

深度信念网络在水火电力系统一次调频能力预测中的应用

崔伟¹, 李武璟¹, 王聪¹, 薛晨¹, 段建东², 魏崑³

(1. 国家电网公司西北分部, 710048, 西安; 2. 西安理工大学电气工程学院, 710048, 西安;

3. 西安理工大学计算机科学与工程学院, 710048, 西安)

摘要: 为了准确地预测电力系统一次调频能力,提出了一种采用深度信念网络的水火电力系统一次调频能力预测方法。以新英格兰39节点系统和某电力公司水火电力系统2016—2019年历史数据作为仿真算例,将系统频率、有功负荷、功率缺额、扰动类型、负荷水平、发电机组惯性时间常数、备用容量与总备用容量作为网络的输入特征值,为网络参数训练提供数据支撑;使用无监督预训练与有监督参数微调相结合来训练网络参数,构建深度信念网络,输出系统一次调频的出力调节曲线,预测水火电力系统一次调频能力。与传统的网络模型进行了对比,结果表明:在新英格兰39节点系统中,最大功率补偿量平均相对误差和均方根误差分别为1.49%和4.04 MW;在电力公司水火电力系统中,最大功率补偿量平均误差和均方根误差分别为1.18%和18.3 MW,均小于循环神经网络的平均误差1.41%和均方根误差21.6 MW。所提深度信念网络的逐层训练解决了传统网络预测方法的参数优化问题,能够避免陷入局部最优和训练周期过长,应可在突发性故障时为调度中心后续制定防护控制故障策略提供信息支撑。

关键词: 一次调频能力;深度信念网络;水火电力系统;预测

中图分类号: TM734 **文献标志码:** A

DOI: 10.7652/xjtuxb202103012 **文章编号:** 0253-987X(2021)03-0099-10



OSID 码

Research on Application of Deep Belief Network in Primary Frequency Modulation Capability of Hydrothermal Power System

CUI Wei¹, LI Wujing¹, WANG Cong¹, XUE Chen¹, DUAN Jiandong², WEI Wei³

(1. Northwest Control Center, State Grid Corporation of China, Xi'an 710048, China;

2. School of Electrical Engineering, Xi'an University of Technology, Xi'an 710048, China;

3. Computer Science and Engineering College, Xi'an University of Technology, Xi'an 710048, China)

Abstract: In order to accurately predict the primary frequency regulation capability of the power system, a method for predicting the primary frequency regulation capability of hydrothermal power systems using a deep belief network is proposed. System frequency, active load, power vacancy, disturbance type, load level, generator set inertia time constant, reserve capacity and total reserve capacity are used as input characteristic values of the network to provide data support for network parameter training. The combination of unsupervised pre-training and supervised parameter fine-tuning is used to train the network parameters, build a deep belief network, output the output adjustment curve of the system's primary frequency modulation to predict the primary frequency modulation ability of the hydrothermal power system. Compared

收稿日期: 2020-07-27。 作者简介: 崔伟(1987—),男,工程师;李武璟(通信作者),男,工程师。 基金项目: 国家自然科学基金资助项目(51877174)。

网络出版时间: 2020-11-18

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20201117.1801.002.html>

with the traditional network model, the results show that: in the New England 39-bus system, the average relative error and root mean square error of the maximum power compensation are 1.49% and 4.04 MW, respectively. In the hydrothermal power system of the electric power company, the average error and the root mean square error of the maximum power compensation are 1.18% and 18.3 MW, respectively, which are smaller than the average error of 1.41% and the root mean square error of the cyclic neural network of 21.6 MW. Compared with the traditional network prediction methods, the layer-by-layer training of deep belief networks solves the problem of parameter optimization and avoids falling into local optimality and long training periods. This model can provide information support for the dispatch center to formulate protection and control failure strategies in the event of sudden failures.

Keywords: primary frequency modulation capability; deep belief neural network; hydrothermal power system; prediction

频率是电力系统安全运行的重要的参数之一,频率的大幅度变化会对整个电力系统的安全稳定运行带来严重的危害。因此,把系统频率控制在允许的正常范围内是电力系统安全稳定运行的前提条件。目前,电力系统的频率调节机制主要由惯性响应、一次调频、二次调频构成。其中,发电机自发进行的一次调频,在频率超出正常范围内会自动调节发电机组的输出有功功率,从而将频率控制在正常范围内。在突发性的频率事件中,一次调频能起到应急作用,为调度人员的二次调频决策争取时间窗口。但是,在频率事故发展迅速的情况下,调度人员很难在短时间内做出正确的判断,评估一次调频能否应对当前频率事件,继而决定是否进行二次调频干涉。因此,需要评估电力系统一次调频能力,在发生频率事件时为调控中心提供辅助决策作用。

从机理上而言,电力系统一次调频能力主要取决于系统中各机组的投运状态、参数设置等。随着智能电网的发展,每台机组的运行状态、参数设置等都进行了测量,相关参数获取更加容易,但各机组的运行状态各不相同,调度人员很难在短时间内准确地分析出电网调频情况并及时决策。因此,需要对电力系统一次调频能力进行预测,辅助调度人员可以在发生扰动时进行紧急控制。

目前,关于一次调频方面的研究主要集中在性能评估^[1-2]、特性分析^[3-5]和控制策略^[6-8]上,主要研究一次调频的各种评价指标、静态特性与动态特性、控制优化等,而对于调频能力本身的研究则关注较少。一次调频能力本身的研究主要分为机组的一次调频能力和电力系统的一次调频能力两类。对于机组的一次调频能力的研究,文献[9]基于同步测量装置的信息,通过实时同步测量机组出力 and 频率变化,

