

基于长短期记忆循环神经网络的AGC实时控制策略

李 滨¹,王靖德¹,梁水莹²,韦昌福³

(1. 广西大学 广西电力系统最优化与节能技术重点实验室,广西 南宁 530004;

2. 广西电网有限责任公司电力科学研究院,广西 南宁 530023;

3. 广西电网有限责任公司电力调度控制中心,广西 南宁 530023)

摘要:大量新能源的接入以及电网中冲击负荷数量的剧增,使得电网对自动发电控制(AGC)策略提出了新的要求。简化AGC的一般控制流程,对比不同AGC策略的控制特性,在每个考核周期内选择控制效果更优的控制策略,并充分发挥多种控制策略在各自优势工况下的性能,以得到优秀控制数据集;在此基础上,以长短期记忆(LSTM)循环神经网络为神经元构建AGC策略深度学习模型,并提出一种基于LSTM循环神经网络的数据驱动型AGC实时控制策略。仿真结果表明,基于深度学习的控制策略的整体性能优于任何单一控制策略。

关键词:自动发电控制;控制策略;深度学习;长短期记忆循环神经网络;数据驱动

中图分类号:TM 73

文献标志码:A

DOI:10.16081/j.epae.202111014

0 引言

自动发电控制AGC(Automatic Generation Control)是实现发电功率和负荷功率平衡、保持电网频率为规定值和联络线交换功率为计划值的重要手段^[1]。世界各国大力推动以风电和光伏为代表的可再生能源发展,促进电能生产的清洁化转型。风电和光伏能源具有随机性、间歇性和难以准确预测等特点,其装机容量的迅速增加给电力系统安全稳定和经济运行带来了巨大挑战。同时,按照我国国家能源局的统一部署,各地区级电网根据区域实际情况,分别颁布了适合各自区域的“两个细则”。各地区调频市场也逐渐完善,亟需提高AGC性能来降低电网运行成本^[2]。

国内外许多学者对该领域进行了研究,并取得了显著成果。现有AGC方法主要可划分为传统控制算法和动态优化控制策略两大类。其中,传统控制算法主要包括传统的比例-积分-微分PID(Proportional Integral Derivative)算法^[3]、模糊逻辑控制算法^[4]、模糊PID^[5]、Q学习^[6]、Q(λ)学习^[7]、R(λ)学习^[8]和分布式模型预测控制算法^[9]等。AGC动态优化策略考虑了负荷预测信息和区域控制偏差ACE(Area Control Error)的变化,通过超短期负荷预测提前对机组进行调整,以经济性或者技术性指标为目标,优化下一周期内各时段的AGC调节功率,避免了传统控制“先有偏差再调节”所带来的滞后问题^[10]。

目前电网中普遍采用的AGC策略为传统的滞后比例-积分PI(Proportional Integral)控制。该策略

通过频繁地下达数值较大的区域总调节指令,对功率缺额部分迅速进行补偿,但这会使参与AGC调节的机组自身产生巨大损耗,且当处于一个较大的迟滞环节时,滞后控制容易引起区域总调节功率过调、欠调。现阶段大量新能源电源并网,负荷逐年增加,这使得联络线功率波动更加复杂,如果继续采用现行的PI控制,则不符合电网未来的实际利益发展。

文献[11]采用基于离散傅里叶变换DFT(Discrete Fourier Transform)方法的AGC策略,利用DFT方法将当前时刻前较长一段时间ACE波动中的高频、低频部分剔除,在仅考虑中频部分波动的情况下,根据控制性能标准CPS(Control Performance Standard)进行功率调节。通过对区域总调节功率的精细化控制,在保证更好的控制效果的前提下,该策略大幅降低了区域总调节功率的下令数值和次数,避免了AGC机组频繁剧烈动作,且由于计及了时间段内数据变化过程,遵循预测的连贯性原则,该策略具有短期预测效应,但其也存在一些缺点,如在区域控制偏差骤变时无法很好地进行调控,如果此时采用调节更迅速的PI控制,则在一定程度上能提升整体控制性能。

近年来,以深度学习为代表的人工智能方法在计算机视觉^[12]、机器翻译^[13]和医疗诊断^[14]等领域均取得了不错的效果。深度学习模型通过多层非线性映射,可以逐层学习到大量数据中蕴含的抽象特征^[15],并有效地解决分类^[16]、预测^[17]等问题。深度学习的快速发展给本文提供了一种全新的基于数据驱动的AGC策略研究思路。

本文提出一种基于长短期记忆LSTM(Long Short-Term Memory)循环神经网络的AGC实时控制策略。首先根据实际PI控制生成调节量,对电网提供的控制后的历史数据进行还原,得到未控制时的

收稿日期:2021-01-03;修回日期:2021-09-28

基金项目:国家自然科学基金资助项目(51767004)

Project supported by the National Natural Science Foundation of China(51767004)

