为:

$$p_{k,g}^{(c)} = f_{\text{dis}}(f_k, f_g) \quad k \neq g \quad (4)$$

$$P^{(c)} = (p_{k,g}^{(c)}) \quad (5)$$

式中: $f_{\text{dis}}(\cdot)$ 表示两样本的邻近度计算规则, 本文使用欧氏距离进行计算; k 和 g 均表示样本的序号, $k=1, 2, \dots, R, g=1, 2, \dots, R$ 。

3) 分别计算每两类合并时导致的离差平方和 (error sum of squares, ESS) 增量, 每轮将 ESS 增量最小的两个类合并成一个新类, 更新迭代次数序号, $c=c+1$, 并更新邻近度矩阵 $P^{(c)}$ 。若总类数不为 1 或未达到指定聚类数, 则重复执行该步骤。

若 C_i 代表第 i 类用户群, $i=1, 2, \dots, R-c$, 则 C_i 对应的 ESS 计算公式为:

$$z_{\text{ESS}}(C_i, \mu_i) = \sum_{q \in C_i} (f_{\text{dis}}(f_q, \mu_i))^2 \quad (6)$$

式中: μ_i 为 C_i 的中心; q 为 C_i 中所含样本的下标; f_q 为 C_i 中对应下标的样本。

合并 C_i 和 C_j 所导致的 Δz_{ESS} 的计算公式如下:

$$\Delta z_{\text{ESS}} = z_{\text{ESS}}(C_i \cup C_j, \mu_{i \cup j}) -$$

$$z_{\text{ESS}}(C_i, \mu_i) - z_{\text{ESS}}(C_j, \mu_j) \quad (7)$$

式中: Δz_{ESS} 为 ESS 增量; $C_i \cup C_j$ 为通过合并 C_i 和 C_j 组成的新一类用户群; μ_j 和 $\mu_{i \cup j}$ 分别为 C_j 和 $C_i \cup C_j$ 的中心。

4) 为选取最佳聚类数, 使用戴维森堡丁指数 (Davies-Bouldin index, DBI) 作为内部评价指标, 其计算公式如下:

$$\epsilon_{\text{DBI}}(K) = \frac{1}{K} \sum_{i=1}^K \max_{j=1, 2, \dots, K; j \neq i} \left(\frac{W_i + W_j}{|D_{ij}|} \right) \quad (8)$$

式中: K 为聚类数; $\epsilon_{\text{DBI}}(K)$ 为聚类数为 K 时 DBI 的值; W_i 和 W_j 分别为第 i 和第 j 类中所有样本到各自聚类中心的平均距离; $|D_{ij}|$ 为第 i 类和第 j 类两聚类中心间的距离。可以看出, DBI 值越小表明类间邻近度越低, 类内邻近度越高, 聚类效果越佳。

5) 将每一类中的全部用户作为相关任务, 以类为单位逐个应用多任务学习, 逐类建立多任务负荷预测模型。

2 基于多维融合的多任务输入特征构建

输入是影响模型表现力的关键,合适的输入有利于模型充分提取其内部特征。然而,现有多任务学习在预测领域的相关应用常常忽视了对输入特征的研究。常规的多任务模型输入特征构建方式大致包含两种:①直接合并全部任务的特征,作为特征共享层的输入^[13];②分别将各个任务的特征并行输入对应的独立全连接层,合并所有输出,并将其作为多任务模型共享层的输入^[19]。当任务数较多时,第1种多任务输入特征构建法极易发生维度爆炸,第2种方法对应的模型参数将急剧增加,容易导致模型训练时间过长。同时,考虑到本文相关任务选择结果中可能出现部分子类用户数较多的情况,为合理容纳相关任务的输入特征,避免常规输入构建方式在任务数较多的情况下易造成维度爆炸、信息混乱和模型复杂度增加等问题,本文提出了基于多维融合的多任务输入特征构建法,主要包括二维特征图构建和三维融合两个步骤。

2.1 二维特征图构建

2.1.1 用户负荷自相关性分析

用户负荷序列本质上是一组高度自相关的时间序列数据,不同时刻的负荷间存在一定关联关系,因此,本文对负荷序列进行自相关性分析,滞后 h 小时的自相关系数的计算公式具体如下:

$$c_h = \frac{\sum_{i=1}^{n-h} (x_i - \bar{x})(x_{i+h} - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (9)$$

式中: n 为序列长度; h 为滞后小时数; $\bar{x}$ 为序列的总体均值; x_i 和 x_{i+h} 分别为序列第 i 时刻和第 $i+h$ 时刻的值。

