

计及模型误差的分布式光伏配电网优化调控方法

窦晓波¹, 蔡超², 段向梅¹, 韩俊², 刘之涵¹, 陈曦²

(1. 东南大学 电气工程学院, 江苏 南京 210096; 2. 国网江苏省电力有限公司经济技术研究院, 江苏 南京 210009)

摘要:当前配电网存在信息采集不全、在线获取电网精确模型困难的问题,导致对分布式光伏的调控存在误差,难以满足配电网安全运行的要求,因此提出了一种计及模型误差的分布式光伏配电网调控方法。基于近似灵敏度建立了光伏调控量粗略计算模型;采用极限学习机(ELM)方法建立人工智能辅助决策模型,作为光伏调控量粗略计算模型的修正;进一步地,基于上述2个模型,设计了计及模型误差的分布式光伏优化调控策略;最后进行仿真分析,结果表明提出的调控方法弥补了仅依赖电网模型进行优化带来的误差,提高了优化调控的精度。

关键词:分布式光伏;配电网;优化调控;近似灵敏度;极限学习机;辅助决策

中图分类号:TM 615

文献标志码:A

DOI:10.16081/j.epae.201911002

0 引言

为了应对能源危机和环境污染问题,分布式光伏(PV)作为一种清洁、可再生的能源大量接入配电网。但由于光伏具有较强的随机性、间歇性和波动性,随着其渗透率的不断提高,配电网电压波动愈发明显,电能质量不断恶化,给配电网的安全、经济和稳定运行带来了诸多挑战^[1]。

为了解决上述问题,大量文献挖掘分布式光伏的有功无功调节能力,研究了配电网中分布式光伏的调控方法,其控制方案整体上可分为本地控制、分布式控制和集中控制这3种。本地控制无需通信,仅利用本地测量数据,对光伏波动快速做出响应。文献[2-3]为了解决响应过程中的超调问题,分别提出了不同的光伏有功和无功本地控制策略;文献[4]提出了本地控制参考值调制方法。然而本地控制仅利用本地信息调节并网点电压,各光伏间没有协调,难以达到全局最优。分布式控制中各控制器可获取相邻节点信息,并利用分布式算法实现协调优化。文献[5]对优化问题凸松弛,并提出了一种分布式算法求解分布式电源出力;文献[6]基于反馈策略实现配电网的分布式优化控制。然而分布式优化算法及其协调流程一般较复杂,同时存在算法收敛性的问题,目前在实际工程中还较难实施。集中控制是通过集中控制器采集电网信息,并统一计算和下发分布式光伏的优化功率调节指令。文献[7]以运行成本和网损最小为目标,建立配电网多目标优化调控

模型,以缩短计算时间和简化模型复杂度;文献[8-9]提出了基于模型预测控制的电压控制策略。综上,相比于本地控制,集中控制能够协调各光伏出力,易于实现全局优化;相比于分布式控制,集中控制优化流程相对简单,易于工程实现。因此在目前技术条件下,集中控制是分布式光伏配电网调控的主流方式。

近年来,人工智能理论在电力系统中得到了飞速发展和应用,从早期的专家系统到中期的神经网络和进化计算,再到相关的向量机,涉及的应用领域包括暂态稳定评估^[10]、配电网网损计算^[11]、故障定位^[12]、负荷与发电预测^[13-14]等。具体到分布式光伏发电领域,文献[15]提出了一种基于改进深度受限玻尔兹曼机算法的光伏发电短期功率概率预测模型;文献[16]总结了基于神经网络实现光伏最大功率点跟踪的技术;文献[17]提出了基于模糊神经网络的光伏逆变器并网控制方法,保证了电网故障时有功功率平衡。在配电网优化调控领域,人工智能的应用主要分为以下2个方面。一方面是利用各种智能算法求解优化调控模型,有效增强全局寻优能力,如文献[18]提出了基于自学习迁移粒子群的无功优化算法;文献[19]基于 Pareto 熵的多目标粒子群优化算法提出了一种应用于多目标无功优化的改进粒子群优化算法。另一方面,利用人工智能强大的自学能力、推广能力以及非线性处理能力挖掘数据的隐含规律,从而拟合输入值和输出值之间的关联关系,如文献[20]以光伏有功出力预测值和负荷预测值等为输入,采用粒子群优化算法计算得到的光伏无功优化值为输出建立神经网络,实现光伏的无功在线优化。需要说明的是,上述优化调控方法都需要建立精确的物理模型。但相比于输电网,配电网中分布式电源和负荷节点数目众多,限于投资,缺乏量测设备,可实时采集到的电网运行数据

收稿日期:2018-12-21;修回日期:2019-09-04

基金项目:国家自然科学基金资助项目(51777031);国网江苏省电力有限公司科技项目(J2018058)

Project supported by the National Natural Science Foundation of China(51777031) and the Science and Technology Project of State Grid Jiangsu Electric Power Co.,Ltd.(J2018058)

通常不够完备。因此基于实时量测数据建立的电网实时模型不精确,存在较大误差,影响了配电网优化调控的效果。

为此,本文提出了一种计及模型误差的分布式光伏配电网调控方法,即利用人工智能来协同挖掘光伏出力与系统电压的关系,并作为配电网优化调控的辅助决策。具体研究内容包括:计及光伏的调控能力,基于近似灵敏度建立了配电网分布式光伏调控量的粗略计算模型;以光伏出力和总负荷为输入、母线电压为输出,以电网运行数据作为学习样本,建立了基于极限学习机(ELM)的人工智能辅助决策模型,规避了故障数据数据量小、累积慢的弊端;在此基础上,设计了含辅助决策的分布式光伏配电网调控策略,实现了光伏调控量的反馈校正,弥补了仅依赖电网模型进行优化带来的误差,提升了分布式光伏优化调控的效果;通过算例及仿真分析验证了所提方法的正确性和有效性。

1 人工智能辅助决策的分布式光伏配电网调控策略

本文所提的分布式光伏配电网调控系统框架如图1所示。首先,通过集中控制器采集各光伏和配电网其他节点的状态信息;然后,由部署在集中控制器中的分布式光伏调控策略优化各光伏的有功和无功出力指令;最后,统一下发至各光伏,各光伏跟踪指令值运行,从而实现配电网的安全经济运行。

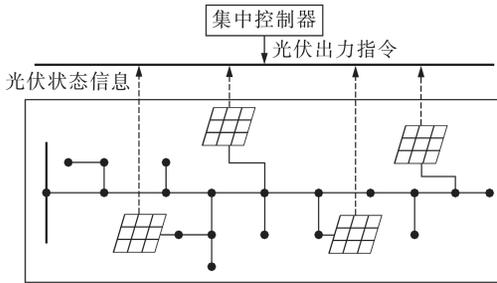


图1 分布式光伏集中调控框架
Fig.1 Centralized optimal control framework of distributed PV

分布式光伏调控策略如图2所示,其主要由以下3个模块构成:基于近似灵敏度的光伏调控量粗略计算模块、基于极限学习机的人工智能辅助决策模块以及光伏调控量的反馈修正模块。

