



(12) 发明专利申请

(10) 申请公布号 CN 113964885 A

(43) 申请公布日 2022. 01. 21

(21) 申请号 202111015446.8

(22) 申请日 2021.08.31

(71) 申请人 国网山东省电力公司东营供电公司  
地址 257000 山东省东营市南一路357号

(72) 发明人 司君诚 王元元 孙名好 蔡言斌  
张双乐 刘航航 刘剑宁 王银忠  
苏小向 吕凤磊 张丹 任敬刚

(74) 专利代理机构 南京金宁专利代理事务所  
(普通合伙) 32479

代理人 林燕辉

(51) Int. Cl.

H02J 3/50 (2006.01)

H02J 3/18 (2006.01)

H02J 3/38 (2006.01)

H02J 3/00 (2006.01)

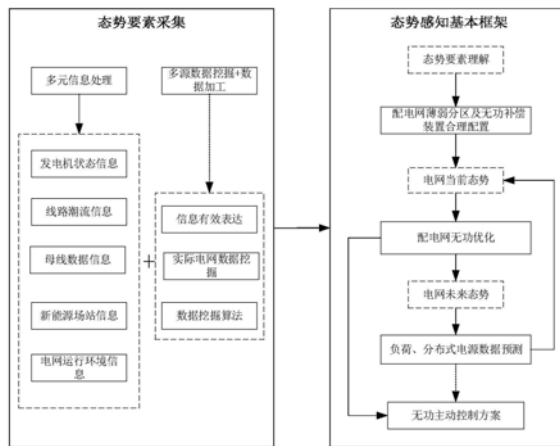
权利要求书7页 说明书16页 附图4页

(54) 发明名称

一种基于态势感知的电网无功主动预测及控制技术

(57) 摘要

本发明公布了一种基于态势感知的电网无功主动预测及控制技术,涉及配电网无功优化领域。步骤如下:(1)对电网运行数据进行态势要素采集;(2)根据态势要素对当前系统进行态势理解,对系统节点所量测得到的数据进行计算,得到节点的薄弱性量化指标,提出无功补偿薄弱区;(3)根据态势要素集,采用BLSTM对分布式电源、负荷进行预测,得到系统的未来态势;(4)态势管控阶段,基于无功补偿薄弱区和预测的特征数据,利用改进粒子群算法对建立的优化模型求解,得到无功配置方案。优点:将态势感知引入无功优化领域,通过态势感知框架得出系统未来态势下的无功控制方案,该过程形成一个闭环系统,提前干预的同时,能够降低网损和运行成本。



1. 一种基于态势感知的电网无功主动预测及控制技术,其特征在于,包括如下步骤:

(1) 态势要素采集阶段,获取电网稳态运行数据、暂态运行数据、电网故障数据和电力设备运行状态数据等。

(2) 态势理解阶段,根据态势要素对当前系统进行态势理解,对系统节点所量测得到的特征数据进行定量计算,得到节点的薄弱性量化指标,根据无功补偿薄弱节点,提出无功补偿薄弱区。

(3) 态势预测阶段,通过态势要素采集到的电网历史数据,采用多层双向的长短期记忆神经网络算法对分布式电源、负荷进行预测,得到未来态势下的系统状态。

(4) 未来态势管控阶段,利用改进粒子群算法对配电网进行无功优化,从而得到无功配置方案。

2. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于所述步骤(1)中的态势要素采集,由于广域测量系统和相量测量单元在电网的投入使用,可实时采集到电网稳态运行数据、暂态运行数据、电网故障数据和电力设备运行状态数据等。该阶段主要是为后面电网态势的理解与分析、以及预测做相对应的准备。根据配电系统分析和控制的需求合理配置量测,以获取所需要的数据。

3. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于所述步骤(2)中的态势要素理解,本发明中的态势理解主要是对当前系统无功补偿薄弱节点识别,统计和提取电网静态场景下各节点电压幅值与相角样本序列组成的集合 $Z_1 = \{(v_1, \theta_1), (v_2, \theta_2), \dots, (v_n, \theta_n)\}$ ,将该集合里每个节点的状态数据样本 $(v_i, \theta_i, i = 1, \dots, n)$ 作为网络中的节点,在电力系统正常运行的状态下,按某一特定比例增加母线上的负荷有功功率值,首先崩溃的节点为该配网中的最薄弱节点,增长方式采用扩展潮流方程:

$$f(\theta, V) + \lambda b = 0$$

其中 $\theta, V$ 分别为节点电压相角和电压幅值, $\lambda$ 为负荷和发电增长参数, $b$ 为系统各节点负荷增长方式常数。

可以将节点 $i$ 的负荷有功和无功注入功率以及发电机注入有功功率分解为两个部分,其中 $P_{Li0}, Q_{Li0}$ 代表初始负荷节点 $i$ 水平, $P_{Gi0}$ 代表发电机节点 $i$ 初始有功出力。另一部分对应由负荷参数 $\lambda$ 表示的负荷变化和有功出力变化,从而得到:

$$\begin{cases} P_{Gi} = P_{Li0} + \lambda b_{Gi}^P \\ P_{Li} = P_{Gi0} + \lambda b_{Li}^P \\ Q_{Li} = Q_{Gi0} + \lambda b_{Li}^Q \end{cases}$$

其中 $P_{Li}, Q_{Li}$ 分别为负荷节点 $i$ 的有功水平、无功水平, $P_{Gi}$ 为发电设备节点 $i$ 的有功出力, $b_{Li}^P, b_{Li}^Q$ 分别为负荷节点 $i$ 的有功增长方式、无功增长方式, $b_{Gi}^P$ 为发电设备节点 $i$ 的有功出力增长方式。按比例增加负荷后的各节点幅值与相角样本序列组成的集合 $Z_2 = \{(v_1, \theta_1), (v_2, \theta_2), \dots, (v_n, \theta_n)\}$ ,由 $Z_1$ 和 $Z_2$ 作为识别薄弱节点的样本集合。

4. 根据权利要求3所述的无功补偿薄弱节点识别,其特征在于,提出一种量化节点薄弱性的指标,通过定量的增加节点负荷,根据分析PV曲线得知,电压容易发生崩溃的节点既薄

弱节点,在增加负荷时,电压和相角变化较为敏感,本发明利用节点复电压变化率来衡量节点的薄弱性。复电压变化率在此定义为电压的变化率和相角的变化率的加权求和,在负荷有功达到最大值之前,当节点j的负荷增加一定比例的有功功率时,该节点复电压变化率(Voltage Change Rate)为VCR,计算如下所示:

$$VCR_j = \frac{V_j - V'_j}{V_j} + \frac{\theta_j - \theta'_j}{\theta_j} \quad (1)$$

其中, $V_j$ 表示正常运行时j节点处电压值, $V'_j$ 表示负荷按给定比例变化后的j节点处电压值。 $\theta_j$ 表示正常运行时j节点处电压相角值, $\theta'_j$ 表示负荷按给定比例变化后的j节点处电压相角值,由以上模型可知,节点的复电压薄弱指标越大,说明该节点的薄弱性越大。

5.根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于,所述步骤(2)中的无功补偿薄弱区的划分,根据无功装置的数量、节点空间位置、节点薄弱性指标三方面考虑,对配电网进行分区划分,将薄弱节点的概念扩展到薄弱区,每个薄弱区对应若干个节点,且提出一种薄弱区指标的概念,定义薄弱区指标为VCRS<sub>Q</sub>,计算如下所示:

$$VCRS_Q = \sum_{i \leq j \leq k} \frac{V_j - V'_j}{V_j} + \frac{\theta_j - \theta'_j}{\theta_j} \quad (2)$$

$$Q \leq N \quad (3)$$

其中,VCRS<sub>Q</sub>是第Q个薄弱区, $i \leq j \leq k$ 为薄弱区Q内的薄弱节点个数, $V_j$ 表示正常运行时j节点处电压值, $V'_j$ 表示负荷按给定比例变化后的j节点处电压值。 $\theta_j$ 表示正常运行时j节点处电压相角值, $\theta'_j$ 表示负荷按给定比例变化后的j节点处电压相角值,N为无功补偿装置组的个数,由以上模型可知,将配电网划分为不同的薄弱区,确保每个薄弱区都包含有无功补偿装置,薄弱分区指标越大,说明该薄弱分区的薄弱性越大。薄弱区的数量应少于无功补偿装置组的数量,根据薄弱区指标的大小进行排序,薄弱性较强的区域,安放补充能力强的无功设备,以此类推,在各区域放置无功设备,在每个薄弱区内部,各个节点的薄弱性指标也会有大小排序,所以装配无功补偿设备的时候优先考虑薄弱性较强的节点。

6.根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于,所述步骤(2)中的态势预测,态势预测部分主要分为两个模块,第一个模块主要是对分布式电源发电进行预测,第二个模块主要是对负荷进行预测。而主动配电网主要是接入了大量的分布式能源,其中对不可控分布式能源的预测对系统态势感知有较大的影响。主动配电网中间歇式能源主要包括光伏发电和风力发电。

在不考虑大气影响的条件下,光伏面板安装处的辐射照度为:

$$G = G_b \cdot \cos\theta \quad (4)$$

其中,G为光伏面板接收的总辐射照度,其单位为W/m<sup>2</sup>;G<sub>b</sub>为太阳直射照度,在真空中辐射到地球为定值;θ为太阳入射光线与光伏面板法线的夹角,一天中会随时间的变化而变化。

分布式光伏的有功出力与光伏面板接收的光照度与温度等天气条件有关,根据光伏电池的物理模型可得输出有功功率最大值的表达式:

$$\begin{aligned}
 P_{\max} &= U_M \cdot I_M & (a) \\
 U_M &= U_{OC} \cdot \left[ 1 - \frac{b}{U_{OC}} \ln a - r_s \cdot (1 - a^{-b}) \right] & (b) \\
 I_M &= I_{SC} \cdot (1 - a^{-b}) & (c) \\
 a &= u_{OC} + 1 - 2u_{OC} \cdot r_s & (d) \\
 b &= a / (1 + a) & (e)
 \end{aligned} \tag{5}$$

其中 $U_{OC}$ 为一定天气情况下的光伏开路电压, $I_{SC}$ 为一定天气情况下的光伏短路电流; $u_{OC}$ 为标准开路电压, $r_s$ 为标准串联电阻。在获取天气数据的情况下,可以根据相应表达式求得光伏最大的输出功率。

