



(12)发明专利申请

(10)申请公布号 CN 111415010 A

(43)申请公布日 2020.07.14

(21)申请号 202010202498.5

(22)申请日 2020.03.20

(71)申请人 广东电网有限责任公司阳江供电局
地址 529500 广东省阳江市漠江路110号

(72)发明人 钱峰 刘俊磊 杨韵 宋子强
蔡秋娜 彭孝强 陈鹏 张韧

(74)专利代理机构 杭州求是专利事务所有限公
司 33200

代理人 刘静

(51) Int. Cl.

G06N 7/00(2006.01)

G06N 3/04(2006.01)

G06N 3/08(2006.01)

G06Q 50/06(2012.01)

权利要求书2页 说明书5页 附图2页

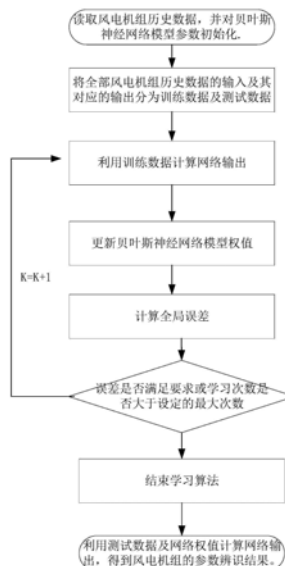
(54)发明名称

一种基于贝叶斯神经网络的风电机组参数
辨识方法

(57)摘要

本发明公开了一种基于贝叶斯神经网络的风电机组参数辨识方法,包括以下步骤:S1,采集风电机组历史数据,并对贝叶斯神经网络模型参数初始化;S2,将全部风电机组历史数据分为训练数据及测试数据;S3,利用训练数据计算网络输出;S4,更新贝叶斯神经网络模型权值;S5,计算全局误差,判断是否满足要求,若满足要求,获得最终的神经网络权值矩阵,结束学习算法。否则,返回S3,进入下一轮的学习;S6,利用测试数据及神经网络权值计算网络输出,得到风电机组的参数辨识结果。本发明将贝叶斯理论与神经网络模型进行结合,与传统参数辨识方法相比,该方法在辨识过程中,考虑了外部环境不确定性变化时的影响,该方法具有全局误差容易收敛,迭代步数少的优点。

CN 111415010 A



1. 一种基于贝叶斯神经网络的风电机组参数辨识方法,其特征在于,包括以下步骤:

步骤S1:采集风电机组历史数据,并对贝叶斯神经网络模型参数初始化;所述风电机组历史数据包括风速和故障对应的参数数据;

步骤S2:将步骤S1采集的风电机组历史数据分为训练数据集及测试数据集;

步骤S3:利用步骤S2得到的训练数据集计算网络输出,具体如下:

将不确定性引入贝叶斯神经网络模型,贝叶斯神经网络模型为三层网络结构,输入为 $y(k-1) \cdots y(k-n)$ 、 $x(k-1) \cdots x(k-n)$,实际输出为 $y_m(k)$;其中, k 表示正在迭代的次数, n 表示输入和对应的输出的个数; x 和 y 分别表示神经网络的输入和输出变量;将该神经网络模型视为条件模型 P ,该条件模型 P 是通过参数 θ 进行参数化的,并且在给定输入 x 时,需要得到对应的输出 y ;

根据贝叶斯定理得到当训练数据为 D 作为输入时的模型参数 θ 概率为:

$$p(\theta|D) = \frac{p(D|\theta) * p(\theta)}{p(D)} \quad (1)$$

其中, $p(\theta)$ 表示参数 θ 的概率; $p(D|\theta)$ 表示已知参数 θ 条件下 D 的概率; $p(D)$ 表示数据 D 的概率。

在新的输入 x^* 与数据 D 同时输入到条件模型 P 中时,输出为 y^* 的概率为:

$$p(y^*|x^*,D) = \int p(y^*|x^*,\theta) p(\theta|D) d\theta \quad (2)$$

其中, $p(y^*|x^*,\theta)$ 表示已知 x^* , θ 时 y^* 的条件分布。

在贝叶斯神经网络中:首先使用已知的分布 q 去逼近真实的分布 p ,其中 q 的具体形式通过参数 θ 表示;其次,利用等距采样法从分布 q 中采取样本数据,得到贝叶斯神经网络模型参数 θ^* 如式(4)所示。

$$\theta^* = \arg \min_{\theta} \sum_{i=1}^n \log(q_{\theta}(\omega_j^s | D)) - \log(p(\omega_j^s)) - \log(p(D | \omega_j^s)) \quad (3)$$

