



(12) 发明专利

(10) 授权公告号 CN 118917481 B

(45) 授权公告日 2025. 04. 01

(21) 申请号 202411026428.3

(22) 申请日 2024.07.30

(65) 同一申请的已公布的文献号

申请公布号 CN 118917481 A

(43) 申请公布日 2024.11.08

(73) 专利权人 广东晶正科技有限公司

地址 510700 广东省广州市黄埔区开泰大道188号1601、1602房

(72) 发明人 夏振超 何建龙 曹晋华 张新宇
周庭军 朱和辰

(74) 专利代理机构 北京壹川鸣知识产权代理事务所(特殊普通合伙) 11765
专利代理师 杜安杰

(51) Int. Cl.

G06Q 10/04 (2023.01)

G06Q 10/0637 (2023.01)

G06Q 50/06 (2024.01)

G06F 30/27 (2020.01)

G06F 18/23213 (2023.01)

G06F 18/241 (2023.01)

G06N 3/043 (2023.01)

G06N 3/08 (2023.01)

G06N 3/006 (2023.01)

H02J 3/00 (2006.01)

(56) 对比文件

CN 103886223 A, 2014.06.25

CN 115829097 A, 2023.03.21

审查员 刘彩凤


权利要求书4页 说明书10页 附图2页

(54) 发明名称

一种光伏功率超短期预测系统与方法

(57) 摘要

本发明提供一种光伏功率超短期预测系统与方法,涉及技术光伏功率预测技术领域,本发明通过数据采集模块采集待预测光伏站所在地的历史环境时序数据和历史光伏功率时序数据,根据每块光伏板的最大平均发电功率,通过聚类算法对光伏板进行分类,模型构建模块构建基于模糊神经网络的光伏功率超短期预测模型,将采集的光伏所在区域的历史环境时序数据作为预测模型的输入,历史功率时序数据作为预测模型的输出,对光伏功率超短期预测模型进行训练,并通过模型优化模块对预测模型的中心值和宽度值进行全局寻优,通过气象预报获取未来时刻的环境数据,通过训练好的预测模型,获得未来时刻的光伏功率预测值。



1. 一种光伏功率超短期预测系统,其特征在于,具体步骤包括:

数据采集模块,所述数据采集模块用于采集待预测光伏站所在地的历史环境时序数据和历史光伏功率时序数据,根据在同一时刻下相同环境数据的光伏功率数据,统计每块光伏板多日的最大发电功率,并计算光伏板的平均最大发电功率,所述环境数据包括太阳辐射量、太阳高度角、温度值、湿度值和风速值,根据平均最大发电功率使用聚类算法对光伏板进行分类,选取其中一类为基准组,计算每组之间的发电率比;

模型构建模块,所述模型构建模块用于构建基于模糊神经网络的光伏功率超短期预测模型,将采集的光伏所在区域的历史环境时序数据作为预测模型的输入,历史功率时序数据作为预测模型的输出,对光伏功率超短期预测模型进行训练,通过气象预报获取未来时刻 t 时的环境数据,输入至训练好的光伏功率超短期预测模型的输入端,获得未来 t 时的光伏功率超短期的预测值;

模型优化模块,所述模型优化模块用于建立优化模型,通过构建优化模型,设置优化模型参数,对预测模型的中心值和宽度值进行全局寻优,并将预测模型的输出的误差函数构造造成适应度函数,根据适应度确定预测模型中心值和宽度值的最优值,提高模型预测精度;

功率预测模块,所述功率预测模块根据预测模型得到的基准组的光伏板未来时刻超短期预测功率,通过发电率比计算其他组光伏板的光伏发电超短期预测功率,根据所有的光伏分组以及每一组中光伏板的数量,计算整个光伏站的光伏超短期的预测功率;

所述基于模糊神经网络的光伏功率超短期预测模型由输入层、模糊层、计算层、输出层组成,具体逻辑为:

第一层为输入层,表示输入参数,此层有 k 个节点 $x_1, x_2, x_3, \dots, x_k$ 代表 k 个与光伏发电相关影响因素,公式为:

$$x_j = (x_1, x_2, x_3, \dots, x_k)$$

其中, x_j 为输入的光伏站所在的环境参数;

第二层为模糊化层,该层用高斯函数作为隶属度函数,计算输入变量 x_j 的隶属度,公式为:

$$u_{F_j^i} = \exp\left(-\frac{(x_j - m_{ji})^2}{\sigma_{ji}}\right)$$

其中, $u_{F_j^i}$ 为输入变量 x_j 的隶属度, m_{ji} 和 σ_{ji} 分别为模糊集 F_j^i 的中心值和宽度值, $j = 1, 2, 3, \dots, k, i = 1, 2, 3, \dots, n, n$ 为对输入进行模糊分级的个数;

第三层为模糊规则计算层,对模糊化后的参数进行规范化操作,公式为:

$$\omega^i = u_{F_j^1}(x_1) * u_{F_j^2}(x_2) * u_{F_j^k}(x_k)$$

其中, ω^i 为输入参数的隶属度连乘积;

第四层为输出层,该层完成中心平均反模糊化操作,输出结果,公式为:

$$y_i = \frac{\sum_{i=1}^n \omega^i (p_0^i + p_1^i x_1 + \dots + p_k^i x_k)}{\sum_{i=1}^n \omega^i}$$

其中, y_i 为功率输出值, p_k^i 为模糊系统参数;

