基于多神经网络融合的短期负荷预测方法

庞 吴1,高金峰1,杜耀恒2

(1. 郑州大学 产业技术研究院,河南 郑州 450001;2. 国家电网山东省电力公司烟台市供电公司,山东 烟台 264000)

摘要:为了利用不同深度神经网络的优势,提高深度学习算法对短期负荷的预测能力,提出一种基于多神经 网络融合的短期负荷预测方法。以电力系统历史有功负荷、季节、日期类型和气象数据为输入特征,并行架 构的深度神经网络和注意力机制网络为核心网络;以并行架构中的卷积神经网络通道提取静态特征,门控循 环单元网络通道挖掘动态时序特征,采用注意力机制网络融合提取的特征并动态调整网络对不同特征的依 赖程度;使用 Maxout 网络增强网络整体的非线性映射能力,通过全连接网络输出预测结果。与支持向量机、 长短期记忆网络的算例结果对比表明,所提方法具有更高的预测平稳性和准确性。

 关键词:短期负荷预测;多神经网络融合;门控循环单元网络;卷积神经网络;注意力机制网络;Maxout网络

 中图分类号:TM 732
 文献标志码:A

 DOI:10.16081/j.epae.202005021

0 引言

电力能源有着发、输、配、用同时进行的特点,利 用各种先进方法准确预测短期负荷,是保证电力系 统稳定、经济运行的必要条件。近年来,我国提出了 充分利用人工智能等先进技术建设"泛在电力物联 网"与"坚强智能电网"的口号和目标,指出了行业发 展的方向。同时,智能电表、智能电网调度管理系统 等收集了包括负荷数据在内的海量历史数据,为深 度学习算法的应用提供了数据基础。

目前,关于短期负荷预测的方法主要分为基于 统计理论的方法和基于机器学习的方法。基于统计 理论的方法主要包括卡尔曼滤波法^[1]、自回归积分滑 动平均法^[2]、回归分析法^[3]、时间序列法^[4]等。这类 方法的特点在于利用了负荷的时序性,但其只能对 少量特征及数据进行处理,且对原始数据的平稳性 要求较高。而基于机器学习的方法可较好地解决非 线性问题,受到了业界的广泛关注,如文献[5-7]分 别采用反向传播神经网络 BPNN(Back Propagation Neural Network)、支持向量机 SVM(Support Vector Machine)和径向基函数神经网络实现了短期负荷预 测。虽然基于一般机器学习的方法在处理非线性问 题的鲁棒性方面优于基于统计理论的方法,但是其 并未考虑负荷的时序性,在处理海量数据方面也存 在局限性。

近年来,包括深度信念网络DBN(Deep Belief Network)、卷积神经网络CNN(Convolutional Neural Network)和循环神经网络RNN(Recurrent Neural Network)及其变种在内的深度学习算法,因面对海量高维数据所展示出强大的自适应及非线性映射能力^[8],逐渐引起了业界的关注^[9]。文献[10-11]分别 从2种不同角度提出基于DBN的短期负荷预测方

法。文献[12]利用 CNN 在提取静态特征方面的优势,将负荷数据转换成曲线图实现短期负荷预测。 但 DBN、CNN 不能有效利用负荷数据关于时间的历 史关联信息,而 RNN 及其变种长短期记忆 LSTM (Long Short-Term Memory)网络、门控循环单元 GRU(Gated Recurrent Unit)网络具有挖掘时间序列 历史关联信息的优势。文献[13]从电价波动的角度 给出基于 LSTM 网络的预测方法,通过挖掘负荷、电 价等数据的时序特征实现了短期负荷预测。

理论上,单一类型的神经网络一般只擅长于挖 掘数据的某一类特征,如:CNN在提取数据局部静态 特征方面有较大优势,因而被广泛用于图像识别等 方面;而RNN及其变种网络适用于提取数据基于时 间的动态关系,其在自然语言处理等领域应用较多。 负荷、天气等数据具有明显的时间序列属性[14],但其 并非只具有这一类特征,上述基于深度学习的短期 负荷预测方法均只使用了单一的神经网络,提取特 征不完全将给某些时刻或某些条件下的负荷预测造 成一定误差。为了利用不同神经网络的优势更充分 地提取数据特征,文献[15-16]采用串行架构提取特 征的思路,相继提出关于CNN-LSTM、Attention-LSTM 的混合模型。文献[17]将负荷数据与其他特征数据 分别输入不同神经网络,提出一种新的神经网络融 合方法。文献[18]则将同类但不同层数的神经网络 通过并行架构提取特征,并用随机森林算法实现了 神经网络的融合。目前在短期负荷预测领域鲜有关 于多类型神经网络并行提取不同特征的研究。

