



(12) 发明专利

(10) 授权公告号 CN 114638555 B

(45) 授权公告日 2022.09.16

(21) 申请号 202210536401.3

(22) 申请日 2022.05.18

(65) 同一申请的已公布的文献号
申请公布号 CN 114638555 A

(43) 申请公布日 2022.06.17

(73) 专利权人 国网江西综合能源服务有限公司
地址 330000 江西省南昌市临空经济区儒
乐湖大街955号临瑞青年公寓1号楼4
楼433室

专利权人 国家电网有限公司
华北电力大学

(72) 发明人 黄山 王虎 詹韬 刘秋林 宁涛
詹文斌 朱云鹏 户艳琴 彭湃
刘念 李承霖 傅皆恺 黄天翔
张延 石德文 胡志强 范志夫

(74) 专利代理机构 南昌贤达专利代理事务所
(普通合伙) 36136

专利代理师 金一娴

(51) Int.Cl.
G06Q 10/06 (2012.01)
G06N 3/08 (2006.01)
G06K 9/62 (2022.01)
G06F 16/215 (2019.01)
G06Q 50/06 (2012.01)

(56) 对比文件
US 2017161606 A1, 2017.06.08
CN 106650920 A, 2017.05.10

审查员 吴海旋

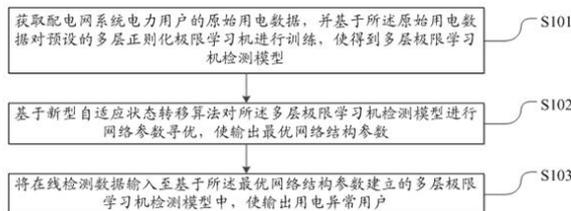
权利要求书4页 说明书12页 附图2页

(54) 发明名称

基于多层正则化极限学习机的用电行为检测方法及系统

(57) 摘要

本发明公开一种基于多层正则化极限学习机的用电行为检测方法及系统,方法包括:获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得到多层极限学习机检测模型;基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数;将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中,使输出用电异常用户。根据新型自适应状态转移算法对多层正则化极限学习机检测模型的网络结构参数进行调优,对状态转移算法的变换因子进行了调整,使其具有非线性自适应特性,从而使得多层正则化极限学习机网络结构参数寻优过程简单易行。



1. 一种基于多层正则化极限学习机的用电行为检测方法,其特征在于,包括:

获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得到多层极限学习机检测模型,其中所述多层正则化极限学习机的目标函数为:

$$\min L = \frac{C}{2} \|Y - H\beta\|^2 + \left\{ \frac{\alpha}{2} \|\beta\|_2^2 + (1-\alpha) \|\beta\|_1 \right\},$$

式中,C为调节经验风险和结构风险的参数, α 为L2正则化和L1正则化的加权系数, $\min L$ 为最小化目标函数,Y为输出数据样本集合,H为隐含层输出矩阵, β 为隐含层输出权重, $\|\beta\|_2$ 为L2正则化的输出权重向量范数, $\|\beta\|_1$ 为L1正则化的向量范数;

基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数,其中,基于新型自适应状态转移算法对所述多层极限学习机检测

模型进行网络参数寻优的表达式为:

$$\begin{cases} v_{k+1} = A_k v_k \\ F(v_{k+1}) = 1 - \frac{N_{actual}}{N_{total}} \end{cases},$$

式中, v_k 为变量空间中的当前状态, A_k 为状态转移矩阵, N_{total} 为训练样本总数, N_{actual} 为被正确检测样本的个数, $F(v_{k+1})$ 为适应度函数,即为用户异常用电行为检测错误率;

输出所述最优网络结构参数的过程包括:

基于非线性自适应调整策略对变换因子进行更新,其中所述变换因子包括旋转因子、平移因子、伸缩因子以及轴向因子,所述非线性自适应调整策略的表达式:

$$\begin{cases} a = S_{a,max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{a,max})}} \right) \right) \\ b = S_{b,max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{b,max})}} \right) \right) \\ c = S_{c,max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{c,max})}} \right) \right) \\ d = S_{d,max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{d,max})}} \right) \right) \end{cases},$$

式中, $S_{a,max}$ 、 $S_{b,max}$ 、 $S_{c,max}$ 、 $S_{d,max}$ 分别为旋转因子的最大取值、平移因子的最大取值、伸缩因子的最大取值以及轴向因子的最大取值,t为当前迭代次数, $T_{a,max}$ 、 $T_{b,max}$ 、 $T_{c,max}$ 、 $T_{d,max}$ 分别为旋转因子满足终止条件的最大迭代次数、平移因子满足终止条件的最大迭代次数、伸缩因子满足终止条件的最大迭代次数以及轴向因子满足终止条件的最大迭代次数,a、b、c、d分别为旋转因子、平移因子、伸缩因子以及轴向因子;

从当前种群中选择适应度函数F达到最小值的一组 $\{l_1, l_2, l_3, C, \alpha\}$ 值,记为 v_{best} ,对应的

适应度为 F_{best} ,将 v_{best} 复制为个体数为初始化种群的个数 N_{SE} 的群体,记为 v_k ,根据伸缩变换算子、旋转变换算子或轴向变换算子进行伸缩变换得到新的种群,经过伸缩变换后的种群中的最优个体为 $v_{newbest}$,对应的适应度为 $F_{newbest}$,如果 $F_{newbest} < F_{best}$,则根据平移变换算子对个体 $v_{newbest}$ 进行平移变换,并更新平移变换后的 v_{best} 和 F_{best} ,否则不进行平移变换,其中, l_1 为多层极限学习机检测模型第一层神经元个数, l_2 为多层极限学习机检测模型第二层神经元个数, l_3 为多层极限学习机检测模型第三层神经元个数,计算所述伸缩变换算子的表达式为:

$$v_{k+1} = v_k + cR_e v_k,$$

式中, v_k 为超参数变量k时刻的状态,即当前状态, v_{k+1} 为超参数变量k+1时刻的状态, c 为平移因子, R_e 为元素服从高斯分布的随机对角矩阵;

计算所述旋转变换算子的表达式为:

$$v_{k+1} = v_k + a \frac{1}{n \|v_k\|_2} R_r v_k,$$

式中, a 为旋转因子, v_k 为超参数变量k时刻的状态,即当前状态, R_r 为元素服从 $[-1,1]$ 均匀分布的随机矩阵, v_{k+1} 为超参数变量k+1时刻的状态, n 为随机矩阵 R_r 的维数, $\|v_k\|_2$ 为超参数变量k时刻的2范数;

计算所述轴向变换算子的表达式为:

$$v_{k+1} = v_k + dR_a v_k,$$

式中, v_{k+1} 为超参数变量k+1时刻的状态, v_k 为超参数变量k时刻的状态,即当前状态, d 为轴向因子, R_a 为非零元素服从高斯分布的稀疏随机对角矩阵;计算所述平移变换算子的表达式为:

$$v_{k+1} = v_k + bR_t \frac{v_k - v_{k-1}}{\|v_k - v_{k-1}\|_2},$$

式中, v_{k+1} 为超参数变量k+1时刻的状态, v_k 为超参数变量k时刻的状态,即当前状态, v_{k-1} 为超参数变量k-1时刻的状态, $\|v_k - v_{k-1}\|_2$ 为超参数变量k时刻与k-1时刻之差的2范数, R_t 为元素服从 $[0,1]$ 均匀分布的随机数, b 为平移因子;

判断适应度函数是否满足最小要求或是否达到最大迭代次数,若适应度函数满足最小要求或达到最大迭代次数,输出种群中的最优个体作为最优网络结构参数;

将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中,使输出用电异常用户。

2. 一种基于多层正则化极限学习机的用电行为检测系统,其特征在于,包括:

训练模块,配置为获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得得到多层极限学习机检测模型,其中所述多层正则化极限学习机的目标函数为:

$$\min L = \frac{C}{2} \|Y - H\beta\|^2 + \left\{ \frac{\alpha}{2} \|\beta\|_2^2 + (1-\alpha) \|\beta\|_1 \right\},$$

式中, C 为调节经验风险和结构风险的参数, α 为L2正则化和L1正则化的加权系数, $\min L$ 为最小化目标函数, Y 为输出数据样本集合, H 为隐含层输出矩阵, β 为隐含层输出权重, $\|\beta\|_2$ 为L2正则化的输出权重向量范数, $\|\beta\|_1$ 为L1正则化的向量范数;

寻优模块,配置为基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数,其中,基于新型自适应状态转移算法对所述多层

$$\text{极限学习机检测模型进行网络参数寻优的表达式为: } \begin{cases} v_{k+1} = A_k v_k \\ F(v_{k+1}) = 1 - \frac{N_{\text{actual}}}{N_{\text{total}}} \end{cases},$$

式中, v_k 为变量空间中的当前状态, A_k 为状态转移矩阵, N_{total} 为训练样本总数, N_{actual} 为被正确检测样本的个数, $F(v_{k+1})$ 为适应度函数,即为用户异常用电行为检测错误率;

输出所述最优网络结构参数的过程包括:

基于非线性自适应调整策略对变换因子进行更新,其中所述变换因子包括旋转因子、平移因子、伸缩因子以及轴向因子,所述非线性自适应调整策略的表达式:

$$\begin{cases} a = S_{a,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{a,\max})}} \right) \right) \\ b = S_{b,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{b,\max})}} \right) \right) \\ c = S_{c,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{c,\max})}} \right) \right) \\ d = S_{d,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{d,\max})}} \right) \right) \end{cases},$$

式中, $S_{a,\max}$ 、 $S_{b,\max}$ 、 $S_{c,\max}$ 、 $S_{d,\max}$ 分别为旋转因子的最大取值、平移因子的最大取值、伸缩因子的最大取值以及轴向因子的最大取值, t 为当前迭代次数, $T_{a,\max}$ 、 $T_{b,\max}$ 、 $T_{c,\max}$ 、 $T_{d,\max}$ 分别为旋转因子满足终止条件的最大迭代次数、平移因子满足终止条件的最大迭代次数、伸缩因子满足终止条件的最大迭代次数以及轴向因子满足终止条件的最大迭代次数, a 、 b 、 c 、 d 分别为旋转因子、平移因子、伸缩因子以及轴向因子;

从当前种群中选择适应度函数 F 达到最小值的一组 $\{l_1, l_2, l_3, C, \alpha\}$ 值, 记为 v_{best} , 对应的适应度为 F_{best} , 将 v_{best} 复制为个体数为初始化种群的个数 N_{SE} 的群体, 记为 v_k , 根据伸缩变换算子、旋转变换算子或轴向变换算子进行伸缩变换得到新的种群, 经过伸缩变换后的种群中的最优个体为 v_{newbest} , 对应的适应度为 F_{newbest} , 如果 $F_{\text{newbest}} < F_{\text{best}}$, 则根据平移变换算子对个体 v_{newbest} 进行平移变换, 并更新平移变换后的 v_{best} 和 F_{best} , 否则不进行平移变换, 其中, l_1 为多层极限学习机检测模型第一层神经元个数, l_2 为多层极限学习机检测模型第二层神经元个数, l_3 为多层极限学习机检测模型第三层神经元个数, 计算所述伸缩变换算子的表达式为:

$$v_{k+1} = v_k + cR_e v_k,$$

式中, v_k 为超参数变量 k 时刻的状态, 即当前状态, v_{k+1} 为超参数变量 $k+1$ 时刻的状态, c 为平移因子, R_e 为元素服从高斯分布的随机对角矩阵;