所选取其中一类为基准组, 计算每组之间的发电率比的公式为:

$$\alpha_i = \frac{P_i}{P_{sta}}$$

其中, α_i 为第 i 组光伏板的发电率比, P_{sta} 基准组的最大功率, P_i 为聚类分组的第 i 组光伏板的最大功率;

根据预测模型得到的基准组光伏板超短期的预测功率, 通过发电率比计算其他组光伏板的光伏发电超短期预测功率的公式如下:

$$P_{i,pre,t} = \alpha_i * P_{sta,pre,t}$$

其中, α_i 为第 i 组光伏板的发电率比, $P_{i,pre,t}$ 第 i 组光伏板未来 t 时的预测功率, $P_{sta,pre,t}$ 为基准组光伏板未来 t 时的预测功率。

2. 根据权利要求1所述的一种光伏功率超短期预测系统, 其特征在于: 平均最大发电功率的计算公式为:

$$P = \frac{1}{d} \sum_{n=1}^{n=d} P_{n, \max.}$$

其中, P 为平均最大发电功率, $P_{n, \max.}$ 为第 n 天最大功率, d 为采集最大功率的天数。

3. 根据权利要求1所述的一种光伏功率超短期预测系统, 其特征在于: 通过聚类算法对光伏板进行分类的具体逻辑为:

将每一块光伏板的最大发电功率作为一个数据节点, 随机选择 K 个数据节点作为初始质心, K 表示聚类后类别的个数, K 为正整数, 其中第 i 个初始质心表示为: $C_i[P(i)]$, $P(i)$ 表示第 i 个作为初始质心的数据节点的最大功率, i 为正整数, 且 $i = 1, 2, \dots, K$;

将每一块光伏板的发电功率作为数据节点的特征向量, 对于每个光伏板的特征向量, 计算它到每个初始质心的距离, 并将其分配到最近的质心所代表的聚类, 计算到初始质心的距离所依据的公式为:

$$d(i, j) = \sqrt{[P(i) - P(j)]^2}$$

其中, $d(i, j)$ 表示第 i 个初始质心和第 j 个数据节点之间的距离, $P(j)$ 表示第 j 个数据节点对应的光伏板的最大功率;

对于每个聚类, 每次聚类完成后, 重新计算聚类内所有点的均值, 并将这个均值作为新的质心的特征数据, 第 i 个质心特征数据的更新公式为:

$$P(i)_{new} = \frac{1}{m} * \sum_{i=1}^m P(i)_{old}$$

其中, m 表示分配给第 i 个质心的数据节点的数量, $P(i)_{old}$ 表示分配给 i 个质心的数据节点对应的光伏板的最大功率, $P(i)_{new}$ 表示更新后的质心的最大功率;

依据更新后的质心的特征向量, 重新进行聚类, 直至所有质心位置的变化小于阈值, 则认为聚类稳定, 结束聚类。

4. 根据权利要求1所述的一种光伏功率超短期预测系统, 其特征在于: 所述构建优化模型基于麻雀搜索优化算法, 麻雀种群由发现者、加入者和一定数量的侦察者, 具体优化逻辑为:

发现者的位置更新公式如下:

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^t * \exp\left(\frac{-i}{\alpha * iter_{max}}\right) & R_2 < ST \\ X_{ij}^t + QL & R_2 \geq ST \end{cases}$$

其中, t 为当前迭代次数, j 为要优化的参数的维度, $j = 1, 2, \dots, d$, d 为被优化的参数的总数, X_{ij} 为第 i 个麻雀在第 j 维中的位置信息; $iter_{max}$ 为最大迭代次数; α 为随机数, $\alpha \in (0, 1)$, R_2 和 ST 为警报值和安全阈值; L 为 $1 \times d$ 维矩阵; Q 为符合正态分布的随机数;

加入者的位置更新公式如下:

$$X_{ij}^{t+1} = \begin{cases} Q * \exp\left(\frac{X_{worst}^t - X_{ij}^t}{i^2}\right) & i > \frac{ni}{2} \\ X_P^{t+1} + |X_{ij}^t - X_P^{t+1}| * A^T (A * A^T)^{-1} * L & i \leq \frac{ni}{2} \end{cases}$$

式中: X_P 为目前发现者的最优位置; X_{worst} 为目前全局最差位置; A 为 $1 \times d$ 的矩阵, 其元素被随机赋值1或-1, ni 为麻雀种群大小;

侦察者位置更新公式如下:

$$X_{ij}^{t+1} = \begin{cases} X_{best}^t + \beta |X_{ij}^t - X_{best}^t| & f_i > f_g \\ X_{ij}^t + K \left(\frac{|X_{ij}^t - X_{best}^t|}{(f_i - f_w) + \varepsilon} \right) & f_i = f_g \end{cases}$$

其中, X_{best} 为全局最优位置, β 为迭代步长, f_i 为当前麻雀个体的适应度值, f_g 和 f_w 为当前全局最优和最差适应度值, K 为一个随机数, $K \in [-1, 1]$, ε 为常数, 防止分母为0;

采用均方根误差来计算适应度, 其计算公式如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2}$$

其中, n 为样本个数, x_i 为光伏功率实际值, y_i 为光伏功率预测值。

5.根据权利要求1所述的一种光伏功率超短期预测系统,其特征在于:所述整个光伏站的光伏超短期的预测功率的计算公式如下:

$$P_{z,pre} = \sum_{i=1}^{i=k} P_{i,pre,t} * l_i$$

其中, $P_{z,pre}$ 为光伏站的超短期 t 时预测功率, $P_{i,pre,t}$ 第 i 组光伏板的超短期 t 时预测功率, l_i 第 i 组光伏板的数量, i 为第 i 组光伏板, k 为光伏板的组数, i 与 k 为正整数。

