

基于深度学习的短期负荷预测综述^①

黄运有^{②*} 詹剑锋^{③*}

(* 中国科学院计算技术研究所 北京 100190)

(** 中国科学院大学 北京 100049)

摘要 负荷预测是电力系统中最重要的工作之一,准确的负荷预测可以帮助决策者合理地进行电网资源的调度,对保持电网高效、稳定、安全、经济地运行具有重要的作用。随着智能电网的发展,用户的用电数据呈指数增长,这促进了负荷预测研究的快速发展。特别是近年来负荷预测领域的技术已经发生了巨大的转变,很多传统的负荷预测方法逐渐被更加精确的基于数据驱动的深度学习方法所取代。本文综述了近年来深度学习方法在短期负荷预测领域的发展,并对深度学习在短期负荷预测中的最新成果进行了总结与深入分析,最后对短期负荷预测领域未来的发展进行了展望。

关键词 负荷预测;机器学习;智能电网;深度学习;大数据

0 引言

2017 年我国的电力能源消耗总量达到了 64 821.0 亿 kWh,比 2007 年的 32 711.8 亿 kWh 增长了 98.16%^[1],其中有 15 843.3 亿 kWh 来自于可再生能源发电。由于可再生能源发电具有成本低廉及环境友好等特点,其将在全年可供电量中占越来越大的比重。然而,波动性是可再生能源发电的最大特点之一。当可再生能源发电并入电网时,其波动性将会给电网的安全性、稳定性和效率带来严峻的挑战。目前仅靠发电侧的调节能力难以解决波动性新能源发电接入后电力系统日趋严重的实时供需失衡、安全系数降低以及效率低下等问题^[2]。为此需要整合发电侧、电网以及用户侧使其形成一个高效统一的整体对电力系统进行调整。而开发各种类型用户导向的应用(如需求响应)是把用户侧与发电侧及电网整合在一起共同对整个电力系统进行调节和维护,从而保证电网健康有效运行的主要手

段^[3]。

在电力系统中负荷预测是实施各类用户导向应用的基础,一直备受研究人员的关注^[4]。一般根据预测期限的长短可以把负荷预测大致分为长期负荷预测(3 a~5 a)、中期负荷预测(14 d~3 a)、短期负荷预测(1 h~7 d)以及超短期负荷预测(1 min~1 h)^[5]。其中,由于长期和中期的负荷变化规律趋于稳定,所以关于长期和中期负荷预测的研究已经很成熟^[6-8]。而短期的负荷变化则比较随机,预测起来难度也比较大,因此短期负荷预测(本文将短期负荷预测和超短期负荷预测统称为短期负荷预测)还处于较为早期的阶段并引起了研究人员的关注^[7-8]。特别是随着深度学习的发展,大量的深度学习技术被用在短期负荷预测研究中并取得了较为理想的效果,这使得深度学习逐渐成为了负荷预测研究中的主流技术之一。本文对近期深度学习技术在短期负荷预测中的应用进行总结与分析,给出短期负荷预测领域未来的发展趋势与建议。

① 国家自然科学基金(61432006)资助项目。

② 男,1990 年生,博士生;研究方向:人工智能,电力大数据;E-mail: huangyunyou@gxnu.edu.cn

③ 通信作者,E-mail: zhanjianfeng@ict.ac.cn

(收稿日期:2020-03-16)

1 深度学习

深度学习是从神经网络演化而来的机器学习的分支,其在语音识别、计算机视觉及自然语言理解等多个领域中已取得突破性进展,属于目前最受关注的人工智能技术^[9]。如图1所示,深度学习通过在输入 x 和输出 y 之间加入多个隐藏层,自动地学习 x 与 y 之间复杂的非线性关系(例如 $y=f(x)$)^[10],深度学习的这种能力也使其成为了目前解决负荷预测问题的首选技术^[11]。目前流行的深度学习架构主要包括卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)。