根据电路关系,可以通过(5)式推导出(6式)计算光伏发电最大功率:

$$P_{\max} = U_M \cdot I_M = a \cdot U_{OC} \cdot I_{SC} \quad (6)$$

其中 $a$ 是与光伏设备有关的参数, $U_{OC}$ 、 $I_{SC}$ 分别为特定天气条件的光伏模块开路电压与短路电流,根据(7)式计算。

$$\begin{cases}
 I_{SC}(G) = \frac{I_{SC}^R}{G^R} \cdot G_b \cdot \cos \theta \\
 U_{OC}(T) = U_{OC}^R + (T - T^R) \cdot k
 \end{cases} \tag{7}$$

其中: $G^R$ 为标准测试状态的辐射照度; $k$ 为光伏系统开路电压的温度系数; $T^R$ 为标准测试状态的温度; $T$ 为光伏系统在辐射照度 $G$ 下的运行温度。

从公式中可以看出,在不考虑大气因素影响的条件下,光伏发电功率的最大值在一天的变化中近似呈正弦函数变化。

在光伏实际发电中,会由于大气折射、云量、雨量等原因,造成发电量的波动。因此光伏发电量与不确定天气因素影响后的发电量会有较大波动,通过Pearson相关系数来计算相关性,如式(8):

$$R_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \tag{8}$$

通过计算可知,辐射照度、温度、湿度相关性较强,但是一般天气预报不会预测辐射照度,获取该数据的难度较大,考虑实际应用,本发明采用温度和湿度作为发电量预测的天气元素,样本的输入格式为

$$X_i = \{T_i, H_i, t_i, s_i\} \quad (9)$$

其中, $t$ 为样本采集日期, $s$ 为天气情况,一般分为0,1,-1;分别代表晴、多云、雨等。

风力发电机组的基本结构为风力机、双馈感应发电机以及变换器。风力机将风能转化成机械能传递给双馈感应发电机,发电机将机械能转化成幅值和频率变化的电能,风力机正常运行中,忽略尾流损失、轮毂损失以及叶尖损失,其可获得的最大功率为:

$$P_{WT.MAX} = \frac{1}{2} C_{P.MAX} \rho A v^3 \tag{10}$$

其中: $C_{P.MAX}$ 为功率系数最大值, $\rho$ 为空气密度, $A$ 为风机扇面面积, $v$ 为风速。从模型中可

以看出风力发电受影响最大的因素为风速。考虑实际应用,本发明采用风速作为发电量预测的天气元素,样本的输入格式为:

$$X_i = \{v_i, t_i, s_i\} \quad (11)$$

其中,  $t$  为样本采集日期,  $s$  为天气情况, 一般分为 0, 1, -1; 分别代表晴、多云、雨等。

针对负荷预测, 社会因素、天气因素对电力负荷都有较大的影响, 分析温度、天气状况、电价、社会发展等对负荷数据的影响程度, 给出具体的影响因素。在具体分析中采用斯皮尔曼相关系数如式 (8) 所示, 分析温度、湿度等气象因素与负荷的相关性, 结合传统负荷预测方法中的相关因素, 本发明的负荷的样本输入格式为:

$$X_i = \{t_i, P_i, T_i, H_i, s_i\} \quad (12)$$

其中,  $t_i$  为样本采集日期,  $P_i$  为有功负荷,  $T_i$  为该天的平均气温,  $H_i$  为该天的平均湿度,  $s_i$  为天气情况, 一般分为 0, 1, -1; 分别代表晴、多云、雨等。

7. 根据权利要求 6 所述的态势预测技术, 其特征在于, 预测方法的选取, LSTM 神经网络由 RNN 神经网络延伸而来, 解决了 RNN 结构上会出现的梯度爆炸与梯度消失的问题, LSTM 在预测中也因为其单向结构造成了误差累计的问题。分析 LSTM 神经网络负荷预测模型的结构与原理, 针对误差累计的问题, 给出了具体改进方法——BLSTM 神经网络。

首先采用 BLSTM 取代传统 LSTM 预测, BLSTM 是在 LSTM 的结构上增加一个反向的预测过程, 正、反相结合的 BLSTM 神经网络, 在理论上能尽可能保留负荷数据真实性。

预测模型每层 BLSTM 神经网络都是由正向的 LSTM 网络和反向的 LSTM 网络组成, 下一层网络的输入是由上一层正、反向 LSTM 的输出结果共同决定, 最后一层网络模型结果由每一层正、反向计算结果同时决定, 式子中  $s_t^{(i)}$ 、 $s_t^{\prime(i)}$  分别表示  $t-1$  时刻和  $t$  时刻第  $i$  个隐藏层的值, 由于正向计算和反向计算不共享权重, 其中, 正向计算时,  $V^{(i)}$ 、 $U^{(i)}$ 、 $W^{(i)}$  表示第  $i$  个隐藏层到输出层、输入层到隐藏层、隐藏层之间的权重矩阵, 反向计算时,  $V^{\prime(i)}$ 、 $U^{\prime(i)}$ 、 $W^{\prime(i)}$  表示相对应的反向权重矩阵。  $i$  表示 BLSTM 层数, 且  $i=0, 1, 2L\infty$ , 表示输出层的值, 预测模型如下:

$$\begin{cases} o_t = g(V^{(i)}s_t^{(i)} + V^{\prime(i)}s_t^{\prime(i)}) \\ s_t^{(i)} = f(U^{(i)}s_t^{(i-1)} + W^{(i)}s_{t-1}^{(i)}) \\ s_t^{\prime(i)} = f(U^{\prime(i)}s_t^{\prime(i-1)} + W^{\prime(i)}s_{t+1}^{\prime(i)}) \\ \dots\dots \\ s_t^{(1)} = f(U^{(1)}x_t + W^{(1)}s_{t-1}^{(1)}) \\ s_t^{\prime(1)} = f(U^{\prime(1)}x_t + W^{\prime(1)}s_{t-1}^{\prime(1)}) \end{cases} \quad (13)$$

其中, 公式中出现的变量为 BLSTM 神经元中的权重, 不在展开。根据预测对象的不同, 对预测模型构造不同的输入输出即可, 预测结果的精确程度通过均方误差、均方根误差、平均绝对误差、决定系数四种评价指标进行评价, 对于预测值为  $\hat{y} = \{\hat{y}_1, \hat{y}_2, \hat{y}_3, \dots, \hat{y}_n\}$ , 真实值为  $y = \{y_1, y_2, y_3, \dots, y_n\}$ 。

#### ① 均方误差 (MSE)

MSE (Mean Squared Error) 叫做均方误差, 又叫方差, MSE 的定义如式下:

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (14)$$

其取值范围为  $[0, +\infty)$ , 当预测值与真实值完全吻合时等于 0, 即完美模型; 误差越大,

该值越大。

### ②均方根误差 (RMSE)

RMSE (Root Mean Squard Error) 均方根误差, 亦称标准误差, 其实就是MSE加了个根号, 这样数量级上比较直观, 比如RMSE=10, 可以认为回归效果相比真实值平均相差10, RMSE的定义如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

其取值范围为 $[0, +\infty)$ , 当预测值与真实值完全吻合时等于0, 即完美模型; 误差越大, 该值越大。

### ③平均绝对误差 (MAE)

平均绝对误差 (Mean Absolute Deviation), 又叫平均绝对离差。平均绝对误差可以避免误差相互抵消的问题, 因而可以准确反映实际预测误差的大小, MAE的定义如下:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

其取值范围为 $[0, +\infty)$ , 当预测值与真实值完全吻合时等于0, 即完美模型; 误差越大, 该值越大。

### ④决定系数 ( $R^2$ )

决定系数 $R^2$  (R-Square), 也称为判定系数或者拟合优度, 一般在回归模型里用于评估预测值和实际值的符合程度,  $R^2$ 的定义如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (17)$$

其取值范围为 $[0, 1]$ , 一般来说, R-Squared越大, 表示模型拟合效果越好, 如果结果是0, 说明模型拟合效果很差; 如果结果是1, 说明模型无差错。

8. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术, 其特征在于所述步骤(4)中的未来态势管控阶段, 态势管控的关键在于调压方式的选取, 本发明采用分布式电源、电网设备进行调压。

对于变速双馈感应式发电机组, 双馈发电机控制依赖于矢量控制技术, 利用该技术进行PQ解耦, 使双馈风机能够对无功电压进行优化控制, 其中定子磁链定向控制技术被运用到转子侧变频器中, 即把以同步速旋转的坐标轴轴置于定子磁链上, 其转子侧的功率如下:

$$\begin{cases} P_s = u_s \frac{L_m}{L_s} i_{rq} \\ Q_s = u_s \left( \frac{L_m}{L_s} i_{rd} - \frac{1}{L_s} \psi_s \right) \end{cases} \quad (18)$$

式中,  $u_s$  代表定子电压幅值;  $L_s$  代表定子自感;  $L_m$  代表定子和转子之间的互感;  $i_{rq}$ ,  $i_{rd}$  分别代表dq0坐标系下d轴和q轴的转子电流;  $\psi_s$  代表定子磁链。

由式(18)可知, 对转子电流进行控制可分别实现对转子侧有功及无功功率的控制。利

用转子侧变频器进行控制,转速控制器提供有功功率参考值,依据风机电压控制的要求确定无功功率参考值。网侧变频器用于有功、无功的解耦,一般采用电压定向控制方案。网侧变频器电压定向控制是将其电压矢量置于轴上,在网侧变频器电压参考坐标系下,网侧的功率为:

$$\begin{cases} P_g = u_s i_d \\ Q_g = -u_s i_q \end{cases} \quad (19)$$

式中,  $i_d, i_q$  分别代表dq0坐标系下注入网络侧的有功电流和无功电流,由式(19)可知,PQ的解耦控制可以通过控制  $i_d, i_q$  来完成。

通过上述分析可知,双馈发电机组可以同时通过定子侧变频器和网侧变频器向电网输出无功功率,即可以参与电网的无功补偿,实现电压控制。

对于分布式电源中的光伏发电,其基本原理是光能到电能的转换,其中,逆变器采用电压型逆变器。光伏发电要完成并网,需要光伏阵列通过逆变器实现直流电到交流电的转换,这种并网方式只存在逆变环节,因此逆变器的控制系统起着非常重要的作用

光伏系统向电网侧输送的功率可由下式得到:

$$\begin{cases} P = \frac{U_1 U}{Z} \cos(\varphi_z - \phi) - \frac{U^2}{Z} \cos \varphi_z \\ Q = \frac{U_1 U}{Z} \sin(\varphi_z - \phi) - \frac{U^2}{Z} \sin \varphi_z \end{cases} \quad (20)$$

式中,Z代表电网和逆变器之间的电抗; $\varphi_z$ 代表线路阻抗角;U代表电网侧电压幅值; $U_1$ 代表逆变器输出电压的幅值; $\phi$ 代表U与 $U_1$ 之间的相位差。