数据,并从DFT方法和PI控制中选择控制效果更好的控制策略,对该还原数据中的每个考核周期进行控制,得到每个周期的总调节指令,最终生成控制数据集;然后构建基于LSTM循环神经网络的AGC策略深度学习模型,通过对生成的数据集进行学习,构建已知输入量和总调节指令间的映射关系,并从数据集中提炼出融合不同控制策略优点的控制特性,组成的全新网络控制策略能适应多种电网的运行工况;最后选取某省级电网半年的调度数据进行训练仿真,并与单独采用PI控制和DFT控制的效果进行对比分析,结果表明深度学习控制策略的整体性能要优于上述2种控制策略单独运行。

1 AGC的基本原理

AGC过程如图1所示,图中“○”表示混合运算。首先区域电网调度中心实时测量计算得到当前系统频率偏差 Δf 、联络线功率偏差 ΔP_T 和ACE,ACE的计算公式见附录A式(A1);然后按照某种AGC策略生成控制区域的总调节功率 ΔP_G ,并根据某种功率分配机制将总调节功率进行分配;最后区域内各AGC机组根据下发控制指令进行AGC功率调节。AGC机组的功率调节会改变系统频率和联络线功率,从而形成一个闭环反馈控制过程^[18]。本文研究的内容是根据ACE生成区域总调节功率 ΔP_G 的过程。




图1 AGC过程的简单描述

Fig.1 Simple description of AGC process

现有研究主要采用由北美电力安全性协会提出的CPS对AGC的安全性能进行评价,公式见附录A式(A2)和式(A3)。CPS包含CPS1和CPS2这2个标准,该标准以区域电网ACE的统计数据为依据,与以往的评价标准相比,其具有更为严格的数学理论基础,且不再要求调节ACE使其频繁为0,减少了AGC机组的调节频度和机组磨损,强调了AGC评价的长期控制性能。

2 基于LSTM循环神经网络的AGC模型

2.1 选择合适的深度学习框架

深度学习本质上是具有多层隐藏层的有监督神经网络^[19],是一种特定类型的典型机器学习,其基本思想是通过多层的网络结构和非线性变换组合低层特征,形成抽象的、易于区分的高层表示,直接构建已知输入量和输出的映射关系,发现数据的分布式特征。近年来,为了改善深度神经网络DNN(Deep

Neural Network)的训练效果,降低DNN的优化难度,一些特有的深度学习模型和框架被相继提出,如堆叠自动编码器、深度信念网络、递归神经网络、卷积神经网络、深度森林和超深度学习等。

在解决实际问题中,不同的深度学习模型和框架适用于不同类型的问题。在选择深度学习框架解决AGC策略时需要考虑到:在深度网络学习的优良控制数据集中,大部分控制指令是在ACE波动不大的常规工况下由带时间序列性质的DFT方法计算得到的。为了更好地得到输入量和总调节指令间的映射关系,选择的框架要能很好地反映各个变量参数之间在时间序列上的关系。

在众多的深度学习框架中,LSTM是一种特殊的循环神经网络,其具有特殊的记忆结构和门结构,可以较好地学习时序数据中含有的相关性特征,被广泛用于时间序列模型中^[20],因此在本文提出的深度学习控制策略中选择LSTM循环神经网络作为学习框架。

2.2 LSTM循环神经网络

循环神经网络凭借其独特的网络结构,能够很好地处理序列数据,对前面的信息进行记忆并且参与当前输出的计算。理论上循环神经网络能处理任意长度的序列数据,循环神经网络的模型如附录B图B1所示。

当输入循环神经网络的序列数据长度过长时,会出现“梯度消失”和“梯度爆炸”的问题。LSTM循环神经网络在传统循环神经网络的基础上设计了遗忘门、输入门和输出门这3个门单元,巧妙地解决了循环神经网络存在的问题,各门结构如附录B图B2虚线框中所示。遗忘门将上一时刻的隐藏状态 h_{t-1} 与本序列数据 x_t 相结合来决定细胞状态中需要丢弃的信息;输入门用来计算本序列数据 x_t 中哪些信息保存到记忆单元状态 c_t 中;输出门用来更新记忆单元状态 c_t ,并得到最后的细胞输出 h_t 。附录A式(A4)~(A6)为LSTM循环神经网络胞体向前传播时的公式与3个门对应的关系。

由LSTM循环神经网络单元结构可知,因其特殊的记忆结构,时刻 t 隐藏层的输出 h_t 不仅与该时刻输入的AGC相关数据和上一时刻隐藏层的输出 h_{t-1} 有关,还与该时刻记忆单元状态 c_t 有关。通过有选择地更新记忆单元, c_t 可以反映深度网络所学习到的各时刻之间的相关性,因此时刻 t 隐藏层的输出 h_t 可以反映该时刻输入的AGC相关数据 x_t 以及较长时间以前的AGC相关数据的共同结构性特征^[20]。