图1 深度学习的基本框架

CNN 是一类包含卷积计算的前馈型神经网络架构,其灵感来自于生物的自然视觉感知机制^[12-13]。CNN 的特点是它在网络中采用局部连接和权值共享的机制。一方面,可以减少网络参数便于网络的优化;另一方面,减少了模型的复杂性和过拟合的风险。除此之外,CNN 被证明有强大的局部数据提取能力,以及拥有某些有用的先验知识以补充数据中缺失的信息^[14-15]。目前 CNN 被广泛地应用于计算机视觉、语音和自然语言处理领域,并取得了显著的效果。

RNN 是一类以序列数据为输入且所有节点(循环单元)按链式连接的神经网络结构,它在序列的演进方向进行递归^[16]。RNN 一次只处理输入序列

中的一个元素并在其隐藏单元中保持一个状态向量,该状态向量隐含了关于序列的所有过去元素的历史信息,使得 RNN 每一步都能根据目前的输入以及历史输入综合地得到结果^[17]。因此,RNN 成为了所有解决序列预测问题(包括负荷预测问题)的首选技术。

2 短期负荷预测

因为在不同的具体负荷预测任务中可获取的用户用电相关信息可能存在差异,所以每个具体的负荷预测任务也不尽相同。为此本文给出了负荷预测的一般定义及形式化表示。负荷预测是利用观测到的历史数据以及未来的计划等信息预测未来的负荷变化,如式(1)所示。

$$\begin{cases} Y' = f(X) \\ X = \{x_1, x_2, \dots, x_i\} \\ Y' = \{y'_1, y'_2, \dots, y'_j\} \end{cases} \quad (1)$$

其中, X 为一个观测到的历史信息序列,如历史用电量序列, Y' 为预测的未来某一个时间段内的用电量序列, f 为输入到输出之间的映射。此外,负荷预测的目标是为了获得未来一段时间内实际的负荷变化,因此负荷预测任务实际上就是最小化式(2)。

$$\begin{cases} \text{loss}(Y', Y) = \sqrt{\frac{1}{n} \sum_{j=1}^n (y'_j - y_j)^2} \\ Y = \{y_1, y_2, \dots, y_j\} \end{cases} \quad (2)$$

其中, Y 为未来某一个时间段内的真实用电量序列, n 为 Y 序列的长度。

不同类型的负荷变化规律差异巨大并且用到的预测模型也各不相同,因此与以前的负荷研究综述按照预测时间长短对负荷预测方法进行分类不一样,本文以负荷预测任务中预测的负荷类型对短期负荷预测方法进行分类^[6,18-19]。目前比较受关注的短期负荷预测有以下4类。

(1) 区域负荷预测。预测某个区域、国家甚至全球在未来短时间内的负荷变化。

(2) 工业或商业用户负荷预测。预测工商业等大用户在未来短时间内的负荷变化。

(3) 居民用户聚合负荷预测。预测多个居民用

户在未来短时间内的总负荷变化或平均负荷变化。

(4) 居民用户负荷预测。预测单个居民用户未来短时间内的负荷变化。

3 负荷预测研究概述

负荷预测在国内外一直都是热点研究问题,为了提供关于负荷预测研究的直观认知,本文查询了近年来 Web of Science (WoS) 上收录的文献。查询语句为 TS = (“load forecasting” AND (“deep learning” OR “ANN” OR “RNN” OR “CNN” OR “DNN” OR “LSTM” OR “TCN” OR “GRU” OR “artificial neural network” OR “recurrent neural network” OR “deep neural network” OR “convolutional neural network” OR “long short-term memory” OR “gated recurrent unit” OR “deep residual learning” OR “ResNet” OR “artificial neural networks” OR “recurrent neural networks” OR “deep neural networks” OR “convolutional neural networks” OR “neural networks” OR “neural network”) AND (“Short Term” OR “Short-Term”))。

图2展示了近十年来被 WoS 收录的负荷预测文献的发表数量。以负荷预测为主题的文献总数量为 6301 篇,其中基于深度学习的文献数量为 2323 篇,占了负荷预测研究数量的 36.87%。而在所有的基于深度学习的负荷预测文献中以短期负荷预测为研究主题的文献数量为 1251 篇,占了基于深度学习的负荷预测文献的 53.85%,成为研究人员最关注的负荷预测技术研究主题。此外,从图2中还可