基于近似灵敏度的光伏调控量粗略计算模块的主要功能是:首先,综合考虑分布式光伏及其并网逆变器控制的特点,得到分布式光伏调控能力模型;然后,根据网络拓扑和稳态系统参数,计算得到光伏的近似电压灵敏度值;最后,考虑配电网调控的优化目标和约束条件,因灵敏度值不精确导致该模块计算的光伏调控量存在一定误差,故建立光伏调控量粗略计算模型。

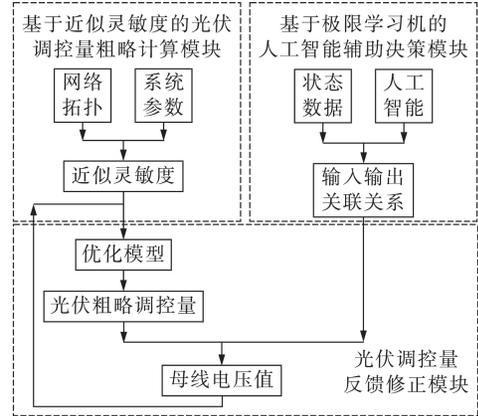


图2 人工智能辅助决策的分布式光伏配电网调控策略
Fig.2 Optimal distributed PV control strategy assisted by artificial intelligence in distributed network

基于极限学习机的人工智能辅助决策模块的主要功能是:首先,从积累的配电网网络拓扑和稳态系统参数中选取光伏出力和总负荷为输入,系统母线或薄弱节点的电压为输出,利用极限学习机构建学习模型;进而探究输入与输出之间的关联关系,建立人工智能辅助决策模型库。

光伏调控量反馈修正模块的功能是:利用人工智能辅助决策模块中建立的输入输出关系修正光伏调控量粗略计算模块产生的调控指令,通过相互迭代实现光伏调控指令的再优化,以提高调控指令的精度。

2 基于近似灵敏度的光伏调控量粗略计算模型

2.1 分布式光伏调控能力模型

(1)有功调控能力。

光伏的有功出力主要受天气影响,正常情况下各光伏工作于最大功率点,因此对光伏有功进行调节时,只能减少其出力值,调节范围可表示为:

$$P_{PV} \in [0, P_{PV, MPP}] \quad (1)$$

其中, P_{PV} 为光伏有功出力; $P_{PV, MPP}$ 为光伏有功最大出力。

利用由于调节导致的有功功率的减少量乘以光伏上网价格,得到第三方利益损失,以此来衡量调节光伏有功功率的成本,计算公式如下:

$$C = F_{PV} \Delta P_{PV} \quad (2)$$

其中, C 为有功调节成本; F_{PV} 为光伏上网价格; ΔP_{PV} 为光伏有功功率削减量。

(2)无功调控能力。

光伏既能发出感性无功功率也能发出容性无功功率,但其受到有功出力、容量和最大允许功率角的限制^[9]。光伏最大无功出力可表示为:

$$Q_{PV, max} = \min(P_{PV} \tan \phi_{max}, \sqrt{S^2 - P_{PV}^2}) \quad (3)$$

其中, S 为光伏容量; ϕ_{\max} 为最大允许功率因数角。

由此得到光伏无功出力调节范围为:

$$Q_{PV} \in [-Q_{PV,\max}, Q_{PV,\max}] \quad (4)$$

当光伏有功出力变化时, 光伏无功调节范围也随之变化; 而当无功变化时不影响有功出力, 故一般不计及无功功率的调节成本。

通过建立有功成本模型, 在优化调控过程中可实现优先调节光伏的无功出力。

2.2 近似电压灵敏度计算方法

通过对配电网稳定运行点局部线性化, 可得到节点电压变化量与节点注入有功功率和无功功率变化量之间的关系^[6], 即电压灵敏度。

利用牛顿-拉夫逊法进行潮流计算, 可得极坐标形式下的修正方程, 即:

$$\begin{bmatrix} H & N \\ K & L \end{bmatrix} \begin{bmatrix} \Delta\theta \\ \Delta V/V \end{bmatrix} = \begin{bmatrix} \Delta P \\ \Delta Q \end{bmatrix} \quad (5)$$

其中, $\begin{bmatrix} H & N \\ K & L \end{bmatrix}$ 为雅可比矩阵; $\Delta\theta$ 和 ΔV 分别为节点电压的相角和幅值修正量; V 为电压幅值的对角阵; ΔP 和 ΔQ 分别为节点注入有功功率和无功功率的扰动量。

正常运行情况下, 电压相角 θ_{ij} 较小, 电压幅值的标幺值在 1.0 p.u. 附近, 由此对雅可比矩阵进行简化, 并进行高斯消去, 得到电压灵敏度如下:

$$\Delta V = \left[(B+Q)(G-P)^{-1}(B-Q) + (G+P) \right]^{-1} \Delta P - \left[(G-P)(B+Q)^{-1}(G+P) + (B-Q) \right]^{-1} \Delta Q \quad (6)$$

其中, B 和 G 分别为节点导纳阵的实部和虚部; P 和 Q 分别为节点注入的有功功率和无功功率的对角阵, 其对角元素分别为 P_i/V_i^2 和 Q_i/V_i^2 , P_i 与 Q_i 分别为节点 i 的有功和无功注入。

如上文所述, 配电网中节点注入的有功和无功实时值难以获取, 本文利用平均负荷建立离线配电网模型, 计算得到电压灵敏度值。由于灵敏度计算过程中采取了近似处理且部分实时值以平均值代替, 所以得到的电压灵敏度值存在一定误差。

2.3 光伏调控量粗略计算模型

基于光伏的近似灵敏度值, 以母线电压偏差和调控成本最小为优化目标, 以光伏有功和无功出力为优化变量, 建立配电网分布式光伏优化调控模型, 得到存在一定误差的分布式光伏粗略调控量。

(1) 优化目标。

优化目标函数可表示为:

$$\min(\alpha |V - V_{\text{ref}}| + \beta C) \quad (7)$$

其中, V 为调节后的电压值; V_{ref} 为电压参考值; α 和 β 为权重系数。

不考虑各光伏之间对电压的耦合作用, 电压变化可采用线性叠加方式, 电压与光伏出力变化量之间的关系如下:

$$V = V^{(0)} + \Delta V = V^{(0)} + \sum_{j=1}^m (S_{P_j} \Delta P_{PV_j} + S_{Q_j} \Delta Q_{PV_j}) \quad (8)$$

