

文章编号:1671-6833(2019)05-0012-10

深度学习在电力负荷预测中的应用综述

朱俊丞¹, 杨之乐², 郭媛君², 于坤杰³, 张建康⁴, 穆晓敏⁴

(1.郑州大学产业技术研究院,河南郑州450001; 2.中国科学院深圳先进技术研究院,广东深圳518000; 3.郑州大学电气工程学院,河南郑州450001; 4.郑州大学信息工程学院,河南郑州450001)

摘要:在综合能源系统和能源互联网的高速发展下,电力负荷预测对电力系统的经济安全运行具有重要的作用。传统的负荷预测模型方法已在电力系统中取得了广泛应用,传统方法的简单计算模型对于高随机性、大数据背景下的动态负荷预测精度无法保证。近年来,在计算工具不断升级和训练数据量大规模提升的背景下,深度学习方法在电力负荷预测领域的应用得到了广泛重视。对多种深度学习方法在负荷预测领域中的应用进行了叙述分析,回顾了循环神经网络(RNN)、长短期记忆网络(LSTM)、深度置信网络(DBN)、卷积神经网络(CNN)等不同深度学习方法预测模型。对比于传统的负荷预测方法,深度学习方法具有更高的预测精度,对于各种外部影响因素具有更好的鲁棒性。

关键词:深度学习;电力系统;负荷预测;人工神经网络;LSTM

中图分类号: TU528.1

文献标志码: A

doi:10.13705/j.issn.1671-6833.2019.05.005

0 引言

自第二次工业革命之后,电力负荷的稳定供应是维持社会正常运转的基本要求。近年来,由于石油等化石能源的短缺和全球碳排放造成气候变暖的影响,可再生能源^[1]成为全世界研究的重要方向。由于电力系统的稳定运行具有负荷平衡的强约束性,精确多时间尺度的电力负荷预测,对于保证电力系统经济、安全和可靠运行具有重要作用。另一方面,在节能减排压力和电力市场逐步放开的背景推动下,各发电和用电企业对于负荷预测精度的要求越来越高,精准的负荷预测有利于各发电企业合理安排调度计划,保证时刻为大众提供高质量电能的情况下对电力设备等进行完善的维护和检查,也能够帮助用电企业采取主动措施提高用电质量和经济性。传统的电力负荷预测方法包括时间序列法^[2]、趋势外推法^[3]、回归分析法^[4]等。近年来,大规模间歇性新能源发电系统以及电动汽车和需求侧响应等新型负荷类型的广泛接入所带来的高度随机性和动态变化特性,对传统的负荷预测方法提出了极大挑战。

随着人工神经网络(artificial neural networks, ANN)广泛应用于图像识别、语音识别等领域, ANN对于非线性结构具有很强的自适应能力,自主学习能力和泛化能力,这些都是其他算法所不具备的特点。文献[5-7]都是 ANN 在负荷预测领域的应用。文献[8]是一篇关于人工神经网络在负荷预测领域应用的综述,选用 1991—1999 年所有相关的文献,证明了 ANN 在负荷预测领域取得了较好的效果,笔者将重点介绍 2000 年以后与 ANN 相关的预测模型。

针对浅层神经网络存在的问题,即神经元个数人为决定,学习速度慢并且容易陷入局部最优等,近年来,随着硬件算力的极速倍增,深度学习(deep learning)方法在图像语义分割^[9]、图像分类^[10]、目标检测^[11]等领域都取得了广泛应用,在负荷预测领域也取得了关注。深度学习的灵感来源于 ANN,是机器学习领域的一个分支。深度学习方法构建的网络结构更为复杂,具有更多的隐藏层和循环结构,使其具备了更强的学习能力、自适应能力、容错能力、自主推理能力和泛化能力等。笔者接下来对近年来人工神经网络在负荷预测方

收稿日期:2018-09-15;修订日期:2018-12-21

基金项目:国家自然科学基金资助项目(51607177,61876169,61806179,61433012,U1435215);广东省自然科学基金项目(2018A030310671);国家博士后科学基金面上项目(2018M631005)

通信作者:郭媛君(1986—),女,河北保定人,中国科学院深圳先进技术研究院助理研究员,博士,主要从事机器学习、人工智能方法在能源及电力系统中的应用,E-mail:yj.guo@siat.ac.cn.

向的发展和深度学习方法在该方向的应用进行详细介绍。

1 传统电力负荷预测方法

早在 20 世纪 80 年代,世界各国研究者就开始针对负荷预测(load forecasting, LF)问题展开研究。负荷值是某一时间点或者时间段的电量或功率采样,最初对于 LF 问题的研究是基于 1976 年 Box 等^[2]提出的时间序列预测方法,被命名为 Box-Jenkins。该方法对于负荷预测模型的输入要求较低,仅考虑了历史数据的时间序列输入,没有考虑影响负荷的其他因素,无法达到对负荷预测的要求。文献[12]提供了一种负荷峰值模型,该模型首次将天气、湿度等外部因素考虑在内。基于 Box-Jenkins 的方法,文献[13]提出了自回归滑动平均模型(auto-regressive and moving average model)预测方法。Juberias 等^[4]建立了自回归积分滑动平均模型(autoregressive integrated moving average model)实现负荷预测。2002 年, Haida 等^[15]把多种影响负荷预测的因素考虑在内,提出了一种多元线性回归分析法,建立了负荷预测模型。

随后机器学习(machine learning)方法被用于负荷预测,文献[16]使用支持向量机的方法进行负荷预测,2005 年,Niu 等^[17]将 ANN 与 SVM 结合进行负荷预测,建立的模型在预测精度和计算速度上均有提升,2013 年,Wei 等^[18]结合主成分分析(principal component analysis)和最小二乘支持向量机(LS-SVM)的方法进行负荷预测,该模型可以有效减少预测模型的输入维数,提高学习速度和精度。