式中, $\arg \min_{\theta}$ 表示当目标函数取最小值时 θ 的取值; $q_{\theta}(\omega_j^s | D)$ 表示已知参数 D 时参数 ω_j^s 的条件概率, q_{θ} 为使用参数 θ 表示的分布 q , $p(\omega_j^s)$ 表示参数 ω_j^s 的概率; $p(D | \omega_j^s)$ 表示已知参数 ω_j^s 时数据 D 的条件概率,其中 ω_j^s 为模型权重参数, $s=1$ 或 2 , $s=1$ 时为输入层至隐藏层的权值, $s=2$ 时为隐藏层至输出层的权值;

步骤S4为,更新贝叶斯神经网络模型权值,得到网络权值矩阵;权值更新过程包括以下步骤:

(1)采用梯度下降法,隐藏层至输出层权值的学习算法如下:

$$\delta^2 = \frac{\partial E(k)}{\partial e(k)} = \frac{\partial E(k)}{\partial e(k)} \frac{\partial e(k)}{\partial y_m(k)} = -e(k) \quad (4)$$

$$\Delta \omega_j^2(k) = -\eta \frac{\partial E(k)}{\partial \omega_j^2(k-1)} = \eta e(k) O_j^2(k) \quad (5)$$

其中, δ^2 表示全局误差相应于输出误差的变化率, η 表示学习速率, $\eta=0.5$ 。 O_j^2 表示隐藏层至输出层之间的连接函数; $E(k)$ 表示网络每一层的误差, $e(k)$ 为输出误差; $\partial \omega_j^2(k)$ 表示

$\omega_j(k)$ 的二次微分, $\Delta\omega_j^2(k)$ 表示全局误差相应于 $\omega_j^2(k)$ 的变化率, $\omega_j^2(k)$ 为第 j 个神经元第 k 次迭代时隐藏层至输出层的权值。

隐藏层至输出层的权值更新公式为:

$$\omega_j^2(k) = \omega_j^2(k-1) + \Delta\omega_j^2(k) \quad (6)$$

(2) 输入层至隐藏层权值的学习算法如下:

$$\Delta\omega_j^1(k) = -\eta \frac{\partial E(k)}{\partial \omega_{ji}^{(1)}(k-1)} = -\eta e(k) \omega_j^2(k-1) f'(\text{net}_j^2(k)) O_i^1(k) \quad (7)$$

其中: O_i^1 表示输入层至隐藏层之间的连接函数; $\Delta\omega_j^1(k)$ 表示每次迭代时的更新值, $\omega_{ji}^{(1)}(k-1)$ 表示从输入层 j 至隐藏层 i 的权重第 $k-1$ 次迭代时的值;

$$f'(\text{net}_j^2(k)) = \frac{e^{-x}}{(1+e^{-x})^2} \Big|_{x=\text{net}_j^2(k)} \quad (8)$$

$\text{net}_j^2(k)$ 表示 k 次迭代时第 j 个隐藏层单元的输入;

则输入层至隐藏层的权值更新公式为:

$$\omega_j^1(k) = \omega_j^1(k-1) + \Delta\omega_j^1(k) \quad (9)$$

步骤S5为, 计算全局误差, 判断是否满足要求, 当全局误差达到预先设置的全局误差精度或学习次数大于设定的最大次数时, 获得最终步骤S4得到的网络权值矩阵, 结束学习算法; 否则, 返回S3, 进入下一轮的迭代学习。全局误差精度 $E_G = 0.002$, 全局误差计算过程如下:

全局误差 E_g 表达式如下所示:

$$E_g = \sum_{k=1}^L E(k) = \frac{1}{2} \sum_{k=1}^L e^2(k) \quad (10)$$

其中: L 表示网络的层数;

$$e(k) = y(k) - y_m(k) \quad (11)$$

其中, $y(k)$ 为第 k 次迭代时的输出;