6.一种光伏功率超短期预测方法,其特征在于:所述光伏功率超短期预测方法由权利要求1-5任一项所述的光伏功率超短期预测系统执行,所述光伏功率超短期预测方法步骤包括:

步骤1:获取光伏站所在地的历史环境时序数据和历史光伏功率时序数据,并根据光伏板的最大光伏功率,通过聚类法对每个发电板进行分类,以其中一类为基准组,计算每组之间的发电率比;

步骤2:构建基于模糊神经网络的光伏功率超短期预测模型,将采集的光伏所在区域的历史环境时序数据作为预测模型的输入,历史功率时序数据作为预测模型的输出,对光伏功率超短期预测模型进行训练;

步骤3:建立优化模型,设置优化模型参数,对预测模型的中心值和宽度值进行全局寻优,并将预测模型的输出的误差函数构造成适应度函数,根据适应度确定预测模型中心值和宽度值的最优值;

步骤4:获取未来时刻 t 时的环境数据,输入至训练好的光伏功率超短期预测模型的输入端,获得未来 t 时的光伏功率超短期的预测值;

步骤5:根据预测模型得到的基准组的光伏板未来时刻超短期预测功率,通过发电率比计算其他组光伏板的光伏发电超短期预测功率,根据所有的光伏分组以及每一组中光伏板的数量,计算整个光伏站的光伏超短期的预测功率。

一种光伏功率超短期预测系统及方法

技术领域

[0001] 本发明涉及技术光伏功率预测技术领域,具体为一种光伏功率超短期预测系统及方法。

背景技术

[0002] 伴随着经济的快速发展,能源需求越来越大,光伏发电具有绿色环保、可再生等优点,世界范围内光伏发电这种新的能源利用方式呈现出稳步增长,但光伏发电系统功率输出受到多种因素的影响,呈现高度的波动性,特别是大规模光伏并网时,电力系统的安全运行和电能质量将受到极大影响,因此,光伏功率预测对电网规划和稳定运行具有重大意义。

[0003] 现有的技术中,对光伏功率超短期预测往往采用神经网络进行预测,即获取光伏电站所在地的气象数据,对神经网络模型进行训练,然后根据训练好的神经网络模型输入当前时刻的气象数据,获取光伏的功率数据,在或者通过对不同天气下的光伏功率进行预测,但是现有技术中使用的神经网络预测模型过于简单,缺乏对自身进行优化的能力。

[0004] 但是现有这些技术,都是基于整个光伏站进行预测,把光伏站的所有光伏板作为一个整体,但是每个光伏板都存在一定的差异,由于光伏站的光伏板众多,因此光伏板的差异也会进一步被放大,同时随着使用时间的增加,光伏板老化会进一步加剧光伏板之间的差异,因此现有的技术将对整体的光伏功率预测会产生一定的误差,因此,急需一种考虑光伏板之间的差异,且能对预测系统进行优化的光伏功率超短期预测系统。

[0005] 在所述背景技术部分公开的上述信息仅用于加强对本公开的背景的理解,因此它可以包括不构成对本领域普通技术人员已知的现有技术的信息。

发明内容

[0006] 本发明的目的在于提供一种光伏功率超短期预测系统及方法,以解决上述背景技术中提出的问题。

[0007] 为实现上述目的,本发明提供如下技术方案:

[0008] 一种光伏功率超短期预测系统及方法,具体步骤包括:

[0009] 数据采集模块,所述数据采集模块用于采集待预测光伏站所在地的历史环境时序数据和历史光伏功率时序数据,根据在同一时刻下相同环境数据的光伏功率数据,统计每块光伏板多日的最大发电功率,并计算光伏板的平均最大发电功率,所述环境数据包括太阳辐射量、太阳高度角、温度值、湿度值和风速值,根据平均最大发电功率使用聚类算法对光伏板进行分类,选取其中一类为基准组,计算每组之间的发电率比;

[0010] 模型构建模块,所述模型构建模块用于构建基于模糊神经网络的光伏功率超短期预测模型,将采集的光伏所在区域的历史环境时序数据作为预测模型的输入,历史功率时序数据作为预测模型的输出,对光伏功率超短期预测模型进行训练,通过气象预报获取未来时刻t时的环境数据,输入至训练好的光伏功率超短期预测模型的输入端,获得未来t时的光伏功率超短期的预测值;

[0011] 模型优化模块,所述模型优化模块用于建立优化模型,通过构建优化模型,设置优化模型参数,对预测模型的中心值和宽度值进行全局寻优,并将预测模型的输出的误差函数构造为适应度函数,根据适应度确定预测模型中心值和宽度值的最优值,提高模型预测精度;

[0012] 功率预测模块,所述功率预测模块根据预测模型得到的基准组的光伏板未来时刻超短期预测功率,通过发电率比计算其他组光伏板的光伏发电超短期预测功率,根据所有的光伏分组以及每一组中光伏板的数量,计算整个光伏站的光伏超短期的预测功率。