在线测算一次调频相关参数,评估发电机的一次调频性能。然而,现今电网规模增大,发电机组数量众多,每个机组的调频能力与自身的设置参数和运行状态有关,无法快速准确获得整个电网的调频能力。因此,众多学者对电力系统的一次调频能力展开广泛研究。文献[10]定义了电网的一次调频能力,结合方差提出了衡量电网一次调频能力的指标,分析了在线估计的计算可能性;文献[11]考虑调频死区,提出利用均方差定义的电网一次调频能力评价指标;文献[12]基于广域相量测量系统中机组的历史数据,结合时间维度和频差维度,得到电网中单机的一次调频能力预测值,并综合电网中所有单机的预测值,得到电网的一次调频能力预测值,该文是一次调频能力预测方面为数不多的探索,但主要按照固定频差进行预测,预测精度受到制约,且在单机预测的基础上预测电网调频能力计算量会很大。

随着人工智能特别是深度学习的发展,各种基于机器学习的方法已经开始应用于电力系统中^[13-15]。电力系统作为一个复杂且高度非线性的系统,含有丰富的特征信息,广泛布置的数据采集与监视控制系统可以为机器学习算法提供大量数据,为模型训练提供样本支撑,构成海量数据集。深度学习算法相较于传统的神经网络算法,具有更加强大的特征提取能力,可以挖掘数据间的深层联系,特别适用于电力系统中海量数据的处理。近些年,电力系统中逐渐应用深度学习算法,尤其是深度信念网络(DBN)。文献[16]应用深度信念网络对电力系统扰动后频率曲线进行预测,结果表明,深度信念网络相较于其他浅层网络更有优势;文献[17]应用深度信念网络对电力系统进行暂态稳定评估预测,结果表明,深度信念网络相较于常规网络具有更高的

准确率。深度信念网络采用逐层训练的方式,解决了深层神经网络存在的参数优化问题,为整个网络赋予了较好的初始权值,最后网络只要经过微调就可以获得优秀的参数。深度信念网络结构灵活,易于拓展,对时序数据的预测精度更高^[18]。

综合以上考虑,为了准确预测电力系统一次调频能力,为电网调度提供信息支撑,本文探索深度神经网络在电力系统一次调频能力预测中的应用,设计了一种基于深度信念网络的水火电网一次调频能力预测的方法,构建基于深度信念网络的水火电力系统一次调频能力预测模型。选取系统频率、负荷水平、有功负荷、功率缺额、事件类型、发电机组惯性时间常数、备用容量与总备用容量作为预测模型的输入特征值,通过无监督预训练与有监督微调训练网络模型参数,预测 60 s 的系统功率补偿量变化曲线。通过新英格兰 10 机 39 节点系统和某电力公司历史数据作为仿真算例,验证本文所提方法在电力系统一次调频能力预测上的准确性与有效性。本文方法可为频率事件发生后的调度控制提供参考依据。

1 问题描述

电网的一次调频能力是指发生频率事件后系统不依赖二次调频,能自发调整功率的能力。电网调节功率主要通过发电机调速系统调节机组出力,从而调节电网系统功率。因此,可以使用所有机组动态出力变化量之和,即功率补偿量曲线反映系统的一次调频能力。在参与一次调频时,功率补偿曲线会在短时间内快速调节,以尽早消除不平衡功率,然后逐渐趋于稳定值,使得系统达到新的平衡状态。调频效果好时,功率补偿曲线会很快接近或超过功率缺额,消除系统不平衡功率,接着开始趋于稳定,重新运行在新的状态。由于电网一次调频的动作时间一般小于 60 s,所以本文采用 60 s 的功率补偿量变化曲线表征电网一次调频能力,通过分析功率补偿量曲线的稳态值与最大补偿量两种特征,表征电网对于频率事件的最终调节能力与快速反应能力。

机组的相关参数、扰动事件的信息、电网的运行状态均会影响功率补偿量曲线,为了准确预测功率补偿量曲线,需要筛选出 3 种因素中的主要影响变量。

发生频率事件时,机组调速系统会改变原动机阀门,增加或减少进气量或进水量,导致机组转速发生变化,从而调整机组出力。机组的转速和输入、输出有功功率的平衡有关联。发电机转子运动方程为

$$T_j \dot{\omega} = P_m - P_e - D\omega \quad (1)$$

式中: T_j 为发电机惯性时间常数; P_m 为机械功率; P_e 为电磁功率; D 为发电机阻尼系数; ω 为角频率。

电网是动态变化的多机系统,其动态方程可由系统惯性中心频率和发电机转子运动方程推导而来

$$\omega_{COI} = \sum_{i=1}^n T_{ji} \omega_i / \sum_{i=1}^n T_{ji} \quad (2)$$

$$T_{j,sys} \dot{\omega}_{COI} = \sum_{i=1}^n P_{mi} - \sum_{i=1}^n P_{ei} - \sum_{i=1}^n D\omega_i \quad (3)$$

式中: ω_{COI} 为惯性中心频率; $T_{j,sys}$ 为所有机组的惯性时间常数之和; P_{mi} 与 P_{ei} 分别为第 i 台机组的机械功率与电磁功率。