其中, $V^{(0)}$ 为电压初始值; ΔV 为电压变化量; S_{P_j} 、 S_{Q_j} 分别为第 j 台光伏有功、无功出力对电压的近似灵敏度值; ΔP_{PV_j} 、 ΔQ_{PV_j} 分别为第 j 台光伏有功、无功出力调控量; m 为馈线上光伏的个数。

(2) 约束条件。

为了使优化结果满足电网运行要求, 在优化模型中增加约束条件。

a. 功率平衡约束。

$$\begin{cases} P_i = \text{Re} \left(V_i \sum_{i=1}^n \hat{Y}_{ij} \hat{V}_i \right) \\ Q_i = \text{Im} \left(V_i \sum_{i=1}^n \hat{Y}_{ij} \hat{V}_i \right) \end{cases} \quad (9)$$

其中, V_i 为节点 i 电压相量; Y_{ij} 为系统导纳矩阵对应元素; n 为节点数目; “ $\hat{}$ ” 表示共轭。

b. 节点电压约束。

$$V_{li,\min} \leq V_{li} \leq V_{li,\max} \quad (10)$$

其中, V_{li} 为正常运行情况下节点 i 处电压幅值; $V_{li,\min}$ 、 $V_{li,\max}$ 分别为配电网正常运行情况下节点 i 电压下限和上限。

$$V_{2i,\min} \leq V_{2i} \leq V_{2i,\max} \quad (11)$$

其中, V_{2i} 为紧急工况下节点 i 处电压幅值; $V_{2i,\min}$ 、 $V_{2i,\max}$ 分别为紧急工况下节点 i 电压下限和上限。

c. 光伏出力约束。

$$\begin{cases} 0 \leq P_{PV_j} \leq P_{PV_j,\text{MPP}} \\ -Q_{PV_j,\max} \leq Q_{PV_j} \leq Q_{PV_j,\max} \end{cases} \quad (12)$$

3 基于极限学习机的人工智能辅助决策模型

3.1 极限学习机设计

极限学习机是一种新的单隐含层前向神经网络, 其结构如图 3 所示, 由输入层、隐含层和输出层这 3 层构成。极限学习机随机初始化输入权重和隐含层节点偏置, 以最小化训练误差为目标, 通过算法确定隐含层输出权重^[21]。

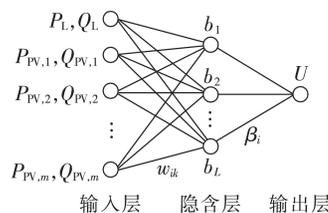


图 3 极限学习机网络模型结构

Fig.3 Structure of ELM network model

(1) 输入层与输出层。

输入层接受外部的信号与数据,输出层实现系统处理结果的输出。现有 N 组样本 (X_j, U_j) , 其中 X_j 为由 m 个光伏的有功、无功功率以及配电网的总负荷组成的样本, 即 $X_j = [P_{PV,j1}, Q_{PV,j1}, P_{PV,j2}, Q_{PV,j2}, \dots, P_{PV,jm}, Q_{PV,jm}, P_{L,j}, Q_{L,j}]^T \in \mathbf{R}^{2m+2}$, U_j 为母线电压样本, 且 $j=1, 2, \dots, N$ 。将 X_j 作为极限学习机的输入层, U_j 作为极限学习机的输出层。

(2) 隐含层。

隐含层处于输入层与输出层之间, 由大量具有计算功能的节点并行组成, 通过这些节点建立输入层与输出层的非线性关系。

含有 L 个隐含节点、激活函数为 $g(x)$ 的极限学习机的数学模型可以表示为:

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + b_i) = O_j \quad j=1, 2, \dots, N \quad (13)$$

其中, $\mathbf{W}_i = [w_{i1}, w_{i2}, \dots, w_{i(2m+2)}]^T$ 为第 i 个隐含层节点与输入节点之间的权重向量; β_i 为第 i 个隐含层节点与输出节点之间的权重; b_i 为第 i 个隐含层节点的偏置; O_j 为极限学习机输出结果; “ \cdot ” 表示矩阵的内积。

极限学习机学习的目标是在最小的误差下逼近 N 个样本, 即存在 $\beta_i, \mathbf{W}_i, b_i$ 使得:

$$\sum_{i=1}^L \beta_i g(\mathbf{W}_i \cdot \mathbf{X}_j + b_i) = U_j \quad j=1, 2, \dots, N \quad (14)$$

式(14)利用矩阵可表示为:

$$\mathbf{H}\boldsymbol{\beta} = \mathbf{U} \quad (15)$$

其中, \mathbf{H} 为隐含层输出矩阵; $\boldsymbol{\beta}$ 为输出权重矩阵; \mathbf{U} 为期望输出矩阵。

$$\mathbf{H}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_L, b_1, b_2, \dots, b_L, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N) = \begin{bmatrix} g(\mathbf{w}_1 \cdot \mathbf{x}_1 + b_1) & g(\mathbf{w}_2 \cdot \mathbf{x}_1 + b_2) & \dots & g(\mathbf{w}_L \cdot \mathbf{x}_1 + b_L) \\ g(\mathbf{w}_1 \cdot \mathbf{x}_2 + b_1) & g(\mathbf{w}_2 \cdot \mathbf{x}_2 + b_2) & \dots & g(\mathbf{w}_L \cdot \mathbf{x}_2 + b_L) \\ \vdots & \vdots & \ddots & \vdots \\ g(\mathbf{w}_1 \cdot \mathbf{x}_N + b_1) & g(\mathbf{w}_2 \cdot \mathbf{x}_N + b_2) & \dots & g(\mathbf{w}_L \cdot \mathbf{x}_N + b_L) \end{bmatrix}_{N \times L} \quad (16)$$

$$\boldsymbol{\beta} = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_L \end{bmatrix}, \quad \mathbf{U} = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_N \end{bmatrix} \quad (17)$$

极限学习机算法中, 一旦输入权重和隐含层的偏置被随机确定, 输出矩阵就被唯一确定, 输出权值可以利用最小二乘法来获得, 解为:

$$\boldsymbol{\beta} = \mathbf{H}^+ \mathbf{U} \quad (18)$$

其中, \mathbf{H}^+ 为隐含层输出矩阵 \mathbf{H} 的 Moore-Penrose 广义逆。

3.2 学习模型建立流程

基于上述分析, 利用极限学习机模型建立人工智能辅助决策模型的具体流程如下: 收集并积累各光伏有功出力 P_{PV} 、无功出力 Q_{PV} 、总负荷有功 P_L 、无