2.3 基于LSTM循环神经网络的AGC模型构思

2.3.1 模型构思

虽然PI控制和基于DFT方法的AGC策略在原理上有很大区别,但是在控制流程上具有相似性,可

以归纳成2个步骤:第一步为分类问题,不同的控制策略根据输入的电网相关数据,判断AGC机组是否需要参与调节,当判定当前电网状态处于控制死区时,AGC机组无需调节,而当判定当前电网状态超出死区时,AGC机组需要参与调节,并进入第二步;第二步为回归问题,在第一步已经判断出需要调节的情况下,利用第一步中计算得到的数据,根据不同的逻辑关系和参数设置确定区域总调节功率。一般AGC流程如附录B图B3(a)所示。

本文模型思路为以训练得到的3个LSTM循环神经网络来替代上述每个步骤中具体的分类判断和回归计算环节,最终组成一种全新的AGC策略:第一步中用1个三分类网络来确定当前要采取的AGC操作;第二步中分别用2个回归网络计算判断出加减速操作之后具体的总调节功率数值。基于LSTM循环神经网络的AGC流程如附录B图B3(b)所示。

3个网络除了结构参数不同外,输入数据集和对应的输出数据类型也有所区别。

2.3.2 数据集输入、输出变量选择

利用PI控制和DFT控制生成控制数据集时,用到 Δf 、ACE、CPS1指标和CPS2指标这4类变量。其中前2类变量 Δf 与ACE属于反映采样时刻电网状态的一类系统特征变量,其与采样时刻电网实际运行情况相关,后2类变量CPS1指标与CPS2指标属于指标变量,在各控制策略中,CPS指标作为判断条件决定是否要生成总调节功率。为了使采样的变量能从各个角度全方位反映采样时刻的电网真实状态,本文选择这4类变量作为数据集的输入变量,网络的特征量即为4。

3个LSTM循环神经网络的输入特征量均为 Δf 、ACE、CPS1指标和CPS2指标这4类变量,但由于网络的任务不同,需选择不同的变量作为输出变量。分类网络选取AGC机组状态量(其值为-1、0、1,分别表示机组减速、保持不变和加速)作为输出变量;加减速回归网络选取对应的正、负区域总调节功率数值作为输出变量。

3 训练LSTM循环神经网络

3.1 LSTM循环神经网络数据预处理

3.1.1 时间序列数据集生成

某省级电网的历史数据为电网AGC策略控制后的数据,首先根据现有的PI控制策略生成调节量^[21],对ACE数据进行还原,将还原控制后的ACE数据作为被控数据生成所需的控制数据集。

在生成控制数据集时,从电网调度实际关心的经济性与安全性2个角度评定策略控制性能的优劣,经济性要求下令次数与调节量相对较低,安全性要求每个考核周期尽量通过CPS指标考核。从这2

点考虑,在大部分考核周期(即10 min)内,DFT控制效果要优于PI控制,由DFT控制生成这些周期的区域总调节指令;如果在某考核周期内DFT控制无法保证CPS指标合格,则在该周期内舍弃经济性,采用PI控制进行调节,生成区域总调节指令来满足安全性要求;在极少的考核周期内,DFT控制与PI控制均无法满足安全性要求,此时需采用人工修正的方法生成区域总调节指令,保证该考核周期内电网安全运行。

每个考核周期代表不同的运行环境,选择控制性能更优的控制策略调节环境中的ACE,所得到的控制指令中就蕴含了各控制策略的优秀控制特性。

3.1.2 数据集输入、输出变量标准化

当使用多变量时间序列进行预测时,不同变量之间的量纲不同,数值差别也较大,这会严重影响网络中权重的训练。根据数据是否连续对数据集中的输入、输出变量进行不同的标准化处理。

当数据连续时,如 Δf 、ACE、CPS1指标和CPS2指标这4类输入变量以及回归网络中作为输出变量的区域总调节功率,均采用数据平均值和方差进行零-均值规范化(z-score标准化)处理,经过处理后的数据均值为0,标准差为1。转化公式为:

$$X' = \frac{x - \bar{x}}{\sigma_x} \quad (1)$$

式中: X' 为变量经标准化处理后的数值; x 为待标准化处理的变量; $\bar{x}$ 为变量的均值; σ_x 为变量的标准差。

当数据非连续时,如分类网络中作为输出变量的加减速状态量(其值为-1、0和1),需要采用独热编码(one-hot encoding),编码之后无需进行其他数据处理。状态-1、0、1编码后分别对应100、010、001。