[0013] 本实施例中,平均最大发电功率的计算公式为:

$$[0014] \quad P = \frac{1}{d} \sum_{n=1}^{n=d} P_{n, \max},$$

[0015] 其中,P为平均最大发电功率, $P_{n, \max}$,为第n天最大功率,d为采集最大功率的天数。

[0016] 本实施例中,通过聚类算法对光伏板进行分类的具体逻辑为:

[0017] 将每一块光伏板的最大发电功率作为一个数据节点,随机选择K个数据节点作为初始质心,K表示聚类后类别的个数,K为正整数,其中第i个初始质心表示为: $C_i [P(i)]$, $P(i)$ 表示第i个作为初始质心的数据节点的最大功率,i为正整数,且 $i=1,2,\dots,K$;

[0018] 将每一块光伏板的发电功率作为数据节点的特征向量,对于每个光伏板的特征向量,计算它到每个初始质心的距离,并将其分配到最近的质心所代表的聚类,计算到初始质心的距离所依据的公式为:

$$[0019] \quad d(i,j) = \sqrt{[P(i) - P(j)]^2}$$

[0020] 其中, $d(i,j)$ 表示第i个初始质心和第j个数据节点之间的距离, $P(j)$ 表示第j个数据节点对应的光伏板的最大功率;

[0021] 对于每个聚类,每次聚类完成后,重新计算聚类内所有点的均值,并将这个均值作为新的质心的特征数据,第i个质心特征数据的更新公式为:

$$[0022] \quad P(i)_{\text{new}} = \frac{1}{m} * \sum_{i=1}^m P(i)_{\text{old}}$$

[0023] 其中,m表示分配给第i个质心的数据节点的数量, $P(i)_{\text{old}}$ 表示分配给i个质心的数据节点对应的光伏板的最大功率, $P(i)_{\text{new}}$ 表示更新后的质心的最大功率;

[0024] 依据更新后的质心的特征向量,重新进行聚类,直至所有质心位置的变化小于阈值,则认为聚类稳定,结束聚类。

[0025] 本实施例中,所选取其中一类为基准组,计算每组之间的发电率比的公式为:

$$[0026] \quad \alpha_i = \frac{P_i}{P_{\text{sta}}}$$

[0027] 其中, α_i 为第i组的发电率比, P_{sta} 基准组的最大功率, P_i 为聚类分组的第i组光伏板的最大功率。

[0028] 本实施例中,所述基于模糊神经网络的光伏功率超短期预测模型由输入层、模糊层、计算层、输出层组成,具体逻辑为:

[0029] 第一层为输入层,表示输入参数,此层有k个节点 $x_1, x_2, x_3, \dots, x_k$ 代表k个与光伏发

电相关影响因素,公式为:

$$[0030] \quad x_j = (x_1, x_2, x_3, \dots, x_k)$$

[0031] 其中, x_j 为输入的光伏站所在的环境参数;

[0032] 第二层为模糊化层,该层用高斯函数作为隶属度函数,计算输入变量 x_j 的隶属度,公式为:

$$[0033] \quad u_{F_j^i} = \exp\left(-\frac{(x_j - m_{ji})^2}{\sigma_{ji}}\right)$$

[0034] 其中, $u_{F_j^i}$ 为输入变量 x_j 的隶属度, m_{ji} 和 σ_{ji} 分别为模糊集 F_j^i 的中心值和宽度值, $j = 1, 2, 3, \dots, k, i = 1, 2, 3, \dots, n$, n 为对输入进行模糊分级的个数;

[0035] 第三层为模糊规则计算层,对模糊化后的参数进行规范化操作,公式为:

$$[0036] \quad \omega^i = u_{F_j^1}(x_1) * u_{F_j^2}(x_2) * u_{F_j^k}(x_k)$$

[0037] 其中, ω^i 为输入参数的隶属度连乘积;

[0038] 第四层为输出层,该层完成中心平均反模糊化操作,输出结果,公式为:

$$[0039] \quad y_i = \frac{\sum_{i=1}^n \omega^i (p_0^i + p_1^i x_1 + \dots + p_k^i x_k)}{\sum_{i=1}^n \omega^i}$$

[0040] 其中, y_i 为功率输出值, p_k^i 为模糊系统参数。

[0041] 本实施例中,所述构建优化模型基于麻雀搜索优化算法,麻雀种群由发现者、加入者和一定数量的侦察者,具体优化逻辑为:

[0042] 发现者的位置更新公式如下:

$$[0043] \quad X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t * \exp\left(\frac{-i}{\alpha * iter_{max}}\right) & R_2 < ST \\ X_{i,j}^t + QL & R_2 \geq ST \end{cases}$$

[0044] 其中, t 为当前迭代次数, j 为要优化的参数的维度, $j = 1, 2, \dots, d$, d 为被优化的参数的总数, $X_{i,j}^t$ 为第 i 个麻雀在第 j 维中的位置信息; $iter_{max}$ 为最大迭代次数; α 为随机数, $\alpha \in (0, 1)$, R_2 和 ST 为警报值和安全阈值; L 为 $1 \times d$ 维矩阵; Q 为符合正态分布的随机数;

[0045] 加入者的位置更新公式如下:

$$[0046] \quad X_{i,j}^{t+1} = \begin{cases} Q * \exp\left(\frac{X_{worst}^t - X_{i,j}^t}{i^2}\right) & i > \frac{ni}{2} \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| * A^T (A * A^T)^{-1} * L & i \leq \frac{ni}{2} \end{cases}$$