本文将神经网络融合的思想应用于短期负荷预 测领域,采用不同类型神经网络并行特征提取的核 心算法构架,提出一种基于多神经网络融合FOMNN (Fusion Of Multiple Neural Networks)的预测方法, 以发挥不同神经网络的优势。首先,将原始数据通 过 CNN 通道提取静态特征并通过池化操作降低特 征的复杂程度,同时将原始数据通过另一个GRU通 道挖掘动态时序特征;其次通过注意力机制网络将 前述两部分特征融合,并动态调整网络在不同条件 下对不同特征的依赖程度,提高网络的运行效率;然 后通过 Maxout 网络综合提升网络的非线性映射能 力,经过循环迭代,最终实现对于连续短期负荷的有 效预测。

1 影响短期负荷的因素

电力系统短期负荷的波动是一个复杂的非线性 过程,主要受历史负荷、气象及季节因素、日期类型 的影响较大。文献[19]针对上述3类不同的影响因 素将短期负荷L,分解为式(1)。

$$L_{t} = L_{th} + L_{tw} + L_{td} + L_{tn} \tag{1}$$

其中,*L*_h为受历史负荷影响较大的短期负荷分量; *L*_{tw}为受气象及季节因素影响较大的分量;*L*_{td}为受日 期类型影响较大的分量;*L*_m为随机产生的分量。由 于*L*_m不可预知,故一般通过挖掘*L*_h、*L*_{tw}、*L*_{td}与历史负 荷、气象及季节因素、日期类型间的非线性关系来预 测短期负荷。

历史负荷对于短期负荷的影响主要表现为两方 面:一是相近的几天同一时刻的负荷值具有相似性; 二是待测负荷前某几个时刻的负荷值与待测负荷在 变化趋势上具有相似性。对于不同实际情况,上述 两方面对于短期负荷实际的影响程度可能不同。经 反复测试,本文选择待测负荷前7个时刻的负荷作 为历史负荷因素。

气象及季节因素是影响短期负荷波动的重要因 素。本文所用的负荷原始数据来源于我国华东某 地,该地气候受海洋影响较大,四季分明、降水较多 且全年多风,因此本文选择温度、相对湿度、降水量、 风速、季节这5种因素。

日期类型不同将使负荷结构产生较大变化,如 周一至周五的日用电量中第二产业工业用电占比较 大,故本文将周一至周日作为日期类型因素。

2 FOMNN 预测方法

2.1 CNN

CNN 主要包括卷积层和池化层,其被广泛用于 图像等数据的静态特征提取。一个典型的 CNN 是 利用卷积层通过卷积核的滑窗运算实现对输入数据 静态特征的提取,再通过池化层利用关键特征的尺 度不变性对提取出的特征进行降维,使得关键特征 进一步凸显,并通过参数共享降低网络的复杂程度。 常用的最大值池化层是滑动选取池化窗内的最大值 作为最终的输出特征。

2.2 GRU网络

时序性是短期负荷的重要属性。在提取数据的

时序特征方面,基于 RNN 改进的 LSTM 和 GRU 具有 较大优势,其可以学习到较长时间跨度内负荷数据 间的时间序列关系,并且 GRU 较 LSTM 有更加简洁 的参数及网络结构,这使得训练 GRU 在时间成本方 面更加经济。

GRU通过独特的更新门和重置门实现对"历史 负荷动态特征"的加强与遗忘:在某一时刻t神经元 的输入负荷状态信息为 x_i ,其上一时刻的负荷状态 信息为 h_{t-1} ,更新门经过线性计算与非线性处理,确 定哪些信息需要被"加强"并输出对应的权值矩阵 z_i ;重置门的工作方式与之类似, r_i 为确定哪些信息 需要被"遗忘"的权值矩阵;利用输入状态信息 x_i 和 r_i 可以产生当前神经元的状态 h'_i ,再经过更新门权值 矩阵 z_i 的加权处理即为该神经元当前时刻的输出状 态信息 h_i 。具体的公式表达如下:

$$\boldsymbol{z}_{t} = \boldsymbol{\sigma} \left(\boldsymbol{U}_{z} \boldsymbol{x}_{t} + \boldsymbol{W}_{z} \boldsymbol{h}_{t-1} \right)$$
(2)