通过回归模型得到的区域总调节功率预测值为标准化处理后的数据,还需要进行一次反标准化处理使其具有物理意义,反标准化的计算公式为:

$$x = \sigma_x X' + \bar{x} \quad (2)$$

3.1.3 将时间序列数据转换为有监督学习数据

对数据预处理结束后,在训练前还需将二维的时间序列数据转换为三维的满足LSTM循环神经网络训练所需的有监督学习数据。

用序列长度 $\times$ 特征量大小的滑动窗口(sliding window)在时间序列数据中每隔一定数量采样点框选出一个二维数据,以该段二维数据最后时刻的输出量作为整个二维数据的输出标签,通过叠加带标签的二维数据,得到LSTM循环神经网络训练所需的三维数据,附录B图B4展示了使用滑动窗口将二维时间序列数据转换为有监督学习所需的三维数据的示意图。

序列长度反映了当前的输出与之前多少个时刻

的输入数据相关。数据集中的大部分控制指令是由基于 DFT 方法的 AGC 策略生成的,只有少部分控制指令是采用 PI 控制对控制偏差进行快速调整生成的,因此序列长度与 DFT 方法采样时设置的长度密切相关。

基于 DFT 方法的 AGC 策略每次根据当前时刻和前 150 个采样点(共涉及 5 min 的采样数据)计算得到调节指令,即生成的每个区域总调节指令均与当前时刻及前 150 个采样点的状态相关,因此在 3 个 LSTM 循环神经网络中序列长度取 151。

分类网络的训练数据集是每 20 个采样点框选出的,将以独热编码后的机组状态量为标签的二维数据叠加而得到的三维数据集。对于加减速回归网络,移动滑动窗口时仅选取区域总调节功率对应的增减数据进行叠加生成三维数据集。3 个不同功能的 LSTM 循环神经网络对应 3 个不同的三维数据集。

3.2 LSTM 循环神经网络模型构造

3.2.1 LSTM 循环神经网络参数设置与函数选择

选取合理的超参数、函数和优化算法对模型预测的准确度十分重要。本文提出的深度 LSTM 循环神经网络涉及的超参数主要有深度 LSTM 循环神经网络层数 L 、隐藏层神经元数量 H 、子训练样本集数量 B 、输入序列长度 I 以及输出序列长度 O 等。本文中输入序列长度 $I=151$;分类网络的输出为 AGC 的 3 种控制状态,因此分类网络输出序列长度 $O=3$;回归网络的输出为区域总调节功率值,因此回归网络输出序列长度 $O=1$ 。深度 LSTM 循环神经网络参数设置情况如表 1 所示。

表 1 深度 LSTM 循环神经网络参数设置情况

Table 1 Parameter setting condition of deep LSTM recurrent neural network

超参数	分类网络	回归网络
深度 LSTM 循环神经网络层数	3	2
子训练样本集	512	512
第一层隐藏层神经元数量	256	256
第二层隐藏层神经元数量	256	256
第三层隐藏层神经元数量	256	无
隐藏层 Dropout	0.3	0.3
隐藏层激活函数	ELU 函数	ELU 函数
输入序列长度	151	151
输出序列长度	3	1
输出层激活函数	Softmax 函数	无
目标函数	交叉熵损失函数	均方误差函数
训练优化算法	Adam	Adam

3.2.2 具体训练流程

3 个深度 LSTM 循环神经网络的数据处理与训练流程基本相同,主要如下:

- 1) 针对不同的数据集输入、输出量分别进行不同的预处理;
- 2) 用序列长度 $\times$ 特征量大小的滑动窗口对预处理之后的时序数据进行滑动采样,假设滑动采样得到 n 个带输出标签的二维训练样本,通过叠加数据将其以 3 维张量($n \times 151 \times 4$)的形式进行存储;

理之后的时序数据进行滑动采样,假设滑动采样得到 n 个带输出标签的二维训练样本,通过叠加数据将其以 3 维张量($n \times 151 \times 4$)的形式进行存储;

3) 按 7:3 的比例划分出训练集和测试集,将训练集的输入数据输入 LSTM 循环神经网络中,得到预测值;

4) 根据预测值与真实值的计算误差,通过随时间反向传播(BPTT)算法对 LSTM 循环神经网络中的参数进行一次更新,实现 LSTM 循环神经网络的有监督学习,此时的真实值为输入网络的训练集所带的输出标签;

5) 完成一次参数更新后,将测试集数据代入训练一半的 LSTM 循环神经网络中得到预测值,通过与实际值对比得到误差,判断网络训练是否出现过拟合现象。

经过反复迭代与训练,得到 3 个深度 LSTM 循环神经网络,则可进行下一步的 AGC 在线控制仿真,并通过 CPS 指标验证该方法 AGC 性能的优劣。

4 基于 LSTM 循环神经网络的 AGC 流程

本文设计的基于 LSTM 循环神经网络的 AGC 流程主要分为 2 个区域,对应于 2.3.1 中的 2 个步骤,2 个区域中共包括 3 个已经训练好的 LSTM 循环神经网络,分别为状态分类网络、加速和减速区域总调节功率回归网络,具体控制流程如图 2 所示。