计算所述旋转变换算子的表达式为:

$$v_{k+1} = v_k + a \frac{1}{n \|v_k\|_2} R_r v_k,$$

式中, a 为旋转因子, v_k 为超参数变量 k 时刻的状态, 即当前状态, R_r 为元素服从 $[-1, 1]$ 均匀分布的随机矩阵, v_{k+1} 为超参数变量 $k+1$ 时刻的状态, n 为随机矩阵 R_r 的维数, $\|v_k\|_2$ 为超参数变量 k 时刻的 2 范数;

计算所述轴向变换算子的表达式为:

$$v_{k+1} = v_k + dR_a v_k,$$

式中, v_{k+1} 为超参数变量 $k+1$ 时刻的状态, v_k 为超参数变量 k 时刻的状态, 即当前状态, d 为轴向因子, R_a 为非零元素服从高斯分布的稀疏随机对角矩阵; 计算所述平移变换算子的表达式为:

$$v_{k+1} = v_k + bR_t \frac{v_k - v_{k-1}}{\|v_k - v_{k-1}\|_2},$$

式中, v_{k+1} 为超参数变量 $k+1$ 时刻的状态, v_k 为超参数变量 k 时刻的状态, 即当前状态, v_{k-1} 为超参数变量 $k-1$ 时刻的状态, $\|v_k - v_{k-1}\|_2$ 为超参数变量 k 时刻与 $k-1$ 时刻之差的 2 范数, R_t 为元素服从 $[0, 1]$ 均匀分布的随机数, b 为平移因子;

判断适应度函数是否满足最小要求或是否达到最大迭代次数, 若适应度函数满足最小要求或达到最大迭代次数, 输出种群中的最优个体作为最优网络结构参数;

输出模块, 配置为将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中, 使输出用电异常用户。

3. 一种电子设备, 其特征在于, 包括: 至少一个处理器, 以及与所述至少一个处理器通信连接的存储器, 其中, 所述存储器存储有可被所述至少一个处理器执行的指令, 所述指令被所述至少一个处理器执行, 以使所述至少一个处理器能够执行权利要求 1 所述的方法。

4. 一种计算机可读存储介质, 其上存储有计算机程序, 其特征在于, 所述程序被处理器执行时实现权利要求 1 所述的方法。

基于多层正则化极限学习机的用电行为检测方法及系统

技术领域

[0001] 本发明属于异常用电分析技术领域,尤其涉及一种基于多层正则化极限学习机的用电行为检测方法及系统。

背景技术

[0002] 随着经济的快速发展,用户的用电需求不断增加,若用户用电行为异常将增大电网的非技术性损失,增加电力公司的运营成本。传统的用户异常用电行为检测方法是现场人员定期巡检线路、定期校验电表、用户举报等,这些手段对人的依赖性较大,需要投入大量的人力成本,同时,用电行为的检测耗时较长、效率较低。

[0003] 对于异常用电行为检测的研究主要分为基于状态和基于人工智能两类方法。基于状态的分析方法是通过实时比较配电网的功率、电压、电流等大量数据的变化来检测异常;基于人工智能的异常用电行为检测模型则首先通过数据分析提取可以反映异常用电行为的指标,再借助人工智能的方法训练指标与用电行为检测结果之间的映射关系,完成异常用电行为检测模型的构建。但是目前的模型在参数寻优以及训练过程的时间长,并且无法适用于不同场景下的用户用电异常检测。

发明内容

[0004] 本发明提供一种基于多层正则化极限学习机的用电行为检测方法及系统,用于至少解决上述技术问题之一。

[0005] 第一方面,本发明提供一种基于多层正则化极限学习机的用电行为检测方法,包括:获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得到多层极限学习机检测模型,其中所述多层正则化极限学