经计算发现,不同用户的负荷序列均存在较为相似的自相关特性。以本文所用数据集中某用户负荷序列为例,图1直观展示了其在滞后192 h范围内,各滞后时间差对应的自相关系数。图1中: $h=0, 1, \dots, 192$ 。自相关特性主要表现为,滞后1 h、滞后24 h和滞后168 h的自相关系数最大。这表明相邻小时的负荷间存在显著的相关性,相邻天同一时刻的负荷间存在较强的关联关系,相邻周的同一日期类型相同时刻的负荷间也存在较高程度的相关性,即负荷序列存在显著的小时相关性、日周期性和周周期性特性。

2.1.2 输入维度转换

基于上述自相关性分析结果,为便于模型充分提取反映负荷小时相关性和日周期性的特征,本文将原始的一维输入特征经维度转换构成一张二维特




图1 居民用户负荷自相关函数图
Fig. 1 Autocorrelation function diagram of load for a certain residential consumer

征图,具体步骤如下。

1) 鉴于用户用电行为存在周周期性规律,本文选取待预测时刻前8天至前一天一周的历史负荷值作为原始输入特征,用于日前负荷预测。假设待预测时刻为 t ,则用于预测第 i 个用户待预测时刻负荷的原始输入特征 E_t^i 为:

$$E_t^i = [e_{t-191}^i, e_{t-190}^i, \dots, e_{t-25}^i, e_{t-24}^i] \quad (10)$$

式中: e_u^i 为第 i 个用户、第 u 时刻的负荷值,其中, $i=1, 2, \dots, R$, R 为用户总数, $u=t-191, t-190, \dots, t-24$ 。

2) 对原始的一维输入特征进行维度转换,将连续一天的负荷值按照由远至近的顺序置于一行,依次构成不同行,则第 i 个用户待预测时刻的原始一维输入特征将转变为如下的二维特征图 E_t^i 。

$$E_t^i = f_{\text{reshape}}(E_t^i) = \begin{bmatrix} e_{t-191}^i & e_{t-190}^i & \cdots & e_{t-169}^i & e_{t-168}^i \\ e_{t-167}^i & e_{t-166}^i & \cdots & e_{t-145}^i & e_{t-144}^i \\ \vdots & \vdots & & \vdots & \vdots \\ e_{t-71}^i & e_{t-70}^i & \cdots & e_{t-49}^i & e_{t-48}^i \\ e_{t-47}^i & e_{t-46}^i & \cdots & e_{t-25}^i & e_{t-24}^i \end{bmatrix} \quad (11)$$

式中: $f_{\text{reshape}}(\cdot)$ 为维度转换函数。

对每个用户待预测时刻的原始输入特征进行输入维度转换。每张二维特征图中,同一行的相邻元素为相邻时刻的负荷,以便模型学习小时相关性;同一列的相邻元素为相邻天同一时刻的负荷,以便模型学习日相关性。

2.2 三维融合

外部因素变化相似的用户,其用电行为趋势大致相同^[20],导致一定范围内不同用户的用电行为间存在相关性。为计及用户间相关性对负荷的影响,本文按照各个时刻一一对齐的方式将不同用户的二维特征图进行三维融合,构成一组三维数据,并将其作为模型输入。

三维融合的示意图如附录A图A2所示。从图

中可以看出,一个用户对应一张二维特征图,不同二维特征图之间相同位置的元素为不同用户相同时刻的负荷,合理有序容纳全部相关任务的输入特征,从而避免常规多任务输入特征构建法易造成维度爆炸和数据信息混乱等问题,帮助模型学习不同用户负荷间的相关性,挖掘相关任务间的关联关系。

3 基于卷积神经网络的多任务用户负荷预测模型

3.1 多任务学习的原理

应用单任务学习处理多个任务,由于不同任务对应的模型间没有联系,往往无法获取任务间相关信息。多任务学习可以获取相关任务间的共享信息,并利用其提高泛化性能^[16]。因此,本文采用多任务学习对每一类用户群建立预测模型,获取同一类用户负荷间的共享信息。考虑到须顾及海量用户负荷预测的运行效率,为避免模型待训练参数过多,采用硬参数共享机制设计多任务用户负荷预测模型。通过共享网络部分隐藏层,实现任务间信息共享,网络结构简单,参数简易。

多任务学习的基本原理可通过式(12)至式(14)进行表述^[21]。假设多任务学习共包含 V 个任务,第 v 个任务对应的输入数据集和输出数据集分别为 x_v 和 y_v , $v=1,2,\dots,V$,则全部的输入数据集 X 可表示为:

$$X=\{x_1,\dots,x_v,\dots,x_V\} \quad (12)$$

定义与第 v 个任务对应的预测函数为 $u^v(X; \theta^{\text{sha}}, \theta^v)$,则第 v 个任务对应的预测值 $\hat{y}^v$ 为:

$$\hat{y}^v = u^v(X; \theta^{\text{sha}}, \theta^v) \quad (13)$$

式中: θ^{sha} 为特征共享层的参数; θ^v 为第 v 个任务特定层的参数, $v=1,2,\dots,V$ 。

多任务对相关任务进行联合训练,通过最小化整体损失函数训练网络参数,则整体损失函数 f_{LOSS} 的计算公式如下:

$$f_{\text{LOSS}} = \sum_{v=1}^V \alpha_v f_{\text{loss},v}(\hat{y}^v, y^v) \quad (14)$$