[0047] 式中: X_p 为目前发现者的最优位置; X_{worst} 为目前全局最差位置; A 为 $1 \times d$ 的矩阵,其元素被随机赋值1或-1, ni 为麻雀种群大小;

[0048] 侦察者位置更新公式如下:

$$[0049] \quad X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta |X_{i,j}^t - X_{best}^t| & f_i > f_g \\ X_{i,j}^t + K \left(\frac{|X_{i,j}^t - X_{best}^t|}{(f_i - f_w) + \varepsilon} \right) & f_i = f_g \end{cases}$$

[0050] 其中, x_{best} 为全局最优位置, β 为迭代步长, f_i 为当前麻雀个体的适应度值, f_g 和 f_w 为当前全局最优和最差适应度值, K 为一个随机数, $K \in [-1, 1]$, ε 为常数, 防止分母为 0;

[0051] 采用均方根误差来计算适应度, 其计算公式如下:

$$[0052] \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2}$$

[0053] 其中, n 为样本个数, x_i 为光伏功率实际值, y_i 为光伏功率预测值。

[0054] 本实施例中, 根据预测模型得到的基准组光伏板超短期的预测功率, 通过发电率比计算其他组光伏板的光伏发电超短期预测功率的公式如下:

$$[0055] \quad P_{i,pre,t} = \alpha_i * P_{sta,pre,t}$$

[0056] 其中, α_i 为第 i 组光伏板的发电率比, $P_{i,pre,t}$ 第 i 组光伏板未来 t 时的预测功率, $P_{sta,pre,t}$ 为基准组光伏板未来 t 时的预测功率。

[0057] 本实施例中, 所述整个光伏站的光伏超短期的预测功率的计算公式如下:

$$[0058] \quad P_{z,pre} = \sum_{i=1}^{i=k} P_{i,pre,t} * l_i$$

[0059] 其中, $P_{z,pre}$ 为光伏站的超短期 t 时预测功率, $P_{i,pre,t}$ 第 i 组光伏板的超短期 t 时预测功率, l_i 第 i 组光伏板的数量, i 为第 i 组光伏板, k 为光伏板的组数, i 与 k 为正整数。

[0060] 本发明另外还提供一种光伏功率超短期预测方法, 所述光伏功率超短期预测方法由上述的光伏功率超短期预测系统执行, 所述光伏功率超短期预测方法步骤包括:

[0061] 步骤1: 获取光伏站所在地的历史环境时序数据和历史光伏功率时序数据, 并根据光伏板的最大光伏功率, 通过聚类法对每个发电板进行分类, 以其中一类为基准组, 计算每组之间的发电率比;

[0062] 步骤2: 构建基于模糊神经网络的光伏功率超短期预测模型, 将采集的光伏所在区域的历史环境时序数据作为预测模型的输入, 历史功率时序数据作为预测模型的输出, 对光伏功率超短期预测模型进行训练;

[0063] 步骤3: 建立优化模型, 设置优化模型参数, 对预测模型的中心值和宽度值进行全局寻优, 并将预测模型的输出的误差函数构造成适应度函数, 根据适应度确定预测模型中心值和宽度值的最优值;

[0064] 步骤4: 获取未来时刻 t 时的环境数据, 输入至训练好的光伏功率超短期预测模型的输入端, 获得未来 t 时的光伏功率超短期的预测值;

[0065] 步骤5: 根据预测模型得到的基准组的光伏板未来时刻超短期预测功率, 通过发电率比计算其他组光伏板的光伏发电超短期预测功率, 根据所有的光伏分组以及每一组中光伏板的数量, 计算整个光伏站的光伏超短期的预测功率。

[0066] 与现有技术相比, 本发明的有益效果是:

[0067] 本发明通过数据采集模块采集待预测光伏站所在地的历史环境时序数据和历史光伏功率时序数据, 根据每块光伏板的最大平均发电功率, 通过聚类算法对光伏板进行分类, 模型构建模块构建基于模糊神经网络的光伏功率超短期预测模型, 将采集的光伏所在区域的历史环境时序数据作为预测模型的输入, 历史功率时序数据作为预测模型的输出,

对光伏功率超短期预测模型进行训练,并通过模型优化模块对预测模型的中心值和宽度值进行全局寻优,通过气象预报获取未来时刻的环境数据,输入至训练好的预测模型,获得未来时刻的光伏功率预测值,通过功率预测模块对整个光伏站的功率进行预测:

[0068] 本发明根据每块光伏板的最大功率,按照光伏板的老化特征对光伏板进行分组,计算每一组光伏板之间的发电效率差异,然后根据每一组的光伏板的数量,以及每一组的光伏板的发电功率,对该组的发电总功率进行预测,本发明还通过优化模型对光伏功率超短期预测模型进行优化,进一步提高光伏功率超短期预测的准确性。

附图说明

[0069] 图1为本发明整体系统结构示意图;

[0070] 图2为本发明整体方法流程示意图。

具体实施方式

[0071] 为使本发明的目的、技术方案和优点更加清楚明白,以下结合具体实施例,对本发明进一步详细说明。

[0072] 需要说明的是,除非另外定义,本发明使用的技术术语或者科学术语应当为本发明所属领域内具有一般技能的人士所理解的通常意义。本发明中使用的“第一”“第二”以及类似的词语并不表示任何顺序、数量或者重要性,而只是用来区分不同的组成部分。“包括”或者“包含”等类似的词语意指出现该词前面的元件或者物件涵盖出现在该词后面列举的元件或者物件及其等同,而不排除其他元件或者物件。“连接”或者“相连”等类似的词语并非限定于物理的或者机械的连接,而是可以包括电性的连接,不管是直接的还是间接的。“上”“下”“左”“右”等仅用于表示相对位置关系,当被描述对象的绝对位置改变后,则该相对位置关系也可能相应地改变。