2 基于神经网络的方法

从 20 世纪 90 年代以来,有关 ANN 在 LF 领域的研究逐渐深入,许多优化算法、数学理论和模型被应用于 ANN。本节概述了几种用于 LF 的经典神经网络模型和基于模型的优化与变体。

2.1 径向基函数神经网络模型

径向基函数(RBF)对于非线性模型的逼近效果良好,由于负荷受到实时电价因素的影响,Zhang 等^[19]在 2008 年将 RBF 神经网络与自适应神经模糊系统(ANFIS)结合,建立了预测模型,该模型首先使用 RBF 网络预测负荷,不考虑电价因素,然后根据实时电价的变化,使用 ANFIS 系统微调结果,该模型克服了 RBF 网络的缺陷。2013

年,文献[20]将支持向量回归(support vector regression)、径向基函数神经网络(RBFNN)和双扩展卡尔曼滤波器(DEKF)结合构建负荷预测模型,使用 SVR 确定 RBFNN 的结构和初始参数,用 DEKF 优化参数,最后采用优化后的模型预测负荷。文献[21]通过 PSO 算法优化 RBF 网络构建预测模型,和传统 RBF 模型相比,具有更好的实用性。针对 PSO 算法容易陷入局部最优解的问题,很多学者致力于提高其性能,提出了许多 PSO 算法的变体。文献[22]提出一种改进型 PSO 算法优化 RBF 网络,通过对比,该模型有效解决了 PSO 算法容易陷入局部最优解的问题,相比于传统 RBF 预测模型具有更快的收敛速度,平均百分比误差可以控制在 1.2% 以内。

2.2 BP 神经网络模型

在众多 ANN 算法中,Rumelhart 等^[23]提出的误差反向传播算法(back propagation, BP)最为常用,但是 BP 算法存在迭代周期长、收敛速度慢等问题。2005 年,马建伟等^[24]将人工鱼群算法与 BP 算法结合,应用于电力系统短期负荷预测,人工鱼群算法可以有效地克服局部最优,获得全局最优值。先由人工鱼群算法训练神经网络的权值,再用人工鱼群神经网络进行负荷预测,有效提高了 BP 神经网络的预测精度。随后出现了各种改进的 BP 神经网络,文献[25]提出了一种共轭梯度 BP 算法,应用于峰值负荷预测。峰值负荷预测是在输入中考虑预测日之前的峰值负荷信息对于预测结果的影响。2013 年,Khan 等^[26]提出了一种递归笛卡尔遗传规则进化人工神经网络(RCGPANN)用于峰值负荷预测,该模型可以预测一年中各个季节的不同负荷模式。2014 年,何川等^[27]针对预测模型输入变量过多导致训练效率低下的问题,将独立分量分析(ICA)方法和主成分分析(PCA)方法对数据进行降维,提高 BP 网络预测模型的训练效率并提高预测精度。2018 年,张凤林等^[28]使用信赖域算法优化 BP 神经网络的权值参数,将预测模型应用于新能源并网方面,得到了良好的效果。

传统 BP 算法收敛速度慢,导致网络训练效率较低,而使用 PSO 算法很好地解决了该问题。文献[29-30]使用 PSO 算法优化神经网络构建的预测模型,性能优于 BP 神经网络预测模型。文献[31]提出一种 MPSO 算法与 BP 算法结合的 MPSO-BP 预测模型,通过实验对比,该模型改善了 BP 神经网络的泛化能力,预测精度高,对电力

系统短期负荷具有良好的预测能力.

2.3 其他神经网络模型

由于电力负荷受到节假日因素影响,2000年,Kim 等^[32]针对该问题将模糊推理方法与 ANN 结合进行负荷预测,将节假日分成 5 种不同类型,每天使用 5 个 ANN 模型和 2 个模糊推理模型进行预测,得到了较为准确的预测结果.2001 年,史德明等^[33]首次将灰色模型 (gray model) 和 ANN 结合进行负荷预测,取得了较传统 ANN 更为理想的效果.文献[34]将灰色模型与 Elman 神经网络结合进行负荷预测.文献[35]提出了一种组合式神经网络,首先采用模糊聚类分析法将数据分成若干类别,然后对每一类别建立 ANN 预测模型,最终通过模式识别的方法得出预测结果.文献[36-37]将小波分析和神经网络结合,负荷预测精度较高.2011 年,Nose-Filho 等^[38]将广义回归神经网络 (GRNN) 用于负荷预测,同年,他们在 GRNN 的基础上进一步提出了 M-GRNN,MR-GRNN 预测模型,M-GRNN 具有良好的泛化能力、稳定性,MR-GRNN 可以减少输入数量,避免了影响预测结果的冗余.文献[39]将遗传算法 (genetic algorithm) 和灰色神经网络结合对实时电价条件下的负荷进行预测.2017 年,文献[40]将小波分解和二阶灰色神经网络结合 (ADF) 提高负荷预测的准确性.文献[41]结合混沌搜索遗传算法 (CGA) 与模拟退火 (SA) 算法并应用于模糊神经网络,称为 FCS,该算法消除了传统 ANN 的缺陷.针对传统神经网络进行负荷预测时,负荷曲线峰值两侧的预测误差很大,针对这个问题,文献[42-43]将粗糙集理论和神经网络结合进行电力负荷预测,使用神经网络得出预测结果后,再使用粗糙集理论对数据进行处理,提高预测精度.