$$\boldsymbol{r}_{t} = \boldsymbol{\sigma} \left(\boldsymbol{U}_{r} \boldsymbol{x}_{t} + \boldsymbol{W}_{r} \boldsymbol{h}_{t-1} \right) \tag{3}$$

$$\boldsymbol{h}_{t}' = \tanh\left[\boldsymbol{U}_{h}\boldsymbol{x}_{t} + \boldsymbol{W}_{h}(\boldsymbol{r}_{t} \circ \boldsymbol{h}_{t-1})\right]$$
(4)

$$\boldsymbol{h}_{t} = (\boldsymbol{I} - \boldsymbol{z}_{t}) \circ \boldsymbol{h}_{t}' + \boldsymbol{z}_{t} \circ \boldsymbol{h}_{t-1}$$
(5)

其中,U为当前时刻输入数据对应的权重;W为历史 记忆对应的权重;σ(·)、tanh(·)为非线性激活函数; I为元素全为1的矩阵;"。"表示对各元素依次相乘。

2.3 注意力机制网络

注意力机制 AM (Attention Mechanism) 网络是 对人脑注意力的模拟,可以帮助网络从众多信息中 更有效地选择对当前目标更关键的信息。本文将不 同负荷特征的注意力值量化为在 0~1之间取值的权 重,且在一个计算周期内,所有特征的注意力值之和 为1。由 CNN 提取出的负荷静态特征记作 C,由 GRU 网络提取出的负荷时序特征记作 C。按照式 (6)对两部分特征进行融合;用点积运算衡量负荷特 征与第*i*个历史负荷特征 F_i(*i*=1,2,…,*n*)的相关性, 进而得到注意力值 A,如式(7)所示;根据注意力值 计算历史负荷特征的加权和即为最终的负荷特征 F_a,如式(8)所示。通过上述操作,网络可以较为完 备地提取负荷历史数据的静态、动态特征,并根据特 征的重要性动态调整其对结果的影响。

$$\boldsymbol{F} = \tanh(\boldsymbol{G}\boldsymbol{W}_{a}\boldsymbol{C}^{\mathrm{T}} + \boldsymbol{b}_{a}) \tag{6}$$

$$A = \frac{\exp(F)}{\sum_{n=1}^{n} (F)}$$
(7)

)

$$\sum_{i=1}^{n} \exp(\mathbf{F}_{i})$$

$$F_A = \sum_{i=1}^{N} A F_i \tag{8}$$

其中,**b**_a为训练得到的偏置项;**F**为融合后的负荷特征。

2.4 Maxout 网络

结果输出模块在传统全连接层的基础上增加了 Maxout^[20]层, Maxout 层的结构如图1所示。Maxout 层可以看作是具有激活函数功能的网络层,其隐藏 层节点的关系及激活函数都可以通过学习不断更 新,采用分段线性化的方式对输入特征进行拟合,理 论上可以拟合任意凸函数,进而可以增强网络的非 线性表示能力,提升网络的鲁棒性。其公式为:

$$\boldsymbol{h}_i(\boldsymbol{x}) = \max(\boldsymbol{o}_{ij}) \tag{9}$$

$$\boldsymbol{o}_{ij} = \boldsymbol{x}^{\mathrm{T}} \boldsymbol{W}_{ij} + \boldsymbol{b}_{ij} \tag{10}$$

其中, h_i 为第i层输出状态;max(•)为取输入量最大 值的函数;x为输入数据; o_i 为第i层第j个神经元的 输出值。



图 1 Maxout 网络 Fig.1 Maxout networks

2.5 FOMNN预测方法

本文所述的FOMNN预测方法如式(11)所示。

 $\hat{L}_{i} = f(l_{i-k}, d_{i}, s_{i}, t_{i}, m_{i}, r_{i}, w_{i})$ (11) 其中, f为深度神经网络从海量原始数据中学习得 到的隐含关系,括号中为输入特征,由与短期负荷有 较强相关性的多维特征数据列构成,根据前述分析, 本文选择待测负荷前7个时刻的历史有功负荷数据 $l_{i-k}(k=7)$ 及对应时刻的日期类型 d_{i} 、季节 s_{i} 、温度 t_{i} 、 相对湿度 m_{i} 、降水量 r_{i} 、风速 w_{i} ,本文旨在验证新的 预测方法,故并未考虑诸如电价等更多的相关因素; \hat{L}_{i} 为输出值,即指定时刻的负荷预测值。式(11)循 环迭代即可得到连续不同时刻的负荷预测值。