[0073] 实施例:

[0074] 请参阅图1,本发明提供一种技术方案:

[0075] 一种光伏功率超短期预测系统,包括数据采集模块、模型构建模块、模型优化模块和功率预测模块,其中:

[0076] 所述数据采集模块用于采集待预测光伏站所在地的历史环境时序数据和历史光伏功率时序数据,根据在同一时刻下相同环境数据的光伏功率数据,统计每块光伏板多日的最大发电功率,并计算光伏板的平均最大发电功率,所述环境数据包括太阳辐射量、太阳高度角、温度值、湿度值和风速值,根据平均最大发电功率使用聚类算法对光伏板进行分类,选取其中一类为基准组,计算每组之间的发电率比。

[0077] 通过历史气象数据,分别获取光伏站所在地的太阳辐射量、太阳高度角、温度值、湿度值和风速值的历史环境时序数据,太阳辐射的强度直接决定了光伏板上单位面积内吸收到的能量,光伏板在接收到光子后,会将其转换为电子,并产生电流,因此,光伏板的发电效率与太阳辐射强度呈正相关关系,太阳高度角直接影响了太阳光线在太阳能板散布量,光伏板在高温下的光电转换效率会降低,这是因为光伏材料中的电子和空穴受热激活,使得电子难以从半导体材料中释放出来,从而降低了电流的产生,高湿度环境可能导致光伏板表面积聚灰尘或其他污染物,这些污染物或者灰尘会降低光的透过率,从而降低光伏板

的发电效率,适度的风速有助于光伏板的散热和清洁,从而在一定程度上提高其发电效率和长期稳定性。

[0078] 随着时间的推移,光伏板在使用过程中会受到多种因素的影响,包括环境条件、温度、湿度、光照强度的变化,以及光伏板内部材料的老化和退化,光伏板的效率会下降,这意味着在同样的光照条件下,光伏板能够转化成电能的比例可能会减少,效率的下降会导致在相同光照下产生的电流和电压可能不再是最优的组合,从而影响最大发电功率点的位置和最大发电功率值,因此光伏板的最大发电功率可以评估其老化特性和长期性能衰退的重要指标之一,能够反映光伏板在实际运行中的逐渐变化和损耗情况,通过聚类法对光伏板的最大发电功率进行分类,把最大发电功率相似的划分为一组,通过对不同组的光伏板进行光伏功率预测,极大地提高了功率预测的准确性。

[0079] 本实施例中,平均最大发电功率的计算公式为:

$$[0080] \quad P = \frac{1}{d} \sum_{n=1}^{n=d} P_{n, \max},$$

[0081] 其中,P为平均最大发电功率, $P_{n, \max}$,为第n天最大功率,d为采集最大功率的天数。

[0082] 本实施例中,通过聚类算法对光伏板进行分类的具体逻辑为:

[0083] 将每一块光伏板的最大发电功率作为一个数据节点,随机选择K个数据节点作为初始质心,K表示聚类后类别的个数,K为正整数,其中第i个初始质心表示为: $C_i [P(i)]$,P(i)表示第i个作为初始质心的数据节点的最大功率,i为正整数,且 $i=1,2,\dots,K$;

[0084] 将每一块光伏板的发电功率作为数据节点的特征向量,对于每个光伏板的特征向量,计算它到每个初始质心的距离,并将其分配到最近的质心所代表的聚类,计算到初始质心的距离所依据的公式为:

$$[0085] \quad d(i, j) = \sqrt{[P(i) - P(j)]^2}$$

[0086] 其中,d(i, j)表示第i个初始质心和第j个数据节点之间的距离,P(j)表示第j个数据节点对应的光伏板的最大功率;

[0087] 对于每个聚类,每次聚类完成后,重新计算聚类内所有点的均值,并将这个均值作为新的质心的特征数据,第i个质心特征数据的更新公式为:

$$[0088] \quad P(i)_{\text{new}} = \frac{1}{m} * \sum_{i=1}^m P(i)_{\text{old}}$$

[0089] 其中,m表示分配给第i个质心的数据节点的数量, $P(i)_{\text{old}}$ 表示分配给i个质心的数据节点对应的光伏板的最大功率, $P(i)_{\text{new}}$ 表示更新后的质心的最大功率;

[0090] 依据更新后的质心的特征向量,重新进行聚类,直至所有质心位置的变化小于阈值,则认为聚类稳定,结束聚类。

[0091] 本实施例中,所选取其中一类为基准组,计算每组之间的发电率比的公式为:

$$[0092] \quad \alpha_i = \frac{P_i}{P_{\text{sta}}}$$

[0093] 其中, α_i 为第i组的发电率比, P_{sta} 基准组的最大功率, P_i 为聚类分组的第i组光伏板的最大功率。

[0094] 所述模型构建模块用于构建基于模糊神经网络的光伏功率超短期预测模型,将采集的光伏所在区域的历史环境时序数据作为预测模型的输入,历史功率时序数据作为预测模型的输出,对光伏功率超短期预测模型进行训练,通过气象预报获取未来时刻t时的环境数据,输入至训练好的光伏功率超短期预测模型的输入端,获得未来t时的光伏功率超短期的预测值。