1995 年,Kennedy 等^[44]提出粒子群优化算法 (particle swarm optimization,PSO),在全世界的优化算法研究中引起了强烈的反响,该算法无需调节过多参数,容易实现.2017 年,Hao 等^[45]基于神经网络的方法构建预测区间 (PI),应用并扩展了上下限估计方法 (LUBE),以使用 NN 模型构建 PI 并且提出了一种新的公式,将主要的多目标问题转化为受约束的单目标问题,与代价函数相比,这种公式更接近实际问题并且参数更少,通过 PSO 算法优化模型得出预测模型,该模型应用于短期负荷预测和风力发电预测,实验结果表明,该模型可以构建高质量的预测区间.

尽管 ANN 已经成为负荷预测中最强大最精

准的非线性模型之一,但是对于网络结构和参数的确定对于用户来讲仍然是一大难题,这限制了它的广泛应用.2009 年,针对这一问题,Mao 等^[46]提出了一种自组织模糊神经网络 (SOFNN) 与双层优化方法结合的预测方法,SOFNN 可以自动确定模型的结构和参数,而双层优化方法自动选择最佳的预训练参数以确保识别出最佳的模糊神经网络,这提高了神经网络的实用性,并且预测效果良好.

ANN 的强大学习能力使它成为负荷预测领域的研究热点,全世界的学者也都致力于不断提高预测模型的准确性,但是由于浅层学习的局限性,无法充分利用历史数据进行学习和知识吸收,难以通过结合了优化算法和理论达到复杂预测问题的精度要求.随着深度学习的发展,其在电力系统负荷预测领域的研究也逐渐深入,接下来本文将重点介绍深度学习方法在负荷预测领域的应用及发展.

3 基于深度学习的方法

深度学习模型起源于文献[47],是由“深度学习之父”Hinton 提出的,能沟通多层可表征或不可表征的中间层达到数据的深度信息挖掘和吸收的作用.深度模型通过学习非线性结构来实现对复杂函数的逼近,达到预期的预测效果,具有极强的泛化能力和自适应能力.近年来深度学习方法搭建负荷预测模型的文献数量及相关文献来源如统计图 1 所示.2016 年,Ryu 等^[48]注意到负荷预测领域中需求侧能源管理这一因素的重要性,提出了基于深度神经网络 (deep neural networks, DNN) 的负荷预测模型,通过和传统方法相比,平均绝对百分比误差 (mean absolute percent error) 和均方根误差 (root mean square error) 得到了有效降低.MAPE 和 RMSE 是负荷预测中用于评估预测性能的重要指标,其公式如下:

$$MAPE = \frac{1}{N} \sum_{n=1}^N \left(\left| \frac{\hat{y}_n - y_n}{y_n} \right| \times 100 \right), \quad (1)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{n=1}^N (\hat{y}_n - y_n)^2}, \quad (2)$$

式中: N 为样本数量; \hat{y} 为目标函数; y 为输入函数.

文献[49]是深度学习方法在智能电网负荷预测领域应用的一篇综述,收集整理了 2014—2016 年的相关文献,并对深度学习各个网络模型做了逐一介绍,当时关于深度学习方法在

负荷预测领域的应用文献较少, 近两年增长趋势明显。表 1 为今年来各个深度学习模型的文献统计。

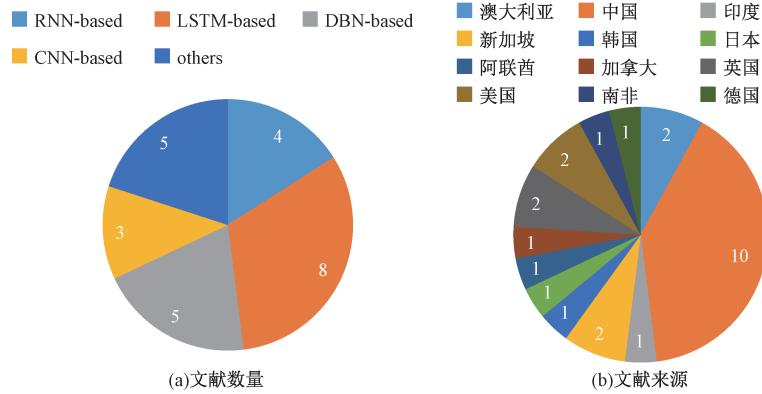


图 1 深度学习方法负荷预测模型文献数量及主要来源

Fig.1 Deep learning method load forecasting model literature quantity and main source

表 1 基于深度学习方法搭建负荷预测模型的文献统计

Tab.1 Literature statistics table for building load forecasting models based on deep learning method

作者及参考文献	年份	方法及模型
Vermaak J 等 ^[49]	2002	RNN
邹政达等 ^[50]	2005	ACO-RNN
Qiu X 等 ^[63]	2015	SVR-DBN
Ryu S 等 ^[47]	2016	DNN
Amarasinghe K 等 ^[54]	2016	LSTM
Kong W 等 ^[55]	2017	LSTM
Gensler A 等 ^[60]	2017	Auto-LSTM
Qiu X 等 ^[65]	2017	EMD-DBN
Shi H 等 ^[51]	2017	DRNN
Li L 等 ^[70]	2017	CNN
Dong X 等 ^[71]	2017	Kmeans-CNN
Shi H 等 ^[52]	2017	PDRNN
Ouyang T 等 ^[64]	2017	Copula-CNN
Zheng H 等 ^[59]	2017	EMD-LSTM
Lu K 等 ^[62]	2018	MS-GRU
Chen K 等 ^[73]	2018	DRN
Zhang X 等 ^[69]	2018	RBM-Elman
Kong W 等 ^[56]	2018	LSTM
Bouktif S 等 ^[58]	2018	GA-LSTM
Kuo P H 等 ^[72]	2018	DeepEnergy
梁智等 ^[66]	2018	VMD-PSO-DBN
陈卓等 ^[57]	2018	LSTM
史佳琪等 ^[68]	2018	DBN
孔祥玉等 ^[67]	2018	DBN
Kumar J 等 ^[61]	2018	LSTM