FOMNN预测方法的核心为深度神经网络,其并行网络结构如图2所示,主要包括2个通道和2个模块,分别为由 CNN构成的静态特征提取通道、由GRU构成的动态时序分析通道以及基于注意力机制网络的特征融合模块、由 Maxout 网络和全连接网络构成的结果输出模块。

静态特征提取通道采用1层1维卷积层与1层1 维最大值池化层堆叠构成。在原始数据输入该通道 前,将其分割成多个7×7阶的方阵,在该通道中首先 经过64个大小为1×3的卷积核提取特征,再经过窗 口为2的最大池化层降低特征维度,最后通过扁平 操作及隐藏层输出提取到的静态特征。动态时序分 析通道采用4层GRU堆叠而成,时间步数设定为7, 神经元个数依次为128、64、64和32。上述2个通道



图 2 基于 FOMNN 的短期负荷预测方法 Fig.2 Short-term load forecasting method based on FOMNN

提取出的不同特征通过注意力机制网络进行融合, 最终的特征通过层数为1、神经元个数为10的 Maxout网络实现非线性映射,最后通过神经元个数 为1的隐藏层输出待测时刻的短期负荷预测结果。

2.6 网络训练及优化

网络训练及优化均以 Dell R730 服务器为硬件 平台,处理器为 Intel Xeon E5-2630,内存为 64 GB, 显卡为 NVIDIA TITAN Xp,操作系统为 Windows Server 2012 R2。网络采用 Python 语言编写,在 Keras 深度学习框架下以 Tensorflow 为后端实现。

网络的训练采用有监督的学习方式,训练过程 中可以将误差损失衰减趋于平稳作为网络停止训练 的标志,误差损失计算采用均方误差:

$$F_{\rm loss} = \frac{1}{n} \sum_{i=1}^{n} (y_i - \hat{y}_i)^2$$
(12)

其中,y_i为负荷的真实值;ŷ_i为网络的输出值。

网络的优化采用 RMSProp 优化算法,该算法可 以自动调整学习率,并对历史梯度进行指数平均衰 减,避免了学习率衰减过快。

2.7 预测结果评价

根据惯例,本文采用平均绝对百分比误差^[21] (MAPE)和均方根误差^[22](RMSE)作为预测结果的 评价指标。

3 算例及网络性能分析

3.1 原始数据预处理

原始数据包括前述输入特征数据和历史负荷数据,2类数据的采样时刻及采样间隔均相同。历史 负荷数据选用我国华东某地区2006至2011年的历 史有功负荷记录。该记录以15 min 的采样时间间隔 每日采集96个数据,在2201 d的时间跨度中采集到 共计211296个历史有功负荷数据。输入特征数据 和历史负荷数据共计1479072个数据。

由于不同属性的数据具有不同的数量级,故对 以上数据采用式(13)进行归一化处理,常规的数据 清洗等工作不再赘述。

$$x_{\rm n} = \frac{x - x_{\rm min}}{x_{\rm max} - x_{\rm min}} \tag{13}$$

其中,x为输入数据;x_{min}与x_{max}为原始数据的2个极 值。对于日期类型和季节数据,周一至周日分别采 用数字1-7表示,春夏秋冬4个季节分别采用数字 1-4表示。经过上述预处理后,将2006至2009年 的数据作为训练集,2010至2011年的数据作为测试 集,分别切分为多个7×7阶的方阵,用于下一步神经 网络训练与超参数调整。

3.2 网络超参数设置

网络超参数主要包括网络层数、隐藏层神经元 个数、输出层神经元个数和学习率,其中全局初始学 习率为0.01,其他参数具体设置如下。

(1)静态特征提取通道。其包含1层1维卷积层 和1层1维最大值池化层。卷积层参数为:卷积核数 量为64,卷积核大小为3,激活函数为relu。最大值 池化层参数为:池大小为2,步长为1。隐藏层神经 元个数为14。