步骤S6为, 利用测试数据集及网络权值计算网络输出, 得到风电机组的参数辨识结果。

2. 根据权利要求1所述的基于贝叶斯神经网络的风电机组参数辨识方法, 其特征在于, 步骤S2中, 训练数据集和测试数据集比例为7:3。

3. 根据权利要求1所述的基于贝叶斯神经网络的风电机组参数辨识方法, 其特征在于, 步骤S4中, 输入层至隐藏层的初始权值为 $\omega_j^1(1) = \mu_1 / \sigma_1$, 隐藏层至输出层的初始权值为

$\omega_j^2(1) = \mu_2 / \sigma_2$; 均值 μ_1 、 μ_2 和标准差 σ_1 、 σ_2 通过随机初始化得到。

4. 根据权利要求1所述的基于贝叶斯神经网络的风电机组参数辨识方法, 其特征在于, 贝叶斯神经网络模型采用BP网络结构, 以提高神经网络对已有数据的拟合能力和对未来数据的泛化能力。

一种基于贝叶斯神经网络的风电机组参数辨识方法

技术领域

[0001] 本发明涉及智能电网配电领域,更具体地,涉及一种基于贝叶斯神经网络的风电机组参数辨识方法。

背景技术

[0002] 随着风电等新能源接入电力系统中存在的不确定性愈发明显。不确定性的存在,使得系统模型难以用固定参数精确建模。忽略这些模型误差无法得到与实际电网相符的计算结果,无法准确判断电力系统的稳定状况。

[0003] 传统的模型参数辨识方法主要有最小二乘法、梯度下降法和神经网络法。其中前两种辨识方法主要用于线性模型参数辨识,而神经网络方法主要用于非线性模型参数的辨识。风电机组模型为非线性模型,因此对于确定的参数可以用神经网络模型来进行辨识。但由于风电并网运行中风速等外部条件的不确定性,风电机组部分参数会不断变化,传统的确定性参数辨识方法无法应对这种随机性变化。

发明内容

[0004] 本发明为克服上述现有技术缺陷,提供一种基于贝叶斯神经网络的风电机组参数辨识方法。本发明方法考虑了外部环境不确定性变化时的影响,辨识对比结果显示,该方法具有全局误差容易收敛,迭代步数少的优点。

[0005] 本发明的目的是通过以下技术方案来实现的:一种基于贝叶斯神经网络的风电机组参数辨识方法,包括以下步骤:

[0006] 步骤S1:采集风电机组历史数据,并对贝叶斯神经网络模型参数初始化;所述风电机组历史数据包括风速和故障对应的参数数据;

[0007] 步骤S2:将步骤S1采集的风电机组历史数据分为训练数据集及测试数据集;

[0008] 步骤S3:利用步骤S2得到的训练数据集计算网络输出,具体如下:

[0009] 将不确定性引入贝叶斯神经网络模型,贝叶斯神经网络模型为三层网络结构,输入为 $y(k-1) \cdots y(k-n)$ 、 $x(k-1) \cdots x(k-n)$,实际输出为 $y_m(k)$;其中, k 表示正在迭代的次数, n 表示输入和对应的输出的个数; x 和 y 分别表示神经网络的输入和输出变量;将该神经网络模型视为条件模型 P ,该条件模型 P 是通过参数 θ 进行参数化的,并且在给定输入 x 时,需要得到对应的输出 y ;

[0010] 根据贝叶斯定理得到当训练数据为 D 作为输入时的模型参数 θ 概率为:

$$[0011] \quad p(\theta|D) = \frac{p(D|\theta) * p(\theta)}{p(D)} \quad (1)$$

[0012] 其中, $p(\theta)$ 表示参数 θ 的概率; $p(D|\theta)$ 表示已知参数 θ 条件下 D 的概率; $p(D)$ 表示数据 D 的概率。

[0013] 在新的输入 x^* 与数据 D 同时输入到条件模型 P 中时,输出为 y^* 的概率为:

$$[0014] \quad p(y^*|x^*,D) = \int p(y^*|x^*,\theta) p(\theta|D) d\theta \quad (2)$$

[0015] 其中, $p(y^* | x^*, \theta)$ 表示已知 x^* , θ 时 y^* 的条件分布。

[0016] 在贝叶斯神经网络中: 首先使用已知的分布 q 去逼近真实的分布 p , 其中 q 的具体形式通过参数 θ 表示; 其次, 利用等距采样法从分布 q 中采取样本数据, 得到贝叶斯神经网络模型参数 θ^* 如式 (4) 所示。

$$[0017] \quad \theta^* = \arg \min_{\theta} \sum_{i=1}^n \log(q_{\theta}(\omega_j^s | D)) - \log(p(\omega_j^s)) - \log(p(D | \omega_j^s)) \quad (3)$$