从式(1)(3)可以看出,发电机惯性时间常数直接影响机组转速,进而影响机组功率调节曲线。在其他参数不变的情况下,机组惯性时间越大,则转子转速变化率越小,机组的功率调节速度越慢。

除了惯性时间常数,发电机组的备用容量同样影响机组的功率调节曲线。在频率事件中,不同备用容量的发电机调频能力不同,对于不平衡功率的消纳程度相异。备用容量公式为

$$\left. \begin{aligned} p_{i+}^i &= p_{\max}^i - p_0^i \\ p_{i-}^i &= p_0^i - p_{\min}^i \end{aligned} \right\} \quad (4)$$

式中: p_{i+}^i 和 p_{i-}^i 分别为第 i 次扰动后系统的向上和向下的备用容量; $p_{\max}^i$ 和 $p_{\min}^i$ 分别为第 i 次扰动后系统能快速响应的最大和最小有功功率; p_0^i 为第 i 次扰动时系统的有功功率。

在机组参数方面,主要影响变量为各机组惯性时间常数、备用容量与系统所有机组的总备用容量。

扰动事件主要分为高频扰动与低频扰动两种,两种事件类型的功率调节曲线趋势相反。电网中发电机组对于高频事件与低频事件的调频性能存在差异,文中使用 +1 与 -1 分别表示高频事件与低频事件。系统功率缺额为系统发电机组总发出的有功功率与系统总消耗的有功功率的差值,而不同强弱程度的扰动导致机组发出的有功功率、负荷消耗的有功功率或联络线交换的有功功率发生变化,而产生的功率缺额也不同,使得功率调节曲线存在差异。因此,从扰动事件方面考虑,主要影响变量为事件类型、功率缺额。

对于相同的机组参数与扰动信息、不同的运行状态,由于电网的状态参数不同,频率事件的响应存在差异,因此功率调节曲线不同。电网运行状态考虑系统的频率、负荷水平、有功负荷这 3 种主要影响变量。

因此,对电力系统调频能力的预测需要结合机组的参数设置、电网的运行状态与事件的扰动程度

这 3 种因素,建立主要影响变量与功率调节响应之间的关系。选取影响电网一次调频能力的 8 个主要变量作为输入特征量,分别是:事件类型,扰动后功率缺额,扰动后机组备用容量,扰动后系统总备用容量,扰动后机组惯性常数,扰动前系统频率,扰动前负荷水平,扰动后有功负荷。

该问题本质为一个高维的回归问题,将事件类型、系统频率、负荷水平、有功负荷、功率缺额、发电机组惯性时间常数、备用容量与总备用容量作为模型的输入量 $\mathbf{S}$, 60 s 的功率补偿量曲线作为输出量 $\mathbf{P}$, 实质为求解输入 $\mathbf{S}$ 与输出 $\mathbf{P}$ 的映射关系。输入集与输出集可描述为

$$\mathbf{S} = \begin{bmatrix} \mathbf{s}_1 \\ \mathbf{s}_2 \\ \vdots \\ \mathbf{s}_i \end{bmatrix} \rightarrow \begin{bmatrix} \mathbf{p}_1 \\ \mathbf{p}_2 \\ \vdots \\ \mathbf{p}_i \end{bmatrix} = \mathbf{P} \quad (5)$$

式中下标 i 表示样本的数量。输入数据集 $\mathbf{S}$ 中任一元素 $\mathbf{s}_i$ 均为一个行向量, 向量中所有元素均为某一样本的输入特征量, 即系统频率、负荷水平、有功负荷、功率缺额、发电机组惯性时间常数、备用容量与总备用容量。输出数据集 $\mathbf{P}$ 中任一元素 $\mathbf{p}_i$ 同样为行向量, 向量中每一个元素对应某一样本的 60 s 的功率补偿量变化值。

对于该类问题,深度学习可以通过多层非线性处理层对海量数据进行提取与转换,充分挖掘数据间的联系。深度信念网络可通过无监督预训练与有监督参数微调相结合的训练方式获得优秀的权值,相较于其他深度神经网络结构灵活,对处理时序数据更具有优势。


2 基于深度信念网络的预测网络模型

2.1 深度信念网络简介

Hinton 在文献[19]中首次提出深度信念网络,该网络由多层受限玻尔兹曼机(RBM)堆叠而成。标准 RBM 由输入层与隐藏层组成,同层节点之间无连接,不同层节点之间相互连接。标准 RBM 的结构如图 1 所示。

设 RBM 可见层有 m 个神经元,隐藏层有 n 个神经元,神经元 v_i 与 h_j 均为二值变量,取值为 0 或 1。某一状态下 RBM 结构的能量函数公式^[19]为

$$E(\mathbf{v}, \mathbf{h} | \theta) = - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j - \sum_{i=1}^m \sum_{j=1}^n h_j W_{ij} v_i = - \mathbf{a}^T \mathbf{v} - \mathbf{b}^T \mathbf{h} - \mathbf{h}^T \mathbf{W} \mathbf{v} \quad (6)$$



v_i —可见层第 i 个神经元; h_j —隐藏层第 j 个神经元;

a_i — v_i 的偏置; b_j — h_j 的偏置; $\mathbf{a}$ —输入层偏置矩阵;