式中: $f_{\text{loss},v}(\cdot)$ 为第 v 个任务的损失函数,本文采用均方误差(mean squared error, MSE)作为损失函数; α_v 为第 v 个任务对应的权重系数。

3.2 卷积神经网络的原理

一方面,卷积神经网络具备处理多通道输入的能力,可用于处理所构建的输入特征;另一方面,考虑到卷积神经网络具有局部连接和权值共享的结构特点,对比同等规模的全连接神经网络,可大幅减少待训练参数、降低模型复杂度^[22]。因此,本文采用

卷积神经网络作为多任务预测模型的特征共享层。将输入特征中不同用户相应的二维特征图与卷积神经网络输入的不同通道一一对应,通过卷积核对多通道输入进行卷积计算,实现通道间关联,学习不同用户在相同时间范围内的负荷相关性,从而充分挖掘共享信息。

卷积神经网络一般由若干个卷积层和池化层交替连接而成,其网络结构示意图如附录A图A3所示。假设第 a 层卷积层的卷积核个数为 C^a ,则该层的输出特征图个数为 C^a ,该卷积层的计算具体如下^[23]:

$$m_e^a = f_{\text{con}}\left(\sum_{r=1}^{C^{a-1}} m_r^{a-1} * w_{re}^a + b_e^a\right) \quad (15)$$

式中: m_e^a 和 m_r^{a-1} 分别为第 a 层的第 e 个输出特征图和第 $a-1$ 层的第 r 个输出特征图, $e=1,2,\dots,C^a$; C^{a-1} 为第 $a-1$ 层的输出特征图个数; w_{re}^a 为第 a 层卷积层第 e 个卷积核对应前一层第 r 个输出特征图的核参数; b_e^a 为第 a 层卷积层中对应第 e 个输出特征图的偏置; $f_{\text{con}}(\cdot)$ 为卷积层激活函数; $*$ 表示卷积运算。

经卷积运算后,考虑到最大池化具有维持局部显著特征的不变性,不仅能减少噪声像素的干扰,还能维持神经节点的稀疏性^[24]。因此,本文采用最大池化对数据特征进行下采样,以降低计算量,减少训练过程中发生过拟合的风险。最大池化层将以给定区域内的最大值来代替该区域的数据。具体计算如下式所示^[24]:

$$s_e^{a+1} = f_{\text{pool}}(\beta_e^{a+1} f_{\text{down}}(m_e^a) + b_e^{a+1}) \quad (16)$$

式中: $f_{\text{down}}(\cdot)$ 为最大池化层中的下采样函数; m_e^a 为第 $a+1$ 层池化层的输入中第 e 个通道对应的特征图, $e=1,2,\dots,C^a$,其中, C^a 为第 $a+1$ 层的输入通道数; s_e^{a+1} 为第 $a+1$ 层池化层中第 e 个通道对应的输出特征图; β_e^{a+1} 和 b_e^{a+1} 分别为该输出特征图中的乘性偏置和加性偏置; $f_{\text{pool}}(\cdot)$ 为池化层激活函数。

3.3 基于卷积神经网络的多任务用户负荷预测模型结构

多任务模型通过联合训练学习相关任务间的共享特征及每个任务的独有特征。然而,当任务数较多时,训练过程中容易发生对单个任务独有特征学习不充分的现象,致使某些任务的学习效果下降。因此,本文对常规硬共享机制的输出端结构进行改进,在任务特定层为每个任务增设特征增强通道,旨在通过为各个任务赋予自身数据的抽象特征,强化对各个任务差异化特征的学习,帮助改善学习效果。

本文所建立的基于卷积神经网络的多任务用户

负荷预测模型结构如图2所示。主要包括特征共享层和任务特定层。以卷积神经网络作为特征共享层,其底部由两组卷积层和池化层交替构成,然后将展开的结果输入顶部的全连接层,提取共享特征,并将其传输给任务特定层中每个任务的输出层。每个任务对应的输出层由特征增强通道、拼接层和全连接层构成。为避免网络参数过多,特征增强通道仅采用一个全连接层,用于从各个任务自身历史负荷序列和日类型变量中抽象出与任务相关的独有特征,将独有特征与共享特征输入拼接层分别进行合并,然后经全连接层处理,并行输出某一类中全部用户待预测时刻的负荷值,其中, N_i 为第 i 类的用户数。本文所提多任务用户负荷预测方法的具体流程如图3所示。