3.1 递归神经网络负荷预测模型

由于负荷预测受到多方面的因素影响, 如天气、电价、节假日等, 这些因素难以量化, 造成了传统预测模型的预测精度不够高, 由此可知, 预测模型的选用越接近实际结果的生成过程, 预测效果

越好。本章下面将对于每个不同的模型在 LF 方面的应用做详细介绍。



图 2 RNN 结构示意图

Fig.2 Diagram of RNN structure

随着 RNN 的发展和对影响 LF 的因素考虑越发全面, 企业和客户对于预测准确性的要求越来越高, 全世界的学者都在致力于提升模型的精度和效率: 2005 年, 邹政达等^[51]通过蚁群算法对 RNN 网络的初始化权重进行优化, 构建了改进型的 RNN 预测模型, 结果显示该模型收敛速度较快, 预测精度较传统 RNN 预测模型高。2017 年, Shi 等^[52]通过不同层次的负荷预测对深度学习方法进行了全面的评估, 并采用两个极端情况实例验证了方法的有效性: ①以新英格兰电力负荷数据为例, 对区域负荷需求进行聚类; ②以爱尔兰的 100 个单体家庭为例, 对家庭的需求进行分类。通过测试, 深度递归神经网络与浅层神经网络相比, 在聚类水平上 MAPE 提高了 23%, 在分类水平上 RMSE 提高了 5%。同年, Shi 等^[53]针对家庭负荷预测的高波动性和不确定性, 提出了一种汇集深度递归神经网络 (PDRNN), 它将一组客户的负荷配置文件按批次输入到一个输入池中, 并在来自爱

尔兰的 920 名客户数据上进行了测试,相比于经典 RNN 预测模型, RMSE 降低了 6.5%.

3.2 长短时记忆网络负荷预测模型

由于 RNN 只能对较短的时间序列数据进行记忆,随着数据量增大,时间间隔增长,RNN 会丢失之前输入的重要信息,引起梯度消失而导致预测模型失效.针对 RNN 的这一问题,文献[54]所提出的长短时记忆网络(long-short term memory,LSTM)可以提供一种有效的解决方案.该网络通过传递转移函数来处理输入的时间序列,相比于 RNN,LSTM 增加了输入门(Γ_i)、遗忘门(Γ_f)和输出门(Γ_o),输入门决定隐藏层信息是否进行更新,遗忘门决定更新后的信息是否包含上一时刻的信息,输出门决定输出更新后信息的那个部分.其参数迭代更新公式为:

$$\Gamma_f = \sigma(\omega_f [a^{(t-1)}, x^{(t)}] + b_f); \quad (3)$$

$$\Gamma_i = \sigma(\omega_i [a^{(t-1)}, x^{(t)}] + b_i); \quad (4)$$

$$\Gamma_o = \sigma(\omega_o [a^{(t-1)}, x^{(t)}] + b_o); \quad (5)$$

$$\tilde{C}^{(t)} = \tanh(\omega_c [a^{(t-1)}, x^{(t)}] + b_c); \quad (6)$$

$$C^{(t)} = \Gamma_i \cdot \tilde{C}^{(t)} + \Gamma_f \cdot C^{(t-1)}; \quad (7)$$

$$a^{(t)} = \Gamma_o \cdot \tanh C^{(t)} M. \quad (8)$$

其网络结构如下图 3 所示.

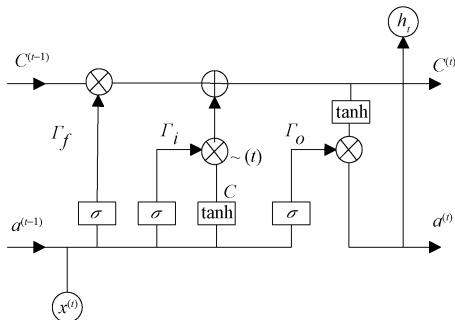


图 3 LSTM 网络结构示意图

Fig.3 Diagram of LSTM structure

个人住宅的负荷预测问题在未来的电网规划和运营中发挥着越来越重要的作用,由于单个能源用户的高波动性和不确定性,负荷预测是一个棘手的问题.2016 年,Marino 等^[55]使用标准 LSTM 架构和 S2S-LSTM 架构对个人住宅的负荷进行预测,以一分钟和一小时作为时间步长进行了实验,结果证明标准 LSTM 架构无法在以一分钟为步长的情况下精准预测结果,而 S2S 在两种时间步长下均表现良好.2017 年,Kong 等^[56]也将 LSTM 网络应用于个人住宅的负荷预测并取得了良好的效果.2018 年,Kong 等^[57]就 meter-level 负荷预测展开研究,将住宅的能源消耗与居民的行为联系在

一起,例如在早餐后洗澡或者在洗衣结束时干燥大量衣物等,如果可以感知到这样的行为模式,预测结果将更加准确,作者将能源设备的能量消耗输入到预测器中,经过实验,LSTM 网络在输入设备能量消耗序列的情况下 MAPE 最低.文献[58]也将 LSTM 网络应用于短期负荷预测,与传统 ARIMA 模型相比,MAPE 从 9.74% 下降到 5.76%.