图2 近年来被 WoS 收录的负荷预测的文章数量

以看出,无论哪一种类型的负荷预测文献其发表量都在逐年增加,这说明了负荷预测不仅一直是研究的热点而且还会越来越受研究人员的关注。

图3展示了近年来被 WoS 收录的基于深度学习的负荷预测文献发表数量的分布,由于篇幅的原因只展示文献发表数量前 10 的国家或地区。其中,中国为发表基于深度学习的负荷预测文献最多的国家,其文献数量为 1299 篇,占文献总数的 64.37%。而美国作为基于深度学习的负荷预测文献发表数量第 2 的国家,其文献数量仅为 182 篇,占文献总数的 9.02%。从文献发表数量可以看出,目前中国对智能电网研究的投入取得了显著的成效。另外,与其他国家相比,短期负荷预测对于改善中国的电网环境存在更大的研究意义。




图3 近年来被 WoS 收录的负荷预测的文章数量的分布

4 国内外研究现状

近年来,如表1所示,研究人员提出了一大批基于深度学习的负荷预测算法,这些算法主要由基于全连接神经网络、RNN 以及 CNN 的深度学习模型构成。为了直观地比较这些算法,表1列出了决定这些算法复杂度的因素(有些因素在相关的文章中并没有给出,本文中用‘-’代替)及算法的输入和输出。其中算法的复杂度主要由模型的网络类型、神经元个数以及层数决定。通常来说,同等条件下基于 RNN 的模型和基于全连接的模型要比基于 CNN 的模型复杂,层数越深的模型越复杂,神经元个数越多的模型越复杂。

4.1 区域负荷预测

区域级别的负荷变化一般较为稳定并且与宏观信息(例如国内生产总值)及天气信息等相关度较

表 1 短期负荷预测研究

文献	网络类型	神经元个数	层数	模型输入	模型输出
[20]	全连接神经网络	-	3	历史负荷值、温度、湿度日类型	某地区接下来 1 h 的负荷值
[21]	深度信念网络	-	-	历史负荷值、历史天气数据	某地区接下来 1 d 的负荷值
[22]	RNN	-	5	历史负荷值、温度、星期、时刻、节假日	某地区接下来 1 d 的负荷值
[23]	RNN	1 × 200 1 × 400 1 × 800	3	历史负荷值	工业用户接下来 15 min 的负荷值
[24]	全连接神经网络	60 × (20 + 20)	60	历史负荷值、温度、季节、周末、节假日	事业单位接下来 1 d 的负荷值
[25]	RNN 或 CNN	-	-	历史负荷值、温度、气压、风速	学校 1 栋楼接下来 1 d 的负荷值
[26]	CNN	-	-	历史负荷值、日期、天气	多个用户接下来 1 d 总的负荷值
[27]	RNN	2 × 50	2	历史负荷值、节假日	多个用户接下来 30 min 总的负荷值
[28]	全连接神经网络	1 × 14 1 × 24	2	历史负荷值、星期、温度、湿度	多个用户接下来 1 d 总的负荷值
[29]	RNN	-	5	历史负荷值、用户 ID	用户接下来 30 min 的负荷值
[3]	RNN	3 × 512	3	历史负荷值、电器用电信息	用户接下来 30 min 总负荷值
[30]	CNN	1 × (4 + 7) 1 × (4 + 5) 1 × (3 + 5) 1 × (3 + 4) 2 × (2 + 3) 1 × 48	7	历史负荷值、用户 ID、周、月、日	用户接下来 1 d 的负荷值

高。因此,区域级别的短期负荷预测相对其他类型的短期负荷预测更简单。

吴润泽等人^[20]提出了基于自编码神经网络的短期负荷预测模型 SAE-NN 用于预测山西电网管辖下的某地区的下 1 h 负荷值。SAE-NN 主要由多层全连接网络和基于逻辑回归的输出层构成。其输入包括历史负荷值、预测日前 1 d 的最高温度、预测日前 1 d 的最低温度、预测日前 1 d 的平均湿度以及预测日日类型;其输出为下 1 h 的负荷值。SAE-NN 可以有效地预测日负荷的变化规律,其预测精度达到了 96.2%。