$\mathbf{b}$ —输出层偏置矩阵; $\mathbf{W}$ —权值矩阵。


图 1 标准 RBM 结构

式中: $\theta = \{W_{ij}, a_i, b_j, 1 \leq i \leq m, 1 \leq j \leq n\}$; W_{ij} 为可见层神经元 v_i 与隐藏层神经元 h_j 之间的权值。根据能量函数可得 RBM 的联合概率分布为

$$P(\mathbf{v}, \mathbf{h} | \theta) = \frac{e^{-E(\mathbf{v}, \mathbf{h} | \theta)}}{Z(\theta)} \quad (7)$$

式中 $Z(\theta)$ 为配分函数, 即所有状态下 RBM 结构的能量函数。

深度信念网络的训练将预训练与参数微调结合, 包含无监督预训练与有监督参数微调两部分。深度信念网络的训练方法如图 2 所示。



$\Delta^{(i)}$ — $\mathbf{b}$ 和 $\mathbf{W}$ 的调整矩阵。

图 2 深度信念网络训练方法^[20]

无监督预训练主要是通过由低到高逐层训练对网络权值参数初始化。将每两层看做一个 RBM 进行训练, 最终得到神经元的偏置矩阵 $\mathbf{b}^{(k)}$ 与各层神经元之间的权值矩阵 $\mathbf{W}^{(k)}$ 。有监督参数微调主要是通过由高到低逐层对网络权值参数进行微调。采用梯度下降算法从高到低对网络权值参数进行调整, 得到更新后的偏置矩阵 $\hat{\mathbf{b}}^{(k)}$ 与权值矩阵 $\hat{\mathbf{W}}^{(k)}$ 。

2.2 基于深度信念网络的电网一次调频能力预测

方法设计

2.2.1 模型结构设计 标准的深度信念网络常用于分类,无法满足一次调频能力预测的需求,因此本文所用 DBN 的输出层采用线性传递函数,从而使 DBN 具备处理回归问题的能力。本文设计的 DBN 结构如图 3 所示。




图3 深度信念神经网络结构

2.2.2 模型训练方法 DBN 网络训练包括无监督预训练与有监督参数微调两部分,其中无监督预训练采用对比散度算法,有监督参数微调采用梯度下降算法。在无监督预训练阶段,将非最高层的每相邻两层看做一个 RBM 进行对比散度算法训练,获得较好的参数初值,伪代码见附录 A。无监督预训练完后,将整个神经网络作为普通的反向传播神经网络,通过梯度下降算法从高到低对参数进行微调,使得 DBN 得到最优的参数,伪代码见附录 B。

2.2.3 评价指标 本文采用平均相对误差和均方根误差来评价模型性能的优劣,二者公式为

$$y_{\text{MRE}} = \frac{1}{M} \sum_{i=1}^M \frac{|y'_i - y_i|}{|y'_i|} \quad (8)$$

$$y_{\text{RMSE}} = \sqrt{\frac{1}{M} \sum_{i=1}^M (y'_i - y_i)^2} \quad (9)$$

式中: M 为数据集中参与模型训练或者验证的数据量; y_i 为数据集中样本 i 的模型预测值; y'_i 为数据集中样本 i 的实际目标值。

3 仿真算例

3.1 新英格兰 39 节点系统仿真算例

3.1.1 算例系统介绍 新英格兰 39 节点系统包括 10 台发电机、12 台变压器、39 条母线、34 条线路^[21]。该系统为美国新英格兰州的一个 345 kV 电力网络,基准功率为 100 MW,基准电压为 345 kV,额定频率为 60 Hz。新英格兰 10 机 39 节点系统接线图如图 4 所示。




图4 新英格兰 10 机 39 节点系统接线图

仿真软件采用 PSASP,模拟扰动类型主要为切机扰动和负荷突变,分别生成高频事件数据与低频事件数据。系统的扰动数据生成过程如下。

(1)根据文献[21]中新英格兰 10 机 39 节点系统的负荷、线路、变压器、发电机、调速器与励磁系统的参数数据,使用 PSASP 软件对系统进行建模。

(2)通过设置各种扰动故障,进行暂态稳定仿真分析,获取所需样本初始数据。对初始数据进行处理,获得预测模型所需要的输入特征数据与对应的 60 s 内系统功率补偿量。根据文献[16]的扰动设置方法,本文设置 31%、32%、……、80% 共 50 种负荷水平,1、0.75、0.5、0.25 共 4 种机组惯性时间常数。低频扰动事件数据通过在同一负荷水平、惯性时间常数下,轮流切除 1 台发电机,共获得 2 000 组仿真样本数据。高频扰动事件数据同样在同一负荷水平、惯性时间常数下,每次负荷骤降 10%、15%、……、55%,共获得 2 000 组仿真样本数据。仿真设置在 0.1 s 时发生扰动故障,时长为 60 s,总共生成 4 000 组样本。

(3)对样本数据进行归一化处理,使用 MATLAB 软件中的 mapminmax 函数将数据归一化至 0~1 之间。

(4)将处理后的数据集随机划分为训练集与测试集。对于高频扰动事件与低频扰动事件,均选取 1 500 组和 500 组样本作为训练和测试样本。

3.1.2 模型参数分析 为预测电网一次调频能力,将模型输出设置为扰动后 60 s 的功率补偿量曲线,故输出神经元数设置为 60。输入特征为第 1 节所

述的各机组惯性时间常数、备用容量、系统所有机组的总备用容量、事件类型、功率缺额、系统频率、负荷水平和有功负荷,在新英格兰 39 节点中对应 26 个输入神经元。对于隐藏层层数与隐藏层神经元数,在隐藏层最多为 5 层的限制下进行多次尝试,获得合适的参数。学习率影响网络模型的收敛,本文通过依次设置学习率为 0.1、0.03、0.01、0.003 等方式进行试验,确定大致区间,最后不断进行调整找到合适的学习率。表 1 为新英格兰 39 节点系统仿真算例下不同隐藏层结构的预测误差结果。