习机的目标函数为: $\min L = \frac{C}{2} \|Y - H\beta\|^2 + \left\{ \frac{\alpha}{2} \|\beta\|_2^2 + (1-\alpha) \|\beta\|_1 \right\}$, 式中, C 为调节经验

风险和结构风险的参数, α 为L2正则化和L1正则化的加权系数, $\min L$ 为最小化目标函数,

Y 为输出数据样本集合, H 为隐含层输出矩阵, β 为隐含层输出权重, $\|\beta\|_2$ 为L2正则化的输出

权重向量范数, $\|\beta\|_1$ 为L1正则化的向量范数;基于新型自适应状态转移算法对所述多层

极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数,其中输出所述最优网

络结构参数的过程包括:基于非线性自适应调整策略对变换因子进行更新,其中所述变换因子包括旋转因子、平移因子、伸缩因子以及轴向因子,所述非线性自适应调整策略的表达

$$\text{式: } \begin{cases} a = S_{a,\max} \times \left(1.5 - \frac{1}{1 + e^{-5 \times (t/T_{a,\max})}} \right) \\ b = S_{b,\max} \times \left(1.5 - \frac{1}{1 + e^{-5 \times (t/T_{b,\max})}} \right) \\ c = S_{c,\max} \times \left(1.5 - \frac{1}{1 + e^{-5 \times (t/T_{c,\max})}} \right) \\ d = S_{d,\max} \times \left(1.5 - \frac{1}{1 + e^{-5 \times (t/T_{d,\max})}} \right) \end{cases}, \text{式中, } S_{a,\max}, S_{b,\max}, S_{c,\max}, S_{d,\max}$$

分别为旋转因子的最大取值、平移因子的最大取值、伸缩因子的最大取值以及轴向因子的最大取值, t 为当前迭代次数, $T_{a,\max}$ 、 $T_{b,\max}$ 、 $T_{c,\max}$ 、 $T_{d,\max}$ 分别为旋转因子满足终止条件的最大迭代次数、平移因子满足终止条件的最大迭代次数、伸缩因子满足终止条件的最大迭代次数以及轴向因子满足终止条件的最大迭代次数, a 、 b 、 c 、 d 分别为旋转因子、平移因子、伸缩因子以及轴向因子; 从当前种群中选择适应度函数 F 达到最小值的一组 $\{l_1, l_2, l_3, C, \alpha\}$ 值, 记为 v_{best} , 对应的适应度为 F_{best} , 将 v_{best} 复制为个体数为初始化种群的个数 N_{SE} 的群体, 记为 v_k , 根据伸缩变换算子、旋转变换算子或轴向变换算子进行伸缩变换得到新的种群, 经过伸缩变换后的种群中的最优个体为 $v_{newbest}$, 对应的适应度为 $F_{newbest}$, 如果 $F_{newbest} < F_{best}$, 则根据平移变换算子对个体 $v_{newbest}$ 进行平移变换, 并更新平移变换后的 v_{best} 和 F_{best} , 否则不进行平移变换, 其中, l_1 为多层极限学习机检测模型第一层神经元个数, l_2 为多层极限学习机检测模型第二层神经元个数, l_3 为多层极限学习机检测模型第三层神经元个数; 判断适应度函数是否满足最小要求或是否达到最大迭代次数, 若适应度函数满足最小要求或达到最大迭代次数, 输出种群中的最优个体作为最优网络结构参数; 将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中, 使输出用电异常用户。

[0006] 第二方面, 本发明提供一种基于多层正则化极限学习机的用电行为检测系统, 包括: 训练模块, 配置为获取配电网系统电力用户的原始用电数据, 并基于所述原始用电数据对预设的多层正则化极限学习机进行训练, 使得到多层极限学习机检测模型, 其中所述多

层正则化极限学习机的目标函数为: $\min L = \frac{C}{2} \|Y - H\beta\|^2 + \left\{ \frac{\alpha}{2} \|\beta\|_2^2 + (1 - \alpha) \|\beta\|_1 \right\}$, 式