卢杏坚和高小征^[21]提出了大数据环境下的基

于深度学习的平行计算框架用于预测广东省某地区接下来 1 d 的电力负荷。此框架结合了分布式计算框架 MapReduce 和深度信念网络。其输入包括历史负荷数据、最高温度、最低温度以及天气晴雨阴等状况;其输出为接下来 1 d 的负荷变化。此框架解决了深度学习训练时间长以及精度差等问题,其预测的电力负荷值与实际值的均方根误差仅为 2.86%。

王增平等人^[22]开发了基于门控循环单元 (gate recurrent unit, GRU) 的深度学习模型用于对美国某地区以及中国某地区接下来 1 d 的电力负荷变化进行预测。GRU 是基于长短期记忆单元 (long-short

term memory, LSTM)改进而来的具有更快收敛性的RNN网络。此模型的输入包括历史负荷值、预测时刻的温度、预测日前1d的最高和最低温度、星期、时刻以及节假日信息;其输出为接下来1d的负荷变化。此模型精确度在美国某地区和中国某地区分别达到了97.30%和97.12%。

4.2 工业或商业用户负荷预测

工商用户作为电力系统中最主要的参与者,在2017年消耗了超过70%的全国电力可供量^[1]。因此,工商业用户的负荷变化对电力系统的运营十分重要的。工商用户的负荷变化虽不如区域级别的负荷变化那样规律,但受生产规划等影响也存在比较明显的规律,并吸引了大量研究人员的关注。

杨甲甲等人^[23]开发了基于LSTM的深度学习模型用于预测来自不同行业的7家工业用户的短期负荷变化情况。模型加入了预防过拟合的Dropout技术用于提升模型预测性能。模型的输入为用户的历史负荷数据,输出为15min后用户的负荷值。此模型具有优异的预测表现,能够将预测的平均绝对百分误差控制在9%以下。

Chen等人^[24]提出了基于残差网络的深度学习模型ResNetPlus用于预测一个北美公共事业单位的短期负荷变化。与常见的深度模型直接使用原始数据不同,ResNetPlus需要根据负荷的月份、星期、日的规律人为地选择及构造特征用于神经网络的输入。ResNetPlus的输入包括历史负荷值、历史温度、预测日当天温度、季节、是否周末以及是否节假日;模型的输出是这个用户未来短期内的电力负荷值。ResNetPlus与现有的最先进模型相比性能有着显著的提升。

Cai等人^[25]基于RNN和CNN分别提出了Gate-RNN以及GateCNN深度学习模型用于预测弗吉尼亚州亚历山大的一栋科研楼以及纽约雪莉一个学校的一栋楼未来1d的负荷变化。这个工作通过在RNN和CNN架构的神经网络上增加一个门机制用以提升模型的预测表现。这两个模型的输入包括历史负荷值、室外温度、气压、湿度以及风速;这两个模型的输出都为用户接下来1d内的负荷变化。与传统的负荷预测模型相比,这两个模型在预测精度上

都取得了长足的进步。

4.3 居民用户聚合负荷预测

作为电力系统中最重要参与者之一,居民用户在电力系统中的作用随着智能电网的发展受到了越来越高的重视^[31]。然而,居民用户的用电行为存在非常大的随机性,造成了居民用户的负荷变化难以被预测^[32]。为了减缓用户用电行为的随机性给负荷预测任务带来的困难,研究人员把分布在同一地区的多个居民用户聚合为一个虚拟的用户。然后,通过预测这个虚拟的用户的负荷变化来了解这个地区的居民用户未来很短一段时间内的负荷变化规律。

文献[26,33-34]提出了基于扩展因果卷积的深度神经网络模型WaveNet用于预测10~200级别的居民用户聚合后的电力负荷变化。扩展因果卷积网络极大地提升了模型的训练速度,是卷积神经网络在时间序列预测上的一个成功应用。WaveNet的输入为历史负荷值以及相关的外部数据,如日期和天气等;WaveNet的输出为将来短时间内用户聚合之后的负荷变化,与典型的人工神经网络模型相比,WaveNet预测精度有13%的提升。