由式(20)可知,通过调节 $U_1$ 和 $\phi$ 可实现对系统功率的调节,因此,光伏发电系统同样具有无功输出的能力,可以起到对电网无功补偿的作用,实现对电压的调节。

对于电网设备的调压控制,主要采用并联电容器、静止无功补偿器SVC、有载调压变压器,电网设备调压方式固定,不在展开说明。

9. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于所述步骤(4)中的未来态势管控,无功调压方式选取之后,关键在于通过优化算法计算出最佳的补偿容量,通过改进的粒子群算法来计算每个无功补偿薄弱分区内的最优无功补偿容量,改进的粒子群算法(Particle Swarm Optimization,PSO)无需梯度信息,参数少,在实际应用中无需编码,可直接使用。每个粒子会根据当前极值Pbest和全局极值Gbest更新飞行速度和此刻的位置,如(21)、(22)式所示:

$$V_i^{k+1} = V_i^k + c_1 r_1 (P_i^k - X_i^k) + c_2 r_2 (P_g^k - X_i^k) \quad (21)$$

$$X_i^{k+1} = X_i^k + V_i^{k+1} \quad (22)$$

其中, $V_i$ 为速度; $X_i$ 为位置;k为迭代的次数;个体学习因子 $c_1$ 和社会学习因子 $c_2$ 一般取值为2; $r_1$ 和 $r_2$ 是位于[0,1]区间内的随机数。

以节点电压最优和网损最小为目标函数,最终能得到系统未来态势的最优无功补偿方案。系统网损最小

$$P_{loss}(t) = \sum_{i,j \in N} r_{ij} I_{ij}(t)^2 \quad (23)$$

其中,  $P_{\text{loss}}(t)$  为  $t$  时刻系统总网损,  $r_{ij}$  为支路  $ij$  的电阻值,  $I_{ij}(t)$  是  $t$  时刻支路  $ij$  的电流,  $N$  为配网线路集合。节点电压偏差最小:

$$\Delta U(t) = \sum_{i=1}^N |U_i(t) - 1| \quad (24)$$

其中:  $\Delta U(t)$  节点在  $t$  时刻的电压偏差。潮流约束:

$$\begin{cases} P_i = V_i \sum_{j=1}^n V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = V_i \sum_{j=1}^n V_j (G_{ij} \sin \theta_{ij} \cos \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (25)$$

其中,  $P_i, Q_i$  分别代表节点  $i$  处的有功功率和无功功率;  $V_i, V_j$  分别代表节点  $i, j$  处的电压;  $G_{ij}, B_{ij}, \theta_{ij}$  分别代表节点  $i, j$  间的电导, 电纳和相位差。

电压约束:

$$U_{\min} \leq U_i \leq U_{\max} \quad (26)$$

无功补偿装置约束:

$$\begin{cases} Q_{DG.i.\min} < Q_{DG.i} < Q_{DG.i.\max} \\ Q_{c.i.\min} < Q_{c.i} < Q_{c.i.\max} \end{cases} \quad (27)$$

其中,  $Q_{DG.i.\min}, Q_{DG.i.\max}$  为节点  $i$  处分布式电源无功出力上下限,  $Q_{c.i.\min}, Q_{c.i.\max}$  为节点  $i$  处无功补偿设备容量上下限。

基于无功薄弱分区、态势预测, 继而通过改进的粒子群算法进行全网优化, 可以确定每个薄弱分区的最优补偿容量, 从而给出最优的无功补偿方案。

10. 根据权利要求9所述未来态势管控中的最优无功补偿方案, 其特征在于, 态势感知准确率的把控, 态势感知准确率从三方面进行考虑, 分别为电压感知准确率、网损感知准确率、无功补偿方案感知准确率, 根据测试集数据得到系统节点电压、系统网损以及预测管控方案, 构成预测态势评估集合:

$$W = \{V_1, V_2, \dots, V_m, P_{\text{loss}}, Q_1, Q_2, \dots, Q_N\} \quad (28)$$

其中  $V$  为未来态势中的电压幅值,  $P_{\text{loss}}$  为未来态势中的系统网损,  $Q$  为未来态势中的无功补偿容量。

实际态势评估集合为

$$W_{\text{TRUTH}} = \{V_{T1}, V_{T2}, \dots, V_{Tm}, P_{T\text{loss}}, Q_{T1}, Q_{T2}, \dots, Q_{TN}\} \quad (29)$$

其中, 其中  $V$  为实际态势中的电压幅值,  $P_{\text{loss}}$  为实际态势中的系统网损,  $Q$  为实际态势中的无功补偿容量。

通过拟合优度:

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{\sum_{i=1}^n (\bar{Y}_i - Y_i)^2} \quad (30)$$

来判定态势感知的准确率。



## 一种基于态势感知的电网无功主动预测及控制技术

### 技术领域

[0001] 本发明涉及一种基于态势感知的电网无功主动预测及控制技术,属于配电网无功优化领域。

### 背景技术

[0002] 随着国民经济的快速发展,配电网规模不断扩大,分布式发电(Distributed Generation, DG)大量接入配电网,其不确定性及随机性的特点也对配电网的安全、经济和稳定运行提出了新的挑战。电力系统运行控制的难度和复杂度大大增加,基于此国内外专家提出了电力系统态势感知技术。

[0003] 态势感知技术在电网中有多种表现形式,如通过与输电网态势感知内容的比较,系统地分析智能配电网,得出开展态势感知和态势利导的核心是聚焦不确定性因素的变化,从而提出态势觉察、理解、预测、呈现最终到态势利导的五步递进式关键技术架构;另一种表现形式是考虑主动配电网在组成元素、拓扑结构和控制手段等方面的变化,结合硬件体系提出主动配电网态势感知框架,从主动管理服务的角度给出了过电压治理、阻塞管控、调度计划的安全性校验等多个态势感知的具体应用场景,并从同步量测装置的优化布点、海量数据整合与挖掘、在线安全校验等角度阐述了态势感知框架具体实现过程中的研究瓶颈。

[0004] 本发明将在现有的智能配电网态势感知框架下,着力于主动配电网态势预测阶段搭建预测框架并提出用于实现该框架的具体技术手段,对充分发挥配电网的可观可控水平并真正实现风险预警、主动管控具有重要意义。

### 发明内容

[0005] 本发明所要解决的技术问题是克服现有的技术缺陷,提出一种基于态势感知的电网无功主动预测及控制技术

[0006] 为解决上述技术问题,本发明提供了一种基于态势感知的电网无功主动预测及控制技术,其特征在于,包括以下步骤:

[0007] (1) 态势要素采集阶段,获取电网稳态运行数据、暂态运行数据、电网故障数据和电力设备运行状态数据等。

[0008] (2) 态势理解阶段,根据态势要素对当前系统进行态势理解,对系统节点所量测得到的特征数据进行定量计算,得到节点的薄弱性量化指标,根据无功补偿薄弱节点,提出无功补偿薄弱区。

[0009] (3) 态势预测阶段,通过态势要素采集到的电网历史数据,采用多层双向的长短期记忆神经网络算法对分布式电源、负荷进行预测,得到未来态势下的系统状态。

[0010] (4) 未来态势管控阶段,利用改进粒子群算法对配电网进行无功优化,从而得到无功配置方案。

[0011] 进一步的,所述步骤(1)中的态势要素采集,由于广域测量系统和相量测量单元在

电网的投入使用,可实时采集到电网稳态运行数据、暂态运行数据、电网故障数据和电力设备运行状态数据等。该阶段主要是为后面电网态势的理解与分析、以及预测做相对应的准备。根据配电系统分析和控制的需求合理配置量测,以获取所需要的数据。

[0012] 进一步的,所述步骤(2)中的态势要素理解,本发明中的态势理解主要是对当前系统无功补偿薄弱节点识别,统计和提取电网静态场景下各节点电压幅值与相角样本序列组成的集合 $Z_1 = \{(v_1, \theta_1), (v_2, \theta_2), \dots, (v_n, \theta_n)\}$ ,将该集合里每个节点的状态数据样本 $(v_i, \theta_i, i=1, \dots, n)$ 作为网络中的节点,在电力系统正常运行的状态下,按某一特定比例增加母线上的负荷有功功率值,首先崩溃的节点为该配网中的最薄弱节点,增长方式采用扩展潮流方程:

$$[0013] \quad f(\theta, V) + \lambda b = 0$$

[0014] 其中 $\theta, V$ 分别为节点电压相角和电压幅值, $\lambda$ 为负荷和发电增长参数, $b$ 为系统各节点负荷增长方式常数。

[0015] 可以将节点 $i$ 的负荷有功和无功注入功率以及发电机注入有功功率分解为两个部分,其中 $P_{Li0}, Q_{Li0}$ 代表初始负荷节点 $i$ 水平, $P_{Gi0}$ 代表发电机节点 $i$ 初始有功出力。另一部分对应由负荷参数 $\lambda$ 表示的负荷变化和有功出力变化,从而得到:

$$[0016] \quad \begin{cases} P_{Gi} = P_{Li0} + \lambda b_{Gi}^P \\ P_{Li} = P_{Gi0} + \lambda b_{Li}^P \\ Q_{Li} = Q_{Gi0} + \lambda b_{Li}^Q \end{cases}$$

[0017] 其中 $P_{Li}, Q_{Li}$ 分别为负荷节点 $i$ 的有功水平、无功水平, $P_{Gi}$ 为发电设备节点 $i$ 的有功出力, $b_{Li}^P, b_{Li}^Q$ 分别为负荷节点 $i$ 的有功增长方式、无功增长方式, $b_{Gi}^P$ 为发电设备节点 $i$ 的有功出力增长方式。按比例增加负荷后的各节点幅值与相角样本序列组成的集合 $Z_2 = \{(v_1, \theta_1), (v_2, \theta_2), \dots, (v_n, \theta_n)\}$ ,由 $Z_1$ 和 $Z_2$ 作为识别薄弱节点的样本集合。

[0018] 进一步的,提出一种量化节点薄弱性的指标,通过定量的增加节点负荷,根据分析PV曲线得知,电压容易发生崩溃的节点既薄弱节点,在增加负荷时,电压和相角变化较为敏感,本文用节点复电压变化率来衡量节点的薄弱性。复电压变化率在此定义为电压的变化率和相角的变化率的加权求和,在负荷有功达到最大值之前,当节点 $j$ 的负荷增加一定比例的有功功率时,该节点复电压变化率(Voltage Change Rate)为VCR,计算如下所示:

$$[0019] \quad VCR_j = \frac{V_j - V'_j}{V_j} + \frac{\theta_j - \theta'_j}{\theta_j} \quad (1)$$

