

[功率动态分配]

基于模糊神经网络的AGC功率动态分配优化研究

文/许建强 彭佩芳

甘肃电投河西水电开发有限责任公司

传统AGC功率动态分配优化方法直接对发电机容量进行调节，未对AGC功率分配模型进行构建，造成传统方法优化效果差。因此，提出基于模糊神经网络的AGC功率动态分配优化研究。构建AGC功率分配模型实时调整发电机的输出，基于模糊神经网络调节发电机容量保持电网的稳定运行，设计基于模糊神经网络的AGC功率最优分配流程。实验结果表明该研究方法AGC功率动态分配优化效果更优。

随着可再生能源在电力系统中的比重日益增大，电力系统的运行环境和控制需求变得更加复杂多变。电力系统是一个复杂且动态的系统，其稳定性和安全性对社会的正常运行至关重要^[1]。

有研究人员基于灰狼算法优化算法，设计一种混合AGC功率分配方法。计算风电并网功率与原始功率的互相关系数，将各固有模态函数（IMF）样本熵作为适应度函数，采用灰狼优化算法对各分量进行寻优，采用ICEEMDAN分解风电功率，将低频IMF信号作为风电并网功率，高频IMF信号作为混合储能系统功率，进行混合储能系统功率的一次分配后对功率进行修正，实现混合储能系统功率的二次分配^[2]。但是由于电力系统中存在许多不确定性和动态性因素，灰狼优化算法在寻优过程中可能会陷入局部最优解，需要频繁地重新优化，导致分配效果不能满足实际需求。还有研究学者基于一致性算法设计HVDC与AGC协同功率分配方法，在二次调频阶段考虑各机组与HVDC的调节成本，通过HVDC的功率调整使得互联异步电网也能够根据调节成本承担部分功率不平衡量，实现AGC功率分配^[3]。但是面对不确定性和变化性，如负荷波动、设备故障或新能源接入等，基于一致性算法的功率分配方法

表现出一定的局限性，进而影响算法的收敛性和分配结果的准确性。

模糊神经网络具有强大的学习和优化能力，能够处理模糊和不精确的信息，使得模糊神经网络能够自动调整其参数，以更好地处理AGC功率动态分配中的复杂性和不确定性。为此，本文基于模糊神经网络的优势，设计AGC功率动态分配优化方法。

基于模糊神经网络的AGC功率动态分配优化方法设计

1. 构建AGC功率分配模型

构建AGC功率分配模型是实现电网优化运行、提高供电可靠性的重要手段^[4]。AGC功率分配模型能够根据电网的运行状态和负荷需求，实时调整发电机的输出，从而保持电网的稳定运行。根据以下目标函数构建AGC功率分配模型。

目标函数1：降低AGC的运营成本^[5]。AGC的运营成本主要包括电力成本、运营和维护成本以及容量损失成本等。该目标旨在减少AGC的运行成本，提高经济效益，即

$$\min f_1 = \sum C_i P_i + P_i w_i \Delta t + L_{mi} C_E \quad (1)$$

式中， P_i 为第*i*个发电机的充电和输出容量； w_i 为维

护成本； C_l 为单个发电机的电力成本； E 为储能器中发电机的数量； L_{mi} 为第 i 个发电机的容量损失； t 为单元的计划时间； C_E 为单元输入成本。

目标函数2：减少能量存储单元的健康状态损失。不规则的储能发电充放电会导致发电机的功率损失^[6]。SOH是描述剩余容量与发电机初始容量之比的重要指标，计算公式为

$$\text{SOH}_i(T) = \frac{C_{mi}(T)}{C_{ni}(T)} \times 100\% \quad (2)$$

式中， $\text{SOH}_i(T)$ 为在 T 周期中第 i 个蓄能器的健康状况； $C_{mi}(T)$ 为 T 周期中剩余的蓄能器功率； $C_{ni}(T)$ 为蓄能器在 T 周期内的额定功率。