Kell等人^[27]开发了基于负荷曲线聚类的负荷预测框架。首先利用K-means算法对用户的所有负荷曲线进行聚类。然后根据聚类的结果把用户分成不同的簇。之后对于每个簇,把簇内的所有用户的负荷相加使得每个簇内的所有用户变成一个聚合起来的用户。最后利用各种机器学习模型(包括随机森林、神经网络、LSTM和支持向量回归模型)对聚合的用户进行负荷预测。该负荷预测框架的输入为历史负荷值以及相关的外部数据,如日期和节假日等信息;该框架的输出包括用户类别以及将来短时间内用户聚合之后的负荷变化。此外,值得注意的是,该研究的实验表明随机森林在用户聚合之后的负荷预测任务上优于基于LSTM的深度学习模型。

Marinescu等人^[28]提出了基于SOM及神经网络的动态负荷预测模型用于预测230个居民用户聚合后的电力负荷变化。当前的短期负荷预测方法通常对正常和异常日期的负荷分开进行预测。然而,由于一些不可预见的事件,正常日期的负荷也有可

能会呈现异常日期的负荷模式,从而导致预测错误。为此,作者在进行负荷预测之前首先利用 SOM 检测用户负荷模式的异常改变。当预测正常日期的负荷时,如果检测到用户的异常负荷模式,基于神经网络的预测系统就会根据先前在异常日期数据库中找到匹配项来更改其输入神经元,以适应异常日期的负荷预测。在异常日期的负荷预测中,该动态预测方法得到的负荷曲线与真实的负荷曲线的误差在3.63%之内。

4.4 居民用户负荷预测

居民用户级别的负荷预测于2011年被 Ghofrani 等人^[35]报道,然而由于居民用户的负荷预测非常困难,关于这方面的研究并不多。随着近年来各类深度学习技术的提出以及深度学习在各种时间序列预测任务中展现出的强大的能力,研究人员提出了一些新的方案去解决居民用户级别的负荷预测问题。

Shi 等人^[29]提出了一种具有新的池化机制的 LSTM 模型用于预测居民用户短期的负荷变化,并提出了基于用户 ID 的池化方法用于克服深度学习中的过拟合问题。模型的输入为历史负荷值以及用户的 ID,输出为 0.5 h 后用户的电力负荷值。与传统的负荷预测模型差分自回归移动平均模型、支持向量回归机以及循环神经网络相比,此模型在均方根误差上分别获得 19.5%、13.1% 以及 6.5% 的提升。

Kong 等人^[3]开发了一个基于 LSTM 的深度学习模型用于预测一个加拿大居民用户的短期负荷变化。该模型考虑了居民用户的活动对用户负荷变化的影响,并且认为家庭用电设备的信息能够反映用户的活动并帮助提高负荷预测的准确率。模型的输入包括历史负荷值以及这个家庭中的 19 个设备的历史信息,模型的输出是这个用户未来短期内的电力负荷值。与传统的负荷预测模型如前馈神经网络相比,该模型的预测精度显著提升。

Huang 等人^[30]提出了一个基于卷积神经网络的深度学习模型 LoadCNN 用于预测居民用户接下来 1 d 内的负荷变化。这个工作在负荷预测任务中提出并分析了一个一直被研究人员忽略的重要问题,即模型训练的时间、能耗以及开发模型对环境造

成的影响。LoadCNN 是一个高效、低能耗以及环境友好的用户级别的深度学习负荷预测模型。LoadCNN 的输入包括历史负荷值、用户 ID、日期以及周末信息,LoadCNN 的输出为居民用户接下来 1 d 内的负荷变化。与目前主流的深度学习模型相比,LoadCNN 在训练时间上只有前者的 1/54,在能耗以及二氧化碳排放上只有前者的 1/45,并且在预测精度上与前者相当。