图 2 基于 LSTM 循环神经网络的 AGC 流程

Fig.2 AGC flowchart based on LSTM recurrent neural network

区域 1 内通过状态分类网络确定当前 AGC 机组是否要进入加减速操作以保持电网的稳定运行。每

20 个采样点(40 s)进行一次控制计算,将判断时刻以及相关历史数据按照 LSTM 循环神经网络输入的要求(序列长度 $\times$ 特征量,本文为 151×4)组成原始数据,以训练网络时采用的数据集的平均值和方差对当前时刻取出的原始数据按式(1)进行标准化处理,并输入判断状态网络中,输出长度为 3 的独热编码后的控制状态,再将 3 位编码转换成编码前的状态,即-1、0 和 1 这 3 个状态结果。若区域 1 的输出为 0,则判定 AGC 无需参与调节,该轮控制流程结束;若区域 1 的输出为 1(-1),则判定 AGC 机组需要采取加速(减速)调节,立即进入区域 2。

区域 2 内准确计算加减速状态下总调节功率值。以区域 1 输出 1 后计算加速区域总调节功率为例,将输入区域 1 内状态分类网络的样本(大小为 151×4 的经标准化处理后的数据)再次输入加速区域总调节功率回归网络中得到预测数值,并按式(2)对其进行反标准化处理得到最终的加速状态下的总调节功率值。

5 算例分析

5.1 数据说明和试验设计

本文的深度 LSTM 循环神经网络在 TensorFlow 深度学习框架下进行训练,硬件平台为一块 Intel Core i7-8700 CPU 和一块 NVIDIA GTX 1080 Ti GPU。

本文数据均来源于某省级电网真实历史数据,采样周期为 2 s,一天共计 43 200 个采样点。为了尽可能涵盖实际运行中发生的各种工况,选择 2018 年 7 至 11 月这 5 个月数据按照 3.1.1 节中的操作,生成深度学习所需训练数据集。

为了验证通过深度学习方法得到的 AGC 策略的有效性,分别用 3 种策略对 2018 年 12 月已经还原的数据进行 AGC,其中 PI 控制的比例系数与积分系数根据现有系统设置分别设定为 0.6 与 5。

5.2 控制效果分析

评定 AGC 性能最直观的方法是从 CPS 指标的角度进行考核,CPS1 指标与 CPS2 指标的数值可以通过实时计算得到,但对 AGC 性能的考核仅取每 10 min 的数值,因此全天共 144 个考核点。PI 控制、DFT 控制和深度 LSTM 循环神经网络控制对 12 月 31 d 的整体控制效果如表 2 所示。

由表 2 可见,深度 LSTM 循环神经网络控制的效果整体优于 PI 控制和 DFT 控制。在某些日期,由于工况复杂多变,单一控制策略难以对偏差进行调节,而深度 LSTM 循环神经网络控制综合了 2 种控制策略的优点,其控制效果得到明显提升。

选取 12 月 28 日作为典型日,该日 3 种控制策略的考核结果如表 3 所示。

由表 3 可知:基于 PI 控制的 AGC 策略的下令次

表 2 12 月各控制策略的合格点数

Table 2 Qualifying points of each control strategy in December

控制策略	天数			最小合格 点数	日均合格 点数
	144	135~143	<135		
未进行控制	3	18	10	113	135
PI 控制	5	20	6	119	138
DFT 控制	8	18	5	123	139
深度 LSTM 循环神经网络控制	11	17	3	131	141

注:栏目中数据情况表示全天合格点数范围。

表 3 12 月 28 日各控制策略考核结果

Table 3 Evaluation results of each control strategy on December 28

控制策略	合格 点数	下令 次数	CPS2 指标 最大值	正调节电 量/(MW·h)	负调节电 量/(MW·h)
PI 控制	136	1 575	174.38	29.94	-29.92
DFT 控制	140	1 012	120.07	13.75	-13.77
深度 LSTM 循环神经网络控制	143	942	116.29	10.85	-10.86

数与调节电量是 3 种控制策略中最多的,这印证了 PI 控制是通过频繁下达数值较大的区域总调节指令对偏差进行调节的;处于一个较大迟滞环节时,PI 控制容易造成过调、欠调,出现很多 CPS 指标不合格的情况,其合格点数为 3 种控制策略中最少的;DFT 控制则对 ACE 进行拆分,对区域总调节功率进行精细化处理,减少了机组的动作次数和调节电量;深度 LSTM 循环神经网络控制策略的各项指标无论是从经济性还是安全性角度均优于其他 2 种控制策略单独控制,其既保留了 DFT 控制下机组动作次数和调节电量少的优点,又能在 ACE 波动较剧烈时进行很好的控制,减少了不合格点数,保证了电网的安全稳定运行。

12 月 28 日 3 种控制策略的下令情况如附录 B 图 B5 所示。由图可以看出,深度 LSTM 循环神经网络控制的下令值波动略小于 DFT 控制,但远小于 PI 控制,这也印证了表 3 中调节电量的大小关系。