[0095] 模糊神经网络是一种结合了模糊逻辑与神经网络的混合型计算模型,它结合了模糊系统对于不确定性和模糊性的处理能力,以及神经网络对于复杂模式识别和数据建模的优势,从而能够处理一些传统方法难以处理的问题,光伏发电受天气条件、光照强度、太阳高度角度等多种因素影响,这些因素带有不确定性和模糊性,模糊神经网络能够有效地处理这些复杂的、模糊的输入数据,并输出相对准确的预测结果,这使得其在复杂系统预测中具有优势。

[0096] 本实施例中,所述基于模糊神经网络的光伏功率超短期预测模型由输入层、模糊层、计算层、输出层组成,具体逻辑为:

[0097] 第一层为输入层,表示输入参数,此层有k个节点 $x_1, x_2, x_3, \dots, x_k$ 代表k个与光伏发电相关影响因素,公式为:

$$[0098] \quad x_j = (x_1, x_2, x_3, \dots, x_k)$$

[0099] 其中, x_j 为输入的光伏站所在的环境参数;

[0100] 第二层为模糊化层,该层用高斯函数作为隶属度函数,计算输入变量 x_j 的隶属度,公式为:

$$[0101] \quad u_{F_j^i} = \exp\left(-\frac{(x_j - m_{ji})^2}{\sigma_{ji}}\right)$$

[0102] 其中, $u_{F_j^i}$ 为输入变量 x_j 的隶属度, m_{ji} 和 σ_{ji} 分别为模糊集 F_j^i 的中心值和宽度值, $j =$

[0103] $1, 2, 3, \dots, k, i = 1, 2, 3, \dots, n, n$ 为对输入进行模糊分级的个数;

[0104] 第三层为模糊规则计算层,对模糊化后的参数进行规范化操作,公式为:

$$[0105] \quad \omega^i = u_{F_j^1}(x_1) * u_{F_j^2}(x_2) * u_{F_j^k}(x_k)$$

[0106] 其中, ω^i 为输入参数的隶属度连乘积;

[0107] 第四层为输出层,该层完成中心平均反模糊化操作,输出结果,公式为:

$$[0108] \quad y_i = \frac{\sum_{i=1}^n \omega^i (p_0^i + p_1^i x_1 + \dots + p_k^i x_k)}{\sum_{i=1}^n \omega^i}$$

[0109] 其中, y_i 为光伏功率输出值, p_k^i 为模糊系统参数。

[0110] 所述模型优化模块用于建立优化模型,通过构建优化模型,设置优化模型参数,对预测模型的中心值和宽度值进行全局寻优,并将预测模型的输出的误差函数构造为适应度函数,根据适应度确定预测模型中心值和宽度值的最优值,提高模型预测精度。

[0111] 模糊神经网络的中心值和宽度的生成通常采用随机初始化的方法,生成初始值限定在一定范围内的随机数组,并通过误差反传算法修正中心值和宽度,然而,该方法存在较大的随机性,易导致模糊神经网络在训练参数时出现局部最优问题。通过麻雀搜索优化算

法模型对模糊神经网络中心值和宽度进行全局寻优,可以避免网络陷入局部最优问题,提高模型的预测精度。

[0112] 本实施例中,所述构建优化模型基于麻雀搜索优化算法,麻雀种群由发现者、加入者和一定数量的侦察者,具体优化逻辑为:

[0113] 发现者的位置更新公式如下:

$$[0114] \quad X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t * \exp\left(\frac{-i}{\alpha * iter_{max}}\right) & R_2 < ST \\ X_{i,j}^t + QL & R_2 \geq ST \end{cases}$$

[0115] 其中,t为当前迭代次数,j为要优化的参数的维度, $j=1,2,\dots,d$,d为被优化的参数的总数, $X_{i,j}$ 为第i个麻雀在第j维中的位置信息, $iter_{max}$ 为最大迭代次数, α 为随机数, $\alpha \in (0,1)$, R_2 和ST为警报值和安全阈值,L为 $1 \times d$ 维矩阵,Q为符合正态分布的随机数;

[0116] 加入者的位置更新公式如下:

$$[0117] \quad X_{i,j}^{t+1} = \begin{cases} Q * \exp\left(\frac{X_{worst}^t - X_{i,j}^t}{i^2}\right) & i > \frac{ni}{2} \\ X_P^{t+1} + |X_{i,j}^t - X_P^{t+1}| * A^T(A * A^T)^{-1} * L & i \leq \frac{ni}{2} \end{cases}$$

[0118] 式中: X_P 为目前发现者的最优位置; X_{worst} 为目前全局最差位置;A为 $1 \times d$ 的矩阵,其元素被随机赋值1或-1,ni为麻雀种群大小;

[0119] 侦察者位置更新公式如下:

$$[0120] \quad X_{i,j}^{t+1} = \begin{cases} X_{best}^t + \beta |X_{i,j}^t - X_{best}^t| & f_i > f_g \\ X_{i,j}^t + K \left(\frac{|X_{i,j}^t - X_{best}^t|}{(f_i - f_w) + \varepsilon} \right) & f_i = f_g \end{cases}$$