5 发展趋势及展望

短期负荷预测是目前电力系统中一个重要的研究方向,在经历了数十年的发展之后,区域负荷预测技术以及工商业等用电大户的负荷预测技术已经趋向于成熟。然而,对居民用户进行短期负荷预测仍然很困难。深度学习的出现及其在时间序列预测任务中的优秀表现,为短期负荷预测提供了新的思路,使得许多研究者对基于深度学习的短期负荷预测展开研究,从而导致深度学习成为目前短期负荷预测任务的主流技术之一。目前短期负荷预测的研究重点和发展趋势主要有以下几点。

(1) 居民用户负荷预测将更受关注。首先,区域及工商用户负荷预测已经比较成熟,而随着深度学习的出现居民负荷预测存在着巨大的提升空间,将会继续受到研究人员更多的关注。其次,随着智能电网中需求响应项目的发展,研究人员重新认识到需求侧的用户在节能减排、削峰填谷等方面的作用,将进一步要求掌握居民用户的负荷变化规律,从而推动居民用户负荷预测研究的发展。

(2) 构建合适的负荷预测模型。虽然深度学习的出现使得居民负荷预测的精度有了很大的提升,但是目前的居民负荷预测精度依然无法令人满意。图 4 为 12 个目前主流的及常用的深度学习模型对用户的负荷进行预测,其中黑色的曲线为用户的真实负荷曲线,其他的曲线是使用不同模型预测的负荷曲线^[30]。从图中可以看出,目前的深度学习模型能够很好地预测出日前负荷曲线的模式,但是却没能预测出日前负荷曲线的细节。例如,虽然目前的深度学习模型能够预测到实际的日前负荷曲线属




图4 居民用户日前负荷预测

于早晚双高峰曲线以及曲线大致的变化,但是实际的日前负荷曲线的1个用电早高峰值和3个用电晚高峰值却无法准确地预测。因此,目前单纯的利用循环神经网络和卷积神经网络等的负荷预测模型还需要进一步的改进,并且更多的用户用电行为相关信息需要被收集然后输入到负荷预测模型以提高负荷预测的精度。

(3) 降低负荷预测模型的训练代价。一方面,由于深度学习模型通常包含数量巨大的参数,训练这样一个模型不仅仅需要大量的数据还需要进行大量的计算。另一方面,要获得一个最优的模型需要进行多次完整的训练以调整网络结构及模型参数。这使得训练深度学习模型需要巨大的代价,包括价格昂贵的计算资源(例如 GPU)、大量的训练时间、巨大的电能消耗以及大量的二氧化碳排放。然而,深度学习模型的训练代价最近才被研究人员重视并加以报道^[36]。Strubell 等人^[36-37]报道了训练自然语言处理模型 LISA 需要 239 942 个 GPU 小时(实际上模型在 60 个 GPU 组成的集群上训练了 6 个月)、消耗了约 9870 美元的电量、以及排放大约相当于 5 辆汽车终生排放的二氧化碳量。面对如此大的训练成本,当开发基于深度学习的负荷预测模型时不仅要考虑如何提高模型的精度,更应该考虑如何降低模型的训练成本。

(4) 构建负荷预测基准数据集。深度学习属于数据驱动型的技术,因此基于深度学习的负荷预测

技术的发展离不开大量的公开可用的负荷数据。然而,首先目前公开可用的负荷数据集难以扩充,并且一般规模较小的负荷数据集难以支撑大数据技术在用户用电行为分析领域的发展^[38]。其次,发展中国家与发达国家的用户用电行为存在巨大差异,而目前为止公开的可用的负荷数据集里仅仅包含了一个发展中国家的用户^[38]。因此,目前的负荷数据集难以支撑发展中国家的用户用电行为研究。最后,鉴于近年来中美贸易摩擦导致的美国对中国的科技限制的担忧,外国的负荷数据集如果被限制,我国将失去用户用电行为研究领域的主动性。因此,构建属于中国的自主可控的公开的负荷预测基准数据集是发展负荷预测研究的研究重点之一。