功 Q_L 和母线电压 U ; 对数据进行归一化处理; 设置极限学习机隐含层数目; 经多次训练得到隐含层节点个数不同的网络模型, 每次训练随机生成权重向量 \mathbf{W}_i 和偏置 b_i , 计算隐含层节点输出 \mathbf{H} 和权重向量 $\boldsymbol{\beta}$; 使用测试样本检测各个模型的均方根误差, 记录不同模型中均方根误差, 采用满足要求且均方根误差最小为人工智能辅助决策模型。

当配电网运行时, 记录所对应的网络拓扑和参数, 通过系统一段时间的运行和数据积累, 利用上述人工智能辅助决策模型建立方法, 针对配电网 1—3 月、4—6 月、7—9 月和 10—12 月的运行数据建立 4 类辅助决策模型; 针对晴天、阴天、雨雪天气建立 3 类辅助决策模型; 针对配电网不同拓扑建立多类辅助决策模型, 形成包含不同运行参数和网络拓扑的辅助决策模型库。

4 含辅助决策的配电网分布式光伏调控流程

当配电网母线电压波动时, 首先, 利用粗略计算模型计算光伏出力粗略调控量; 然后, 为提高实时性, 根据当前系统的网络拓扑和运行参数, 直接从决策模型库中选取最匹配的辅助决策模型, 基于该模型建立母线电压与分布式光伏出力的关联关系, 将粗略调控量作为初始值, 对光伏调控量进行快速修正; 最后, 优化后的调控指令由集中控制器同步下发给各台分布式光伏, 以实现配电网电压的全局优化。

综上, 人工智能辅助决策的配电网分布式光伏调控的总流程如图 4 所示。

需要说明的是, 因为存在通信环节, 数据采集和控制指令延迟不可避免, 特别是目前配电网自动化尚未实现光纤全覆盖。当发生电压严重越限等故障类事件时还需首先依靠快速无功设备, 如电容器、电抗器、静态无功发生器、光伏逆变器等本地控制以保障电压安全, 然后由集中调控实现电压的全局二次优化。

5 算例分析

5.1 系统参数

本文基于 IEEE 33 节点的拓扑结构, 设计如图 5 所示含多台分布式光伏的有源配电网系统。图中, 2 号节点为平衡节点, 分别在 2、24、7、28 号节点处接入可控的分布式光伏 PV₁—PV₄, 接入容量分别为 1 000、500、500、300 kV·A, 功率因数限制为 0.95; 分别在 5、12、14、15、20、22、31 号节点接入不可控的分布式光伏。

本文算例以配电网正常运行情况为背景, 配电网正常运行情况下母线电压的上、下限分别设为 $U_{\max} = 1.045$ p.u.、 $U_{\min} = 0.955$ p.u., 参考电压 U_{ref} 设为

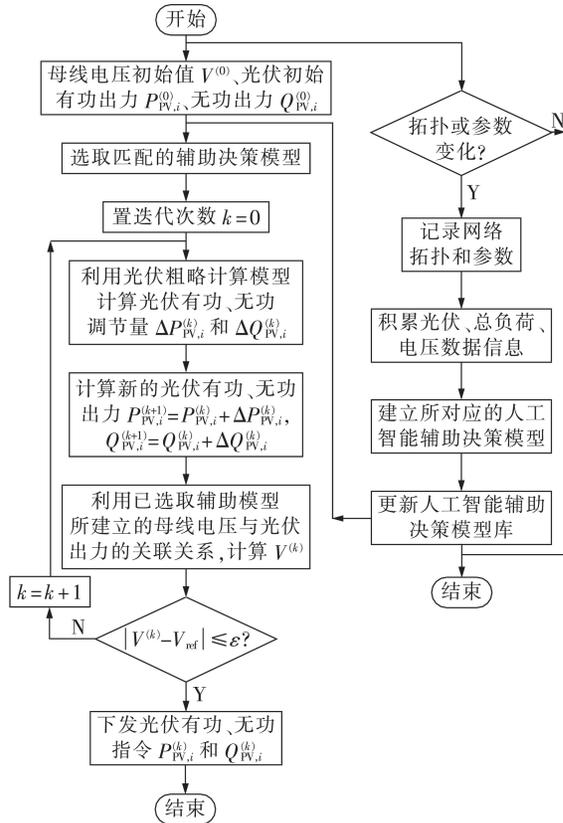


图 4 配电网分布式光伏调控流程图

Fig.4 Flowchart of optimal distributed PV control in distribution network

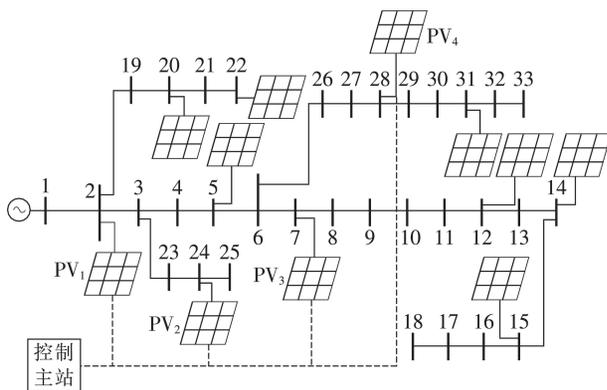


图 5 改进的 IEEE 33 节点仿真系统结构

Fig.5 Structure of modified IEEE 33-bus simulation system

1.03 p.u.。详细的线路参数见附录 A。

5.2 近似灵敏度计算与极限学习机学习结果分析

根据 2.2 节中近似电压灵敏度计算方法,可以得到系统中可控分布式光伏 PV₁—PV₄的有功对母线电压的近似灵敏度值分别为 7.09×10⁻⁵、5.29×10⁻⁵、5.15×10⁻⁵、5.32×10⁻⁵ p.u./kW,无功对母线电压的近似灵敏度值分别为 7.08×10⁻⁵、7.21×10⁻⁵、7.13×10⁻⁵、7.26×10⁻⁵ p.u./kvar。可见,PV₁的有功-电压灵敏度较其他 3 个有功-电压灵敏度值偏大。

不同天气状况下对不同负荷日分别进行仿真,

得到并选取 800 组样本,每个样本数据包包含 10 个输入值(4 台可控光伏的有功、无功出力和总负荷的有功、无功)、1 个输出值(母线电压)。对 800 组样本全部进行标注,抽取其中的 720 组样本作为训练数据,建立含多个不同隐含层节点数目的极限学习神经网络模型,剩下的 80 组数据作为测试样本进行测试,通过计算均方根误差(RMSE)检验和比较各个模型的准确性。