选取 12 月 28 日 09:10—09:20 时段的控制结果进行对比分析,3 种控制策略在该 10 min 内整体的控制情况如表 4 所示。

表 4 12 月 28 日 09:10—09:20 的控制情况

Table 4 Control situation from 09:10 to 09:20 on December 28

控制策略	CPS1 指标	CPS2 指标	下令次数
PI 控制	1.78	6.53	12
DFT 控制	1.69	0.32	11
深度 LSTM 循环神经网络控制	1.75	10.43	5

由表 4 可知,虽然在该段考核周期内从 CPS 指标的考核角度来看,深度 LSTM 循环神经网络控制

在3种控制策略中的表现并不是最优秀的,但其却通过最少的下令次数使CPS指标满足电网的考核要求,体现了该控制策略的经济性。

该时段3种控制策略的16个下令点的下令情况如附录B图B6所示。由图可见,深度LSTM循环神经网络控制的下令次数均少于另外2种控制策略,且其每次总调节指令生成的数值与DFT控制相近,而远低于PI控制。

6 结论

本文提出一种全新的AGC研究思路,在每个考核周期内选择控制效果更优的控制策略,由这些控制策略在各自优势工况下生成优秀控制数据集,并运用深度学习网络从优秀控制数据集中提炼出融合不同控制策略优点的控制特性,组成全新的网络AGC策略。通过仿真算例分析可得到如下结论。

1)深度学习网络通过对优良数据集的学习,能够将数据集中蕴含的PI控制和DFT控制的特性进行很好的综合,所组成的全新的网络控制策略能够有效地补偿ACE,控制其在考核范围之内。对2018年12月数据的仿真控制发现,相较于PI控制与DFT控制,深度LSTM循环神经网络控制的日均合格点数分别提高了2.17%与1.44%。

2)采用深度LSTM循环神经网络进行AGC时,能有效地较少机组的动作次数与调节电量,降低AGC调节机组自身产生的损耗。对2018年12月28日数据的仿真控制发现,相较于PI控制与DFT控制,深度LSTM循环神经网络控制的下令次数分别减少了40.19%与6.92%,调节总量分别减少了63.76%与21.09%。

3)从一个月、一天和一个考核时段这3个时间维度对各数据指标进行对比,控制结果验证了本文深度LSTM循环神经网络控制的可行性和优越性。

虽然深度LSTM循环神经网络控制有效增加了日均CPS考核合格点数,但由于训练LSTM循环神经网络的数据集规模有限,能反映的电网状态也是有限的,在全天的考核中仍然会出现少量考核周期不合格的现象,可以用各种控制策略对不合格周期的总调节指令进行修正后将其扩充到训练数据集中。随着数据集的不断扩充,可以通过反复训练网络,使网络更加成熟强健。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

[1] 胡泽春,罗造成. 大规模可再生能源接入背景下自动发电控制研究现状与展望[J]. 电力系统自动化,2018,42(8):2-15.
HU Zechun, LUO Haocheng. Research status and prospect of automatic generation control with integration of large-scale renewable energy[J]. Automation of Electric Power Systems, 2018, 42(8): 2-15.

[2] 李晓敏,王立军. 基于超临界机组适应两个细则的AGC协调控制系统优化[J]. 东北电力技术,2017,38(2):18-21.
LI Xiaomin, WANG Lijun. Optimization on AGC coordinate control system basic on supercritical generation unit with two rules[J]. Northeast Electric Power Technology, 2017, 38(2): 18-21.

[3] 高宗和,滕贤亮,涂力群. 互联网AGC分层控制与CPS控制策略[J]. 电力系统自动化,2004,28(1):78-81.
GAO Zonghe, TENG Xianliang, TU Liqun. Hierarchical AGC mode and CPS control strategy for interconnected power systems[J]. Automation of Electric Power Systems, 2004, 28(1): 78-81.

[4] SHABANI H, VAHIDI B, EBRAHIMPOUR M. A robust PID controller based on imperialist competitive algorithm for load-frequency control of power systems[J]. ISA Transactions, 2013, 52(1):88-95.

[5] MOHANTY P K, SAHU B K, PATI T K, et al. Design and analysis of fuzzy PID controller with derivative filter for AGC in multi-area interconnected power system[J]. IET Generation, Transmission & Distribution, 2016, 10(15):3764-3776.

[6] 张孝顺,李清,余涛,等. 基于协同一致性迁移Q学习算法的虚拟发电部落AGC功率动态分配[J]. 中国电机工程学报,2017, 37(5):1455-1467.
ZHANG Xiaoshun, LI Qing, YU Tao, et al. Collaborative consensus transfer Q-learning based dynamic generation dispatch of automatic generation control with virtual generation tribe [J]. Proceedings of the CSEE, 2017, 37(5):1455-1467.