表 1 新英格兰 39 节点系统仿真算例下
不同隐藏层结构的预测误差结果

隐藏层 数量	各隐藏层 单元数量	功率补偿量 均方根误差 /MW	功率补偿量 平均相对误差 /%
2	50,50	4.89	1.82
3	50,50,50	5.84	2.42
4	50,50,50,50	5.41	2.07
5	50,50,50,50,50	5.61	2.03

本文最终将 DBN 模型隐藏层层数设置为 4,各层神经元数为 26、150、100、100、150、60。无监督学习阶段采用对比散度算法,学习率为 0.01,迭代次数为 100。有监督学习阶段采用反向传播算法,激活函数采用 tanh 函数,输出层采用线性函数,学习率为 0.04,迭代次数为 100。

3.1.3 仿真结果分析 图 5 和图 6 分别为选取的某一高频、低频扰动事件的功率补偿量预测曲线对比。




图 5 高频扰动事件功率补偿量预测曲线对比

功率补偿量曲线的最大功率补偿量的均方根误差和平均相对误差分别为 4.04 MW 和 1.49%，功率补偿量稳态值的均方根误差和平均相对误差分别为 1.42 MW 和 0.71%，预测结果较准。从图 5 和图 6 可以看出:预测曲线可以较精确地预测功率补偿量;高频扰动事件数据由负荷突变生成,数据粒度

小,相较于低频扰动事件预测准确率更高。




图 6 低频扰动事件功率补偿量预测曲线对比

根据本小节仿真结果可知,功率补偿量预测误差很小,均小于 1.5%，可以较准确地预测系统功率补偿量曲线,同时单个测试样本的预测时间小于 0.05 s,可以满足实际的应用需求。

3.2 电网系统仿真算例

3.2.1 算例系统介绍 选择某电网系统 2016—2019 年的历史数据,全网参与调频的直调机组有 56 台(30 台火电机组,26 台水电机组),其中 35 台机组装机容量 600 MW 及以上,17 台机组装机容量 300 MW 及以上,4 台装机容量 200 MW 及以上。电网系统原始数据存在错误数据和无效数据,直接进行训练会导致误差大、速度慢、效果差,因此需要对数据进行处理来获取有效数据集。图 7 为有效数据集获取过程。




图 7 有效数据集获取过程

电网系统历史数据既包含稳定运行的数据,也包含频率事件数据,需要进行筛选。但是,历史数据容易受各种影响,存在许多一次调频回路没有动作的瞬间扰动、数据坏点、高频噪声等。因此,确定一次频率事件为频率偏移超过调频死区,并持续一段时间,具体的选取规则^[1]为

$$\left. \begin{aligned} &|f_{i-1} - f_{\text{ref}}| \leq \Delta f \\ &|f_i - f_{\text{ref}}| \geq \Delta f \\ &\vdots \\ &|f_{i+n} - f_{\text{ref}}| \geq \Delta f \end{aligned} \right\} \quad (10)$$

式中: f_i 为第 i 时刻的电网频率; $f_{\text{ref}}=50\text{ Hz}$ 为电网标准频率; $\Delta f=0.07\text{ Hz}$ 为有效扰动频率偏差。

采集的事件数据集存在数据缺失、数据重复、数据无效等问题,直接使用会影响网络模型预测精度。重复数据和无效数据不能为模型的训练提供帮助,甚至会增大误差,因此直接进行删除。对于缺失数

据,根据缺失值前后序列的数据均值来进行填充。填补、删除后的数据集中的数据具有较为明显的量级差别,直接进行训练会导致网络模型收敛速度慢且容易产生数值问题。因此,对数据集采用归一化处理,让所有数据保持相同的维度与区间,映射到[0,1]区间上。由于最终获取的数据集本身就存在噪声信号,因而不再对其添加噪声信号分析模型的适应性。

将预处理得到的数据集按照 6:2:2 的比例分为训练集、验证集和测试集共 3 部分。训练集用于训练网络模型,确定神经网络的参数;验证集用于判断训练结束后的模型性能,调整网络隐藏层数量、隐藏层层数等超参数;测试集用于客观评价网络的性能。经过处理得到 2 500 组有效数据样本,其中高频事件数据与低频事件数据均为 1 250 组。按 1:1 的比例选取高频与低频事件数据,将 1 500 组作为训练集,500 组作为验证集,500 组作为测试集。

3.2.2 模型参数分析 输入层与输出层均只有一层,而隐藏层层数需要根据具体问题进行设置。输入层与输出层的神经元数一般等于输入向量与输出向量的维数。输入特征向量包括机组参数与全网参数共 118 组参数。机组参数为备用容量和惯性时间常数,参与一次调频的直调机组有 56 台。全网参数为频率、有功负荷、负荷水平、事件类型、功率缺额和总的备用容量。输出特征向量为系统 60 s 功率补偿量变化曲线。模型参数选取方法与 3.1.2 节一致,本文设置输入层和输出层神经元数分别为 116 和 60,各层神经元数为 118、100、50、50、50、20、60,隐藏层层数为 5。无监督学习阶段采用对比散度算法,学习率为 0.06,迭代次数为 300。有监督学习阶段采用反向传播算法,激活函数为 tanh 函数,输出层采用线性函数,学习率为 0.03,迭代次数为 400。表 2 为电网系统仿真算例下不同隐藏层结构的预测误差结果。