令隐含层节点数目 L 从 5 到 100 递增,分别计算不同 L 值下测试样本的均方根误差,选取部分计算结果如表 1 所示。

表 1 不同隐含层节点时均方根误差
Table 1 RMSE of different numbers of hidden layer nodes

隐含层节点数	均方根误差	隐含层节点数	均方根误差
25	0.03597	28	0.04199
26	0.02301	29	0.03260
27	0.04142	30	0.03362

结果表明当隐含层节点数目 L=26 时,均方根误差最小,为 0.023 01。因此,以 26 为隐含层节点数目,建立适用于图 5 所示的拓扑和参数的极限学习神经网络,作为人工辅助决策模型,该极限学习神经网络的权重系数和偏置见附录 B。

5.3 调控结果分析

为验证所提方法的有效性,以光伏出力波动和负荷变化模拟配电网运行状态的变化,使得母线电压在不同程度上越限,比较 3 种不同控制策略(S₁—S₃)的调控效果。控制策略 S₁ 为本文提出的含辅助决策的调控方法,控制策略 S₂ 为不含辅助决策的调控方法,控制策略 S₃ 为无调控方法。

5.3.1 算例 1

该场景模拟天气转晴,各光伏有功出力增大,母线电压抬升但是没有越上限,3 种不同控制策略下的优化过程如图 6 所示。图中电压为标么值,后同。

图 6(a)为母线电压变化曲线图。t₁ 时刻,光伏出力增加,母线电压随之快速上升,至 t₂ 时刻,母线电压上升到 1.045 p.u.,触发配电网优化调控。在该场景中,由于可控光伏的无功容量充裕,策略 S₁ 和 S₂ 都只优化了光伏的无功出力。策略 S₂ 直接利用近似灵敏度计算光伏无功指令值,而策略 S₁ 利用粗略计算模型与辅助决策模型相互迭代 3 次得到无功指令值。具体光伏无功指令值如下:策略 S₁ 下 PV₁—PV₄ 无功出力指令值分别为 263.7、98.6、66.4、42.9 kvar,策略 S₂ 下 PV₁—PV₄ 无功出力指令值分别为 235.2、80.1、52.9、30.5 kvar。需要说明的是,策略 S₁ 与 S₂ 的产生指令时间在同一数量级。t₃ 时刻光伏调整其无功出力值,发出感性无功,因此母线电压开始下降,并于

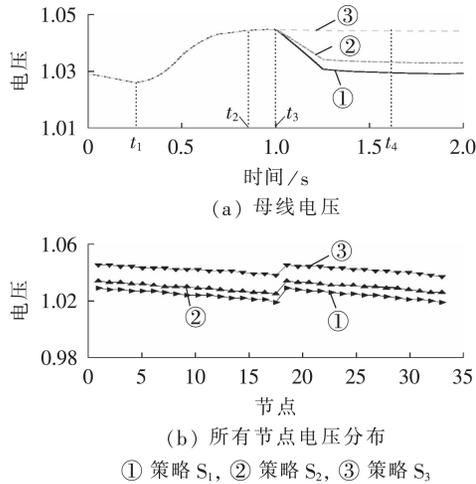


图6 算例1中不同控制策略下电压曲线

Fig.6 Voltage curves under different control strategies in Case 1

t_4 时刻稳定, S_1 和 S_2 这2种策略下母线电压分别调整至1.029 p.u.和1.034 p.u.。

选取图6(a)中的 t_4 时刻,配电网系统中所有节点在 S_1 — S_3 这3种策略下电压分布如图6(b)所示。可以看出,当电压波动较小时,只利用光伏的无功可以抑制电压的波动,其中策略 S_2 由于灵敏度值有误差,优化结果有偏差,但是策略 S_1 对无功调节量进行了修正,与策略 S_2 相比,调节结果更接近于参考值。

5.3.2 算例2

该场景模拟用户用电减少、负荷削减、电压波动较大且越上限,单一地调节光伏的无功无法满足优化要求,因此利用光伏的有功和无功协调进行电压优化。

策略 S_1 和 S_2 中,在无功调节能力不足的情况下,由于 PV_1 处的电压灵敏度值最大,为了降低调控成本,优先削减 PV_1 的有功出力。具体指令值如表2所示。策略 S_1 共迭代4次, PV_1 的有功、无功指令值分别为462.6 kW、152.7 kvar,策略 S_2 没有迭代过程, PV_1 有功、无功指令值分别为633.4 kW、209.0 kvar。

表2 算例2中不同策略下光伏有功、无功指令值

Table 2 Active and reactive power command value of PVs under different strategies in Case 2

调控策略	有功指令值/kW				无功指令值/kvar			
	PV_1	PV_2	PV_3	PV_4	PV_1	PV_2	PV_3	PV_4
S_1	462.6	264.0	290.0	182.0	152.7	87.1	95.7	60.1
S_2	633.4	264.0	290.0	182.0	209.0	87.1	95.7	60.1

母线电压在3种调控方法下的变化如图7(a)所示。与算例1中母线电压变化过程相类似, t_1 时刻,母线电压由于负荷削减开始上升; t_2 时刻,母线电压上升到最高值1.068 p.u.,越电压上限1.05 p.u.,触发配电网分布式光伏调控策略; t_3 时刻,按照表2所计算得到的优化指令值,分别对光伏有功出力进行削

减、对光伏无功出力进行调整,因此母线电压开始下降,并于 t_4 时刻电压趋于稳定。从结果可以看出, S_1 和 S_2 这2种策略下,母线电压分别调整至1.031 p.u.和1.045 p.u.。

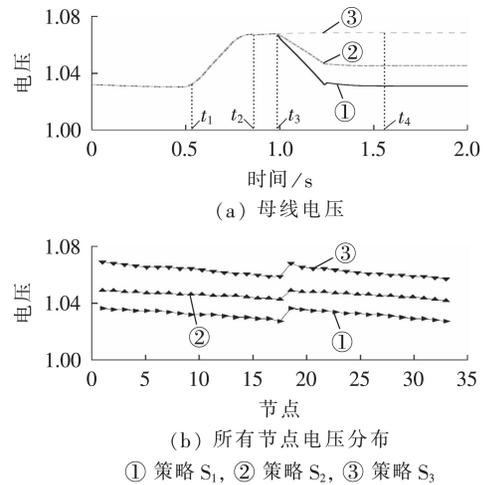


图7 算例2中不同控制策略下电压曲线

Fig.7 Voltage curves under different control strategies in Case 2

类似地,选取图7(a)所示的电压稳定时刻,即 t_4 时刻,得到3种策略下所有节点的电压分布如图7(b)所示。结果表明,利用光伏的有功和无功协调配合,整个配电网系统实现了安全运行,且相较于策略 S_2 ,因策略 S_1 修正了灵敏度不精确带来的误差,调节精度有所提高。