[0020] 其中, $V_j$ 表示正常运行时 $j$ 节点处电压值, $V'_j$ 表示负荷按给定比例变化后的 $j$ 节点处电压值。 $\theta_j$ 表示正常运行时 $j$ 节点处电压相角值, $\theta'_j$ 表示负荷按给定比例变化后的 $j$ 节点处电压相角值,由以上模型可知,节点的复电压薄弱指标越大,说明该节点的薄弱性越大。

[0021] 进一步的,所述步骤(2)中的无功补偿薄弱区的划分,根据无功装置的数量、节点空间位置、节点薄弱性指标三方面考虑,对配电网进行分区划分,将薄弱节点的概念扩展到薄弱区,每个薄弱区对应若干个节点,且提出一种薄弱区指标的概念,定义薄弱区指标为VCRS,计算如下所示:

$$[0022] \quad VCRS_Q = \sum_{i \leq j \leq k}^j \frac{V_j - V'_j}{V_j} + \frac{\theta_j - \theta'_j}{\theta_j} \quad (2)$$

$$[0023] \quad Q \leq N \quad (3)$$

[0024] 其中,  $VCRS_Q$  是第  $Q$  个薄弱区,  $i \leq j \leq k$  为薄弱区  $Q$  内的薄弱节点个数,  $V_j$  表示正常运行时  $j$  节点处电压值,  $V'_j$  表示负荷按给定比例变化后的  $j$  节点处电压值,  $\theta_j$  表示正常运行时  $j$  节点处电压相角值,  $\theta'_j$  表示负荷按给定比例变化后的  $j$  节点处电压相角值,  $N$  为无功补偿装置组的个数, 由以上模型可知, 将配电网划分为不同的薄弱区, 确保每个薄弱区都包含有无功补偿装置, 薄弱分区指标越大, 说明该薄弱分区的薄弱性越大。薄弱区的数量应少于无功补偿装置组的数量, 根据薄弱区指标的大小进行排序, 薄弱性较强的区域, 安放补充能力强的无功设备, 以此类推, 在各区域放置无功设备, 在每个薄弱区内部, 各个节点的薄弱性指标也会有大小排序, 所以装配无功补偿设备的时候优先考虑薄弱性较强的节点。

[0025] 进一步的, 所述步骤 (3) 中的态势预测, 态势预测部分主要分为两个模块, 第一个模块主要是对分布式电源发电进行预测, 第二个模块主要是对负荷进行预测。而主动配电网主要是接入了大量的分布式能源, 其中不可控分布式能源的预测对系统态势感知有较大的影响。主动配电网中间歇式能源主要包括光伏发电和风力发电。

[0026] 在不考虑大气影响的条件下, 光伏面板安装处的辐射照度为:

$$[0027] \quad G = G_b \cdot \cos \theta \quad (4)$$

[0028] 其中,  $G$  为光伏面板接收的总辐射照度, 其单位为  $W/m^2$ ;  $G_b$  为太阳直射照度, 在真空中辐射到地球为定值;  $\theta$  为太阳入射光线与光伏面板法线的夹角, 一天中会随时间的变化而变化。

[0029] 分布式光伏的有功出力与光伏面板接收的光照度与温度等天气条件有关, 根据光伏电池的物理模型可得输出有功功率最大值的表达式:

$$[0030] \quad \begin{aligned} P_{\max} &= U_M \cdot I_M & (a) \\ U_M &= U_{OC} \cdot \left[ 1 - \frac{b}{U_{OC}} \ln a - r_s \cdot (1 - a^{-b}) \right] & (b) \\ I_M &= I_{SC} \cdot (1 - a^{-b}) & (c) \\ a &= u_{OC} + 1 - 2u_{OC} \cdot r_s & (d) \\ b &= a / (1 + a) & (e) \end{aligned} \quad (5)$$

[0031] 其中  $U_{OC}$  为一定天气情况下的光伏开路电压,  $I_{SC}$  为一定天气情况下的光伏短路电流;  $u_{OC}$  为标准开路电压,  $r_s$  为标准串联电阻。在获取天气数据的情况下, 可以根据相应表达式求得光伏最大的输出功率。

[0032] 根据电路关系, 可以通过 (5) 式推导出 (6) 式计算光伏发电最大功率:

$$[0033] \quad P_{\max} = U_M \cdot I_M = a \cdot U_{OC} \cdot I_{SC} \quad (6)$$

[0034] 其中  $a$  是与光伏设备有关的参数,  $U_{OC}$ 、 $I_{SC}$  分别为特定天气条件的光伏模块开路电压与短路电流, 根据 (7) 式计算。

$$[0035] \quad \begin{cases} I_{SC}(G) = \frac{I_{SC}^R}{G^R} \cdot G_b \cdot \cos \theta \\ U_{OC}(T) = U_{OC}^R + (T - T^R) \cdot k \end{cases} \quad (7)$$

[0036] 其中： $G^R$ 为标准测试状态的辐射照度； $k$ 为光伏系统开路电压的温度系数； $T^R$ 为标准测试状态的温度； $T$ 为光伏系统在辐射照度 $G$ 下的运行温度。

[0037] 从公式中可以看出，在不考虑大气因素影响的条件下，光伏发电功率的最大值在一天的变化中近似呈正弦函数变化。

[0038] 在光伏实际发电中，会由于大气折射、云量、雨量等原因，造成发电量的波动。因此光伏发电量与不确定天气因素影响后的发电量会有较大波动，通过Pearson相关系数来计算相关性，如式(8)：

$$[0039] \quad R_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (8)$$

[0040] 通过计算可知，辐射照度、温度、湿度相关性较强，但是一般天气预报不会预测辐射照度，获取该数据的难度较大，考虑实际应用，本发明采用温度和湿度作为发电量预测的天气元素，样本的输入格式为

$$[0041] \quad X_i = \{T_i, H_i, t_i, s_i\} \quad (9)$$

[0042] 其中， $t$ 为样本采集日期， $s$ 为天气情况，一般分为0, 1, -1；分别代表晴、多云、雨等。

[0043] 风力发电机组的基本结构为风力机、双馈感应发电机以及变换器。风力机将风能转化成机械能传递给双馈感应发电机，发电机将机械能转化成幅值和频率变化的电能，风力机正常运行中，忽略尾流损失、轮毂损失以及叶尖损失，其可获得的最大功率为：

$$[0044] \quad P_{WT,MAX} = \frac{1}{2} C_{P,MAX} \rho A v^3 \quad (10)$$

[0045] 其中： $C_{P,MAX}$ 为功率系数最大值， $\rho$ 为空气密度， $A$ 为风机扇面面积， $v$ 为风速。从模型中可以看出风力发电受影响最大的因素为风速。考虑实际应用，本发明采用风速作为发电量预测的天气元素，样本的输入格式为：

$$[0046] \quad X_i = \{v_i, t_i, s_i\} \quad (11)$$

[0047] 其中， $t$ 为样本采集日期， $s$ 为天气情况，一般分为0, 1, -1；分别代表晴、多云、雨等。

[0048] 针对负荷预测，社会因素、天气因素对电力负荷都有较大的影响，分析温度、天气状况、电价、社会发展等对负荷数据的影响程度，给出具体的影响因素。在具体分析中采用斯皮尔曼相关系数如式(8)所示，分析温度、湿度等气象因素与负荷的相关性，结合传统负荷预测方法中的相关因素，本发明的负荷的样本输入格式为：

$$[0049] \quad X_i = \{t_i, P_i, T_i, H_i, s_i\} \quad (12)$$

[0050] 其中， $t_i$ 为样本采集日期， $P_i$ 为有功负荷， $T_i$ 为该天的平均气温， $H_i$ 为该天的平均湿度， $s_i$ 为天气情况，一般分为0, 1, -1；分别代表晴、多云、雨等。

[0051] 进一步的，预测方法的选取，LSTM神经网络由RNN神经网络延伸而来，解决了RNN结构上会出现的梯度爆炸与梯度消失的问题，LSTM在预测中也因为其单向结构造成了误差累计的问题。分析LSTM神经网络负荷预测模型的结构与原理，针对误差累计的问题，给出了具体改进方法——BLSTM神经网络。

[0052] 首先采用BLSTM取代传统LSTM预测，BLSTM是在LSTM的结构上增加一个反向的预测过程，正、反相结合的BLSTM神经网络，在理论上能尽可能保留负荷数据真实性。

[0053] 预测模型每层BLSTM神经网络都是由正向的LSTM网络和反向的LSTM网络组成,下一层网络的输入是由上一层正、反向LSTM的输出结果共同决定,最后一层网络模型结果由每一层正、反向计算结果同时决定,式子中 $s_t^{(i)}$ 、 $s_{t-1}^{(i)}$ 分别表示t-1时刻和t时刻第i个隐藏层的值,由于正向计算和反向计算不共享权重,其中,正向计算时, $V^{(i)}$ 、 $U^{(i)}$ 、 $W^{(i)}$ 表示第i个隐藏层到输出层、输入层到隐藏层、隐藏层之间的权重矩阵,反向计算时, $V'^{(i)}$ 、 $U'^{(i)}$ 、 $W'^{(i)}$ 表示相对应的反向权重矩阵。 $i$ 表示BLSTM层数,且 $i=0,1,2L\infty$ ,表示输出层的值,预测模型如下:

$$[0054] \quad \begin{cases} o_t = g(V^{(i)}s_t^{(i)} + V'^{(i)}s_t'^{(i)}) \\ s_t^{(i)} = f(U^{(i)}s_t^{(i-1)} + W^{(i)}s_{t-1}^{(i)}) \\ s_t'^{(i)} = f(U'^{(i)}s_t'^{(i-1)} + W'^{(i)}s_{t-1}'^{(i)}) \\ \dots\dots \\ s_t^{(1)} = f(U^{(1)}x_t + W^{(1)}s_{t-1}^{(1)}) \\ s_t'^{(1)} = f(U'^{(1)}x_t + W'^{(1)}s_{t-1}'^{(1)}) \end{cases} \quad (13)$$

[0055] 其中,公式中出现的变量为BLSTM神经元中的权重,不在展开。根据预测对象的不同,对预测模型构造不同的输入输出即可,预测结果的精确程度通过均方误差、均方根误差、平均绝对误差、决定系数四种评价指标进行评价,对于预测值为 $\hat{y} = \{\hat{y}_1, \hat{y}_2, \hat{y}_3, \dots, \hat{y}_n\}$ ,真实值为 $y = \{y_1, y_2, y_3, \dots, y_n\}$ 。

[0056] ②均方误差(MSE)