将各种算法与网络模型结合的方式一直是负荷预测领域的热点研究方向,Bouktif S 等^[59]为了更加容易的选择预测模型,将机器学习算法与 LSTM 网络结合,通过训练几种线性和非线性的 ML 算法,选择最好的作为基本算法,使用 wrapper 和 embedded 特征选择方法选择最佳特征,最后使用遗传算法选出最佳时间间隔和 LSTM 网络层数,实验结果表明,使用各种算法选择出的参数训练出的预测模型比人工调试参数的预测模型具有更高的精度.文献[60]将经验模态分解(Empirical Mode Decomposition)和类似日选择的方法与 LSTM 网络结合,将极端梯度增强的加权 K 均值算法用于评估预测日和历史天数之间的相似性,EMD 方法用于将 SD 负荷分解为本征模态函数(intrinsic mode function,IMF)和残差函数,分离的 LSTM 网络用于预测每个 IMF 和残差函数,最终结果表明 SD-EMD-LSTM 可以准确预测用电负荷.文献[61]将 AutoEncoder 和 LSTM 结合,提出了 Auto-LSTM 预测模型,在可再生能源预测领域进行负荷预测,与传统模型、人工神经网络模型和深度置信网络(deep belief networks)进行对比,新的预测模型取得了更高的精度.2018 年,Kumar 等^[62]发现,尽管云计算带来很大的收益,但是由于没有遇到任何挑战和问题,导致云系统脆弱并且成本高昂,他们使用 LSTM 网络对云计算中心的工作负荷进行预测,该方法有效地解决了云计算中心动态资源扩展和功耗的问题,可以使云系统面临考验时及时做出相应措施,同时可以降低云计算成本.

门控循环单元(gated recurrent unit)是 LSTM 网络的一种变体,它将 LSTM 的输入门与遗忘门结合,使结构变得更加简单.文献[63]建立了一种多层自标准化门控循环单元模型(MS-GRU)用于 STLF,并且引入缩放指数线性单元(SELU)作为激活函数来压缩隐藏状态以计算模型的输出,这种方式可以克服梯度爆炸和梯度消失等问题.模糊聚类均值(FCM)算法用于选择类似日.通过与

其他 RNN 模型对比, MS-GRU 模型的预测精度更高.

3.3 深度置信网络负荷预测模型

DBN 是由 Hinton^[46] 提出的无监督高效学习算法, 由一系列受限的玻尔兹曼机 (restricted boltzmann machine) 堆叠而成, 具有很强大的数据拟合能力, 其结构如图 4 所示.

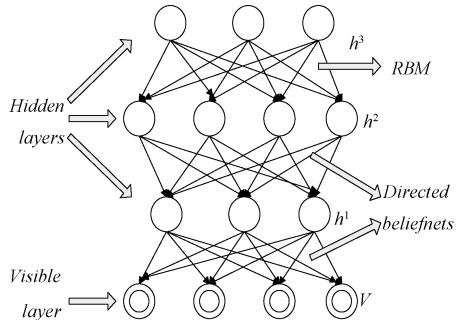


图 4 DBN 结构示意图

Fig.4 Diagram of DBN structure

Qiu 等^[64] 在 2015 年时首次提出将 DBN 用于时间序列预测, 并且通过支持向量回归模型来拟合输出, 将模型应用在三个电力负荷需求数据集, 一个人工时间序列数据集和三个回归数据集, 充分展示了 DBN 模型的优势. 2017 年, Ouyang 等^[65] 将深度置信网络用于负荷预测, 首先通过 Box-Cox 变换处理负荷数据, 为了量化电价和温度两个参数的功率和服的尾部依赖性, 拟合参数 Copula 模型并计算峰值负荷的阈值, 接下来建立 DBN 网络来预测每小时的负荷. 经过实际数据证实提出的模型效果优于以往的模型. 文献[66]将 EMD 算法和 DBN 网络结合构建负荷预测模型, 通过 EMD 将负荷数据序列分解为 IMF, 通过 DBN 预测 IMF 的趋势, 最后将所有 IMF 的预测结果通过无偏或加权求和组合起来得到聚合输出, 通过与 9 种预测模型对比, 该模型具有更高的精度. 文献[67] 将变分模态分解 (VMD)、PSO 算法和 DBN 网络结合构建预测模型. 文献[68] 使用高斯-伯努利 RBM 作为 DBN 的第一个模块, 并采用列文伯格-马夸尔特 (LM) 算法对预训练阶段得到的初始网络参数进行优化, 该模型与传统方法相比具有更好的预测精度. 文献[69] 提出了基于深度结构多任务学习的短期电、热、气负荷联合预测方法, 将 DBN 与多任务回归层结合, DBN 用于提取高级特征, 多任务回归层作为有监督学习方法输出预测结果, 该模型应用在园区型综合能源系统中, 取得了良好的效果. 随着 DBN 在负荷预测领域越来越流行, 2018 年, Zhang 等^[70] 提出

了一种基于 RBM 和 Elman 神经网络的新型深度学习框架, 和经典 DBN 预测模型、Elman 预测模型相比, 该模型可以显著改善预测精度.

3.4 卷积神经网络负荷预测模型

卷积神经网络 (convolutional neural networks, CNN) 是一种前馈神经网络, 经常用于处理网格数据拓扑, 而时间序列属于一维的网格数据, 所以 CNN 不仅可以应用于图像、视频、语音等领域, 也可用于负荷预测.