[0121] 其中, X_{best} 为全局最优位置, β 为迭代步长, f_i 为当前麻雀个体的适应度值, f_g 和 f_w 为当前全局最优和最差适应度值,K为一个随机数, $K \in [-1,1]$, ε 为常数,防止分母为0;

[0122] 采用均方根误差来计算优化模型的适应度,其计算公式如下:

$$[0123] \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2}$$

[0124] 其中,n为样本个数, x_i 为光伏功率实际值, y_i 为光伏功率预测值。

[0125] 适应度值反映了当前个体解决方案的质量或者性能表现,通常情况下,适应度值越高,表示个体解越优秀,离问题的最优解越接近,而适应度值越低,则表示个体解越差,需要进一步优化,计算过程中通过迭代优化过程,不断更新个体的中心值和宽度值,以使得适应度值逐步改善,最终达到问题的最优解或者接近最优解的状态。

[0126] 随机初始化一组麻雀个体,每个个体对应模糊神经网络中的中心值和宽度值数据集,根据当前的中心值和宽度值组合,根据模糊神经网络的适应度,评估模糊神经网络的预测准确性,并判断当前的中心值和宽度值是否最优,然后根据麻雀搜索优化算法的策略,更新每个麻雀个体的位置,重复进行评估和更新步骤,直到达到设定的最大迭代次数或者达到适应度阈值,在搜索过程中记录并保留全局最优的中心值和宽度值组合,作为模糊神经

网络的最佳参数设置。

[0127] 所述功率预测模块根据预测模型得到的基准组的光伏板未来时刻超短期预测功率,通过发电率比计算其他组光伏板的光伏发电超短期预测功率,根据所有的光伏分组以及每一组中光伏板的数量,计算整个光伏站的光伏超短期的预测功率。

[0128] 本实施例中,根据预测模型得到的基准组光伏板超短期的预测功率,通过发电率比计算其他组光伏板的光伏发电超短期预测功率的公式如下:

$$[0129] \quad P_{i,pre,t} = \alpha_i * P_{sta,pre,t}$$

[0130] 其中, α_i 为第 i 组光伏板的发电率比, $P_{i,pre,t}$ 第 i 组光伏板未来 t 时的预测功率, $P_{sta,pre,t}$ 为基准组光伏板未来 t 时的预测功率。

[0131] 本实施例中,所述整个光伏站的光伏超短期的预测功率的计算公式如下:

$$[0132] \quad P_{z,pre} = \sum_{i=1}^{i=k} P_{i,pre,t} * l_i$$

[0133] 其中, $P_{z,pre}$ 为光伏站的超短期 t 时预测功率, $P_{i,pre,t}$ 第 i 组光伏板的超短期 t 时预测功率, l_i 第 i 组光伏板的数量, i 为第 i 组光伏板, k 为光伏板的组数, i 与 k 为正整数。

[0134] 请参阅图2,本发明另外还提供一种光伏功率超短期预测方法,所述光伏功率超短期预测方法由上述的光伏功率超短期预测系统执行,所述光伏功率超短期预测方法步骤包括:

[0135] 步骤1:获取光伏站所在地的历史环境时序数据和历史光伏功率时序数据,并根据光伏板的最大光伏功率,通过聚类法对每个发电板进行分类,以其中一类为基准组,计算每组之间的发电率比;

[0136] 步骤2:构建基于模糊神经网络的光伏功率超短期预测模型,将采集的光伏所在区域的历史环境时序数据作为预测模型的输入,历史功率时序数据作为预测模型的输出,对光伏功率超短期预测模型进行训练;

[0137] 步骤3:建立优化模型,设置优化模型参数,对预测模型的中心值和宽度值进行全局寻优,并将预测模型的输出的误差函数构造成为适应度函数,根据适应度确定预测模型中心值和宽度值的最优值;

[0138] 步骤4:获取未来时刻 t 时的环境数据,输入至训练好的光伏功率超短期预测模型的输入端,获得未来 t 时的光伏功率超短期的预测值;

[0139] 步骤5:根据预测模型得到的基准组的光伏板未来时刻超短期预测功率,通过发电率比计算其他组光伏板的光伏发电超短期预测功率,根据所有的光伏分组以及每一组中光伏板的数量,计算整个光伏站的光伏超短期的预测功率。

[0140] 上述公式均是去量纲取其数值计算,公式是由采集大量数据进行软件模拟得到最近真实情况的一个公式,公式中的预设参数由本领域的技术人员根据实际情况进行设置。

[0141] 上述实施例,可以全部或部分地通过软件、硬件、固件或其他任意组合来实现。当使用软件实现时,上述实施例可以全部或部分地以计算机程序产品的形式实现。本领域技术人员可以意识到,结合本文中所公开的实施例描述的各示例的单元及算法步骤,能够通过电子硬件,或者计算机软件和电子硬件的结合来实现。这些功能究竟以硬件还是软件方法来执行,取决于技术方案的特定应用和设计约束条件。

[0142] 所述作为分离部件说明的单元可以是或者也可以不是物理上分开的,作为单元显示的部件可以是或者也可以不是物理单元,既可以位于一个地方,或者也可以分布到多个网络单元上。可以根据实际的需要选择其中的部分或者全部单元来实现本实施例方案的目的。

[0143] 以上所述,仅为本申请的具体实施方式,但本申请的保护范围并不局限于此,任何熟悉本技术领域的技术人员在本申请揭露的技术范围内,可轻易想到变化或替换,都应涵盖在本申请的保护范围之内。




图1




图2