定义发电机的剩余电量为

$$C_{mi} = C_{ni} - L_{mi} \quad (3)$$

AGC的健康损失最小定义为

$$\min f_2 = \sum \text{SOH}_i(T-1) - \text{SOH}_i(T) \quad (4)$$

目标函数3：荷电状态一致性。荷电状态的最佳一致性是储能单元并联运行的基础^[7]。高荷电状态一致性可以提高AGC的效率，有助于AGC的整体控制。平衡的荷电状态可以反映配电策略的效率。荷电状态一致性的目标函数应由每个储能单元的剩余累积荷电状态的剩余状态方差表示

$$\min f_3 = \frac{1}{n} \left(\sum \text{SOC}_i(t) - \frac{1}{n} \sum \text{SOC}_i(t) \right)^2 \quad (5)$$

式中， $\text{SOC}_i(t)$ 为 i 个发电机存储设施，在 t 期间的装载位置。

AGC功率分配模型定义为

$$\begin{cases} L_{mi} = \min f_1 A e^{\frac{-31700+370.3 \text{cdt}, r}{HT_e}} (\Delta Q_i)^{0.55} (r_{\text{cdt}, i})^{\frac{2}{3}} \Delta t \\ r_{\text{cdt}, i} = \min f_2 \frac{P_{ri}}{P_{ni}} \\ \Delta Q_i = \min f_3 \frac{P_{ri} \Delta t}{C_{ni}} \end{cases} \quad (6)$$

式中， A 为常数系数，为27 128； cdt, i 和 T_e 分别为储能单元的收集和输出速度； H 为气体常数，值为8.314 J/(mol·K)； ΔQ_i 为储能厂的热量变化； P_{ri} 和 P_{ni} 分别为储能厂的集排气能力和标称集排气能力； Δt 为规划的时间间隔。

最大蓄能发电单元的最大充电和排气容量限制计算公式为

$$P_{i-d \min} \leq P_i(t) \leq P_{i-c \max} \quad (7)$$

式中， $P_{i-d \min}$ 和 $P_{i-c \max}$ 分别为第 i 个发电机的最小输出和最大充电允许值； $P_i(t)$ 表示在 t 时刻分配给第 i 个发电机的功率。

发电机单元SOC约束计算公式为

$$\text{SOC}_{\min} \leq \text{SOC}_i(t) \leq \text{SOC}_{\max} \quad (8)$$

AGC总出力约束计算公式为

$$P_N(t) = \sum P_i(t) \quad (9)$$

式中， $P_N(t)$ 为AGC总功率需求。

2. 基于模糊神经网络调节发电容量

模糊神经网络具有处理不确定性和模糊性的能力，能够更好地逼近复杂的非线性映射关系。将模糊神经网络用于调节发电容量，通过模糊化层进行模糊化处理，然后传递给神经网络进行学习和联想，最后通过去模糊化层输出处理结果。充分利用发电机的全时运行来参与AGC网络，同时满足用户的需求。连接到电网的每个储能发电机都有预定的荷电状态（SOC），通常不是AGC控制的一部分。基于模糊神经网络该过程可以描述为

$$\lambda_{\text{SOCe}} = e_{\text{SOCin}} + \frac{\eta \int P_{ev} dt}{E_{\max}} P_N(t) \quad (10)$$

$$0 \leq P_{ev} \leq P_{ev}^{\max} \quad (11)$$

式中， λ_{SOCe} 为接入发电机的荷电状态（SOC）； e_{SOCin} 为发电机连接到网络时的初始荷电状态； η 为发电机的优选时间； P_{ev} 为用于收集发电机的预期功率，并在收集完成后将其减少到0； $E_{\max}$ 为发电机的最大充电容量； $P_{ev}^{\max}$ 为发电机的最大充电能力。

当发电机由于AGC调整而连接时，无法立即知道实际收集的结束时间。只能根据本地控制中心的期望荷电状态（SOC）和期望发出时间进行评估，并响应来自本地控制中心功率校正团队的指令。AGC功率控制原理图如图1所示。