(2)动态时序分析通道。其含4层GRU隐藏层。 神经元个数分别为128、64、64、32,激活函数为relu。

(3)结果输出模块。其包含1层Maxout层和1 层隐藏层。Maxout层参数为:神经元个数为10。隐 藏层参数为:神经元个数为1,激活函数为sigmoid。

3.3 预测结果及对比分析

本文预测的基本时间跨度为1d,按照15 min的时间间隔逐次预测1d中96个不同时刻的负荷值。

在保证输入特征等条件相同的情况下,选择 SVM、BPNN、GRU这3种方法与本文所述FOMNN 进行对比,某天部分时刻的预测结果以及评价指 标对比详见附录中表A1。图3为该天不同方法的 预测结果曲线图。从图中可以看出,相较于其他方 法,FOMNN的MAPE在1d内均保持在较低水平, 其最大值为 2.89,也远小于其他 3 种方法,体现了 FOMNN 较高的预测准确性及平稳性;本文所述 FOMNN 预测方法的预测结果曲线能够最大限度拟 合负荷的实际曲线,体现了网络较强的非线性映射 能力。由于本文仅以较为关键的 7 种因素作为输入 特征,并且在原始数据采集过程中也会存在一定的 误差,故在波动较大的部分时刻(如 15:00 左右)4 种 方法均产生了一定的误差,但 FOMNN 的预测效果 相对更好。此外,考虑到算法运行速度也是衡量算 法优劣的重要指标,在上述的硬件条件下,FOMNN 的平均训练时间为 830.12 s,而 SVM、BPNN 和 GRU 的平均训练时间分别为 714.35、896.22、788.31 s,可 以看出 FOMNN 的平均训练时间相较于 GRU 有所增 加,但仍短于 BPNN;在滚动预测 1 d的负荷时各方 法的耗时差别不大,均在1 s以内。





仅根据某一天的预测结果不能对FOMNN方法 进行综合评价,由于工作日与休息日的日负荷情况 常有较大不同,本文采用不同方法对不同日期类型 的日负荷进行预测,结果评价指标如表1所示。由 表1可知,4种方法预测误差的最小值均出现在工作 日,SVM、BPNN、GRU的误差在休息日明显增大,而 FOMNN的预测表现相对较为平稳,由此可见FOMNN 对于不同日期类型的负荷均具有较好的适应能力。

不同季节的日负荷也会有较大的变化,本文在 春夏秋冬4个季节各随机选择某一天,将多神经网 络融合前后的不同方法进行对比,预测结果的评价 指标如表2所示。由表可知,7种方法在春季和秋季

表1 不同方法在不同日期类型下的对比

Table 1	Comparison	among	different	methods	under	different	date	ty	pe

日期	SVM		BPNN		GRU		FOMNN	
类型	MAPE / %	RMSE / MW						
1	1.76	295.49	3.30	378.69	3.25	423.24	2.23	329.68
2	3.47	413.24	2.59	334.46	2.38	386.23	0.79	193.24
3	1.45	262.72	2.27	290.87	1.03	179.66	1.25	309.80
4	2.24	288.50	3.15	421.90	0.85	165.40	0.92	223.12
5	2.11	351.38	1.73	288.15	1.18	186.21	0.34	116.93
6	5.82	579.46	5.38	517.44	4.67	473.24	0.88	177.05
7	3.61	462.43	4.37	598.56	4.04	419.35	1.09	224.44

表2 神经网络融合前后预测性能的对比

Table 2 Comparison of prediction performance between before and after neural network fusion

	春季某随机日		夏季某随机日		秋季某随机日		冬季某随机日	
刀伝	MAPE / %	RMSE / MW						
LSTM	2.98	345.11	4.78	486.62	3.72	469.37	4.93	546.27
GRU	3.12	365.34	5.01	603.89	3.45	428.63	4.83	529.68
CNN-GRU	2.52	280.91	2.45	435.61	2.03	327.39	3.63	309.51
AM-GRU	1.65	261.13	4.56	562.80	2.61	374.77	3.85	429.34
Maxout-GRU	2.66	301.24	3.57	480.35	1.39	254.23	2.99	339.24
CNN-AM-GRU	1.01	203.88	2.69	381.09	1.89	279.01	3.08	354.74
FOMNN	0.73	187.90	1.52	209.26	1.03	223.40	1.78	263.41

的预测效果较好,而在夏季和冬季出现了一定波动, 通过不同神经网络的融合,预测误差有降低趋势。 整体而言,FOMNN的 MAPE 和 RMSE 在4个季节保 持在较低的水平,体现了本文所提方法具有较高的 预测性能。此外,本文也尝试剔除部分输入特征(如 天气特征或季节特征)以检验其对预测结果鲁棒性 的影响,实验结果表明,无论剔除哪种输入特征均会 降低预测结果的准确性,这也说明合适的输入特征 对于实现短期负荷的准确预测是必不可少的。