2017 年, Li 等^[71] 将数值预测问题转化为图像处理任务, 使用 CNN 模型底输入数据执行精确的聚类, 然后考虑温度、湿度、风速等外部影响因素, 使用另外一个神经网络来预测负荷. 同年, Dong 等^[72] 将 CNN 和 K 均值聚类算法结合, 提出一种新型预测模型, 使用 K 均值算法将大数据集聚集成小的子集, 然后使用子集训练 CNN, 最终得出预测结果, 该模型效果并且具有良好的扩展性. 2018 年, Kuo 等^[73] 提出了一种 DeepEnergy 模型来预测负荷, 该模型结构由三个一维的卷积层和三个池化层组成, 最后由一个全连接层连接输出层, 经过测试, 该模型的 MAPE 和 CV-RMSE 分别为 9.77% 和 11.66%, 具有很高的精度.

近期, Chen 等^[74] 提出了一种不同于以往模型的新预测模型, 该模型基于深度残差网络, 深度残差网络在图像识别领域也取得了良好的效果, 该网络在负荷预测领域的研究还会进一步展开.

4 结论与展望

针对 21 世纪以来人工神经网络和深度学习方法在电力系统负荷预测领域方面的应用和发展进行综述和回顾. 在高速发展的智能化信息时代, 精准的负荷预测已经成为电力领域必不可少的一环, 从人工神经网络到机器学习再到深度学习, 对于负荷预测模型的构建不断趋近实际情况. 从现有的预测模型来看, 基于 LSTM、CNN、DBN、RNN 等深度学习方法所构建的预测模型效果明显优于人工神经网络和传统机器学习算法构建的模型, 而通过将智能优化算法等领域方法与深度学习网络结合的预测模型实际应用价值更高, 对难以量化的外部因素的学习效果很强, 并且拥有良好的扩展性.

除传统的负荷预测外, 间歇性可再生能源和电动汽车^[75] 等对象包含因素更为复杂, 但目前采用深度学习方法对其出力和负荷预测的相关研究还十分有限. 全面有效的深度学习方法, 有望成为

智能电网研究的新方向.将人工智能算法应用于新能源领域,是人工智能新的典型应用场景,也为打造我国的低碳能源未来提供新的智能化解决方案.

参考文献:

- [1] TURNER J A. A realizable renewable energy future [J]. *Science*, 1999, 285(5428):687-689.
- [2] Box Gep G, Box G, Jenkins G. Time series analysis: forecasting and control[J]. *Journal of Time*, 1976, 31(4):238-242.
- [3] 李金颖,牛东晓.非线性季节型电力负荷灰色组合预测研究[J].*电网技术*,2003,27(5):26-28.
- [4] CHEN C, ZHOU J N. Application of regression analysis in power system load forecasting [J]. *Advanced Materials Research*, 2014 (960/961):1516-1522.
- [5] PARK D C, ELSHARKAWI M A, MARKS R J I, et al. Electric load forecasting using an artificial neural network[J]. *IEEE Transactions on Power Systems*, 1991, 6(2):442-449.
- [6] KANDIL N, WAMKEUE R, SAAD M, et al. An efficient approach for short term load forecasting using artificial neural networks[J]. *International Journal of Electrical Power & Energy Systems*, 2006, 28(8):525-530.
- [7] ZHANG G, PATUWO B E, HU M Y. Forecasting with artificial neural networks: The state of the art [J]. *International Journal of Forecasting*, 1998, 14(1):35-62.
- [8] HIPPERT H S, PEDREIRA C E, SOUZA R C. Neural networks for short-term load forecasting: a review and evaluation[J]. *IEEE Transactions on Power Systems*, 2001, 16(1):44-55.
- [9] SHELHAMER E, LONG J, DARRELL T. Fully Convolutional networks for semantic segmentation[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2014, 39(4):640-651.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]// International Conference on Neural Information Processing Systems. Curran Associates Inc. 2012:1097-1105.
- [11] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// IEEE Conference on Computer Vision and Pattern Recognition. IEEE Computer Society, 2014:580-587.
- [12] CORPENING S L, REPPEN N D, RINGLEE R J. Experience with weather sensitive load models for short and long-term forecasting [J]. *IEEE Transactions on Power Apparatus Systems*, 1973, 92(6):1966-1972.
- [13] HAGAN M T, BEHR S M. The time series approach to short term load forecasting [J]. *Power Systems IEEE Transactions on*, 1987, 2(3):785-791.
- [14] JUBERIAS G, YUNTA R, MORENO J G, et al. A new ARIMA model for hourly load forecasting[C]// Transmission and Distribution Conference. IEEE, 1999:314-319.
- [15] HAIDA T, MUTO S. Regression based peak load forecasting using a transformation technique [J]. *IEEE Transactions on Power Systems*, 2002, 9(4):1788-1794.
- [16] CHEN B J, CHANG M W, LIN C J. Load forecasting using support vector Machines: a study on EUNITE competition 2001 [J]. *IEEE Transactions on Power Systems*, 2004, 19(4):1821-1830.
- [17] NIU D X, QIANG W, LI J C. Short term load forecasting model using support vector machine based on artificial neural network[C]// International Conference on Machine Learning and Cybernetics. IEEE, 2005:4260-4265.
- [18] WEI R R, WEI Z Z, RONG R, et al. Short term load forecasting based on PCA and LS-SVM[J]. *Advanced Materials Research*, 2013, 756-759:4193-4197.
- [19] ZHANG Y, ZHOU Q, SUN C, et al. RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment [J]. *IEEE Transactions on Power Systems*, 2008, 23(3):853-858.
- [20] KO C N, LEE C M. Short-term load forecasting using SVR (support vector regression)-based radial basis function neural network with dual extended Kalman filter[J]. *Energy*, 2013, 49(49):413-422.
- [21] 陆宁,周建中,何耀耀.粒子群优化的神经网络模型在短期负荷预测中的应用[J].*电力系统保护与控制*,2010,38(12):65-68.
- [22] 师彪,李郁侠,于新花,等.基于改进粒子群-径向基神经网络模型的短期电力负荷预测[J].*电网技术*,2009,33(17):180-184.
- [23] RUMELHART D E, MCCLELLAND J L. Parallel Distributed Processing [M]// Parallel distributed processing / . The MIT Press, 1986:45 - 76.
- [24] 马建伟,张国立.人工鱼群神经网络在电力系统短期负荷预测中的应用[J].*电网技术*,2005,29(11):36-39.
- [25] SAINI L M, SONI M K. Artificial neural network-based peak load forecasting using conjugate gradient