中, C 为调节经验风险和结构风险的参数, α 为 L2 正则化和 L1 正则化的加权系数, $\min L$ 为最小化目标函数, Y 为输出数据样本集合, H 为隐含层输出矩阵, β 为隐含层输出权重, $\|\beta\|_2$ 为 L2 正则化的输出权重向量范数, $\|\beta\|_1$ 为 L1 正则化的向量范数; 寻优模块, 配置为基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优, 使输出最优

网络结构参数,其中输出所述最优网络结构参数的过程包括:基于非线性自适应调整策略对变换因子进行更新,其中所述变换因子包括旋转因子、平移因子、伸缩因子以及轴向因子,

$$\text{子,所述非线性自适应调整策略的表达式:} \begin{cases} a = S_{a,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{a,\max})}} \right) \right) \\ b = S_{b,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{b,\max})}} \right) \right) \\ c = S_{c,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{c,\max})}} \right) \right) \\ d = S_{d,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{d,\max})}} \right) \right) \end{cases},$$

式中, $S_{a,\max}$ 、 $S_{b,\max}$ 、 $S_{c,\max}$ 、 $S_{d,\max}$ 分别为旋转因子的最大取值、平移因子的最大取值、伸缩因子的最大取值以及轴向因子的最大取值, t 为当前迭代次数, $T_{a,\max}$ 、 $T_{b,\max}$ 、 $T_{c,\max}$ 、 $T_{d,\max}$ 分别为旋转因子满足终止条件的最大迭代次数、平移因子满足终止条件的最大迭代次数、伸缩因子满足终止条件的最大迭代次数以及轴向因子满足终止条件的最大迭代次数, a 、 b 、 c 、 d 分别为旋转因子、平移因子、伸缩因子以及轴向因子;从当前种群中选择适应度函数 F 达到最小值的一组 $\{l_1, l_2, l_3, C, \alpha\}$ 值,记为 v_{best} ,对应的适应度为 F_{best} ,将 v_{best} 复制为个体数为初始化种群的个数 N_{SE} 的群体,记为 v_k ,根据伸缩变换算子、旋转变换算子或轴向变换算子进行伸缩变换得到新的种群,经过伸缩变换后的种群中的最优个体为 $v_{newbest}$,对应的适应度为 $F_{newbest}$,如果 $F_{newbest} < F_{best}$,则根据平移变换算子对个体 $v_{newbest}$ 进行平移变换,并更新平移变换后的 v_{best} 和 F_{best} ,否则不进行平移变换,其中, l_1 为多层极限学习机检测模型第一层神经元个数, l_2 为多层极限学习机检测模型第二层神经元个数, l_3 为多层极限学习机检测模型第三层神经元个数;判断适应度函数是否满足最小要求或是否达到最大迭代次数,若适应度函数满足最小要求或达到最大迭代次数,输出种群中的最优个体作为最优网络结构参数;输出模块,配置为将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中,使输出用电异常用户。

[0007] 第三方面,提供一种电子设备,其包括:至少一个处理器,以及与所述至少一个处理器通信连接的存储器,其中,所述存储器存储有可被所述至少一个处理器执行的指令,所述指令被所述至少一个处理器执行,以使所述至少一个处理器能够执行本发明任一实施例的基于多层正则化极限学习机的用电行为检测方法的步骤。

[0008] 第四方面,本发明还提供一种计算机可读存储介质,其上存储有计算机程序,所述程序指令被处理器执行时,使所述处理器执行本发明任一实施例的基于多层正则化极限学习机的用电行为检测方法的步骤。

[0009] 本申请的基于多层正则化极限学习机的用电行为检测方法及系统,能够实现用户用电异常的精准检测,而且大大降低了模型在参数寻优以及训练过程中的时间,此外,对于不同场景下的用户用电异常检测也能有很好的适应性和高效性。