图1 AGC功率控制原理图

图1中，基于模糊神经网络假设负载扰动发生在时间段内，发电机的充电状态为 $e_{\text{SOC}_{\text{off}}}$ 。当 $e_{\text{SOC}_{\text{e}}}$ 是用户的首选充电位置时，如果满足以下条件，发电机可以参与AGC减电控制。

1) 发电机的充电状态 $e_{\text{SOC}_{\text{e}}}$ 大于用户首选充电位置的阈值。

2) 发电机的充电状态 $e_{\text{SOC}_{\text{e}}}$ 小于用户首选充电位置的阈值，但发电机的当前输出功率小于其最大输出功率。

满足以上条件时，发电机可以根据用户的指令和AGC减电控制策略进行相应的调整。发电机参与AGC减电控制公式为

$$(t_{\text{off}} + \Delta t_{\text{agc}} + \Delta t_{\text{c}}^{\min}) \leq t_{\text{e}} \quad (12)$$

$$\Delta t_{\text{c}}^{\min} = \frac{E_{\text{max}}(e_{\text{SOC}_{\text{e}}} - e_{\text{SOC}_{\text{off}}})}{\eta P_{\text{ev}}^{\text{max}}} \quad (13)$$

式中， $\Delta t_{\text{c}}^{\min}$ 为AGC加入后发电机加工的最短时间； Δt_{agc} 为AGC调整时间。

因此，具有更长负载时限的发电机可以根据发电机充电的时限来实现AGC第三电力层的动态分配，该动态分配优先参与AGC的减载控制，其中发电机的充电时间裕度为

$$t_{\text{m}}^{\text{down}} = t_{\text{e}} - (t_{\text{off}} + \Delta t_{\text{agc}} + \Delta t_{\text{c}}^{\min}) \quad (14)$$

此外，如果发电机满足以下条件，则可以参与AGC功率上调控制

$$(t_{\text{off}} + \Delta t_{\text{agc}}) < t_{\text{e}} \quad (15)$$

因此，即使在存在基于发电机充电时间限制来调整电力的指令的情况下，第三层AGC（即具有更长充电时间限制的发电机）的容量的动态分配也可以优先参与AGC的调整控制。基于模糊神经网络调节发电机的充电时间裕度可描述为

$$t_{\text{m}}^{\text{up}} = t_{\text{e}} - (t_{\text{off}} + \Delta t_{\text{agc}}) \quad (16)$$

此外，本文假设每台发电机的本地控制中心等同代理，并且AGC对代理管理的发电机的调整所涉及的成本是相同的。

3. AGC功率动态分配优化流程设计

基于模糊神经网络的AGC功率动态分配，由高比例的模糊神经网络根据SCR灵敏度标准获得功率分配优化计算的最优方法。AGC功率动态分配优化流程如图2所示。

步骤1：构建一个自动发电控制（AGC）的功率分配模型。在这个模型中，需要考虑电网的拓扑

结构，并设定相应的交流电网命令值以及新能源场的初始功率。




图2 基于模糊神经网络的AGC功率最优分配

步骤2：使用该模型来计算自动发电控制系统的相关参数。然后验证每个现场的AGC是否符合最小AGC请求的标准。

步骤3：根据相关公式计算AGC对每个新能源并网容量的综合灵敏度。通过比较这些综合灵敏度的值，找出综合灵敏度绝对值最低的新能源站，记为新能源站 i 。

步骤4：首先需要判断新能源站 i 是否已经达到其最大输出容量。一旦新能源站 i 达到其最大输出容量，将不再计算其综合灵敏度。

步骤5：增加或调整新能源站 i 的发电能力，并记录其生产能力和重复次数。

步骤6：基于模糊神经网络，需要调节发电机的容量。在调节过程中，记录下最小的SCR与必要系统值 ΔVMRSCR （ $\text{VMRSCR} - M_{\text{ref}}$ ）之间的差值。

步骤7：将 ΔVMRSCR 与预设的偏差值进行比较。如果 ΔVMRSCR 小于偏差值，或者已经达到最大重复次数，那么继续进行步骤8。否则，返回步骤3。

步骤8：最后，输出AGC功率动态分配的最优方案，以及相应的发电极限。

实验论证

为验证基于模糊神经网络的AGC功率动态分配优化方法的效果，进行对比实验，将文献[2]提出的基于灰狼优化算法的AGC功率分配方法和文献[3]提出基于一致性的AGC功率分配方法作为对照组，本文方法为实验组，建立如下实验环境。