4 结论

针对电力系统对于短期负荷预测准确度要求日益提高的现状,本文提出一种并行架构的 FOMNN 预测方法。算例和性能分析表明,本文所提方法通 过多神经网络融合提升了网络的预测准确性与平稳 性,增强了网络针对不同季节、日期类型日负荷的鲁 棒性与非线性映射能力,且在输入特征种类增多时 优势更加明显,相较于使用单一神经网络的预测方 法更具实际应用价值。

在本文所提方法的基础上,增加特征相关性判 定等环节,即可衍生出针对不同外部条件的短期负 荷预测方法。利用本文方法输出的短期负荷预测结 果也可进一步实现针对短期负荷的区间预测,使短 期负荷预测更具决策参考意义。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- [1]陈昊,王玉荣.基于随机波动模型的短期负荷预测[J].电力 自动化设备,2010,30(11):86-89.
 CHEN Hao,WANG Yurong. Short-term load forecasting based on SV model[J]. Electric Power Automation Equipment,2010, 30(11):86-89.
- [2] HOR C L, WATSON S J, MAJITHIA S. Daily load forecasting and maximum demand estimation using ARIMA and GARCH [C/OL]. Stockholm, Sweden: IEEE, 2006[2019-01-05]. https:// ieeexplore.ieee.org / document / 4202249.
- [3] MAHMUD M A. Isolated area load forecasting using linear regression analysis: practical approach[J]. Energy and Power Engineering, 2011, 3(4):547-550.
- [4]万昆,柳瑞禹.区间时间序列向量自回归模型在短期电力负荷 预测中的应用[J].电网技术,2012,36(11):77-81.

WAN Kun,LIU Ruiyu. Application of interval time-series vector autoregressive model in short-term load forecasting[J]. Power System Technology, 2012, 36(11):77-81.

 [5]张平,潘学萍,薛文超.基于小波分解模糊灰色聚类和BP神经 网络的短期负荷预测[J].电力自动化设备,2012,32(11):121-125,141.

ZHANG Ping, PAN Xueping, XUE Wenchao. Short-term load forecasting based on wavelet decomposition, fuzzy gray correlation clustering and BP neural network[J]. Electric Power Automation Equipment, 2012, 32(11):121-125, 141.

[6] 王保义,王冬阳,张少敏. 基于 Spark 和 IPPSO_LSSVM 的短期 分布式电力负荷预测算法[J]. 电力自动化设备,2016,36(1): 117-122.

WANG Baoyi, WANG Dongyang, ZHANG Shaomin. Distributed short-term load forecasting algorithm based on Spark and IPPSO_SSVM[J]. Electric Power Automation Equipment, 2016, 36(1):117-122.

- [7]张智晟,于道林.考虑需求响应综合影响因素的RBF-NN短期 负荷预测模型[J].中国电机工程学报,2018,38(6):1631-1638,1899.
 ZHANG Zhisheng, YU Daolin. RBF-NN based short-term load forecasting model considering comprehensive factors affecting demand response[J]. Proceedings of the CSEE,2018,38(6):
- 1631-1638,1899.
 [8] 鞠平,周孝信,陈维江,等."智能电网+"研究综述[J]. 电力自动化设备,2018,38(5):2-11.
 JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. "Smart Grid Plus" research overview[J]. Electric Power Automation Equipment,2018,38(5):2-11.
- [9] SCOTT D, SIMPSON T, DERVILIS N, et al. Machine learning for energy load forecasting [J]. Journal of Physics: Conference Series, 2018, 11(1):12-25.
- [10] 孔祥玉,郑锋,鄂志君,等. 基于深度信念网络的短期负荷预测 方法[J]. 电力系统自动化,2018,42(5):133-139.
 KONG Xiangyu,ZHENG Feng, E Zhijun, et al. Short-term load forecasting based on deep belief network[J]. Automation of Electric Power Systems,2018,42(5):133-139.
- [11] 梁智,孙国强,李虎成,等.基于VMD与PSO优化深度信念网络的短期负荷预测[J].电网技术,2018,42(2):598-606.
 LIANG Zhi,SUN Guoqiang,LI Hucheng, et al. Short-term load forecasting based on VMD and PSO optimized deep belief network[J]. Power System Technology,2018,42(2):598-606.
- [12] LI L Z, OTA K, DONG M X. Everything is image: CNN-based short-term electrical load forecasting for smart grid [C]//2017 14th International Symposium on Pervasive Systems, Algorithms and Networks & 2017 11th International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing(ISPAN-FCST-ISCC). Exeter, UK: IEEE, 2017:344-351.
- [13] 李鹏,何帅,韩鹏飞,等.基于长短期记忆的实时电价条件下智能电网短期负荷预测[J].电网技术,2018,42(12):4045-4052.