6 结论

本文针对调控过程中由于灵敏度不准确而导致的误差问题,提出了一种计及模型误差的分布式光伏配电网优化调控方法,其充分利用光伏的有功无功调节能力,有效应对配电网中电压波动的问题,并得到以下结论。

(1)将电网正常运行数据作为学习样本,具有数据规模大、积累快的优点;避免了将电网故障数据作为样本、样本积累慢、训练过程长的缺点,有利于人工智能在配电网优化运行中发挥作用。

(2)采用极限学习机算法随机产生输入权重和偏置,在训练过程中无需调整;优化隐含层节点个数,减少了学习误差。

(3)基于辅助决策模型,对采用常规优化方法得到的调度指令进行修正,提高了分布式光伏功率调度精度,电压调节效果更优。

需要说明的是,当配电网拓扑或参数发生变化后,需建立与之对应的辅助决策模型;而当配电网规模较大时,可能的拓扑组合和参数较多,一方面会导致决策模型数目变多,另一方面会导致匹配难度变大。如何在保证决策精度的前提下解决这一工程实际问题,将是笔者后续的研究方向。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 赵波,张雪松,洪博文. 大量分布式光伏电源接入智能配电网后的能量渗透率研究[J]. 电力自动化设备,2012,32(8):95-100.
ZHAO Bo,ZHANG Xuesong,HONG Bowen. Energy penetration of large-scale distributed photovoltaic sources integrated into smart distribution network[J]. Electric Power Automation Equipment,2012,32(8):95-100.
- [2] 魏昊焜,刘健,高慧. 分布式电源的本地电压控制策略[J]. 电力自动化设备,2016,36(9):40-45.
WEI Haokun,LIU Jian,GAO Hui. Local voltage control of distributed generations[J]. Electric Power Automation Equipment,2016,36(9):40-45.
- [3] GHOSH S,RAHMAN S,PIPATTANASOMPORN M. Distribution voltage regulation through active power curtailment with PV inverters and solar generation forecasts[J]. IEEE Transactions on Sustainable Energy,2016,8(1):13-22.
- [4] MEHRIZI-SANI A,IRAVANI R. Online set point modulation to enhance microgrid dynamic response:theoretical foundation [J]. IEEE Transactions on Power Systems,2012,27(4):2167-2174.
- [5] ZHANG B,LAM A Y S,DOMÍNGUEZ-GARCÍA A D, et al. An optimal and distributed method for voltage regulation in power distribution systems[J]. IEEE Transactions on Power Systems,2015,30(4):1714-1726.
- [6] BOLOGNANI S,CARLI R,CAVRARO G, et al. Distributed reactive power feedback control for voltage regulation and loss minimization[J]. IEEE Transactions on Automatic Control,2013,60(4):966-981.
- [7] 曾博,杨煦,张建华. 考虑可再生能源跨区域消纳的主动配电网多目标优化调度[J]. 电工技术学报,2016,31(22):148-158.
ZENG Bo,YANG Xu,ZHANG Jianhua. Multi-objective optimization for active distribution network scheduling considering renewable energy harvesting across regions[J]. Transactions of China Electrotechnical Society,2016,31(22):148-158.
- [8] VALVERDE G,CUTSEM T V. Model predictive control of voltages in active distribution networks[J]. IEEE Transactions on Smart Grid,2013,4(4):2152-2161.
- [9] 任佳依,顾伟,王勇,等. 基于模型预测控制的主动配电网多时间尺度有功无功协调调度[J]. 中国电机工程学报,2018,38(5):1397-1407.
REN Jiayi,GU Wei,WANG Yong, et al. Multi-time scale active and reactive power coordinated optimal dispatch in active distribution network based on model predictive control [J]. Proceedings of the CSEE,2018,38(5):1397-1407.
- [10] 胡伟,郑乐,闵勇,等. 基于深度学习的电力系统故障后暂态稳定评估研究[J]. 电网技术,2017,41(10):3140-3146.
HU Wei,ZHENG Le,MIN Yong, et al. Research on power system transient stability assessment based on deep learning of big data technique[J]. Power System Technology,2017,41(10):3140-3146.
- [11] 李亚,刘丽平,李柏青,等. 基于改进K-Means聚类和BP神经网络的台区线损率计算方法[J]. 中国电机工程学报,2016,36(17):4543-4551.
LI Ya,LIU Liping,YANG Baiqing, et al. Calculation of line loss rate in transformer district based on improved K-Means clustering algorithm and BP neural network[J]. Proceedings of the CSEE,2016,36(17):4543-4551.
- [12] 刘文轩,严凤,田霖,等. 基于LVQ神经网络的配电网故障定位方法[J]. 电力系统保护与控制,2012,40(5):90-95.
LIU Wenxuan,YAN Feng,TIAN Lin, et al. LVQ neural network approach for fault location of distribution network[J]. Power System Protection and Control,2012,40(5):90-95.
- [13] 王保义,赵硕,张少敏. 基于云计算和极限学习机的分布式电力负荷预测算法[J]. 电网技术,2014,38(2):526-531.
WANG Baoyi,ZHAO Shuo,ZHANG Shaomin. A distributed load forecasting algorithm based on cloud computing and extreme learning machine[J]. Power System Technology,2014,38(2):526-531.
- [14] QUAN H,SRINIVASAN D,KHOSRAVI A. Incorporating wind power forecast uncertainties into stochastic unit commitment using neural network-based prediction intervals[J]. IEEE Transactions on Neural Networks & Learning Systems,2015,26(9):2123-2135.
- [15] 李晓利,高金峰. 用于配电网多目标无功优化的改进粒子群优化算法[J]. 电力自动化设备,2019,39(1):106-111.
LI Xiaoli,GAO Jinfeng. Improved particle swarm optimization algorithm for multi-objective reactive power optimization of distribution network[J]. Electric Power Automation Equipment,2019,39(1):106-111.
- [16] ELOBAD L M,ABDELSALAM A K,ZAKZOUK E E. Artificial neural network-based photovoltaic maximum power point tracking techniques: a survey[J]. IET Renewable Power Generation,2015,9(8):1043-1063.
- [17] YONA A,SENJYU T,FUNABASHI T, et al. Determination method of insolation prediction with fuzzy and applying neural network for long-term ahead PV power output correction[J]. IEEE Transactions on Sustainable Energy,2013,4(2):527-533.
- [18] 邓长虹,马庆,肖永,等. 基于自学习迁移粒子群算法及高斯罚函数的无功优化方法[J]. 电网技术,2014,38(12):3341-3346.
DENG Changhong,MA Qing,XIAO Yong, et al. Reactive power optimization based on self-learning migration particle swarm optimization and gaussian penalty function[J]. Power System Technology,2014,38(12):3341-3346.
- [19] 王继东,冉冉,宋智林. 基于改进深度受限玻尔兹曼机算法的光伏发电短期功率概率预测[J]. 电力自动化设备,2018,38(5):43-49.
WANG Jidong,RAN Ran,SONG Zhilin. Probability forecast of short-term photovoltaic power generation based on improved depth restricted Boltzmann machine algorithm[J]. Electric Power Automation Equipment,2018,38(5):43-49.
- [20] SAYADI F,ESMAEILI S,KEYNIA F. Two-layer volt / var / total harmonic distortion control in distribution network based on PVs output and load forecast errors[J]. IET Generation Transmission & Distribution,2017,11(8):2130-2137
- [21] HUANG G B,ZHU Q Y,SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing,2006,70(1):489-501.