6 结论

本文对基于深度学习的短期负荷预测进行了详细的介绍。首先,介绍了负荷预测的背景以及负荷预测的分类。其次,介绍了深度学习的基本结构。然后,形式化地定义了短期负荷预测任务并重新对短期负荷预测进行分类,再从总体上分析了负荷预测研究的分布及趋势,进而分别对不同类型的短期负荷预测研究进行了介绍。最后,对短期负荷预测研究进行了展望和总结。

短期负荷预测一直是电力系统中最热门的研究领域之一。特别是随着深度学习技术的发展,短期

负荷预测研究获得了研究人员更多的关注。然而国内并没有公开可用的负荷数据集用以支持短期负荷预测的研究。如何构建自主可控的公开的负荷数据集同时考虑预测精度及模型训练代价的负荷预测研究是一个值得思考的问题。

参考文献

- [1] 中华人民共和国国家统计局. 国家数据-电力平衡表 [EB/OL]. <http://data.stats.gov.cn/easyquery.htm?cn=C01>; 中华人民共和国国家统计局, 2019
- [2] 张东霞, 苗新, 刘丽平, 等. 智能电网大数据技术发展研究[J]. 中国电机工程学报, 2015, 35(1): 2-12
- [3] Kong W, Dong Z Y, Hill D J, et al. Short-term residential load forecasting based on resident behaviour learning [J]. *IEEE Transactions on Power Systems*, 2017, 33(1):1087-1088
- [4] Raza M Q, Khosravi A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings[J]. *Renewable and Sustainable Energy Reviews*, 2015, 50:1352-1372
- [5] Zor K, Timur O, Teke A. A state-of-the-art review of artificial intelligence techniques for short-term electric load forecasting[C]//2017 6th International Youth Conference on Energy (IYCE), Budapest, Hungary, 2017:1-7
- [6] 康重庆, 夏清, 张伯明. 电力系统负荷预测研究综述与发展方向的探讨[J]. 电力系统自动化, 2004, 28(17):1-11
- [7] 廖旋焕, 胡智宏, 马莹莹, 等. 电力系统短期负荷预测方法综述[J]. 电力系统保护与控制, 2011, 39(1):154-159
- [8] 王惠中, 周佳, 刘轲. 电力系统短期负荷预测方法研究综述[J]. 电气自动化, 2015, 37(1):1-3
- [9] 尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, 41(1):48-59
- [10] Zhou X X, Zeng W F, Chi H, et al. pDeep: predicting MS/MS spectra of peptides with deep learning[J]. *Analytical Chemistry*, 2017, 89(23):12690-12697
- [11] Almalaq A, Edwards G. A review of deep learning methods applied on load forecasting[C]//2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA), Cancun, Mexico, 2017:511-516
- [12] Lecun Y, Bengio Y. Convolutional networks for images, speech, and time series[J]. *The Handbook of Brain Theory and Neural Networks*, 1995, 3361(10):1-14
- [13] Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77:354-377
- [14] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks [C]//Advances in Neural Information Processing Systems, Nevada, USA, 2012:1097-1105
- [15] Wang N, Cui L, Huang X, et al. EasiCSDeep: a deep learning model for cervical spondylosis identification using surface electromyography signal[J]. *arXiv:1812.04912*, 2018
- [16] Goodfellow I, Bengio Y, Courville A. Deep Learning [M]. Boston: MIT Press, 2016
- [17] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, 521(7553):436
- [18] 陆宇焯, 张健钊, 徐岩哲, 等. 电力系统负荷预测方法综述[J]. 电子科技, 2013, 26(11):173-175
- [19] Khuntia S R, Rueda J L, van der Meijden M A M M. Forecasting the load of electrical power systems in mid- and long-term horizons: a review [J]. *IET Generation, Transmission and Distribution*, 2016, 10(16):3971-3977
- [20] 吴润泽, 包正睿, 宋雪莹, 等. 基于深度学习的电网短期负荷预测方法研究[J]. 现代电力, 2018, 35(2): 43-48
- [21] 卢杏坚, 高小征. 基于深度学习的并行负荷预测方法[J]. 自动化与信息工程, 2017, 38(4):26-30
- [22] 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): 86-95
- [23] 杨甲甲, 刘国龙, 赵俊华, 等. 采用长短期记忆深度学习模型的工业负荷短期预测方法[J]. 电力建设, 2018, 39(10): 20-27
- [24] Chen K, Chen K, Wang Q, et al. Short-term load forecasting with deep residual networks[J]. *IEEE Transactions on Smart Grid*, 2018, 10(4): 3943-3952
- [25] Cai M, Pipattanasomporn M, Rahman S. Day-ahead building-level load forecasts using deep learning vs. traditional time-series techniques[J]. *Applied Energy*, 2019, 236:1078-1088
- [26] Voß M, Bender-Saebelkamp C, Albayrak S. Residential short-term load forecasting using convolutional neural net-