[0018] 式中, $\arg \min_{\theta}$ 表示当目标函数取最小值时 θ 的取值; $q_{\theta}(\omega_j^s | D)$ 表示已知参数 D 时参数 ω_j^s 的条件概率, q_{θ} 为使用参数 θ 表示的分布 q , $p(\omega_j^s)$ 表示参数 ω_j^s 的概率; $p(D | \omega_j^s)$ 表示已知参数 ω_j^s 时数据 D 的条件概率, 其中 ω_j^s 为模型权重参数, $s=1$ 或 2 , $s=1$ 时为输入层至隐藏层的权值, $s=2$ 时为隐藏层至输出层的权值;

[0019] 步骤 S4 为, 更新贝叶斯神经网络模型权值, 得到网络权值矩阵; 权值更新过程包括以下步骤:

[0020] (1) 采用梯度下降法, 隐藏层至输出层权值的学习算法如下:

$$[0021] \quad \delta^2 = \frac{\partial E(k)}{\partial e(k)} = \frac{\partial E(k)}{\partial e(k)} \frac{\partial e(k)}{\partial y_m(k)} = -e(k) \quad (4)$$

$$[0022] \quad \Delta \omega_j^2(k) = -\eta \frac{\partial E(k)}{\partial \omega_j^2(k-1)} = \eta e(k) O_j^2(k) \quad (5)$$

[0023] 其中, δ^2 表示全局误差相应于输出误差的变化率, η 表示学习速率, $\eta=0.5$ 。 O_j^2 表示隐藏层至输出层之间的连接函数; $E(k)$ 表示网络每一层的误差, $e(k)$ 为输出误差; $\partial \omega_j^2(k)$ 表示 $\omega_j^2(k)$ 的二次微分, $\Delta \omega_j^2(k)$ 表示全局误差相应于 $\omega_j^2(k)$ 的变化率, $\omega_j^2(k)$ 为第 j 个神经元第 k 次迭代时隐藏层至输出层的权值。

[0024] 隐藏层至输出层的权值更新公式为:

$$[0025] \quad \omega_j^2(k) = \omega_j^2(k-1) + \Delta \omega_j^2(k) \quad (6)$$

[0026] (3) 输入层至隐藏层权值的学习算法如下:

$$[0027] \quad \Delta \omega_j^1(k) = -\eta \frac{\partial E(k)}{\partial \omega_{ji}^1(k-1)} = -\eta e(k) \omega_j^2(k-1) f'(\text{net}_j^2(k)) O_i^1(k) \quad (7)$$

[0028] 其中: O_i^1 表示输入层至隐藏层之间的连接函数; $\Delta \omega_j^1(k)$ 表示每次迭代时的更新值, $\omega_{ji}^1(k-1)$ 表示从输入层 j 至隐藏层 i 的权重第 $k-1$ 次迭代时的值;

$$[0029] \quad f'(\text{net}_j^2(k)) = \frac{e^{-x}}{(1+e^{-x})^2} \Big|_{x=\text{net}_j^2(k)} \quad (8)$$

[0030] $\text{net}_j^2(k)$ 表示 k 次迭代时第 j 个隐藏层单元的输入;

[0031] 则输入层至隐藏层的权值更新公式为:

$$[0032] \quad \omega_j^1(k) = \omega_j^1(k-1) + \Delta \omega_j^1(k) \quad (9)$$

[0033] 步骤S5为,计算全局误差,判断是否满足要求,当全局误差达到预先设置的全局误差精度或学习次数大于设定的最大次数时,获得最终步骤S4得到的网络权值矩阵,结束学习算法;否则,返回S3,进入下一轮的迭代学习。全局误差精度 $E_G=0.002$,全局误差计算过程如下:

[0034] 全局误差 E_g 表达式如下所示:

$$[0035] \quad E_g = \sum_{k=1}^L E(k) = \frac{1}{2} \sum_{k=1}^L e^2(k) \quad (10)$$

[0036] 其中:L表示网络的层数;

$$[0037] \quad e(k) = y(k) - y_m(k) \quad (11)$$

[0038] 其中, $y(k)$ 为第k次迭代时的输出;