图2 基于卷积神经网络的多任务用户负荷预测模型
Fig. 2 Multi-task consumer load forecasting model based on convolutional neural network

4 算例分析

4.1 数据来源

目前,尚无法获取国内海量用户的开源负荷数据。因此,本文使用爱尔兰能源监管委员会提供的开源智能计量试验的数据集,选用其中“1-E-E”型代码的居民用户负荷数据。该数据集包含929户居民从2009年7月14日至2010年12月31日每隔30 min采样的用电数据。

4.2 误差评价指标

考虑到所用数据集中存在居民用户某些时刻的负荷为零,采用均方根误差 ϵ_{RMSE} 和平均绝对误差 ϵ_{MAE} 这2种预测误差指标^[25],计算公式分别如下:

$$\epsilon_{\text{RMSE}} = \sqrt{\frac{1}{B_i} \sum_{j=1}^{B_i} (\hat{y}_j^i - y_j^i)^2} \quad (17)$$

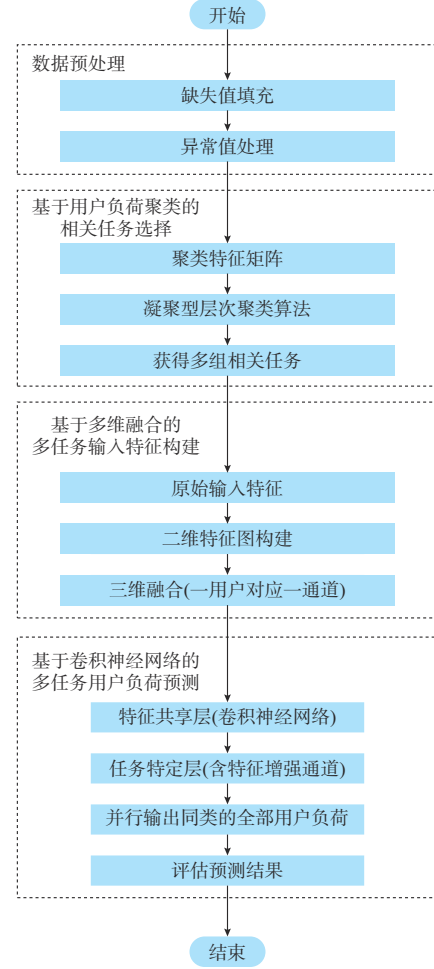


图3 基于多维融合特征和卷积神经网络的多任务用户短期负荷预测流程

Fig. 3 Process of multi-task consumer load forecasting based on multi-dimensional fusion feature and convolutional neural network

$$\epsilon_{\text{MAE}} = \frac{1}{B_i} \sum_{j=1}^{B_i} |\hat{y}_j^i - y_j^i| \quad (18)$$

式中: B_i 为第 i 个用户包含的样本个数; $\hat{y}_j^i$ 为第 i 个用户第 j 个样本的负荷预测值; y_j^i 为第 i 个用户第 j 个样本的负荷真实值。

为衡量所有用户负荷预测精度的平均情况,本文分别对上述2种误差指标取均值,则均方根误差和平均绝对误差的平均误差 ϵ_{mRMSE} 和 ϵ_{mMAE} 计算公式分别为:

$$\epsilon_{\text{mRMSE}} = \frac{1}{R} \sum_{i=1}^R \sqrt{\frac{1}{B_i} \sum_{j=1}^{B_i} (\hat{y}_j^i - y_j^i)^2} \quad (19)$$

$$\epsilon_{\text{mMAE}} = \frac{1}{R} \sum_{i=1}^R \frac{1}{B_i} \sum_{j=1}^{B_i} |\hat{y}_j^i - y_j^i| \quad (20)$$

4.3 预测结果

为对比凝聚型层次聚类算法的效果,本文设置

K-means 聚类算法作为对照,两种聚类算法的 ϵ_{DBI} 如附录 A 图 A4 所示。整体上,不同聚类数下凝聚型层次聚类算法的 DBI 小于 K-means 算法,且当聚类数为 28 时,DBI 较小且下降速率显著。因此,本文将所有居民用户共聚为 28 个类簇,每类包含的用户数具体见附录 A 表 A1。分别为每一类用户群搭建多任务用户负荷预测模型,且网络结构和超参数设置一致,具体见附录 A 表 A2,各个任务对应的权重系数均设为任务数的倒数。将每个用户待预测时刻前 8 天至前一天的历史负荷数据和日期类型变量共同作为特征增强通道的输入特征。其中,日期类型变量具体见附录 A 表 A3。将 2009 年 7 月 14 日至 2010 年 7 月 13 日一年的数据集作为训练集,剩余数据集作为测试集,提前一天预测居民用户负荷。