附图说明

[0010] 为了更清楚地说明本发明实施例的技术方案,下面将对实施例描述中所需要使用的附图作一简单地介绍,显而易见地,下面描述中的附图是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0011] 图1为本发明一实施例提供的一种基于多层正则化极限学习机的用电行为检测方法的流程图;

[0012] 图2为本发明一实施例提供一个具体实施例的基于多层正则化极限学习机的用电行为检测方法的流程图;

[0013] 图3为本发明一实施例提供的一种基于多层正则化极限学习机的用电行为检测系统的结构框图;

[0014] 图4是本发明一实施例提供的电子设备的结构示意图。

具体实施方式

[0015] 为使本发明实施例的目的、技术方案和优点更加清楚,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例是本发明一部分实施例,而不是全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例,都属于本发明保护的范围。

[0016] 请参阅图1,其示出了本申请的一种基于多层正则化极限学习机的用电行为检测方法的流程图。

[0017] 如图1所示,步骤S101,获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得到多层极限学习机检测模型。

[0018] 在本实施例中,多层正则化极限学习机,引入了L1和L2正则化的加权和来降低模型结构化风险,充分利用了L1和L2正则化的优点,L1正则化可以产生稀疏的权值矩阵,给予多层极限学习机隐含层特征提取不同的关注度,起到特征选择的作用,有利于模型学习到更好的特征表示;L2正则化可以有效限制多层极限学习机模型权值参数数量,从而有效降低模型的复杂度,提升模型的稳定性。结合二者的优势,可以实现多层极限学习机模型网络结构的优化,不仅可以达到简化模型,防止过拟合的作用,而且还具有较为出色的学习能力和泛化性能。

[0019] 综上,本实施例的方法采用多层极限学习机检测模型,可以充分学习隐藏于数据内部的用电行为隐性特征,同时起到特征筛选的功能,既简化了检测模型,又提高了检测精确度,节省了时间成本。

[0020] 步骤S102,基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数。

[0021] 在本实施例中,通过非线性自适应调整策略对变换因子进行非线性自适应处理,

使得在迭代初期变换因子能够以较快的速度下降,到了迭代后期变换因子的变化趋于平稳,从而能够快速、精确、高效地实现多层极限学习机模型超参数的寻优,使得多层极限学习机模型具有出色的用户用电异常检测能力。

[0022] 步骤S103,将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中,使输出用电异常用户。

[0023] 综上,本申请的方法能够实现用户用电异常的精准检测,而且大大降低了模型在参数寻优以及训练过程中的时间,此外,对于不同场景下的用户用电异常检测也能有很好的适应性和高效性。

[0024] 请参阅图2,其示出了本申请的一个具体实施例的基于多层正则化极限学习机的用电行为检测方法的流程图。

[0025] 如图2所示,基于多层正则化极限学习机的用电行为检测方法具体包括以下步骤:

[0026] 步骤1:数据采集

[0027] 从用电采集系统和能量管理系统获取配电网系统电力用户的原始用电数据,其中包括用户的用电基本信息数据,终端的告警信息数据和该地区用户的窃电信息数据。

[0028] 步骤2:数据预处理

[0029] 数据清洗:数据清洗是指删除原始数据中的冗余、无关数据,从而平滑数据噪声。公用事业等非居民用户一般不会存在异常用电行为,可将此类非居民用户的用电数据删除。

[0030] 缺失值处理:用电采集系统记录的数据会由于采集设备故障、传输丢包等原因存在部分缺失,若直接忽略缺失样本,会导致日线损率数据误差较大,从而降低异常用电行为检测的精确度。为了避免缺失值的影响,采用插补法对缺失值进行处理。

[0031] 数据变换:对数据进行规范化处理,即转换数据格式使之适应于本发明提出的检测技术。根据数据特点,可以从规范化处理和属性构造两个方面进行数据变化。规范化处理将具有不同量纲的数据转换到同一量纲,将数据规定到一个较小的范围。采用最小-最大规范化可达到规范化处理的目的,其公式为:

$$[0032] \quad x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}}, \quad (1)$$