[0057] MSE(Mean Squared Error)叫做均方误差,又叫方差,MSE的定义如式下:

$$[0058] \quad MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (14)$$

[0059] 其取值范围为 $[0, +\infty)$ ,当预测值与真实值完全吻合时等于0,即完美模型;误差越大,该值越大。

[0060] ②均方根误差(RMSE)

[0061] RMSE(Root Mean Squard Error)均方根误差,亦称标准误差,其实就是MSE加了个根号,这样数量级上比较直观,比如 $RMSE=10$ ,可以认为回归效果相比真实值平均相差10, RMSE的定义如下:

$$[0062] \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

[0063] 其取值范围为 $[0, +\infty)$ ,当预测值与真实值完全吻合时等于0,即完美模型;误差越大,该值越大。

[0064] ③平均绝对误差(MAE)

[0065] 平均绝对误差(Mean Absolute Deviation),又叫平均绝对离差。平均绝对误差可以避免误差相互抵消的问题,因而可以准确反映实际预测误差的大小,MAE的定义如下:

$$[0066] \quad MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

[0067] 其取值范围为 $[0, +\infty)$ ,当预测值与真实值完全吻合时等于0,即完美模型;误差越大,该值越大。

[0068] ④决定系数 ( $R^2$ )

[0069] 决定系数  $R^2$  (R-Square), 也称为判定系数或者拟合优度, 一般在回归模型里用于评估预测值和实际值的符合程度,  $R^2$  的定义如下:

$$[0070] \quad R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (17)$$

[0071] 其取值范围为  $[0, 1]$ , 一般来说, R-Squared 越大, 表示模型拟合效果越好, 如果结果是 0, 说明模型拟合效果很差; 如果结果是 1, 说明模型无差错。

[0072] 进一步的, 所述步骤 (4) 中的未来态势管控阶段, 态势管控的关键在于调压方式的选取, 本发明采用分布式电源、电网设备进行调压。

[0073] 分布式电源的控制方式包括变速双馈感应式发电机组和光伏发电。

[0074] 对于变速双馈感应式发电机组, 双馈发电机控制依赖于矢量控制技术, 利用该技术进行 PQ 解耦, 使双馈风机能够对无功电压进行优化控制, 其中定子磁链定向控制技术被运用到转子侧变频器中, 即把以同步速旋转的坐标轴置于定子磁链上, 其转子侧的功率如下:

$$[0075] \quad \begin{cases} P_s = u_s \frac{L_m}{L_s} i_{rq} \\ Q_s = u_s \left( \frac{L_m}{L_s} i_{rd} - \frac{1}{L_s} \psi_s \right) \end{cases} \quad (18)$$

[0076] 式中,  $u_s$  代表定子电压幅值;  $L_s$  代表定子自感;  $L_m$  代表定子和转子之间的互感;  $i_{rq}$ ,  $i_{rd}$  分别代表 dq0 坐标系下 d 轴和 q 轴的转子电流;  $\psi_s$  代表定子磁链。

[0077] 由式 (18) 可知, 对转子电流进行控制可分别实现对转子侧有功及无功功率的控制。利用转子侧变频器进行控制, 转速控制器提供有功功率参考值, 依据风机电压控制的要求确定无功功率参考值。网侧变频器用于有功、无功的解耦, 一般采用电压定向控制方案。网侧变频器电压定向控制是将其电压矢量置于轴上, 在网侧变频器电压参考坐标系下, 网侧的功率为:

$$[0078] \quad \begin{cases} P_g = u_s i_d \\ Q_g = -u_s i_q \end{cases} \quad (19)$$

[0079] 式中,  $i_d$ ,  $i_q$  分别代表 dq0 坐标系下注入网络侧的有功电流和无功电流, 由式 (19) 可知, PQ 的解耦控制可以通过控制  $i_d$ ,  $i_q$  来完成。

[0080] 通过上述分析可知, 双馈发电机组可以同时通过定子侧变频器和网侧变频器向电网输出无功功率, 即可以参与电网的无功补偿, 实现电压控制。

[0081] 对于分布式电源中的光伏发电, 其基本原理是光能到电能的转换, 其中, 逆变器采用电压型逆变器。光伏发电要完成并网, 需要光伏阵列通过逆变器实现直流电到交流电的转换, 这种并网方式只存在逆变环节, 因此逆变器的控制系统起着非常重要的作用

[0082] 光伏系统向电网侧输送的功率可由下式得到:

$$[0083] \quad \begin{cases} P = \frac{U_1 U}{Z} \cos(\varphi_z - \phi) - \frac{U^2}{Z} \cos \varphi_z \\ Q = \frac{U_1 U}{Z} \sin(\varphi_z - \phi) - \frac{U^2}{Z} \sin \varphi_z \end{cases} \quad (20)$$

[0084] 式中,Z代表电网和逆变器之间的电抗; $\varphi_z$ 代表线路阻抗角;U代表电网侧电压幅值; $U_1$ 代表逆变器输出电压的幅值; $\phi$ 代表U与 $U_1$ 之间的相位差。

[0085] 由式(20)可知,通过调节 $U_1$ 和 $\phi$ 可实现对系统功率的调节,因此,光伏发电系统同样具有无功输出的能力,可以起到对电网无功补偿的作用,实现对电压的调节。

[0086] 对于电网设备的调压控制,主要采用并联电容器、静止无功补偿器SVC、有载调压变压器,电网设备调压方式固定,不在展开说明。

[0087] 进一步的,所述步骤(4)中的未来态势管控,无功调压方式选取之后,关键在于通过优化算法计算出最佳的补偿容量,通过改进的粒子群算法来计算每个无功补偿薄弱分区内的最优无功补偿容量,改进的粒子群算法(Particle Swarm Optimization,PSO) 无需梯度信息,参数少,在实际应用中无需编码,可直接使用。每个粒子会根据当前极值Pbest和全局极值Gbest更新飞行速度和此刻的位置,如(21)、(22)式所示:

$$[0088] \quad V_i^{k+1} = V_i^k + c_1 r_1 (P_i^k - X_i^k) + c_2 r_2 (P_g^k - X_i^k) \quad (21)$$

$$[0089] \quad X_i^{k+1} = X_i^k + V_i^{k+1} \quad (22)$$

[0090] 其中, $V_i$ 为速度; $X_i$ 为位置;k为迭代的次数;个体学习因子 $c_1$ 和社会学习因子 $c_2$ 一般取值为2; $r_1$ 和 $r_2$ 是位于[0,1]区间内的随机数。

[0091] 以节点电压最优和网损最小为目标函数,最终能得到系统未来态势的最优无功补偿方案。系统网损最小

$$[0092] \quad P_{loss}(t) = \sum_{i,j \in N} r_{ij} I_{ij}(t)^2 \quad (23)$$

[0093] 其中, $P_{loss}(t)$ 为t时刻系统总网损, $r_{ij}$ 为支路ij的电阻值, $I_{ij}(t)$ 是t时刻支路ij的电流,N为配网线路集合。节点电压偏差最小:

$$[0094] \quad \Delta U(t) = \sum_{i=1}^N |U_i(t) - 1| \quad (24)$$

[0095] 其中: $\Delta U(t)$ 节点在t时刻的电压偏差。潮流约束:

$$[0096] \quad \begin{cases} P_i = V_i \sum_{j=1}^n V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = V_i \sum_{j=1}^n V_j (G_{ij} \sin \theta_{ij} \cos \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (25)$$

[0097] 其中, $P_i, Q_i$ 分别代表节点i处的有功功率和无功功率; $V_i, V_j$ 分别代表节点i,j处的电压; $G_{ij}, B_{ij}, \theta_{ij}$ 分别代表节点i,j间的电导,电纳和相位差。

[0098] 电压约束:

$$[0099] \quad U_{\min} \leq U_i \leq U_{\max} \quad (26)$$

[0100] 无功补偿装置约束:

$$[0101] \quad \begin{cases} Q_{DG.i.min} < Q_{DG.i} < Q_{DG.i.max} \\ Q_{c.i.min} < Q_{c.i} < Q_{c.i.max} \end{cases} \quad (27)$$

[0102] 其中,  $Q_{DG.i.min}$ 、 $Q_{DG.i.max}$  为节点i处分布式电源无功出力上下限,  $Q_{c.i.min}$ 、 $Q_{c.i.max}$  为节点 i 处无功补偿设备容量上下限。

[0103] 基于无功薄弱分区、态势预测, 继而通过改进的粒子群算法进行全网优化, 可以确定每个薄弱分区的最优补偿容量, 从而给出最优的无功补偿方案。

[0104] 进一步的, 态势感知准确率从三方面进行考虑, 分别为电压感知准确率、网损感知准确率、无功补偿方案感知准确率, 根据测试集数据得到系统节点电压、系统网损以及预测管控方案, 构成预测态势评估集合:

$$[0105] \quad W = \{V_1, V_2, \dots, V_m, P_{loss}, Q_1, Q_2, \dots, Q_N\} \quad (28)$$

[0106] 其中V为未来态势中的电压幅值,  $P_{loss}$  为未来态势中的系统网损, Q为未来态势中的无功补偿容量。

[0107] 实际态势评估集合为

$$[0108] \quad W_{TRUTH} = \{V_{T1}, V_{T2}, \dots, V_{Tm}, P_{Tloss}, Q_{T1}, Q_{T2}, \dots, Q_{TN}\} \quad (29)$$

[0109] 其中, 其中V为实际态势中的电压幅值,  $P_{loss}$  为实际态势中的系统网损, Q为实际态势中的无功补偿容量。

[0110] 通过拟合优度:

$$[0111] \quad R^2 = 1 - \frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{\sum_{i=1}^n (\bar{Y}_i - Y_i)^2} \quad (30)$$

[0112] 来判定态势感知的准确率。

[0113] 本发明的有益效果如下:

[0114] 本发明将态势感知技术引入无功优化领域, 通过态势感知框架, 首先通过系统节点薄弱性指标, 划分无功补偿薄弱分区; 态势预测阶段, 采用BLSTM对特征数据进行预测, 获得未来态势下的系统运行状态, 态势管控阶段, 通过改进的PSO算法对全网进行无功优化, 获得未来态势下的控制方案; 整个过程涉及到当前时刻和未来时刻, 形成一个闭环系统, 提前干预的同时, 能够降低系统损耗和运行成本。