LI Peng, HE Shuai, HAN Pengfei, et al. Short-term load forecasting of smart grid based on long-short-term memory recurrent neural networks in condition of real-time electricity price [J]. Power System Technology, 2018, 42(12):4045-4052.

- [14] 吴倩红,韩蓓,冯琳,等."人工智能+"时代下的智能电网预测 分析[J]. 上海交通大学学报,2018,52(10):1206-1219,1266.
 WU Qianhong,HAN Bei,FENG Lin, et al. "AI+" based smart grid prediction analysis[J]. Journal of Shanghai Jiao Tong University,2018,52(10):1206-1219,1266.
- [15] 陆继翔,张琪培,杨志宏,等.基于CNN-LSTM混合神经网络模型的短期负荷预测方法[J].电力系统自动化,2019,43(8): 131-137.

LU Jixiang, ZHANG Qipei, YANG Zhihong, et al. Short-term load forecasting method based on CNN-LSTM hybrid neural network model[J]. Automation of Electric Power Systems, 2019, 43(8):131-137.

- [16] 彭文,王金睿,尹山青.电力市场中基于Attention-LSTM 的短期负荷预测模型[J].电网技术,2019,43(5):1745-1751.
 PENG Wen,WANG Jinrui,YIN Shanqing. Short-term load forecasting model based on Attention-LSTM in electricity market
 [J]. Power System Technology,2019,43(5):1745-1751.
- [17] 王增平,赵兵,纪维佳,等. 基于 GRU-NN 模型的短期负荷预测 方法[J]. 电力系统自动化,2019,43(5):53-58.
 WANG Zengping,ZHAO Bing,JI Weijia, et al. Short-term load forecasting method based on GRU-NN model[J]. Automation of Electric Power Systems,2019,43(5):53-58.
- [18] 陈海文,王守相,王绍敏,等. 基于门控循环单元网络与模型融合的负荷聚合体预测方法[J]. 电力系统自动化,2019,43(1): 65-74.

CHEN Haiwen, WANG Shouxiang, WANG Shaomin, et al. Aggregated load forecasting method based on gated recurrent unit networks and model fusion[J]. Automation of Electric Power Systems, 2019, 43(1):65-74.

- [19] CHEN H, CANIZARES C A, SINGH A. ANN-based short-term load forecasting in electricity markets [C / OL]. Columbus, OH, USA: IEEE, 2001[2019-01-05]. http://ieeexplore.ieee.org/ xpls/icp.jsp?arnumber=916876.
- [20] GOODFELLOW I J, WARDE-FARLEY D, MIRZAM, et al. Maxout networks[J]. Computer Science, 2013, 28(3):1319.
- [21] 李伟,董伟栋,袁亚南.基于组合函数和遗传算法最优化离散 灰色模型的电力负荷预测[J].电力自动化设备,2012,32(4): 76-79.
 LI Wei,DONG Weidong,YUAN Yanan. Load forecasting based

on discrete grey model optimized by composite function and genetic algorithm[J]. Electric Power Automation Equipment, 2012,32(4):76-79.

[22] 刘文霞,徐晓波,周樨. 基于支持向量机的纯电动公交车充 / 换电站日负荷预测[J]. 电力自动化设备,2014,34(11):41-47. LIU Wenxia,XU Xiaobo,ZHOU Xi. Daily load forecasting based on SVM for electric bus charging station[J]. Electric Power Automation Equipment,2014,34(11):41-47.

作者简介:



底 吴(1994—), 男, 河南安阳人, 硕 士研究生, 研究方向为人工智能技术在电 力系统中的应用(**E-mail**: Pang.hao@outlook. com);

高金峰(1963—),男,河南项城人,教 授,博士研究生导师,博士,主要研究方向为 电工理论与新技术(E-mail: jfgao@zzu.edu. cn);

杜耀恒(1990—),男,山东烟台人,工 程师,硕士,主要研究方向为电力系统状态估计(E-mail: 937075064@qq.com)。

(编辑 王锦秀)

Short-term load forecasting method based on fusion of multiple neural networks PANG Hao¹, GAO Jinfeng¹, DU Yaoheng²