- works[C]//2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm), Aalborg, Denmark, 2018:1-6
- [27] Kell A, McGough A S, Forshaw M. Segmenting residential smart meter data for short-term load forecasting[C]// Proceedings of the 9th International Conference on Future Energy Systems, Karlsruhe, Germany, 2018:91-96
- [28] Marinescu A, Dusparic I, Harris C, et al. A dynamic forecasting method for small scale residential electrical demand [C] // 2014 International Joint Conference on Neural Networks (IJCNN), Beijing, China, 2014:3767-3774
- [29] Shi H, Xu M, Li R. Deep learning for household load forecasting —a novel pooling deep RNN [J]. *IEEE Transactions on Smart Grid*, 2017, 9(5) :5271-5280
- [30] Huang Y Y, Wang N N, Hao T S, et al. Loadcnn: an efficient green deep learning model for day-ahead individual resident load forecasting[J]. *arXiv*:1908.00298, 2019
- [31] 杨旭英, 周明, 李庚银. 智能电网下需求响应机理分析与建模综述[J]. *电网技术*, 2016, 40(1) :220-226
- [32] Li R, Li F, Smith N D. Multi-resolution load profile clustering for smart metering data[J]. *IEEE Transactions on Power Systems*, 2016, 31(6) :4473-4482
- [33] van den Oord A, Dieleman S, Zen H, et al. Wavenet: a generative model for raw audio[J]. *arXiv*:1609.03499, 2016
- [34] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions[J]. *arXiv*:1511.07122, 2015
- [35] Ghofrani M, Hassanzadeh M, Etezadi-Amoli M, et al. Smart meter based short-term load forecasting for residential customers[C]//2011 North American Power Symposium, Boston, USA, 2011:1-5
- [36] Strubell E, Ganesh A, McCallum A. Energy and policy considerations for deep learning in NLP[C]//57th Annual Meeting of the Association for Computational Linguistics (ACL), Florence, Italy, 2019: 3645-3650
- [37] Strubell E, Verga P, Andor D, et al. Linguistically-informed self-attention for semantic role labeling[C]//Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing, Brussels, Belgium, 2018: 5027-5038
- [38] Huang Y Y, Zhan J F, Luo C J, et al. An electricity consumption model for synthesizing scalable electricity load curves[J]. *Energy*, 2019, 169:674-683

A review of short-term load forecasting based on deep learning

Huang Yunyou^{***}, Zhan Jianfeng^{**}

(* Institute of Computing Technology, Chinese Academy of Sciences, Beijing 100190)

(** University of Chinese Academy of Sciences, Beijing 100049)

Abstract

Load forecasting is one of the most important tasks in the power system. Accurate load forecasting is able to help decision makers to reasonably dispatch grid resources, which plays an important role in maintaining efficient, stable, safe, and economic operation of the power grid. With the development of smart grids, the exponential growth of users' electricity consumption data has promoted the rapid development of load forecasting research. Especially in recent years, the technology in the field of load forecasting has undergone huge changes. Many traditional load forecasting methods have gradually been replaced by more accurate data-driven deep learning methods. This paper reviews the development of deep learning methods in the short-term load prediction field in recent years, summarizes and analyzes the latest researches of deep learning in short-term load prediction, and finally looks into the future development of the short-term load forecasting research.

Key words: load forecasting, machine learning, smart grid, deep learning, big data