## 附图说明

[0115] 图1: 态势感知基本框架图

[0116] 图2: PV曲线

[0117] 图3: BLSTM模型图

[0118] 图4: 改进粒子群算法流程图

[0119] 图5: 基本流程图

## 具体实施方式

[0120] 以下结合附图以及给出的实施例, 对本发明作进一步的说明, 但并不局限于此。

[0121] 如图5所示, 一种基于态势感知的电网无功主动预测及控制技术, 其特征在于, 包



括：

[0122] 态势要素采集模块：获取电网运行数据

[0123] 态势理解模块：对系统节点所量测得到的特征数据进行定量计算，得到节点的薄弱性量化指标，根据无功补偿薄弱节点，提出无功补偿薄弱区。

[0124] 态势预测模块，通过态势要素采集到的电网历史数据，采用多层双向的长短期记忆神经网络算法对分布式电源、负荷进行预测，得到未来态势下的系统状态。

[0125] 未来态势管控模块，利用改进粒子群算法对配电网进行无功优化，从而得到无功配置方案。

[0126] 如图一所示，一种基于态势感知的电网无功主动预测及控制技术，包括如下步骤：

[0127] (1) 态势要素采集阶段，获取电网稳态运行数据、暂态运行数据、电网故障数据和电力设备运行状态数据等。

[0128] (2) 态势理解阶段，根据态势要素对当前系统进行态势理解，对系统节点所量测得到的特征数据进行定量计算，得到节点的薄弱性量化指标，根据无功补偿薄弱节点，提出无功补偿薄弱区。

[0129] (3) 态势预测阶段，通过态势要素采集到的电网历史数据，采用多层双向的长短期记忆神经网络算法对分布式电源、负荷进行预测，得到未来态势下的系统状态。

[0130] (4) 未来态势管控阶段，利用改进粒子群算法对配电网进行无功优化，从而得到无功配置方案。

[0131] 2. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术，其特征在于所述步骤(1)中的态势要素采集，由于广域测量系统和相量测量单元在电网的投入使用，可实时采集到电网稳态运行数据、暂态运行数据、电网故障数据和电力设备运行状态数据等。该阶段主要是为后面电网态势的理解与分析、以及预测做相对应的准备。根据配电系统分析和控制的需求合理配置量测，以获取所需要的数据。

[0132] 3. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术，其特征在于所述步骤(2)中的态势要素理解，本发明中的态势理解主要是对当前系统无功补偿薄弱节点识别，统计和提取电网静态场景下各节点电压幅值与相角样本序列组成的集合  $Z_1 = \{(v_1, \theta_1), (v_2, \theta_2), \dots, (v_n, \theta_n)\}$ ，将该集合里每个节点的状态数据样本  $(v_i, \theta_i, i = 1, \dots, n)$  作为网络中的节点，在电力系统正常运行的状态下，按某一特定比例增加母线上的负荷有功功率值，首先崩溃的节点为该配网中的最薄弱节点，增长方式采用扩展潮流方程：

$$[0133] \quad f(\theta, V) + \lambda b = 0$$

[0134] 其中 $\theta, V$ 分别为节点电压相角和电压幅值， $\lambda$ 为负荷和发电增长参数， $b$ 为系统各节点负荷增长方式常数。

[0135] 可以将节点 $i$ 的负荷有功和无功注入功率以及发电机注入有功功率分解为两个部分，其中 $P_{Li0}, Q_{Li0}$ 代表初始负荷节点 $i$ 水平， $P_{Gi0}$ 代表发电机节点 $i$ 初始有功出力。另一部分对应由负荷参数 $\lambda$ 表示的负荷变化和有功出力变化，从而得到：

$$[0136] \quad \begin{cases} P_{Gi} = P_{Li0} + \lambda b_{Gi}^P \\ P_{Li} = P_{Gi0} + \lambda b_{Li}^P \\ Q_{Li} = Q_{Gi0} + \lambda b_{Li}^Q \end{cases}$$

[0137] 其中 $P_{Li}$ 、 $Q_{Li}$ 分别为负荷节点i的有功水平、无功水平， $P_{Gi}$ 为发电设备节点i的有功出力， $b_{Li}^P$ 、 $b_{Li}^Q$ 分别为负荷节点i的有功增长方式、无功增长方式， $b_{Gi}^P$ 为发电设备节点i的有功出力增长方式。按比例增加负荷后的各节点幅值与相角样本序列组成的集合  $Z_2 = \{(v_1, \theta_1), (v_2, \theta_2), \dots, (v_n, \theta_n)\}$ ，由 $Z_1$ 和 $Z_2$ 作为识别薄弱节点的样本集合。

[0138] 4. 根据权利要求3所述的无功补偿薄弱节点识别，其特征在于，提出一种量化节点薄弱性的指标，通过定量的增加节点负荷，根据分析PV曲线得知，电压容易发生崩溃的节点既薄弱节点，在增加负荷时，电压和相角变化较为敏感，本文用节点复电压变化率来衡量节点的薄弱性。复电压变化率在此定义为电压的变化率和相角的变化率的加权求和，在负荷有功达到最大值之前，当节点j的负荷增加一定比例的有功功率时，该节点复电压变化率 (Voltage Change Rate) 为VCR，计算如下所示：

$$[0139] \quad VCR_j = \frac{V_j - V'_j}{V_j} + \frac{\theta_j - \theta'_j}{\theta_j} \quad (1)$$

[0140] 其中， $V_j$ 表示正常运行时j节点处电压值， $V'_j$ 表示负荷按给定比例变化后的j节点处电压值。 $\theta_j$ 表示正常运行时j节点处电压相角值， $\theta'_j$ 表示负荷按给定比例变化后的j节点处电压相角值，由以上模型可知，节点的复电压薄弱指标越大，说明该节点的薄弱性越大。

[0141] 5. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术，其特征在于所述步骤(2)中的无功补偿薄弱区的划分，根据无功装置的数量、节点空间位置、节点薄弱性指标三方面考虑，对配电网进行分区划分，将薄弱节点的概念扩展到薄弱区，每个薄弱区对应若干个节点，且提出一种薄弱区指标的概念，定义薄弱区指标为VCRS，计算如下所示：

$$[0142] \quad VCRS_Q = \sum_{i \leq j \leq k} \frac{V_j - V'_j}{V_j} + \frac{\theta_j - \theta'_j}{\theta_j} \quad (2)$$

$$[0143] \quad Q \leq N \quad (3)$$

[0144] 其中， $VCRS_Q$ 是第Q个薄弱区， $i \leq j \leq k$ 为薄弱区Q内的薄弱节点个数， $V_j$ 表示正常运行时区j节点处电压值， $V'_j$ 表示负荷按给定比例变化后的j节点处电压值。 $\theta_j$ 表示正常运行时j节点处电压相角值， $\theta'_j$ 表示负荷按给定比例变化后的j节点处电压相角值，N为无功补偿装置组的个数，由以上模型可知，将配电网划分为不同的薄弱区，确保每个薄弱区都包含有无功补偿装置，薄弱分区指标越大，说明该薄弱分区的薄弱性越大。薄弱区的数量应少于无功补偿装置组的数量，根据薄弱区指标的大小进行排序，薄弱性较强的区域，安放补充能力强的无功设备，以此类推，在各区域放置无功设备，在每个薄弱区内部，各个节点的薄弱性指标也会有大小排序，所以装配无功补偿设备的时候优先考虑薄弱性较强的节点。

[0145] 6. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术，其特征在于所述步骤(2)中的态势预测，态势预测部分主要分为两个模块，第一个模块主要是对分布式电源发电进行预测，第二个模块主要是对负荷进行预测。而主动配电网主要是接

入了大量的分布式能源,其中不可控分布式能源的预测对系统态势感知有较大的影响。主动配电网中间歇式能源主要包括光伏发电和风力发电。

[0146] 在不考虑大气影响的条件下,光伏面板安装处的辐射照度为:

$$[0147] \quad G = G_b \cdot \cos \theta \quad (4)$$

[0148] 其中,G为光伏面板接收的总辐射照度,其单位为W/m<sup>2</sup>;G<sub>b</sub>为太阳直射照度,在真空中辐射到地球为定值;θ为太阳入射光线与光伏面板法线的夹角,一天中会随时间的变化而变化。

[0149] 分布式光伏的有功出力与光伏面板接收的光照度与温度等天气条件有关,根据光伏电池的物理模型可得输出有功功率最大值的表达式:

$$[0150] \quad \begin{aligned} P_{\max} &= U_M \cdot I_M & (a) \\ U_M &= U_{OC} \cdot \left[ 1 - \frac{b}{U_{OC}} \ln a - r_s \cdot (1 - a^{-b}) \right] & (b) \\ I_M &= I_{SC} \cdot (1 - a^{-b}) & (c) \\ a &= u_{OC} + 1 - 2u_{OC} \cdot r_s & (d) \\ b &= a / (1 + a) & (e) \end{aligned} \quad (5)$$

[0151] 其中U<sub>OC</sub>为一定天气情况下的光伏开路电压,I<sub>SC</sub>为一定天气情况下的光伏短路电流;u<sub>OC</sub>为标准开路电压,r<sub>s</sub>为标准串联电阻。在获取天气数据的情况下,可以根据相应表达式求得光伏最大的输出功率。

[0152] 根据电路关系,可以通过(5)式推导出(6)式计算光伏发电最大功率:

$$[0153] \quad P_{\max} = U_M \cdot I_M = a \cdot U_{OC} \cdot I_{SC} \quad (6)$$

[0154] 其中a是与光伏设备有关的参数,U<sub>OC</sub>、I<sub>SC</sub>分别为特定天气条件的光伏模块开路电压与短路电流,根据(7)式计算。

$$[0155] \quad \begin{cases} I_{SC}(G) = \frac{I_{SC}^R}{G^R} \cdot G_b \cdot \cos \theta \\ U_{OC}(T) = U_{OC}^R + (T - T^R) \cdot k \end{cases} \quad (7)$$

[0156] 其中:G<sup>R</sup>为标准测试状态的辐射照度;k为光伏系统开路电压的温度系数;T<sup>R</sup>为标准测试状态的温度;T为光伏系统在辐射照度G下的运行温度。

[0157] 从公式中可以看出,在不考虑大气因素影响的条件下,光伏发电功率的最大值在一天的变化中近似呈正弦函数变化。

[0158] 在光伏实际发电中,会由于大气折射、云量、雨量等原因,造成发电量的波动。因此光伏发电量与不确定天气因素影响后的发电量会有较大波动,通过Pearson相关系数来计算相关性,如式(8):

$$[0159] \quad R_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (8)$$

[0160] 通过计算可知,辐射照度、温度、湿度相关性较强,但是一般天气预报不会预测辐射照度,获取该数据的难度较大,考虑实际应用,本发明采用温度和湿度作为发电量预测的