4.3.1 与单任务用户负荷预测方法的结果对比

本节设置了 3 种基于不同模型的单任务用户负荷预测方法作为对照,通过对比,分析本文所提方法的预测效果。3 种对比方法分别采用自回归积分滑动平均 (autoregressive integrated moving average, ARIMA)、支持向量回归 (support vector regression, SVR) 和深度神经网络 (deep neural network, DNN) 模型。3 种单任务方法均需通过逐一建模、训练再预测的方式才能完成所有用户的负荷预测。表 1 给出了全部用户基于所提方法和 3 种单任务用户负荷预测方法的预测误差平均值和累计运行时间。

表 1 不同用户负荷预测方法的预测结果
Table 1 Forecasting results of different consumer load forecasting methods

预测方法	$\epsilon_{\text{mRMSE}}/\text{kW}$	$\epsilon_{\text{mMAE}}/\text{kW}$	时间/s
所提方法	0.530 3	0.319 1	2 801
基于 ARIMA 单任务方法	0.620 7	0.383 1	473 790
基于 SVR 单任务方法	0.591 2	0.364 9	78 065
基于 DNN 单任务方法	0.545 6	0.327 1	3 387

由表 1 可以看出,基于所提方法的预测误差平均值小于所测每一种单任务对比方法。相较于基于 ARIMA 的单任务用户负荷预测误差,全部用户基于所提方法获得的 ϵ_{mRMSE} 和 ϵ_{mMAE} 分别减小了 14.6% 和 16.7%;与基于 SVR 的单任务预测方法相比,基于所提方法的 ϵ_{mRMSE} 下降了 10.3%, ϵ_{mMAE} 下降了 12.6%;对比基于 DNN 的单任务用户负荷预测结果可知,全部用户基于所提方法获取的 ϵ_{mRMSE} 和 ϵ_{mMAE} 分别减小了 2.8% 和 2.4%。结果表明,本文所提方法的平均预测精度优于其他 3 种单任务负荷预测对比方法。这是因为多任务学习弥补了单任务学习无法学习相关信息的不足,利用所学相关用户间的共享信息,帮助改善模型泛化性能,提高平均预测

精度。




图 4 编号 5328 用户基于不同用户负荷预测方法的预测结果对比
Fig. 4 Forecasting result comparison of number 5328 consumer based on different consumer load forecasting methods

为直观展示所提方法的预测优越性,本文随机选取了某居民用户任意 3 天的负荷预测结果进行展示。考虑到 3 种对比方法中基于 DNN 的单任务负荷预测方法预测效果最佳,图 4 给出了编号 5328 的用户在 2010 年 8 月 1 日、2010 年 9 月 16 日和 2010 年 10 月 20 日的真实值曲线和基于 DNN 及所提方法的预测曲线。可以看出,在预测整体变化趋势方面,所提方法的拟合效果明显优于基于 DNN 的单任务负荷预测方法。此外,由 2010 年 9 月 16 日和 2010 年 10 月 20 日的预测结果可以看出,所提方法在局部峰值处的预测曲线更贴近负荷的真实值。这再次验证了本文所提方法的可行性及优越性。

此外,表 1 还列出了不同用户负荷预测方法的累计运行时间,包括训练和测试时间。由表 1 可以明显看出,所提方法的整体运行效率高于其他 3 种单任务用户负荷预测方法。这主要是因为:一方面,

累计训练时间与建模总次数成正比,应用单任务预测法的建模总次数为用户总数,而应用所提方法的建模总次数为聚类总类数,大幅缩短了累计训练时长;另一方面,在测试阶段,单任务负荷预测方法需对每户居民逐一测试,而所提方法中每一个模型可同时输出相应类中全部用户的测试结果,减少了累计测试时间。待测用户数越多,所提方法在提升整体运行效率方面的优越性将越突出。上述结果表明,本文所提出的基于多维融合特征和卷积神经网络的多任务用户短期负荷预测方法兼顾了平均预测精度和整体运行效率,在海量用户负荷预测中潜力可观。

4.3.2 与不同多任务用户负荷预测方法的结果对比

本文所提方法在输入特征和模型结构两方面不同于传统的多任务方法,为进一步全面评估所提方法的预测性能,本节设置了3种多任务对比方法,用于探究所提方法中多维融合特征和特征增强通道对负荷预测精度的影响。3种多任务预测方法分别为:传统多任务方法,即对各个任务的特征进行拼接并作为模型特征共享层的输入,同时,模型输出端不增设特征增强通道;基于多维融合特征的多任务方法,其与所提方法的唯一区别在于输出端未设置特征增强通道;基于特征增强通道的多任务方法,其与所提方法的唯一区别在于模型输入采用了各个任务特征的拼接结果。为保证可比性,相关任务选择、模型的其他结构和超参数设置均与所提方法保持一致。