[0039] 步骤S6为,利用测试数据集及网络权值计算网络输出,得到风电机组的参数辨识结果。

[0040] 进一步地,步骤S2中,训练数据集和测试数据集比例为7:3。

[0041] 进一步地,步骤S4中,输入层至隐藏层的初始权值为 $\omega_j^1(1) = \mu_1 / \sigma_1$,隐藏层至输出层的初始权值为 $\omega_j^2(1) = \mu_2 / \sigma_2$;均值 μ_1 、 μ_2 和标准差 σ_1 、 σ_2 通过随机初始化得到。

[0042] 进一步地,贝叶斯神经网络模型采用BP网络结构,以提高神经网络对已有数据的拟合能力和对未来数据的泛化能力。

[0043] 本发明的有益效果如下:本发明将贝叶斯理论与神经网络模型进行结合,与传统参数辨识方法相比,本发明在辨识过程中,考虑了外部环境不确定性变化对风电机组参数的影响,将贝叶斯神经网络的参数学习方法用于风机组参数辨识中,具有全局误差容易收敛,迭代步数少的优点。

附图说明

[0044] 图1为本发明基于贝叶斯神经网络的风电机组参数辨识方法流程图;

[0045] 图2为贝叶斯神经网络结构图。

具体实施方式

[0046] 为使本发明的上述目的、特征和优点能够更加明显易懂,下面结合附图对本发明的具体实施方式做详细的说明。

[0047] 在下面的描述中阐述了很多具体细节以便于充分理解本发明,但是本发明还可以采用其他不同于在此描述的其它方式来实施,本领域技术人员可以在不违背本发明内涵的情况下做类似推广,因此本发明不受下面公开的具体实施例的限制。

[0048] 如图1所示,本实施例提供一种基于贝叶斯神经网络的风电机组参数辨识方法,包括以下步骤:

[0049] 步骤S1:采集风电机组历史数据,并对贝叶斯神经网络模型参数初始化;为了进行参数辨识,本实施例采集2015-2018年三年全部数据,包括风速、故障对应的参数数据。

[0050] 步骤S2:将步骤S1采集的风电机组历史数据分为训练数据集及测试数据集;为了

利用2015-2018年三年全部数据进行训练和测试,将全部数据按7:3的比例进行随机抽取,70%的数据用于对贝叶斯神经网络参数的训练,30%的数据用于对模型的测试。

[0051] 步骤S3:利用步骤S2得到的训练数据集计算网络输出,具体如下:

[0052] 将不确定性引入贝叶斯神经网络模型,贝叶斯神经网络模型采用BP网络结构,以提高神经网络对已有数据的拟合能力和对未来数据的泛化能力,贝叶斯神经网络模型为三层网络结构,如附图2所示,输入为 $y(k-1) \cdots y(k-n)$ 、 $x(k-1) \cdots x(k-n)$,实际输出为 $y_m(k)$;其中, k 表示正在迭代的次数, n 表示输入和对应的输出的个数; x 和 y 分别表示神经网络的输入和输出变量;将该神经网络模型视为条件模型 P ,该条件模型 P 是通过参数 θ 进行参数化的,并且在给定输入 x 时,需要得到对应的输出 y ;

[0053] 根据贝叶斯定理得到当训练数据为 D 作为输入时的模型参数 θ 概率为:

$$[0054] \quad p(\theta|D) = \frac{p(D|\theta) * p(\theta)}{p(D)} \quad (1)$$

[0055] 其中, $p(\theta)$ 表示参数 θ 的概率; $p(D|\theta)$ 表示已知参数 θ 条件下 D 的概率; $p(D)$ 表示数据 D 的概率。

[0056] 在新的输入 x^* 与数据 D 同时输入到条件模型 P 中时,输出为 y^* 的概率为:

$$[0057] \quad p(y^*|x^*,D) = \int p(y^*|x^*,\theta) p(\theta|D) d\theta \quad (2)$$

[0058] 其中, $p(y^*|x^*,\theta)$ 表示已知 x^* , θ 时 y^* 的条件分布。

[0059] 在贝叶斯神经网络中:首先使用已知的分布 q 去逼近真实的分布 p ,其中 q 的具体形式通过参数 θ 表示;其次,利用等距采样法从分布 q 中采取样本数据,得到贝叶斯神经网络模型参数 θ^* 如式(4)所示。

$$[0060] \quad \theta^* = \arg \min_{\theta} \sum_{i=1}^n \log(q_{\theta}(\omega_j^s | D)) - \log(p(\omega_j^s)) - \log(p(D | \omega_j^s)) \quad (3)$$