天气元素,样本的输入格式为

$$[0161] \quad X_i = \{T_i, H_i, t_i, s_i\}. \quad (9)$$

[0162] 其中,t为样本采集日期,s为天气情况,一般分为0,1,-1;分别代表晴、多云、雨等。

[0163] 风力发电机组的基本结构为风力机、双馈感应发电机以及变换器。风力机将风能转化成机械能传递给双馈感应发电机,发电机将机械能转化成幅值和频率变化的电能,风力机正常运行中,忽略尾流损失、轮毂损失以及叶尖损失,其可获得的最大功率为:

$$[0164] \quad P_{WT,MAX} = \frac{1}{2} C_{P,MAX} \rho A v^3 \quad (10)$$

[0165] 其中: $C_{P,MAX}$ 为功率系数最大值, $\rho$ 为空气密度,A为风机扇面面积,v为风速。从模型中可以看出风力发电受影响最大的因素为风速。考虑实际应用,本发明采用风速作为发电量预测的天气元素,样本的输入格式为:

$$[0166] \quad X_i = \{v_i, t_i, s_i\} \quad (11)$$

[0167] 其中,t为样本采集日期,s为天气情况,一般分为0,1,-1;分别代表晴、多云、雨等。

[0168] 针对负荷预测,社会因素、天气因素对电力负荷都有较大的影响,分析温度、天气状况、电价、社会发展等对负荷数据的影响程度,给出具体的影响因素。在具体分析中采用斯皮尔曼相关系数如式(8)所示,分析温度、湿度等气象因素与负荷的相关性,结合传统负荷预测方法中的相关因素,本发明的负荷的样本输入格式为:

$$[0169] \quad X_i = \{t_i, P_i, T_i, H_i, s_i\} \quad (12)$$

[0170] 其中, $t_i$ 为样本采集日期, $P_i$ 为有功负荷, $T_i$ 为该天的平均气温, $H_i$ 为该天的平均湿度  $s_i$ 为天气情况,一般分为0,1,-1;分别代表晴、多云、雨等。

[0171] 7.根据权利要求6所述的态势预测技术,其特征在于预测方法的选取,LSTM神经网络由RNN神经网络延伸而来,解决了RNN结构上会出现的梯度爆炸与梯度消失的问题,LSTM在预测中也因为其单向结构造成了误差累计的问题。分析LSTM神经网络负荷预测模型的结构与原理,针对误差累计的问题,给出了具体改进方法——BLSTM神经网络。

[0172] 首先采用BLSTM取代传统LSTM预测,BLSTM是在LSTM的结构上增加一个反向的预测过程,正、反相结合的BLSTM神经网络,在理论上能尽可能保留负荷数据真实性。

[0173] 预测模型每层BLSTM神经网络都是由正向的LSTM网络和反向的LSTM网络组成,下一层网络的输入是由上一层正、反向LSTM的输出结果共同决定,最后一层网络模型结果由每一层正、反向计算结果同时决定,式子中 $s_t^{(i)}$ 、 $s_{t-1}^{(i)}$ 分别表示t-1时刻和t时刻第i个隐藏层的值,由于正向计算和反向计算不共享权重,其中,正向计算时, $V^{(i)}$ 、 $U^{(i)}$ 、 $W^{(i)}$ 表示第i个隐藏层到输出层、输入层到隐藏层、隐藏层之间的权重矩阵,反向计算时, $V'^{(i)}$ 、 $U'^{(i)}$ 、 $W'^{(i)}$ 表示相对应的反向权重矩阵。i表示BLSTM层数,且 $i=0,1,2L\infty$ ,表示输出层的值,预测模型如下:

$$[0174] \quad \begin{cases} o_t = g(V^{(i)} s_t^{(i)} + V'^{(i)} s_t'^{(i)}) \\ s_t^{(i)} = f(U^{(i)} s_t^{(i-1)} + W^{(i)} s_{t-1}^{(i)}) \\ s_t'^{(i)} = f(U'^{(i)} s_t'^{(i-1)} + W'^{(i)} s_{t+1}'^{(i)}) \\ \dots\dots \\ s_t^{(1)} = f(U^{(1)} x_t + W^{(1)} s_{t-1}^{(1)}) \\ s_t'^{(1)} = f(U'^{(1)} x_t + W'^{(1)} s_{t-1}'^{(1)}) \end{cases} \quad (13)$$

[0175] 其中,公式中出现的变量为BLSTM神经元中的权重,不在展开。根据预测对象的不同,对预测模型构造不同的输入输出即可,预测结果的精确程度通过均方误差、均方根误差、平均绝对误差、决定系数四种评价指标进行评价,对于预测值为  $\hat{y} = \{\hat{y}_1, \hat{y}_2, \hat{y}_3, \dots, \hat{y}_n\}$ , 真实值为  $y = \{y_1, y_2, y_3, \dots, y_n\}$ 。

[0176] ③均方误差(MSE)

[0177] MSE(Mean Squared Error)叫做均方误差,又叫方差,MSE的定义如式下:

$$[0178] \quad MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (14)$$

[0179] 其取值范围为  $[0, +\infty)$ , 当预测值与真实值完全吻合时等于0,即完美模型;误差越大,该值越大。

[0180] ②均方根误差(RMSE)

[0181] RMSE(Root Mean Squard Error)均方根误差,亦称标准误差,其实就是MSE加了个根号,这样数量级上比较直观,比如RMSE=10,可以认为回归效果相比真实值平均相差10, RMSE的定义如下:

$$[0182] \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (15)$$

[0183] 其取值范围为  $[0, +\infty)$ , 当预测值与真实值完全吻合时等于0,即完美模型;误差越大,该值越大。

[0184] ③平均绝对误差(MAE)

[0185] 平均绝对误差(Mean Absolute Deviation),又叫平均绝对离差。平均绝对误差可以避免误差相互抵消的问题,因而可以准确反映实际预测误差的大小,MAE的定义如下:

$$[0186] \quad MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

[0187] 其取值范围为  $[0, +\infty)$ , 当预测值与真实值完全吻合时等于0,即完美模型;误差越大,该值越大。

[0188] ④决定系数( $R^2$ )

[0189] 决定系数 $R^2$ (R-Square),也称为判定系数或者拟合优度,一般在回归模型里用于评估预测值和实际值的符合程度, $R^2$ 的定义如下:

$$[0190] \quad R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y}_i - y_i)^2} \quad (17)$$

[0191] 其取值范围为  $[0, 1]$ , 一般来说, $R^2$ 越大,表示模型拟合效果越好,如果结果是0,说明模型拟合效果很差;如果结果是1,说明模型无差错。

[0192] 8. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于所述步骤(4)中的未来态势管控阶段,态势管控的关键在于调压方式的选取,本发明采用分布式电源、电网设备进行调压。

[0193] 对于变速双馈感应式发电机组,双馈发电机控制依赖于矢量控制技术,利用该技

术进行PQ解耦,使双馈风机能够对无功电压进行优化控制,其中定子磁链定向控制技术被运用到转子侧变频器中,即把以同步速旋转的坐标轴置于定子磁链上,其转子侧的功率如下:

$$[0194] \quad \begin{cases} P_s = u_s \frac{L_m}{L_s} i_{rq} \\ Q_s = u_s \left( \frac{L_m}{L_s} i_{rd} - \frac{1}{L_s} \psi_s \right) \end{cases} \quad (18)$$

[0195] 式中, $u_s$ 代表定子电压幅值; $L_s$ 代表定子自感; $L_m$ 代表定子和转子之间的互感; $i_{rq}$ , $i_{rd}$ 分别代表dq0坐标系下d轴和q轴的转子电流; $\psi_s$ 代表定子磁链。

[0196] 由式(18)可知,对转子电流进行控制可分别实现对转子侧有功及无功功率的控制。利用转子侧变频器进行控制,转速控制器提供有功功率参考值,依据风机电压控制的要求确定无功功率参考值。网侧变频器用于有功、无功的解耦,一般采用电压定向控制方案。网侧变频器电压定向控制是将其电压矢量置于轴上,在网侧变频器电压参考坐标系下,网侧的功率为:

$$[0197] \quad \begin{cases} P_g = u_s i_d \\ Q_g = -u_s i_q \end{cases} \quad (19)$$

[0198] 式中, $i_d$ , $i_q$ 分别代表dq0坐标系下注入网络侧的有功电流和无功电流,由式(19)可知,PQ的解耦控制可以通过控制 $i_d$ , $i_q$ 来完成。

[0199] 通过上述分析可知,双馈发电机组可以同时通过定子侧变频器和网侧变频器向电网输出无功功率,即可以参与电网的无功补偿,实现电压控制。

[0200] 对于分布式电源中的光伏发电,其基本原理是光能到电能的转换,其中,逆变器采用电压型逆变器。光伏发电要完成并网,需要光伏阵列通过逆变器实现直流电到交流电的转换,这种并网方式只存在逆变环节,因此逆变器的控制系统起着非常重要的作用

[0201] 光伏系统向电网侧输送的功率可由下式得到:

$$[0202] \quad \begin{cases} P = \frac{U_1 U}{Z} \cos(\varphi_z - \phi) - \frac{U^2}{Z} \cos \varphi_z \\ Q = \frac{U_1 U}{Z} \sin(\varphi_z - \phi) - \frac{U^2}{Z} \sin \varphi_z \end{cases} \quad (20)$$

[0203] 式中, $Z$ 代表电网和逆变器之间的电抗; $\varphi_z$ 代表线路阻抗角; $U$ 代表电网侧电压幅值; $U_1$ 代表逆变器输出电压的幅值; $\phi$ 代表 $U$ 与 $U_1$ 之间的相位差。

[0204] 由式(20)可知,通过调节 $U_1$ 和 $\phi$ 可实现对系统功率的调节,因此,光伏发电系统同样具有无功输出的能力,可以起到对电网无功补偿的作用,实现对电压的调节。

[0205] 对于电网设备的调压控制,主要采用并联电容器、静止无功补偿器SVC、有载调压变压器,电网设备调压方式固定,不在展开说明。

[0206] 9. 根据权利要求1所述的一种基于态势感知的电网无功主动预测及控制技术,其特征在于所述步骤(4)中的未来态势管控,无功调压方式选取之后,关键在于通过优化算法计算出最佳的补偿容量,通过改进的粒子群算法来计算每个无功补偿薄弱分区内的最优无功补偿容量,改进的粒子群算法(Particle Swarm Optimization,PSO)无需梯度信息,参数