表2给出了所有用户基于3种多任务对比方法的预测误差平均值。对比表2中各对比方法和所提方法的预测结果可知,与基于多维融合特征的多任务方法相比,所提方法的平均预测误差 ϵ_{RMSE} 和 ϵ_{MAE} 分别减小了3.9%和5.6%。这表明本文所提

方法中增设的特征增强通道能够改善负荷预测性能。通过特征增强通道为各个任务赋予与自身相关的特征,可以强化对各个任务差异化特征的学习,帮助缓解任务数较多时部分单个任务学习不充分的情况,从而有效提高平均预测准确性。

表2 不同多任务用户负荷预测方法的预测结果
Table 2 Forecasting results of different multi-task consumer load forecasting methods

预测方法	$\epsilon_{\text{RMSE}}/\text{kW}$	$\epsilon_{\text{MAE}}/\text{kW}$
传统多任务方法	0.585 2	0.354 8
基于多维融合特征多任务方法	0.551 9	0.338 0
基于特征增强通道多任务方法	0.559 1	0.340 8

对比基于特征增强通道的多任务方法,所提方法的 ϵ_{RMSE} 减小了5.15%, ϵ_{MAE} 减小了6.4%。这表明本文所提方法中多维融合输入特征可提高平均预测精度。通过将原始输入特征构造成符合用户用电规律的形式,为模型提供合理有序的输入,帮助模型学习不同用户间的共享信息,从而有效改善预测性能。

基于所提方法获得的 ϵ_{RMSE} 和 ϵ_{MAE} 与传统多任务方法相比分别减小了9.4%和10.1%。结果表明,所提方法的平均预测性能优于传统多任务负荷预测方法。此外,同时使用多维融合特征和特征增强通道将给平均预测结果带来更大改善。

4.3.3 多任务学习中负迁移的分析

多任务学习中容易因任务间共享信息学习不充分发生负迁移现象。为评估所提方法及其他多任务负荷预测方法是否发生负迁移以及各自的负迁移程度,本文从用户的角度进行分析,将各个居民用户基于DNN单任务方法的负荷预测结果作为参照,分别统计基于所提方法和其他3种多任务方法预测误差减少的用户数,具体统计结果见表3。

表3 基于不同多任务方法的预测误差减小情况统计
Table 3 Forecasting error reduction statistics based on different multi-task methods

方法对比	ϵ_{RMSE}		ϵ_{MAE}	
	用户数	用户占比/%	用户数	用户占比/%
所提方法-基于DNN的单任务方法	733	78.90	704	75.78
传统多任务方法-基于DNN的单任务方法	97	10.44	84	9.04
基于多维融合特征多任务方法-基于DNN的单任务方法	633	68.14	602	64.80
基于特征增强通道多任务方法-基于DNN的单任务方法	577	62.11	557	59.96

由表3可知,基于所提方法获得负荷预测准确性提升的用户数最多,用户占比最大;基于传统多任务方法预测性能获得提升的用户数最少,占比最小;对比基于DNN的单任务方法,基于多维融合特征多任务方法和特征增强通道多任务方法,分别有大

约68.14%和62.11%的用户所得 ϵ_{RMSE} 减小,分别有64.80%和59.96%左右的用户所得 ϵ_{MAE} 减小。

结果表明,传统多任务负荷预测方法中负迁移现象最为严重;多维融合特征和特征增强通道对于缓解传统多任务学习中负迁移具有积极作用。此

外,由于所提方法同时应用二者,负迁移现象得到了最大程度的改善。

5 结语

本文考虑到不同用户负荷间存在一定相关性,将多任务学习应用于海量用户的负荷预测,提出了一种基于多维融合特征和卷积神经网络的多任务用户短期负荷预测方法。经算例分析,本文得出如下结论。

1) 基于多维融合特征和卷积神经网络的多任务用户短期负荷预测方法能够获得比单任务预测法累计运行时间更短、平均预测误差更小的预测结果,可以兼顾整体运行效率和平均预测精度的双重目标。

2) 采用多维融合特征和特征增强通道均能缓解应用多任务学习时发生的负迁移,从而改善平均预测性能,且同时应用二者对负迁移的改善和平均预测精度的提升能取得最佳效果。

未来,可将新型聚类算法或性能更强的新颖模型应用于本文所提方法“相关任务选择+多任务学习预测模型”的框架中,并考虑气象、电价等外部因素对负荷的影响,进一步提升海量用户的负荷预测准确性。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