(1. Industrial Technology Research Institute, Zhengzhou University, Zhengzhou 450001, China;

2. Yantai Power Supply Company of State Grid Shandong Electric Power Company, Yantai 264000, China)

Abstract: In order to make use of the advantages of different deep neural networks and improve the ability of deep learning algorithm for short-term load forecasting, a short-term load forecasting method based on multiple neural networks fusion is proposed. The historical active power load, season, date type and weather data of power system are taken as input characteristics, while the deep neural network and attention mechanism network of parallel architecture are taken as core network. The static features are extracted by the convolutional neural network channel in the parallel architecture, the dynamic time series features are mined by the gated recurrent unit network channel, and the attention mechanism network is adopted to fuse the extracted features and dynamically adjust the dependent degree of network on different features. Maxout network is used to enhance the non-linear mapping ability of the whole network, and the forecasting results are output through the fully connected network. Compared with the results of support vector machine and long- and short-term memory network, the proposed method has higher forecasting stability and accuracy. **Key words**:short-term load forecasting;fusion of multiple neural networks;gated recurrent unit network;convolutional neural network;attention mechanism network;Maxout network



图 A1 空调可关断时间计算示意图

Fig.A1 Schematic diagram of the of shutoff time calculation of air conditioning

图中
$$A(0) = \frac{T_{\text{max}} - T_{\text{in}}^0}{T_{\text{max}} - T_{\text{min}}}$$
为空调的初始状态。由图中的比例关系可知 $\frac{T_{\text{max}} - T_{\text{in}}^0}{T_{\text{max}} - T_{\text{min}}} = \frac{h_{\text{off}}^0}{h_{\text{off}}} = A(0)$ 。

因此 $A(0)h_{off}$ 为空调由初始状态第一次上升至温度区间上限时的关断时间 h_{off}^0 。在之后的调度时间中,空调进行反复多次的轮控,但是调度时间 $T_{opt} - A(0)h_{off}$ 往往不能被控制周期 h 整除,所以 q_1 为轮控的次数, q_2 为余下不满一个控制周期的时间,即 $T_{opt} = A(0)h_{off} + q_1h + q_2$

但是当 $q_2 > h_{on}$ 时,可关断时间仍需加上 q_3 , $q_3 = \begin{cases} 0 & q_2 \le h_{on} \\ q_2 - h_{on} & q_2 > h_{on} \end{cases}$ 。

可关断时间 H 即为图中标圆圈的几段相加,即 $H = A(0)h_{off} + q_1h_{off} + q_3$ 表 A1 节点 6 聚类小组 14 温度情况

Table A1 Temperature conditions of Clustering group 14 of Bus of							
空调编号	优化窗3结束温度/℃	优化窗4结束温度/℃					
170	25.483 88	24.945 78					
127	25.299 07	24.978 40					
131	25.272 77	25.076 42					
199	25.239 02	25.239 02					
155	25.199 03	25.009 42					
114	25.132 99	24.859 95					
198	25.009 42	24.608 62					
179	24.987 53	24.549 73					
163	24.945 78	24.424 17					

附录:



图 A2 节点 6 聚类小组 14 各空调温度曲线图

Fig.A2 Temperature profiles of air conditioning of Clustering group 14 of Bus 6

以遗传算法为例说明筛选的过程。分别以 *T*_{max} 和 *T*_{min} 作为空调温度的上、下限。首先生成一个优化时间 窗所有组空调的多维决策样本,即染色体样本。计算该决策下空调是否会出现温度越限问题,若越限则舍弃 该样本。不断循环生成满足要求的染色体样本,直到达到一定的种群数量。此时的样本满足温度约束但是调 度偏差较大。所以需要进行多次的遗传迭代,通过交叉变异不断筛选,最后从结果中选出调度偏差最小的决 策样本。

以一个聚类小组为单位分析空调启停的状态量。选取节点 6 第四个优化时间窗聚类小组 14 的空调温度情况,未分组前空调编号 1—200。聚类小组 14 中的空调编号如表 A1 所示。第四个优化时间窗内空调启停状态的决策结果如下(0表示关闭,1表示开启):

由表 A1、图 A2 可以看出,所有的空调的温度都在 23~27℃范围内,满足用户舒适度的要求。同时可以发 现空调并没有达到上下限,这是由于受控于大目标负荷削减量的要求,并且需要配合其他聚类组的情况,用 户端的空调虽希望尽可能发挥可调控潜力,但无法总是发挥它的最大潜力。