少,在实际应用中无需编码,可直接使用。每个粒子会根据当前极值Pbest和全局极值Gbest更新飞行速度和此刻的位置,如(21)、(22)式所示:

$$[0207] \quad V_i^{k+1} = V_i^k + c_1 r_1 (P_i^k - X_i^k) + c_2 r_2 (P_g^k - X_i^k) \quad (21)$$

$$[0208] \quad X_i^{k+1} = X_i^k + V_i^{k+1} \quad (22)$$

[0209] 其中, $V_i$ 为速度; $X_i$ 为位置; $k$ 为迭代的次数;个体学习因子 $c_1$ 和社会学习因子 $c_2$ 一般取值为2; $r_1$ 和 $r_2$ 是位于 $[0, 1]$ 区间内的随机数。

[0210] 以节点电压最优和网损最小为目标函数,最终能得到系统未来态势的最优无功补偿方案。系统网损最小

$$[0211] \quad P_{loss}(t) = \sum_{i,j \in N} r_{ij} I_{ij}(t)^2 \quad (23)$$

[0212] 其中, $P_{loss}(t)$ 为t时刻系统总网损, $r_{ij}$ 为支路ij的电阻值, $I_{ij}(t)$ 是t时刻支路ij的电流, $N$ 为配网线路集合。节点电压偏差最小:

$$[0213] \quad \Delta U(t) = \sum_{i=1}^N |U_i(t) - 1| \quad (24)$$

[0214] 其中: $\Delta U(t)$ 节点在t时刻的电压偏差。潮流约束:

$$[0215] \quad \begin{cases} P_i = V_i \sum_{j=1}^n V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = V_i \sum_{j=1}^n V_j (G_{ij} \sin \theta_{ij} \cos \theta_{ij} - B_{ij} \cos \theta_{ij}) \end{cases} \quad (25)$$

[0216] 其中, $P_i, Q_i$ 分别代表节点i处的有功功率和无功功率; $V_i, V_j$ 分别代表节点i, j处的电压; $G_{ij}, B_{ij}, \theta_{ij}$ 分别代表节点i, j间的电导,电纳和相位差。

[0217] 电压约束:

$$[0218] \quad U_{\min} \leq U_i \leq U_{\max} \quad (26)$$

[0219] 无功补偿装置约束:

$$[0220] \quad \begin{cases} Q_{DG.i.min} < Q_{DG.i} < Q_{DG.i.max} \\ Q_{c.i.min} < Q_{c.i} < Q_{c.i.max} \end{cases} \quad (27)$$

[0221] 其中, $Q_{DG.i.min}, Q_{DG.i.max}$ 为节点i处分布式电源无功出力上下限, $Q_{c.i.min}, Q_{c.i.max}$ 为节点i处无功补偿设备容量上下限。

[0222] 基于无功薄弱分区、态势预测,继而通过改进的粒子群算法进行全网优化,可以确定每个薄弱分区的最优补偿容量,从而给出最优的无功补偿方案。

[0223] 10. 根据权利要求9所述未来态势管控中的最优无功补偿方案,其特征在于,态势感知准确率的把控,态势感知准确率从三方面进行考虑,分别为电压感知准确率、网损感知准确率、无功补偿方案感知准确率,根据测试集数据得到系统节点电压、系统网损以及预测管控方案,构成预测态势评估集合:

$$[0224] \quad W = \{V_1, V_2, \dots, V_m, P_{loss}, Q_1, Q_2, \dots, Q_N\} \quad (28)$$

[0225] 其中V为未来态势中的电压幅值, $P_{loss}$ 为未来态势中的系统网损,Q为未来态势中的无功补偿容量。

[0226] 实际态势评估集合为

[0227]  $W_{\text{TRUTH}} = \{V_{T1}, V_{T2}, \dots, V_{Tm}, P_{T\text{loss}}, Q_{T1}, Q_{T2}, \dots, Q_{TN}\}$  (29)

[0228] 其中,其中V为实际态势中的电压幅值, $P_{\text{loss}}$ 为实际态势中的系统网损,Q为实际态势中的无功补偿容量。

[0229] 通过拟合优度:

[0230] 
$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{Y}_i - Y_i)^2}{\sum_{i=1}^n (\bar{Y}_i - Y_i)^2} \quad (30)$$

[0231] 来判定态势感知的准确率。



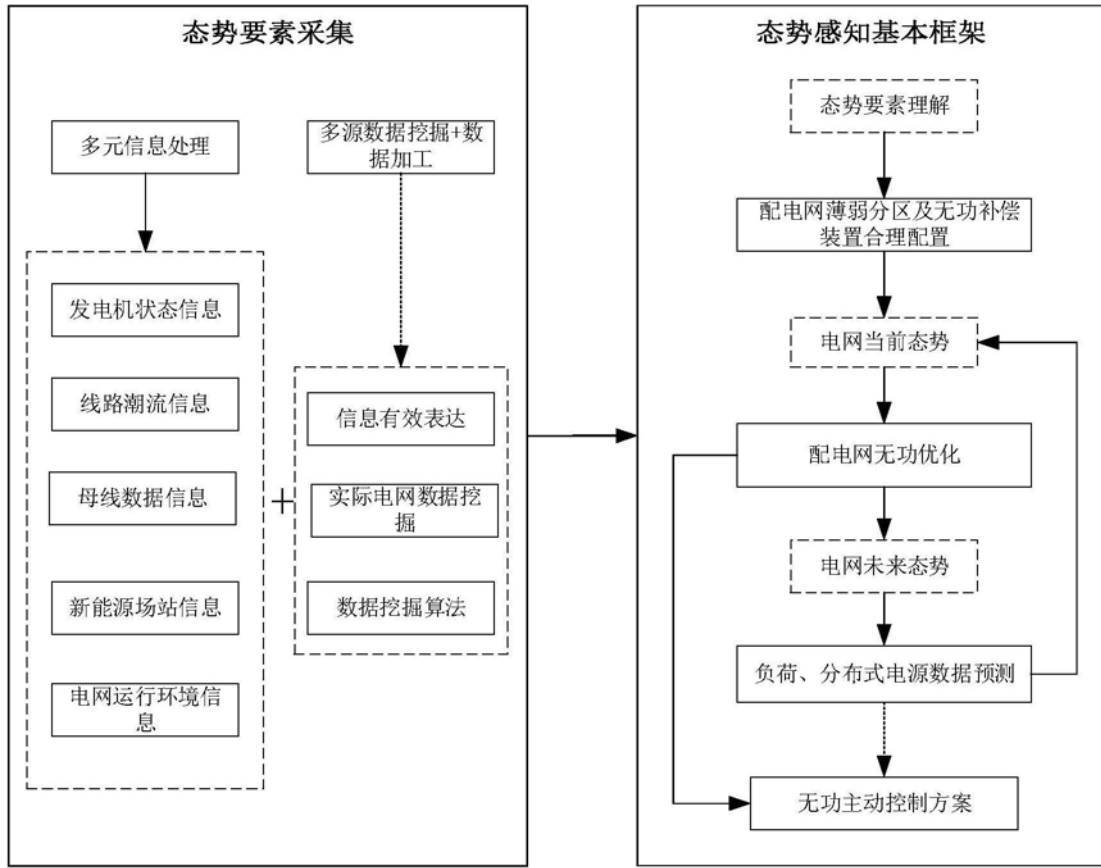


图1




图2




图3

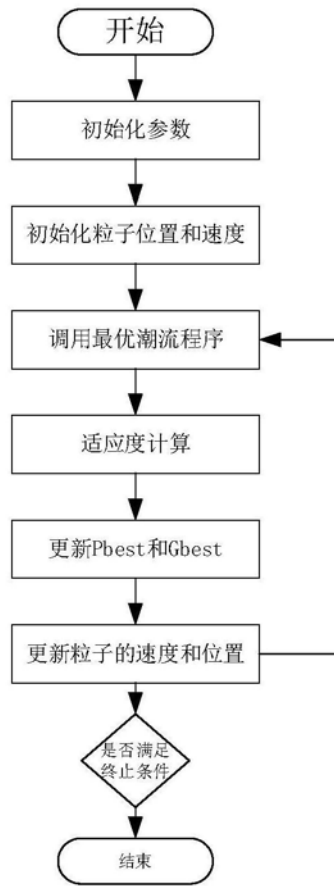


图4

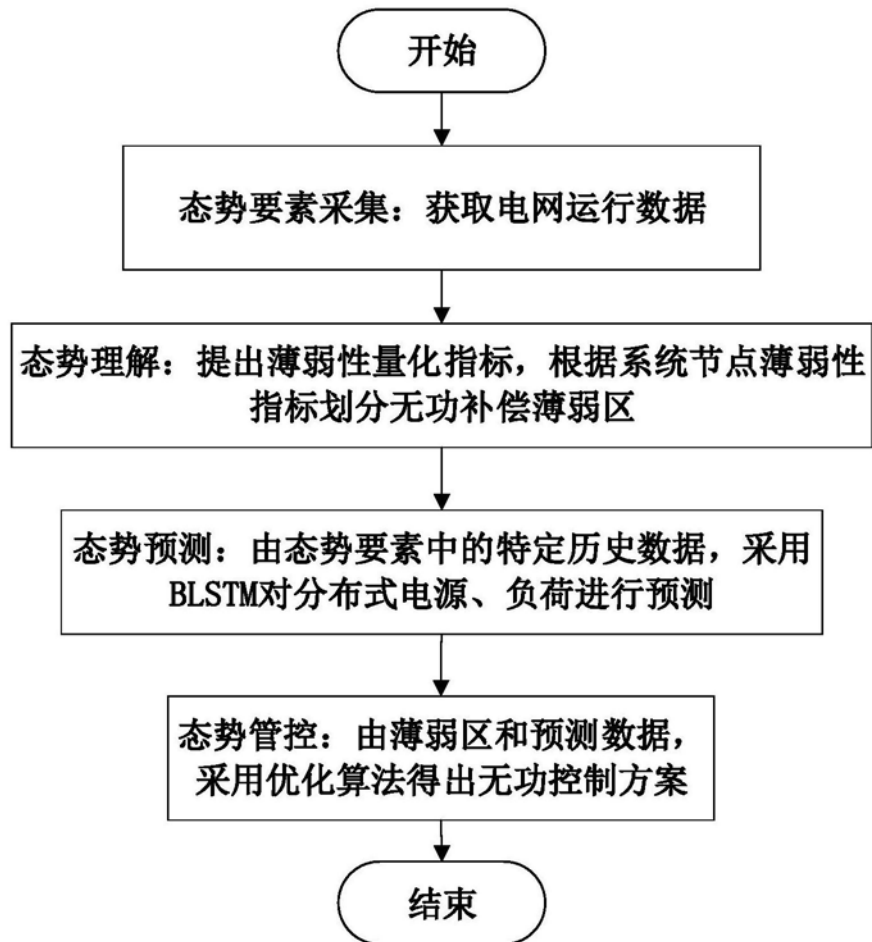


图5