- methods [J]. IEEE Transactions on Power System, 2002, 17(3) : 907-912.
- [26] KHAN G M, KHATTAK A R, ZAFARI F, et al. Electrical load forecasting using fast learning recurrent neural networks [J]. IEEE Transactions on Power System, 2013, 38(2) : 1-6.
- [27] 何川, 舒勤, 贺含峰, 等. ICA 特征提取与 BP 神经网络在负荷预测中的应用 [J]. 电力系统及其自动化学报, 2014, 26(8) : 40-46.
- [28] 张凤林, 陈峦, 姚亮, 等. 基于信赖域法改进的 BP 网络在新能源并网方面的研究 [J]. 可再生能源, 2018(1) : 43-50.
- [29] ZHAOYU P, LI S, HONG Z, et al. The application of the PSO based BP network in short-term load forecasting [J]. Physics Procedia, 2012, 24 (16) : 626-632.
- [30] BASHIR Z A, EL-HAWARY M E. Applying wavelets to short-term load forecasting using PSO-based neural networks [J]. IEEE Transactions on Power Systems, 2009, 24(1) : 20-27.
- [31] 师彪, 李郁侠, 于新花, 等. 改进粒子群-BP 神经网络模型的短期电力负荷预测 [J]. 计算机应用, 2009, 29(4) : 1036-1039.
- [32] KIM K H, YOUN H S, KANG Y C. Short-term load forecasting for special days in anomalous load conditions using neural networks and fuzzy inference method [J]. IEEE Transactions on Power Systems, 2000, 15(2) : 559-565.
- [33] 史德明, 李林川, 宋建文. 基于灰色预测和神经网络的电力系统负荷预测 [J]. 电网技术, 2001, 25 (12) : 14-17.
- [34] 张健美, 周步祥, 林楠, 等. 灰色 Elman 神经网络的电网中长期负荷预测 [J]. 电力系统及其自动化学报, 2013, 25(4) : 145-149.
- [35] 陈耀武, 汪乐宇, 龙洪玉. 基于组合式神经网络的短期电力负荷预测模型 [J]. 中国电机工程学报, 2001, 21(4) : 79-82.
- [36] 郁能灵, 侯志俭. 小波模糊神经网络在电力系统短期负荷预测中的应用 [J]. 中国电机工程学报, 2004, 24(1) : 24-29.
- [37] 王玉龙, 崔玉, 李鹏, 等. 基于小波分析改进的神经网络模型电力系统负荷预测 [J]. 电网与清洁能源, 2015, 31(2) : 16-20.
- [38] NOSE-FILHO K, LOTUFO A D P, MINUSSI C R. Short-term multinodal load forecasting in distribution systems using general regression neural networks [C]// PowerTech, 2011 IEEE Trondheim. IEEE, 2011 : 1-7.
- [39] 葛少云, 贾鸥莎, 刘洪. 基于遗传灰色神经网络模型的实时电价条件下短期电力负荷预测 [J]. 电网技术, 2012, 36(1) : 224-229.
- [40] LI B, ZHANG J, HE Y, et al. Short-term load-forecasting method based on wavelet decomposition with second-order gray neural network model combined with ADF test [J]. IEEE Access, 2017, (99) : 1-11.
- [41] LIAO G C, TSAO T P. Application of a fuzzy neural network combined with a chaos genetic algorithm and simulated annealing to short-term load forecasting [J]. IEEE Transactions on Evolutionary Computation, 2006, 10(3) : 330-340.
- [42] PANG Q, ZHANG M. Very Short-term load forecasting based on neural network and rough set [C]// International Conference on Intelligent Computation Technology and Automation. IEEE, 2010 : 1132-1135.
- [43] 庞清乐. 基于粗糙集理论的神经网络预测算法及其在短期负荷预测中的应用 [J]. 电网技术, 2010 (12) : 168-173.
- [44] KENNEDY J, EBERHART R C. Particle swarm optimization [C]. International symposium on neural networks, 1995 : 1942-1948.
- [45] HAO Q, SRINIVASAN D, KHOSRAVI A. Short-term load and wind power forecasting using neural network-based prediction intervals [J]. IEEE Transactions on Neural Networks & Learning Systems, 2017, 25(2) : 303-315.
- [46] MAO H, ZENG X J, LENG G, et al. Short-term and midterm load forecasting using a bilevel optimization model [J]. IEEE Transactions on Power Systems, 2009, 24(2) : 1080-1090.
- [47] HINTON G E, OSINDERO S, TEH Y W, et al. A fast learning algorithm for deep belief nets [J]. Neural Computation, 2006, 18(7) : 1527-1554.
- [48] RYU S, NOH J, KIM H, et al. Deep neural network based demand side short term load forecasting [J]. Energies, 2016, 10(1) : 3.
- [49] ALMALAQ A, EDWARDS G. A review of deep learning methods applied on load forecasting [C]// IEEE International Conference on Machine Learning and Applications. IEEE, 2017 : 511-516.
- [50] VERMAAKJ, BOTHA E C. Recurrent neural networks for short-term load forecasting [J]. IEEE Transactions on Power Systems, 2002, 13(1) : 126-132.
- [51] 邹政达, 孙雅明, 张智晟. 基于蚁群优化算法递归神经网络的短期负荷预测 [J]. 电网技术, 2005(03) : 59-63.
- [52] SHI H, XU M, MA Q, et al. A whole system assessment of novel deep learning approach on short-term load forecasting [J]. Energy Procedia, 2017, 142 :