作者简介:



窦晓波

窦晓波(1979—),男,江苏南京人,教授,博士,主要研究方向为分布式电源(储能)变流器优化控制、分布式电源高渗透配电网、分布式发电与微电网(**E-mail**: dxb_2001@sina.com);

蔡超(1985—),男,江苏南京人,工程师,博士,主要研究方向为电力系统继电保护(**E-mail**: caichao@outlook.com);

段向梅(1994—),女,江苏连云港人,硕士研究生,主要研究方向为分布式电源高渗透配电网优化(**E-mail**: 220162198@seu.edu.cn)。

(编辑 李玮)

Optimal control method of distributed PV considering model errors in distribution network

DOU Xiaobo¹, CAI Chao², DUAN Xiangmei¹, HAN Jun², LIU Zhihan¹, CHEN Xi²

(1. School of Electrical Engineering, Southeast University, Nanjing 210096, China;

2. State Grid Economic Research Institute of China Electric Power Research Institute, Nanjing 210009, China)

Abstract: At present, the information collection is incomplete and the on-line accurate grid model is inaccessible in distribution network, which leads to error of distributed PV (PhotoVoltaic) control and makes it difficult to meet the requirement of the safe operation for distribution network. Thus, an optimal control method of distributed PV considering model errors in distribution network is proposed. A rough calculation model of PV control based on approximate sensitivity is built. Meanwhile, the artificial intelligence assistant decision model is established adopting ELM (Extreme Learning Machine) method as a modification of the rough calculation model for PV control. Based on the above two models, the optimal control strategy of distributed PV considering model errors in distribution network is designed. Finally, the simulative results show that the proposed control method makes up the errors caused by the optimization only relying on grid model, and improves the accuracy of the optimal control.