- [1] 曾嘉志,赵雄飞,李静,等.用电侧市场放开下的电力市场多主体博弈[J].电力系统自动化,2017,41(24):129-136.
ZENG Jiazhi, ZHAO Xiongfei, LI Jing, et al. Game among multiple entities in electricity market with liberalization of power demand side market[J]. Automation of Electric Power Systems, 2017, 41(24): 129-136.
- [2] 喻小宝,谭忠富,马佳乐,等.计及需求响应的售电公司正偏差电量考核优化模型[J].电力系统自动化,2019,43(7):120-128.
YU Xiaobao, TAN Zhongfu, MA Jiale, et al. Optimal model for positive deviation penalty of power retailers considering demand response[J]. Automation of Electric Power Systems, 2019, 43(7): 120-128.
- [3] ALHUSSEIN M, AURANGZEB K, HAIDER S I. Hybrid CNN-LSTM model for short-term individual household load forecasting[J]. IEEE Access, 2020, 8: 180544-180557.
- [4] 顾洁,孟璐,郑睿程,等.考虑集群辨识的海量用户负荷分层概率预测[J].电力系统自动化,2021,45(5):71-78.
GU Jie, MENG Lu, ZHENG Ruicheng, et al. Load-stratified probability forecasting for massive users considering cluster identification[J]. Automation of Electric Power Systems, 2021, 45(5): 71-78.
- [5] 张素香,赵丙镇,王风雨,等.海量数据下的电力负荷短期预测[J].中国电机工程学报,2015,35(1):37-42.
ZHANG Suxiang, ZHAO Bingzhen, WANG Fengyu, et al. Short-term power load forecasting based on big data[J]. Proceedings of the CSEE, 2015, 35(1): 37-42.
- [6] JIANG L J, WANG X L, LI W, et al. Hybrid multitask multi-information fusion deep learning for household short-term load forecasting[J]. IEEE Transactions on Smart Grid, 2021, 12(6): 5362-5372.
- [7] HONG Y, ZHOU Y J, LI Q B, et al. A deep learning method for short-term residential load forecasting in smart grid[J]. IEEE Access, 2020, 8: 55785-55797.
- [8] YANG W W, SHI J, LI S J, et al. A combined deep learning load forecasting model of single household resident user considering multi-time scale electricity consumption behavior[J]. Applied Energy, 2022, 307: 118197.
- [9] KIM T Y, CHO S B. Predicting residential energy consumption using CNN-LSTM neural networks[J]. Energy, 2019, 182: 72-81.
- [10] 杨德昌,赵肖余,何绍文,等.面向海量用户用电数据的集成负荷预测[J].电网技术,2018,42(9):2923-2929.
YANG Dechang, ZHAO Xiaoyu, HE Shaowen, et al. Aggregated load forecasting based on massive household smart meter data[J]. Power System Technology, 2018, 42(9): 2923-2929.
- [11] 吕忠麟,顾洁,孟璐.基于耦合特征与多任务学习的综合能源系统短期负荷预测[J].电力系统自动化,2022,46(11):58-66.
LYU Zhonglin, GU Jie, MENG Lu. Short-term load forecasting for integrated energy system based on coupling features and multi-task learning[J]. Automation of Electric Power Systems, 2022, 46(11): 58-66.
- [12] FIOT J B, DINUZZO F. Electricity demand forecasting by multi-task learning[J]. IEEE Transactions on Smart Grid, 2018, 9(2): 544-551.
- [13] 王玉峰,肖灿彬,陈焱,等.一种利用多任务学习的短期住宅负荷预测方案[J].北京邮电大学学报,2021,44(3):47-52.
WANG Yufeng, XIAO Canbin, CHEN Yan, et al. An short-term residential load forecasting scheme using multi-task learning[J]. Journal of Beijing University of Posts and Telecommunications, 2021, 44(3): 47-52.
- [14] 李智勇,苏寅生,李斌,等.基于MT-BSGP的电力负荷预测方法[J].哈尔滨理工大学学报,2021,26(4):46-55.
LI Zhiyong, SU Yinsheng, LI Bin, et al. Power load forecasting method based on MT-BSGP[J]. Journal of Harbin University of Science and Technology, 2021, 26(4): 46-55.
- [15] 苏运,卜凡鹏,郭乃网,等.基于低秩表示的多任务短期电力负荷预测的研究[J].现代电力,2019,36(3):58-65.
SU Yun, BU Fanpeng, GUO Naiwang, et al. Research on short-term load forecast using multi-task with low-rank representation[J]. Modern Electric Power, 2019, 36(3): 58-65.
- [16] 张钰,刘建伟,左信.多任务学习[J].计算机学报,2020,43(7):1340-1378.
ZHANG Yu, LIU Jianwei, ZUO Xin. Survey of multi-task learning[J]. Chinese Journal of Computers, 2020, 43(7): 1340-1378.