- 2791–2796.
- [53] 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.
- [54] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8): 1735–1780.
- [55] MARINO D L, AMARASINGHE K, MANIC M. Building energy load forecasting using deep neural networks[C]// IECON 2016–42 nd Annual Conference of the IEEE Industrial Electromls Society.IEEE.2016: 7046–7051.
- [56] KONG W, DONG Z Y, JIA Y, et al. Short-term residential load forecasting based on LSTM recurrent neural network[J]. IEEE Transactions on Smart Grid, 2017, 10(1):841–851.
- [57] 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, 2018, (3302):1087–1088.
- [58] 陈卓, 孙龙祥. 基于深度学习 LSTM 网络的短期电力负荷预测方法[J]. 电子技术, 2018(1):39–41.
- [59] BOUKTIF S, FIAZ A, OUNI A, et al. Optimal deep learning LSTM model for electric load forecasting using feature selection and genetic algorithm: comparison with machine learning approaches [J]. Energies, 2018, 11(7):1636–1641.
- [60] ZHENG H, YUAN J, CHEN L. Short-term load forecasting using EMD-LSTM neural networks with a xgboost algorithm for feature importance evaluation[J]. Energies, 2017, 10(8):1168.
- [61] GENSLER A, HENZE J, SICK B, et al. Deep learning for solar power forecasting: an approach using AutoEncoder and LSTM neural networks[C]// IEEE International Conference on Systems, Man, and Cybernetics, 2017:2858–2865.
- [62] KUMAR J, GOOMER R, SINGH A K. Long short term memory recurrent neural network (LSTM-RNN) based workload forecasting model for cloud datacenters [J]. Procedia Computer Science, 2018, (125):676–682.
- [63] LU K, ZHAO Y, WANG X, et al. Short-term electricity load forecasting method based on multilayered self-normalizing GRU network [C]// IEEE Conference on Energy Internet and Energy System Integration, 2018:1–5.
- [64] QIU X, ZHANG L, REN Y, et al. Ensemble deep learning for regression and time series forecasting [C]// Computational Intelligence in Ensemble Learning, 2015:1–6.
- [65] OUYANG T, HE Y, LI H, et al. A deep learning framework for short-term power load forecasting [J]. Arxiv Preprint 2017, 21(3):1711–1178.
- [66] QIU X, REN Y, SUGANTHAN P N, et al. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting[J]. Applied Soft Computing, 2017, 54(C):246–255.
- [67] 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.
- [68] 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.
- [69] 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.
- [70] ZHANG X, WANG R, ZHANG T, et al. Short-term load forecasting using a novel deep learning framework [J]. Energies, 2018, 11(6):1554–1159.
- [71] LI L, OTA K, DONG M. Everything is image: CNN-based short-term electrical load forecasting for smart grid[C]// International Symposium on Pervasive Systems, Algorithms and Networks & 2017, International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing. IEEE Computer Society, 2017:344–351.
- [72] DONG X, QIAN L, HUANG L. Short-term load forecasting in smart grid: A combined CNN and K-means clustering approach[C]// IEEE International Conference on Big Data and Smart Computing, 2017: 119–125.
- [73] KUO P H, HUANG C J. A high precision artificial neural networks model for short-term energy load forecasting[J]. Energies, 2018, 11(1):213.
- [74] CHEN K, CHEN K, WANG Q, et al. Short-term load forecasting with deep residual networks [J]. IEEE Transactions on Smart Grid, 2018 (1014): 3943–3952.
- [75] CHAN C, CHAU K. Modern electric vehicle technology [M], Oxford Umversity Press on Demand, 2001.

Deep Learning Applications in Power System Load Forecasting: a Survey

ZHU Juncheng¹, YANG Zhile², GUO Yuanjun², Yu Kunjie³, ZHANG Jiangkang⁴, MU xiaomin⁴

(1.Institute of industrial technology , Zhengzhou University , Zhengzhou 450001 , China; 2.Shenzhen Institutes of Advanced Technology , Chinese Academy of Sciences , Shenzhen 518000 , China; 3.School of Electrical Engineering , Zhengzhou University , Zhengzhou , 450001 , China; 4.School of Information Engineering , Zhengzhou University , Zhengzhou , 450001 , China)

Abstract: In the rapid development of integrated energy systems and energy network , power load forecasting played an important role in the economic and safe operation of energy and power systems. The traditional load forecasting modelling methods have been widely used in power systems. However, the simple computational model structure limited by traditional methods could not guarantee the dynamic load prediction accuracy under high randomness and big data background. In recent years , in the context of the continuous upgrading of computing tools and the increasing large-scale of training data volume , the application of deep learning methods in the field of power system load forecasting attracted extensive attentions. This paper analyzed the applications of various deep learning methods in the field of load forecasting , and revieed the Recurrent Neural Network (RNN) , Long- and Short-Term Memory Network (LSTM) , Deep Belief Network (DBN) , and Convolutional Neural Network (CNN). Compared with the traditional load forecasting method , the deep learning method showed higher prediction accuracy and better robustness to various external influences.

Key words: Deep learning; power system; load forecasting; artificial neural network; LSTM