Key words: distributed PV; distribution network; optimal control; approximate sensitivity; ELM; assistant decision

~~~~~  
(上接第6页 continued from page 6)

## Description and application of SSOA of neutral-point-clamped three-level converter

TU Chunming, LONG Liu, XIAO Biao, YU Xueping, CHAI Ming

(National Electric Power Conversion Control Engineering Technology Research Center,  
Hunan University, Changsha 410082, China)

**Abstract:** In order to improve the reliability of the neutral-point-clamped three-level converter, based on the safe operating area of device, the mathematical model of the SSOA (Systematic Safe Operating Area) of converter is deduced with considering the converter topology, the stray parameters of DC bus, the delay of the control system, the temperature and other factors. The influence of junction temperature and wind speed on the SSOA boundary is analyzed quantitatively, and the corresponding three-dimensional graphics of the SSOA are depicted respectively. The proposed method is applied to the protection design of 55 kW/380 V converter prototype, and the experimental results validate the effectiveness of the protection boundary set based on SSOA, which show that the SSOA can guarantee the reliable and stable operation of the converter and improve the sustainable operation ability of the converter.

**Key words:** neutral-point-clamped three-level converter; SSOA; mathematical models; junction temperature; wind speed; protection design

## 附录

### 附录 A

表 A1 线路参数

Table A1 Line parameters

| 始端节点 | 末端节点 | 等效电阻/ $\Omega$ | 等效电抗/ $\Omega$ | 始端节点 | 末端节点 | 等效电阻/ $\Omega$ | 等效电抗/ $\Omega$ |
|------|------|----------------|----------------|------|------|----------------|----------------|
| 1    | 2    | 0.493          | 0.2511         | 1    | 18   | 0.164          | 0.1565         |
| 2    | 3    | 0.366          | 0.1864         | 18   | 19   | 1.5042         | 1.3554         |
| 3    | 4    | 0.3811         | 0.1941         | 19   | 20   | 0.4095         | 0.4784         |
| 4    | 5    | 0.819          | 0.707          | 20   | 21   | 0.7089         | 0.9373         |
| 5    | 6    | 0.1872         | 0.6188         | 2    | 22   | 0.4512         | 0.3083         |
| 6    | 7    | 0.7114         | 0.2351         | 22   | 23   | 0.898          | 0.7091         |
| 7    | 8    | 1.03           | 0.74           | 23   | 24   | 0.896          | 0.7011         |
| 8    | 9    | 1.044          | 0.74           | 5    | 25   | 0.203          | 0.1034         |
| 9    | 10   | 0.1966         | 0.065          | 25   | 26   | 0.2842         | 0.1447         |
| 10   | 11   | 0.3744         | 0.1238         | 26   | 27   | 1.059          | 0.9337         |
| 11   | 12   | 1.468          | 1.155          | 27   | 28   | 0.8042         | 0.7006         |
| 12   | 13   | 0.5416         | 0.7129         | 28   | 29   | 0.5075         | 0.2585         |
| 13   | 14   | 0.591          | 0.526          | 29   | 30   | 0.9744         | 0.963          |
| 14   | 15   | 0.7463         | 0.545          | 30   | 31   | 0.3105         | 0.3619         |
| 15   | 16   | 1.289          | 1.721          | 31   | 32   | 0.3410         | 0.5362         |
| 16   | 17   | 0.372          | 0.574          |      |      |                |                |

### 附录 B

表 B1 隐含层偏置

Table B1 Bias of hidden neurons

| 节点 | 偏置                 | 节点 | 偏置                  |
|----|--------------------|----|---------------------|
| 1  | 0.714493696747410  | 14 | 0.237265992309270   |
| 2  | 0.801286062819921  | 15 | 0.546406632909462   |
| 3  | 0.257381431356295  | 16 | 0.799961792146336   |
| 4  | 0.226659403208819  | 17 | 0.902224699942504   |
| 5  | 0.263407457352751  | 18 | 0.871056585576793   |
| 6  | 0.710706011390183  | 19 | 0.597997272635442   |
| 7  | 0.842281058697062  | 20 | 0.313659251399834   |
| 8  | 0.122640133552490  | 21 | 0.0470571986325830  |
| 9  | 0.705039199849024  | 22 | 0.410139689928166   |
| 10 | 0.155292774750495  | 23 | 0.125245111496103   |
| 11 | 0.708213866238071  | 24 | 0.181489507933420   |
| 12 | 0.0379486490329606 | 25 | 0.821087178657175   |
| 13 | 0.898506046863483  | 26 | 0.00325540978697914 |

表 B2 输入层权重  
Table B2 Input weights

| 输入层<br>隐藏层 | 1       | 2       | 3       | 4       | 5       | 6       | 7       | 8       | 9       | 10      |
|------------|---------|---------|---------|---------|---------|---------|---------|---------|---------|---------|
| 1          | 0.5102  | 0.2027  | -0.4298 | -0.7568 | 0.6293  | -0.4786 | -0.8948 | 0.7564  | 0.8894  | -0.4873 |
| 2          | 0.3911  | -0.5340 | -0.2126 | -0.5298 | 0.6231  | -0.8697 | -0.0002 | -0.3394 | 0.4038  | 0.0408  |
| 3          | -0.5211 | -0.3711 | 0.4759  | -0.9117 | 0.4262  | 0.2116  | 0.6336  | 0.6323  | -0.6034 | -0.5431 |
| 4          | -0.1460 | 0.8157  | 0.1605  | 0.9068  | 0.8945  | -0.3514 | 0.7125  | 0.8426  | -0.9771 | 0.6604  |
| 5          | 0.1701  | 0.0540  | -0.9187 | 0.4639  | 0.5240  | -0.5462 | 0.5826  | -0.9126 | 0.8405  | 0.7244  |
| 6          | -0.1011 | 0.6156  | -0.9127 | -0.0799 | 0.3003  | -0.2160 | 0.5187  | 0.4454  | -0.0061 | 0.1508  |
| 7          | -0.3023 | 0.1670  | -0.7617 | 0.0891  | 0.1611  | 0.3212  | -0.5771 | 0.9724  | -0.5299 | 0.9229  |
| 8          | 0.6725  | -0.3212 | 0.7620  | 0.4444  | -0.4239 | -0.9105 | 0.6697  | -0.3411 | -0.5513 | -0.2053 |
| 9          | 0.6697  | -0.8893 | -0.5500 | -0.9429 | -0.9232 | 0.0428  | 0.7020  | -0.1643 | 0.5440  | 0.7582  |
| 10         | 0.8560  | -0.7196 | 0.7841  | -0.9727 | -0.7184 | -0.9333 | -0.5829 | 0.8099  | -0.1610 | -0.9270 |
| 11         | -0.0043 | 0.4437  | 0.5683  | 0.4836  | -0.0826 | -0.9155 | 0.3398  | -0.0804 | 0.5423  | -0.3932 |
| 12         | 0.3995  | 0.5067  | 0.4720  | -0.3326 | -0.6469 | 0.0153  | 0.8301  | -0.9098 | -0.5013 | -0.2680 |
| 13         | -0.5300 | 0.3326  | -0.8420 | -0.6967 | -0.3491 | 0.4076  | -0.2556 | -0.4444 | 0.5961  | -0.7998 |
| 14         | -0.9082 | 0.1620  | -0.1714 | -0.5273 | -0.6356 | -0.0340 | -0.9080 | -0.0697 | -0.0685 | -0.7145 |
| 15         | -0.5189 | 0.4809  | 0.5776  | 0.1830  | 0.6540  | 0.4696  | -0.0711 | -0.2332 | -0.7834 | -0.7197 |
| 16         | -0.2114 | 0.5081  | 0.0717  | 0.6010  | 0.7031  | 0.8711  | 0.4062  | -0.3839 | 0.7026  | 0.8474  |
| 17         | -0.4538 | -0.4648 | 0.7978  | 0.2256  | -0.2677 | 0.8965  | 0.8622  | 0.1196  | 0.1155  | 0.5143  |
| 18         | -0.7677 | 0.8394  | -0.9773 | -0.2195 | -0.7651 | 0.2299  | -0.5629 | -0.8451 | 0.7632  | 0.6717  |
| 19         | -0.0273 | 0.5717  | -0.2280 | 0.1596  | -0.1434 | 0.8712  | -0.5143 | -0.3095 | -0.6762 | 0.4089  |
| 20         | 0.6084  | 0.9073  | -0.7714 | -0.9081 | 0.8413  | -0.0245 | -0.4634 | 0.9869  | 0.8347  | 0.4287  |
| 21         | 0.9366  | 0.6243  | 0.4516  | 0.0560  | 0.0011  | 0.1102  | -0.6382 | -0.2931 | 0.3335  | 0.9012  |
| 22         | -0.2126 | 0.0218  | 0.7487  | -0.9906 | -0.7334 | -0.4070 | -0.2016 | -0.0407 | -0.8061 | 0.2784  |
| 23         | -0.7377 | 0.4417  | 0.9269  | -0.2710 | -0.0855 | 0.6792  | -0.8095 | 0.0579  | -0.6680 | -0.6500 |
| 24         | 0.5426  | 0.5083  | -0.4041 | -0.4147 | 0.8459  | 0.0135  | -0.7139 | 0.7260  | -0.1251 | 0.7095  |
| 25         | -0.7605 | 0.2687  | -0.9612 | 0.6728  | 0.0845  | -0.2118 | 0.7595  | 0.0191  | 0.0809  | 0.3765  |
| 26         | 0.2453  | -0.6651 | -0.9592 | -0.6391 | 0.6962  | 0.3182  | -0.3059 | 0.8929  | 0.6126  | -0.4293 |

表 B3 输出层权重  
Table B3 Onput weights

| 节点 | 偏置                 | 节点 | 偏置                |
|----|--------------------|----|-------------------|
| 1  | -7.10582744072005  | 14 | -36.5175391506865 |
| 2  | -22.4918790278892  | 15 | 7.15577115173983  |
| 3  | -0.559862905430457 | 16 | -27.2709301534425 |
| 4  | 30.2557314070824   | 17 | 26.2026601741431  |
| 5  | -2.84869732037993  | 18 | 40.7268781852849  |
| 6  | -12.2135296471432  | 19 | -9.04421712200540 |
| 7  | -3.80411501842916  | 20 | 8.67053806158853  |
| 8  | 74.5087254952146   | 21 | 31.8275607364891  |
| 9  | 12.3523118345792   | 22 | -41.3604867333101 |
| 10 | 7.75062121074412   | 23 | 53.4395545835284  |
| 11 | -25.4029147243310  | 24 | -53.5156128597904 |
| 12 | -45.6308189908737  | 25 | -33.5720801067636 |
| 13 | 30.6293370807415   | 26 | 1.18793549806541  |