- [17] JU Y, LI J, SUN G Y. Ultra-short-term photovoltaic power prediction based on self-attention mechanism and multi-task learning[J]. IEEE Access, 2020, 8: 44821-44829.
- [18] 翟俐民, 张建伟, 韩云祥. 基于层次聚类和LSTM的航空器到达时刻预测[J]. 现代计算机, 2021(14): 9-13.
ZHAI Limin, ZHANG Jianwei, HAN Yunxiang. Arrival flight time prediction based on hierarchical clustering and LSTM[J]. Modern Computer, 2021(14): 9-13.
- [19] 孙庆凯, 王小君, 张义志, 等. 基于LSTM和多任务学习的综合能源系统多元负荷预测[J]. 电力系统自动化, 2021, 45(5): 63-70.
SUN Qingkai, WANG Xiaojun, ZHANG Yizhi, et al. Multiple load prediction of integrated energy system based on long short-term memory and multi-task learning[J]. Automation of Electric Power Systems, 2021, 45(5): 63-70.
- [20] SHI H, XU M H, LI R. Deep learning for household load forecasting—a novel pooling deep RNN[J]. IEEE Transactions on Smart Grid, 2018, 9(5): 5271-5280.
- [21] 史佳琪, 谭涛, 郭经, 等. 基于深度结构多任务学习的园区型综合能源系统多元负荷预测[J]. 电网技术, 2018, 42(3): 698-707.
SHI Jiaqi, TAN Tao, GUO Jing, et al. Multi-task learning based on deep architecture for various types of load forecasting in regional energy system integration [J]. Power System Technology, 2018, 42(3): 698-707.
- [22] ZANG H X, LIU L, SUN L, et al. Short-term global horizontal irradiance forecasting based on a hybrid CNN-LSTM model with spatiotemporal correlations[J]. Renewable Energy, 2020, 160: 26-41.
- [23] SAJJAD M, KHAN Z A, ULLAH A, et al. A novel CNN-GRU-based hybrid approach for short-term residential load forecasting[J]. IEEE Access, 2020, 8: 143759-143768.
- [24] ZUBAIR S, YAN F, WANG W W. Dictionary learning based sparse coefficients for audio classification with max and average pooling[J]. Digital Signal Processing, 2013, 23(3): 960-970.
- [25] 孔祥玉, 李闯, 郑锋, 等. 基于经验模态分解与特征相关分析的短期负荷预测方法[J]. 电力系统自动化, 2019, 43(5): 46-56.
KONG Xiangyu, LI Chuang, ZHENG Feng, et al. Short-term load forecasting method based on empirical mode decomposition and feature correlation analysis [J]. Automation of Electric Power Systems, 2019, 43(5): 46-56.

臧海祥(1986—),男,通信作者,博士,副教授,博士生导师,主要研究方向:电力系统规划与运行分析、新能源发电技术等。E-mail: zanghaixiang@hhu.edu.cn

许瑞琦(1996—),女,硕士研究生,主要研究方向:电力系统大数据分析、负荷预测技术等。E-mail: xrqpost@163.com

刘璟璇(1998—),男,硕士研究生,主要研究方向:新能源发电技术。E-mail: 211306080023@hhu.edu.cn

(编辑 孔丽蓓)

Short-term Load Forecasting for Multi-task Consumers Based on Multi-dimensional Fusion Feature and Convolutional Neural Network

ZANG Haixiang, XU Ruiqi, LIU Jingxuan, CHEN Yuwei, WEI Zhinong, SUN Guoqiang
(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: Aiming at the problems of low operation efficiency and being unable to learn the correlation between related tasks caused by the application of load forecasting method for single-task consumers in the scenario of load forecasting for massive users, a short-term load forecasting method for multi-task consumers based on multi-dimensional fusion feature and convolutional neural network is proposed. Firstly, the selection of relevant tasks in multi-task learning is realized based on clustering technology. Then, multi-dimensional fusion input is constructed for each cluster of consumers to reasonably and orderly accommodate the features of multiple tasks in order to avoid the dimensional explosion and the information chaos. Finally, a multi-task forecasting model with convolutional neural network as the sharing layer is established for each cluster of consumers to learn the sharing feature, and the load forecasting values of all consumers in the corresponding cluster are output in parallel. Case analysis on the basis of the measured data of smart meters provided by the Energy Management Commission of Ireland, the results show that the proposed method performs well in improving the overall operation efficiency and average forecasting accuracy.

This work is supported by National Natural Science Foundation of China (No. 52077062).

Key words: massive user; load forecasting; multi-task learning; multi-dimensional fusion feature; convolutional neural network