[7] YU T, ZHOU B, CHAN K W, et al. Stochastic optimal relaxed automatic generation control in non-Markov environment based on multi-step $Q(\lambda)$ learning[J]. IEEE Transactions on Power Systems, 2011, 26(3):1272-1282.

[8] YU T, ZHOU B, CHAN K W, et al. $R(\lambda)$ imitation learning for automatic generation control of interconnected power grids [J]. Automatica, 2012, 48(9):2130-2136.

[9] ZHANG Y, LIU X J, QU B. Distributed model predictive load frequency control of multi-area power system with DFigs[J]. IEEE / CAA Journal of Automatica Sinica, 2017, 4(1):125-135.

[10] 赵霞,张荣荣,赵瑞峰,等. CPS标准下AGC机组动态优化调度的改进模型[J]. 电工技术学报,2016,31(5):99-106.
ZHAO Xia, ZHANG Rongrong, ZHAO Ruifeng, et al. An extended dynamic optimization model for AGC generators dispatch under CPS [J]. Transactions of China Electrotechnical Society, 2016, 31(5):99-106.

[11] LI B, LI Z N, BAI X Q. AGC real-time control strategy based on DFT method[C]//2019 IEEE 3rd Conference on Energy Internet and Energy System Integration(EI²). Changsha, China: IEEE, 2019:1928-1932.

[12] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas, NV, USA: IEEE, 2016:2818-2826.

[13] SINGH S P, KUMAR A, DARBARI H, et al. Machine translation using deep learning: an overview[C]//2017 International Conference on Computer, Communications and Electronics (Comptelix). Jaipur, India: IEEE, 2017:162-167.

[14] LITJENS G, KOOI T, BEJNORDI B E, et al. A survey on deep learning in medical image analysis[J]. Medical Image Analysis, 2017, 42:60-88.

[15] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553):436-444.

[16] 屈相帅,段斌,尹桥宣,等. 基于稀疏自动编码器深度神经网络的电能质量扰动分类方法[J]. 电力自动化设备,2019,39(5):

- 157-162.
QU Xiangshuai, DUAN Bin, YIN Qiaoxuan, et al. Classification method of power quality disturbances based on deep neural network of sparse auto-encoder[J]. Electric Power Automation Equipment, 2019, 39(5): 157-162.
- [17] 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.
- [18] 李滨, 韦化, 农蔚涛, 等. 互联电网CPS下AGC控制参数的优化[J]. 电力系统自动化, 2009, 33(18): 37-41.
LI Bin, WEI Hua, NONG Weitao, et al. Optimization of AGC control parameters under the control performance standard for interconnected power grids[J]. Automation of Electric Power Systems, 2009, 33(18): 37-41.
- [19] 赵万宗, 韦化, 韦昌福, 等. 考虑市场力风险约束的最优AGC控制模型[J]. 电力自动化设备, 2018, 38(5): 77-82, 109.
ZHAO Wanzong, WEI Hua, WEI Changfu, et al. Optimal AGC model with risk constraints of market power[J]. Electric Power Automation Equipment, 2018, 38(5): 77-82, 109.
- [20] 郑瑞晓, 张妹, 肖先勇, 等. 考虑温度模糊化的多层长短时记忆神经网络短期负荷预测[J]. 电力自动化设备, 2020, 40(10): 181-186.
ZHENG Ruixiao, ZHANG Shu, XIAO Xianyong, et al. Short-term load forecasting of multi-layer long short-term memory neural network considering temperature fuzziness[J]. Electric Power Automation Equipment, 2020, 40(10): 181-186.
- [21] 王彬, 孙勇, 吴文传, 等. 协同电网安全性与经济性的新能源优先实时调度方法及应用[J]. 电力系统自动化, 2020, 44(16): 105-113.
WANG Bin, SUN Yong, WU Wenchuan, et al. Real-time prior dispatch method for renewable energy with safety and economy coordination of power grid and its application[J]. Automation of Electric Power Systems, 2020, 44(16): 105-113.

作者简介:



李 滨

李 滨(1975—),女,广东中山人,副教授,博士,主要研究方向为电力系统最优化(E-mail: lizhen@gxu.edu.cn);

王靖德(1996—),男,浙江温州人,硕士研究生,主要研究方向为电力系统优化控制方法(E-mail: 1812301033@st.gxu.edu.cn)。

(编辑 王锦秀)

AGC real-time control strategy based on LSTM recurrent neural network

LI Bin¹, WANG Jingde¹, LIANG Shuiying², WEI Changfu³

(1. Guangxi Key Laboratory of Power System Optimization and Energy Technology, Guangxi University, Nanning 530004, China;

2. Electric Power Research Institute of Guangxi Power Grid Co., Ltd., Nanning 530023, China;

3. Power Dispatching Control Center of Guangxi Power Grid Co., Ltd., Nanning 530023, China)

Abstract: The connection of a large number of renewable energy and the sharp increase of the number of impact loads in power grid make power grid put forward new requirements for AGC (Automatic Generation Control) strategies. The general control process of AGC is simplified, the control characteristics of different AGC strategies are compared, the control strategy with better control effect in each evaluation cycle is selected, and the performance of multiple control strategies under their respective advantageous conditions is given full play to obtain excellent control data set. On this basis, LSTM (Long Short-Term Memory) recurrent neural network is taken as the neuron to construct a deep learning model of AGC strategy, and a data-driven AGC real-time control strategy based on LSTM recurrent neural network is proposed. The simulative results show that the overall performance of the control strategy based on deep learning is better than any single control strategy.