表 2 电网系统仿真算例下不同隐藏层结构的预测误差结果

隐藏层数量	各隐藏层单元数量	功率补偿量 均方根误差 /MW	功率补偿量 平均相对误差 /%
2	50,50	50.2	3.51
3	50,50,50	41.3	3.05
4	50,50,50,50	32.6	2.31
5	50,50,50,50,50	25.1	1.76

3.2.3 仿真结果分析 为检验模型性能,将 DBN 模型与 DNN 模型和 RNN 模型进行了对比测试。DBN 模型层数为 6,各层神经元数分别为 118、100、50、50、50、20、60。DNN 和 RNN 模型的结构均与 DBN 设置相同,但不进行无监督预训练,只采用反向传播算法进行监督学习。DNN 模型激活函数采用 sigmoid 函数,RNN 模型激活函数采用 tanh 函数,损失函数均采用均方误差函数,迭代次数为 300。表 3 和表 4 为 3 种模型在测试集中的误差结果。

表 3 最大功率补偿量误差结果

预测模型	最大功率补偿量 均方根误差/MW	最大功率补偿量 平均相对误差/%
DNN	26.5	1.83
RNN	21.6	1.41
DBN	18.3	1.18

表 4 功率补偿量稳态值误差结果

预测模型	功率补偿量稳态值 均方根误差/MW	功率补偿量稳态值 平均相对误差/%
DNN	15.4	1.03
RNN	11.6	0.78
DBN	9.5	0.63

通过表 3 和表 4 可知,DBN 模型的预测性能优于其他两种预测模型的。这是因为虽然 DNN 模型与 RNN 模型和 DBN 模型结构参数一致,但 DBN 模型无监督预训练获得了良好的初值,使得预测准确率提升。RNN 模型相较于 DNN 模型,神经元具有记忆性,可以挖掘数据时序信息,预测精度更高。

本文分别选取两个高频事件与低频事件,对功率补偿曲线进行分析。图 8~11 分别为选取的高频事件样本 A 与 B 的 60 s 功率补偿量变化曲线和对应的均方根误差变化曲线。高频样本 A 为电网某直流极 I 闭锁事件,事件发生时全网功率缺额约为 +1 500 MW;高频样本 B 为电网某直流极 II 闭锁事件,事件发生时全网功率缺额约为 +1 000 MW。图 12~15 分别为低频事件样本 A 与 B 的功率补偿量




图 8 高频事件 A 中 3 种模型的功率补偿曲线对比




图9 高频事件 A 中预测模型的功率补偿量均方根误差




图10 高频事件 B 中 3 种模型的功率补偿曲线对比




图11 高频事件 B 中预测模型的功率补偿量均方根误差




图12 低频事件 A 中 3 种模型的功率补偿曲线对比




图13 低频事件 A 中预测模型的功率补偿量均方根误差

曲线和对应的均方根误差曲线。低频事件 A 为某电厂机组故障停机,事件发生时全网功率缺额约为 -800 MW;低频事件 B 为某电厂机组跳闸,事件发




图14 低频事件 B 中 3 种模型的功率补偿曲线对比




图15 低频事件 B 中预测模型的功率补偿量均方根误差

生时全网功率缺额约为 $-1\,000$ MW。可以看出,无论是高频事件还是低频事件,DBN 预测曲线与实际曲线重合度最高、误差最小,DNN 预测曲线误差最大。因此,DBN 预测曲线的补偿功率稳态值最小、最大有功增量的偏移程度最小,DNN 预测曲线的偏移程度最大,符合 3.1 节的仿真结果。

4 结 论

本文将深度学习应用于电力系统一次调频能力预测,提出一种基于深度置信网络的电力系统一次调频能力预测方法。相较于浅层神经网络的机器学习算法,深度学习可以更好地特征提取,挖掘数据间的隐性联系。本文考虑扰动信息、系统运行状态和机组的状态特征这 3 种因素,采用机组惯性时间常数、备用容量、系统所有机组的总备用容量、事件类型、功率缺额、系统频率、负荷水平和有功负荷共 8 维特征作为模型输入,预测扰动后系统的有功功率补偿量动态变化。采用新英格兰 39 节点系统与某电力系统历史扰动数据进行仿真,与 RNN、DNN 模型的性能进行对比。结果表明,DBN 模型的预测曲线与实际曲线最接近,误差最小,验证了深度信念网络在调频能力预测中的有效性与优越性。DBN 模型相较于其他模型,可以通过无监督预训练获得好的初值,挖掘特征间的关系,有效地提升预测的精度。本文通过对功率补偿量曲线的预测,得到扰动后功率补偿量最大值与稳态值,应可为判断扰动危险程度与制定防护控制提供辅助,为人为调控干涉

提供依据。

参考文献:

- [1] 高林,戴义平,王江峰,等. 机组一次调频参数指标在线估计方法 [J]. 中国电机工程学报, 2012, 32(16): 62-69.
- GAO Lin, DAI Yiping, WANG Jiangfeng, et al. An online estimation method of primary frequency regulation parameters of generation units [J]. Proceedings of the CSEE, 2012, 32(16): 62-69.
- [2] 张艳军,高凯,曲祖义. 基于发电机组出力曲线特征的一次调频性能评价方法 [J]. 电力系统自动化, 2012, 36(7): 99-103.
- ZHANG Yanjun, GAO Kai, QU Zuyi. An evaluation method of primary frequency modulation performance based on characteristics of unit output power curves [J]. Automation of Electric Power Systems, 2012, 36(7): 99-103.
- [3] 曾庆达. 电力系统频率动态特性与一次调频控制 [D]. 广州: 广东工业大学, 2014: 23-38.
- [4] 王蕊. 火电机组一次调频特性的分析及仿真研究 [D]. 北京: 北京交通大学, 2009: 5-56.
- [5] DU L, LIU J Y, LEI X. The primary frequency regulation dynamic model based on power network [C] // Proceedings of the International Conference on Power System Technology. Piscataway, NJ, USA: IEEE, 2007: 4116197.
- [6] 陶骞,贺颖,潘杨,等. 电力系统频率分布特征及改进一次调频控制策略研究 [J]. 电力系统保护与控制, 2016, 44(17): 133-138.
- TAO Qian, HE Ying, PAN Yang, et al. Characteristics of power system frequency abnormal distribution and improved primary frequency modulation control strategy [J]. Power System Protection and Control, 2016, 44(17): 133-138.
- [7] ZHAO Changhong, TOPCU U, LI Na, et al. Design and stability of load-side primary frequency control in power systems [J]. IEEE Transactions on Automatic Control, 2014, 59(5): 1177-1189.
- [8] 孙辰辰. 发电机组一次调频与二次调频策略及其优化 [D]. 北京: 华北电力大学, 2015: 7-38.
- [9] 郑涛,高伏英. 基于 PMU 的机组一次调频特性参数在线监测 [J]. 电力系统自动化, 2009, 33(11): 57-61, 71.
- ZHENG Tao, GAO Fuying. On-line monitoring and computing of unit PFR characteristic parameter based on PMU [J]. Automation of Electric Power Systems, 2009, 33(11): 57-61, 71.
- [10] 于达仁,郭钰锋. 电网一次调频能力的在线估计 [J]. 中国电机工程学报, 2004, 24(3): 72-76.
- YU Daren, GUO Yufeng. The online estimate of primary frequency control ability in electric power system [J]. Proceedings of the CSEE, 2004, 24(3): 72-76.
- [11] 贺颖,潘杨,陶骞,等. 考虑调频死区的电网一次调频能力评价指标 [J]. 电力系统保护与控制, 2016, 44(19): 85-90.
- HE Ying, PAN Yang, TAO Qian, et al. Evaluation index of power grid primary frequency modulation considering dead zone [J]. Power System Protection and Control, 2016, 44(19): 85-90.
- [12] 张琦兵,徐春雷,刘栋,等. 基于广域相量测量系统的电网一次调频能力预测 [J]. 电力工程技术, 2019, 38(2): 64-68.
- ZHANG Qibing, XU Chunlei, LIU Dong, et al. Ability of primary frequency regulation estimate based on wide area measurement system [J]. Electric Power Engineering Technology, 2019, 38(2): 64-68.
- [13] 叶圣永,王晓茹,刘志刚,等. 基于受扰严重机组特征及机器学习方法的电力系统暂态稳定评估 [J]. 中国电机工程学报, 2011, 31(1): 46-51.
- YE Shengyong, WANG Xiaoru, LIU Zhigang, et al. Power system transient stability assessment based on severely disturbed generator attributes and machine learning method [J]. Proceedings of the CSEE, 2011, 31(1): 46-51.
- [14] 周艳真,吴俊勇,于之虹,等. 基于转子角轨迹簇特征的电力系统暂态稳定评估 [J]. 电网技术, 2016, 40(5): 1482-1487.
- ZHOU Yanzhen, WU Junyong, YU Zhihong, et al. Power system transient stability assessment based on cluster features of rotor angle trajectories [J]. Power System Technology, 2016, 40(5): 1482-1487.
- [15] ABDEL-NASSER M, MAHMOUD K. Accurate photovoltaic power forecasting models using deep LSTM-RNN [J]. Neural Computing and Applications, 2019, 31(7): 2727-2740.
- [16] 仇怡超,闻达,王晓茹,等. 基于深度置信网络的电力系统扰动后频率曲线预测 [J]. 中国电机工程学报, 2019, 39(17): 5095-5104.
- ZHANG Yichao, WEN Da, WANG Xiaoru, et al. A method of frequency curve prediction based on deep belief network of post-disturbance power system [J]. Proceedings of the CSEE, 2019, 39(17): 5095-5104.
- [17] 朱乔木,党杰,陈金富,等. 基于深度置信网络的电力系统暂态稳定评估方法 [J]. 中国电机工程学报, 2018, 38(3): 735-743.

- ZHU Qiaomu, DANG Jie, CHEN Jinfu, et al. A method for power system transient stability assessment based on deep belief networks [J]. Proceedings of the CSEE, 2018, 38(3): 735-743.
- [18] 周念成, 廖建权, 王强钢, 等. 深度学习在智能电网中的应用现状分析与展望 [J]. 电力系统自动化, 2019, 43(4): 180-191.
- ZHOU Niancheng, LIAO Jianquan, WANG Qiang-gang, et al. Analysis and prospect of deep learning application in smart grid [J]. Automation of Electric Power Systems, 2019, 43(4): 180-191.
- [19] HINTON G E. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [20] ZHU Chengzhang, YIN Jianping, LI Qian. A stock decision support system based on DBNs [J]. Journal of Computational Information Systems, 2014, 10(2): 883-893.
- [21] PAI M A. Energy function analysis for power system stability [M]. Cham, Germany: Springer, 1989: 256.