[0061] 式中, $\arg \min_{\theta}$ 表示当目标函数取最小值时 θ 的取值; $q_{\theta}(\omega_j^s | D)$ 表示已知参数 D 时参数 ω_j^s 的条件概率, q_{θ} 为使用参数 θ 表示的分布 q , $p(\omega_j^s)$ 表示参数 ω_j^s 的概率; $p(D | \omega_j^s)$ 表示已知参数 ω_j^s 时数据 D 的条件概率,其中 ω_j^s 为模型权重参数, $s=1$ 或 2 , $s=1$ 时为输入层至隐藏层的权值, $s=2$ 时为隐藏层至输出层的权值;

[0062] 步骤S4为,更新贝叶斯神经网络模型权值,得到网络权值矩阵;输入层至隐藏层的初始权值为 $\omega_j^1(1) = \mu_1 / \sigma_1$,隐藏层至输出层的初始权值为 $\omega_j^2(1) = \mu_2 / \sigma_2$;均值 μ_1 、 μ_2 和标准差 σ_1 、 σ_2 理论上通过初始化得到,取值均有可能不同,在运算时取值为 $\mu_1 = \mu_2 = 2 + \text{random}(0, 1)$ 、 $\sigma_1 = \sigma_2 = 10 + \text{random}(0, 1)$,其中 $\text{random}(0, 1)$ 表示0到1之间的随机数。

[0063] 权值更新过程包括以下步骤:

[0064] (1) 采用梯度下降法,隐藏层至输出层权值的学习算法如下:

$$[0065] \quad \delta^2 = \frac{\partial E(k)}{\partial e(k)} = \frac{\partial E(k)}{\partial e(k)} \frac{\partial e(k)}{\partial y_m(k)} = -e(k) \quad (4)$$

$$[0066] \quad \Delta \omega_j^2(k) = -\eta \frac{\partial E(k)}{\partial \omega_j^2(k-1)} = \eta e(k) O_j^2(k) \quad (5)$$

[0067] 其中, δ^2 表示全局误差相应于输出误差的变化率, η 表示学习速率, $\eta=0.5$ 。 O_j^2 表示隐藏层至输出层之间的连接函数; $E(k)$ 表示网络每一层的误差, $e(k)$ 为输出误差; $\partial\omega_j^2(k)$ 表示 $\omega_j(k)$ 的二次微分, $\Delta\omega_j^2(k)$ 表示全局误差相应于 $\omega_j^2(k)$ 的变化率, $\omega_j^2(k)$ 为第j个神经元第k次迭代时隐藏层至输出层的权值。

[0068] 隐藏层至输出层的权值更新公式为:

$$[0069] \quad \omega_j^2(k) = \omega_j^2(k-1) + \Delta\omega_j^2(k) \quad (6)$$

[0070] (4) 输入层至隐藏层权值的学习算法如下:

$$[0071] \quad \Delta\omega_j^1(k) = -\eta \frac{\partial E(k)}{\partial \omega_{ji}^{(1)}(k-1)} = -\eta e(k) \omega_j^2(k-1) f'(\text{net}_j^2(k)) O_i^1(k) \quad (7)$$

[0072] 其中: O_i^1 表示输入层至隐藏层之间的连接函数; $\Delta\omega_j^1(k)$ 表示每次迭代时的更新值, $\omega_{ji}^{(1)}(k-1)$ 表示从输入层j至隐藏层i的权重第k-1次迭代时的值;

$$[0073] \quad f'(\text{net}_j^2(k)) = \frac{e^{-x}}{(1+e^{-x})^2} \Big|_{x=\text{net}_j^2(k)} \quad (8)$$

[0074] $\text{net}_j^2(k)$ 表示k次迭代时第j个隐藏层单元的输入;

[0075] 则输入层至隐藏层的权值更新公式为:

$$[0076] \quad \omega_j^1(k) = \omega_j^1(k-1) + \Delta\omega_j^1(k) \quad (9)$$

[0077] 步骤S5为, 计算全局误差, 判断是否满足要求, 当全局误差达到预先设置的全局误差精度或学习次数大于设定的最大次数时, 获得最终步骤S4得到的网络权值矩阵, 结束学习算法; 否则, 返回S3, 进入下一轮的迭代学习。全局误差精度 $E_G=0.002$, 全局误差计算过程如下:

[0078] 全局误差 E_g 表达式如下所示:

$$[0079] \quad E_g = \sum_{t=1}^L E(k) = \frac{1}{2} \sum_{t=1}^L e^2(k) \quad (10)$$

[0080] 其中: L 表示网络的层数;

$$[0081] \quad e(k) = y(k) - y_m(k) \quad (11)$$

[0082] 其中, $y(k)$ 为第k次迭代时的输出;

[0083] 步骤S6为, 利用测试数据集及网络权值计算网络输出, 得到风电机组的参数辨识结果。

[0084] 显然, 本发明的上述实施例仅仅是为清楚地说明本发明所作的举例, 而并非是对本发明的实施方式的限定。对于所属领域的普通技术人员来说, 在上述说明的基础上还可以做出其它不同形式的变化或变动。这里无需也无法对所有的实施方式予以穷举。凡在本发明的精神和原则之内所作的任何修改、等同替换和改进等, 均应包含在本发明权利要求的保护范围之内。

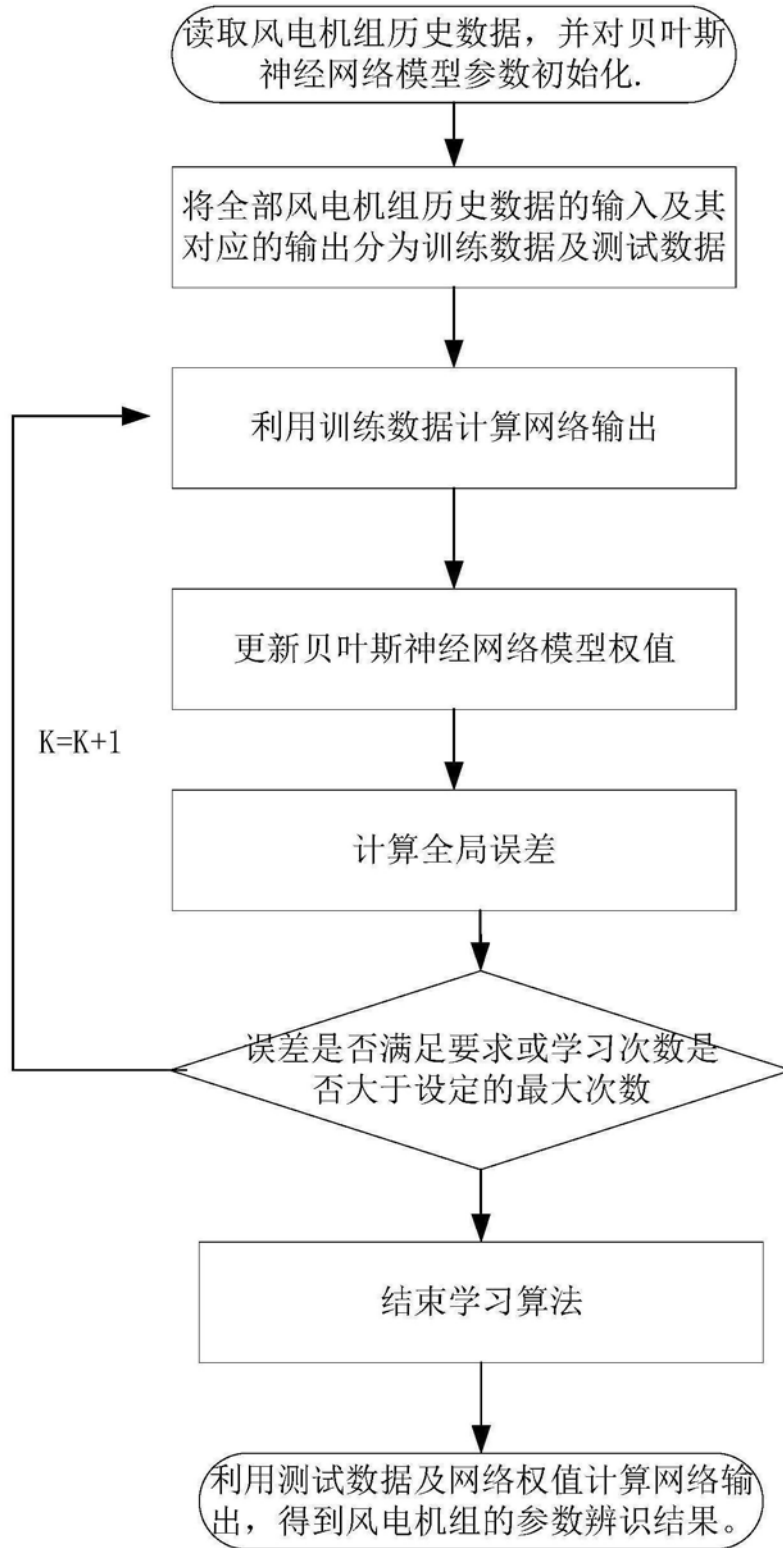


图1

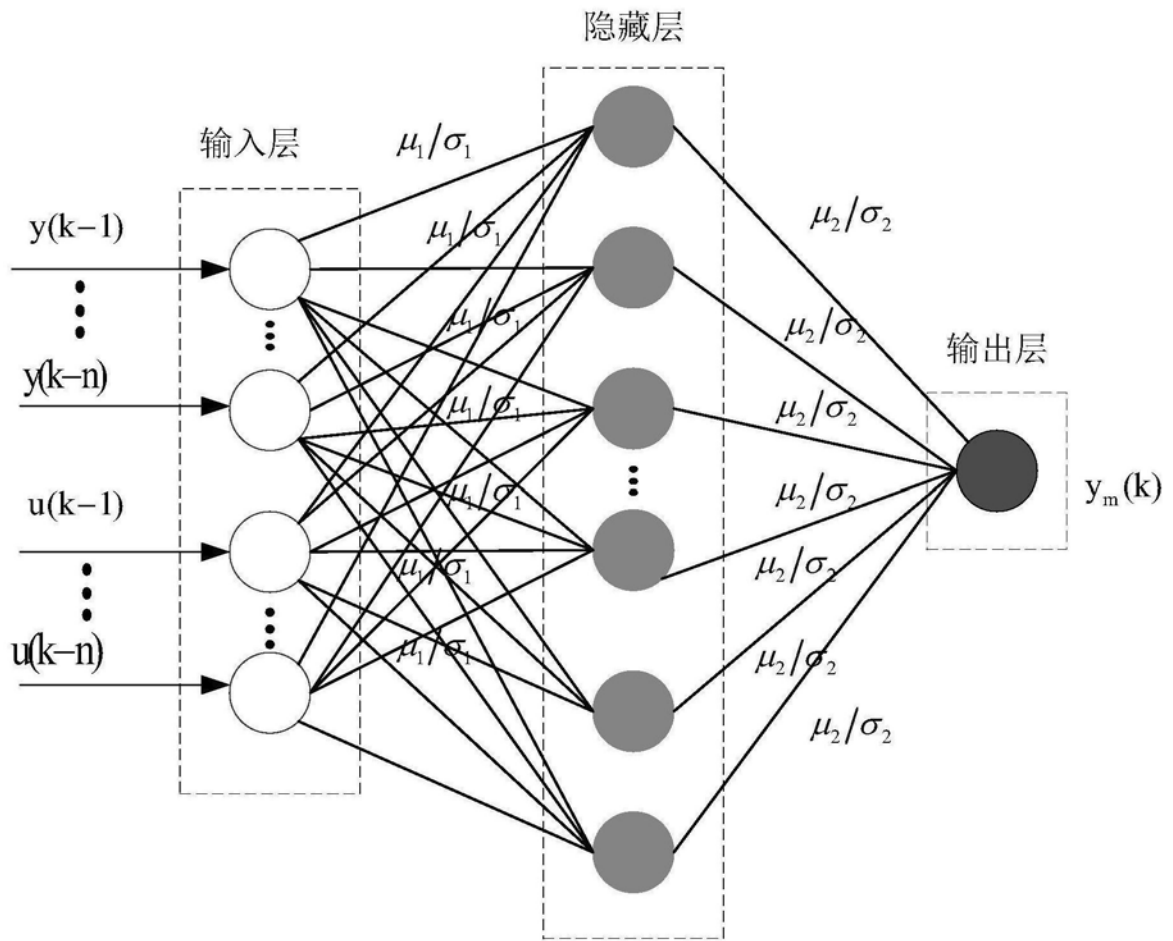


图2