Key words: automatic generation control; control strategy; deep learning; long short-term memory recurrent neural network; data-driven

附录 A:

1. ACE 计算。

不考虑无意交换电量, ACE 计算公式为:

$$E_{ACE} = (\sum P_{Ti} - \sum I_{Oj}) + 100B(f - f_0) \quad (A1)$$

式中: $\sum P_{Ti}$ 为控制区所有联络线的实际测量值之和; $\sum I_{Oj}$ 为控制区与外区的交易计划之和; B 为控制区的频率响应系数 (单位为 MW/Hz); f 、 f_0 分别表示频率的实际值、额定值。

2. CPS 标准。

CPS1 是统计 ACE 变化量与频率偏差关系的标准, 应小于一个给定的限值, 主要侧重考核 AGC 对频率控制的贡献。其指标值为:

$$K_{CPS1} = 2 - \sum [E_{AVE-min} \Delta F_{AVE-min} / (100B_i)] / (n_{time} \epsilon_1^2) \quad (A2)$$

式中: $E_{AVE-min}$ 为 1 min ACE 的平均值; $\Delta F_{AVE-min}$ 为 1 min 频率平均偏差值; B_i 为控制区 i 的频率响应系数 (单位为 MW/Hz); n_{time} 为考核期分钟总数; ϵ_1 为一年时段内互联电网实际频率与标准频率偏差的 1 min 平均值的方均根值, 是频率控制的目标值, 也是一个长期的考核指标。

CPS2 是统计 ACE 幅值变化, 用于评估控制区域控制联络线潮流偏差的能力, 即控制区 ACE 的 10 min 平均值, 必须控制在给定限值, 以限制大的不可接受且不可预见的系统潮流。其指标值为:

$$K_{CPS2} = \frac{1}{N} \sum_{t=1}^N (100B \Delta f^t + \Delta P_T^t) \leq L_{10} \quad (A3)$$

$$L_{10} = 1.65 \epsilon_{10} \sqrt{(-100B_i)(-100B_s)}$$

式中: N 为考核周期; Δf^t 为频率偏差; ΔP_T^t 为联络线功率偏差; ϵ_{10} 为一年中基于 10 min 的平均频率与标准频率偏差的均方值; B_s 为互联电网的频率偏差系数。为满足频率质量的要求, 控制区域 10 min 的 ACE 平均值应满足 $\delta = \epsilon_{10} \sqrt{(-100B_i)(-100B_s)}$ 的正态分布。NERC 要求 CPS2 的合格率在 90% 以上。根据正态分布的特点, 事件概率为 90%, 其状态分布范围为 $(-1.65\delta, 1.65\delta)$, 由此系数为 1.65。

根据某省级电网 AGC 定值单, 当 $K_{CPS1} \geq 200\%$ 或 $K_{CPS1} \geq 100\%$ 且 $K_{CPS2} \leq L_{10}$ 时, CPS 考核合格, 其中 L_{10} 取 100。

3. LSTM 胞体向前传播时与 3 个门相关的公式。

遗忘门:

$$f_t = \sigma(W_f [h_{t-1}, x_t] + b_f) \quad (A4)$$

输入门:

$$\begin{cases} i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \\ \tilde{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \\ c_t = f_t c_{t-1} + i_t \tilde{c}_t \end{cases} \quad (A5)$$

输出门:

$$\begin{cases} o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \\ h_t = o_t \tanh(c_t) \end{cases} \quad (A6)$$

式中: σ 为 sigmoid 函数; W_f 、 W_i 、 W_c 、 W_o 为各个环节中的权重矩阵; b_f 、 b_i 、 b_c 、 b_o 为各个环节中的偏置项, 权重矩阵和偏置项为同一层所有 LSTM 单元共有的参数, 即为网络需要学习的部分。

附录 B:




图 B1 循环神经网络模型

Fig.B1 Recurrent neural network model




图 B2 LSTM 单元结构

Fig.B2 Structure of LSTM unit




图 B3 模型构思

Fig.B3 Model idea




图 B4 滑动窗口采样

Fig.B4 Sliding window sampling




图 B5 12 月 28 日 3 种方法全天下令情况

Fig.B5 Order situation throughout day of three methods on December 28




图 B6 3 种方法 09:10—09:20 下令情况
Fig.B6 Order situation of three methods from 09:10 to 09:20