1. 实验准备

本文中的实验数据来自某省某市一个装机容量为20.3 MW的光伏电站。该电站输电中心将主变压器的高压半部分视为有效的功率评估点。损耗主要包括箱式变流器、密集型方案和主要网络损耗。

在创建混合误差函数之前，应对训练数据进行处理，以提高网络训练的效率。经过优化滤波后，获得了93 602个周期内的有效数据。数据集分割方法是将原始数据的98%用作训练集，而最后的2%用作验证集。

为验证基于模糊神经网络的AGC功率动态分配优化方法的效果，分别使用文献[2]提出的基于灰狼优化算法的AGC功率分配方法和文献[3]提出基于一致性的AGC功率分配方法作为对比方法，与本文提出方法共同参与实验。在9:30—16:30的这段时间内，发电厂处于调度状态。在其余时间里，所有电站的变流器都处于MPPT运行模式，不受电力限制。利用上述3种功率分配方法进行功率分配，全站全天功率响应结果见表1。

表1 三种方法实验结果对比

时间	文献[2]方法平均响应误差百分比 (%)	文献[3]方法平均响应误差百分比 (%)	本文方法平均响应误差百分比 (%)
9:30-10:30	3.54	2.14	0.62
10:31-11:30	5.76	4.75	0.83
11:31-12:30	3.56	2.65	0.56
12:31-13:30	3.12	3.25	0.84
13:31-14:30	3.45	3.45	0.75
14:31-15:30	4.65	4.66	0.63
15:31-16:30	5.33	5.26	0.58
平均值	4.20	3.74	0.69

2. 对比实验

从表1可以看出，在整个实验期间，本文提出的

方法在配电方面表现出了较好的性能。与文献[2]方法和文献[3]方法相比，本文方法平均响应误差百分比更低，始终低于1%以下，具有更高的发电分配性能。实验结果表明，本文提出的最优分配方案能够在满足电力需求的同时，最小化平均响应误差百分比，实际应用效果更优。

结束语

本文对基于模糊神经网络的AGC功率动态分配优化进行了深入研究。通过对比传统控制策略的局限性和不足，提出了一种基于模糊神经网络的方法，旨在提高AGC的性能。经过仿真实验和实际应用验证，该方法为保障电网的安全、稳定运行提供有力支持。EA

(收稿日期：2024-03-25)

参考文献

[1] 李思佳, 丛犁, 黄成斌, 等. 可重构智能表面辅助传输的电力通信中继系统性能分析与功率优化分配 [J]. 科学技术与工程, 2023, 23 (31): 13438-13447.

[2] 刘勇, 刘大鹏, 穆勇, 等. 基于GWO优化ICEEMDAN分解的混合储能系统功率分配策略 [J]. 电气工程学报, 2022, 17(4): 257-267.

[3] 张朝辉, 杨家豪, 苏杰和. 直流互联异步电网的HVDC与AGC协同功率分配[J]. 电测与仪表, 2022, 59(1): 162-167.

[4] 黄柯昊, 吴水军, 张瑀明, 等. 基于目标函数优化法的风场层一次调频功率分配策略 [J]. 电机与控制应用, 2023, 50 (4): 58-68+76.

[5] 闫晓健, 刘建业, 张鹏强, 等. 基于优化算法的混合储能功率分配策略 [J]. 科技创新与应用, 2023, 13 (6): 13-17+21.

[6] 姚林萍, 李梦达, 梁智超, 等. 基于改进灰狼优化算法的虚拟同步发电机功率分配策略 [J]. 上海电机学院学报, 2023, 26 (1): 14-20+27.

[7] 王奇, 何鑫雨, 何森, 等. 电力市场环境两阶段交直流输电通道功率优化分配方法 [J]. 南方电网技术, 2023, 17 (4): 38-48.