附录 A

算法 1 对比散度算法(伪代码)

输入: 可视层向量 $\mathbf{v}=[v_1, \dots, v_m]$, 隐藏层向量 $\mathbf{h}=[h_1, \dots, h_n]$

输出: 连接权重矩阵 $\mathbf{W}=[w_{ij}], 1 \leq i \leq n, 1 \leq j \leq m$, 可视层偏置向量 $\mathbf{b}=[b_j], 1 \leq j \leq m$, 隐藏层偏置向量 $\mathbf{c}=[c_i], 1 \leq i \leq n$

初始化: $w_{ij}=b_j=c_i=0, 1 \leq i \leq n, 1 \leq j \leq m$

- (1) for $i=1, 2, \dots, n$ do
- (2) $p(h_i=1|\mathbf{v})=\text{logistic}(c_i+\sum_j W_{ij}v_j)$
- (3) $h_i=\begin{cases} 1, & r_i < p(h_i=1|\mathbf{v}) \\ 0, & \text{其他} \end{cases}$ // 计算隐藏层神经元状态, r_i 为 $[0, 1]$ 上的随机数
- (4) end for
- (5) for $j=1, 2, \dots, m$ do
- (6) $p(v'_j=1|\mathbf{h})=\text{logistic}(b_j+\sum_i W_{ij}h_i)$
- (7) $v'_j=\begin{cases} 1, & r_j < p(v_j=1|\mathbf{h}) \\ 0, & \text{其他} \end{cases}$ // 计算重构的可视层神经元状态, r_j 为 $[0, 1]$ 上的随机数
- (8) end for
- (9) for $i=1, 2, \dots, n$ do
- (10) $p(h'_i=1|\mathbf{v}')=\text{logistic}(c_i+\sum_j W_{ij}v'_j)$ // 计算重构的隐藏层条件分布

- (11) end for
- (12) for $i=1, 2, \dots, n, j=1, 2, \dots, m$ do
- (13) $\mathbf{W} \leftarrow \mathbf{W} + p(h_i=1|\mathbf{v})v_j - p(h'_i=1|\mathbf{v}')v'_j$ // 更新权重矩阵
- (14) end for
- (15) for $j=1, 2, \dots, m$ do
- (16) $\mathbf{b} \leftarrow \mathbf{b} + (v_j - v'_j)$ // 更新可视层偏置向量
- (17) end for
- (18) for $i=1, 2, \dots, n$ do
- (19) $\mathbf{c} \leftarrow \mathbf{c} + p(h_i=1|\mathbf{v}) - p(h'_i=1|\mathbf{v}')$ // 更新隐藏层偏置向量
- (20) end for

附录 B

算法 2 有监督参数微调算法(伪代码)

输入: 实际输出 $\mathbf{o}'$, 学习速率 η , 激活函数 σ 为 sigmoid 函数, 训练集输入向量 $\mathbf{x}=[x'_a], 1 \leq t \leq N, 1 \leq a \leq m$, 训练集输出向量 $\mathbf{y}=[y'_b], 1 \leq b \leq c$

输出: 连接权值矩阵 $\mathbf{W}^k$, 偏置矩阵 $\mathbf{b}^k$, 其中 $1 \leq k \leq r, r$ 为网络层数

初始化: 使用预训练获得的网络参数 $\mathbf{W}^k, \mathbf{b}^k$

- (1) for $t=1, 2, \dots, N$ do
- (2) for $k=1, 2, \dots, r$ do
- (3) $\mathbf{x}^t \rightarrow \mathbf{g}_0^t$
- (4) $\mathbf{h}_k^t = \mathbf{W}^k \mathbf{g}_{k-1}^t + \mathbf{b}^k$
- (5) $\mathbf{g}_k^t = \sigma(\mathbf{h}_k^t)$
- (6) end for
- (7) $\delta_r^t = (\mathbf{o}^t - \mathbf{y}^t) \circ \delta(\mathbf{h}_r^t)$ // $\circ$ 为阿达玛乘积运算符
- (8) for $k=1, 2, \dots, r-1$ do
- (9) $\delta_k^t = [(\mathbf{W}^{k+1})^T \delta_{k+1}^t] \circ \sigma(\mathbf{h}_k^t)$
- (10) end for
- (11) $\mathbf{E} = \frac{1}{2} \sum_t (\mathbf{o}^t - \mathbf{y}^t)^2$
- (12) for $k=1, 2, \dots, r$ do
- (13) $\frac{\partial \mathbf{E}}{\partial \mathbf{W}^k} = \sum_t \delta_k^t (\mathbf{h}_{k-1}^t)^T$
- (14) $\frac{\partial \mathbf{E}}{\partial \mathbf{b}^k} = \sum_t \delta_k^t$
- (15) $\mathbf{W}^k \leftarrow \mathbf{W}^k - \eta \frac{\partial \mathbf{E}}{\partial \mathbf{W}^k}$
- (16) $\mathbf{b}^k \leftarrow \mathbf{b}^k - \eta \frac{\partial \mathbf{E}}{\partial \mathbf{b}^k}$
- (17) end for
- (18) end for

(编辑 陶晴)