[0033] 式中, x^* 为归一化后的样本数据, x 为样本数据实际值, x_{\min} 为样本数据最小值, x_{\max} 为样本数据最大值;

[0034] 步骤3:构建基于多层正则化极限学习机的多层极限学习机检测模型

[0035] 1)模型输入

[0036] 将经过预处理的样本数据集按8:2的比例划分为训练集和测试集,基于训练集训练多层极限学习机,测试集作为模型性能评价的输入数据。

[0037] 2)构建多层正则化极限学习机

[0038] 极限学习机(ELM)是一种单隐含层前馈神经网络,ELM算法随机产生输入与隐含层的连接权值及隐含层神经网络的阈值,在训练过程中无需调整,只需对隐含层神经元个数进行设定,就可获得求解问题的全局最优解。该方法与传统前馈神经网络相比,其学习速度快,泛化性能好,不易陷入局部最优解。对于N个训练样本 $(x_i, y_i), i=1, \dots, N$,基本ELM算法的

表达形式如下：

$$[0039] \quad f_k(x) = \sum_{i=1}^k \beta_i h_i(x) = \sum_{i=1}^k \beta_i g(w_i \times x_j + b_i), j = 1, \dots, N, \quad (2)$$

[0040] 式中, k 为隐含层神经元的个数, N 是训练样本的数量, $h_i(x)$ 为与输入 x 对应的第 i 个隐层神经元的输出, β_i 为第 i 个隐含层神经元与输出神经元之间的连接权向量, $g(\cdot)$ 表示隐含层激活函数, x_j 为第 j 个输入样本, w_i 为与第 j 个输入样本与第 i 个隐含节点相连的输入权重, b_i 为第 i 个隐含节点的阈值, ELM算法通过最小化输出权重 β 保证神经网络的泛化能力,通常取最小二乘解。

[0041] 公式(2)的矩阵表示为：

$$[0042] \quad H\beta = Y, \quad (3)$$

[0043] 式中, H 为隐含层输出矩阵, β 为隐含层输出权重, Y 为输出数据样本集合；

[0044] 训练ELM相当于求解 β 的最小标准二乘数解,其表达式为：

$$[0045] \quad \beta = H^\dagger Y, \quad (4)$$

[0046] H^\dagger 是 H 矩阵的Moore-Penrose广义逆矩阵。

[0047] 在深度学习中,网络参数过多会导致训练模型出现过拟合现象,因此为了得到更好的训练模型,引入L2和L1的加权正则化项的代价函数来求取输出权值,从而得到如下公式：

$$[0048] \quad \min L = \frac{C}{2} \|Y - H\beta\|^2 + \left\{ \frac{\alpha}{2} \|\beta\|_2^2 + (1-\alpha) \|\beta\|_1 \right\}, \quad (5)$$

[0049] 式中, C 为调节经验风险和结构风险的参数, α 为L2正则化和L1正则化的加权系数, $\min L$ 为最小化目标函数, Y 为输出数据样本集合, H 为隐含层输出矩阵, β 为隐含层输出权重, $\|\beta\|_2$ 为L2正则化的输出权重向量范数, $\|\beta\|_1$ 为L1正则化的向量范数；

[0050] 对目标函数(5)进行求导,可以得到输出权重 β ,如下公式所示：

$$[0051] \quad \beta = \left(\frac{\alpha I}{C} + H^T H \right)^{-1} \left(H^T Y - \frac{(1-\alpha)I}{C} \right), \quad (6)$$

[0052] ELM-AE(extreme learning machine-AutoEncoder,极限学习机-自动编码器)和传统ELM的主要区别在于,ELM是一种监督学习算法,其输出为对应标签。而ELM-AE是一种无监督学习算法,它的输出即为其输入的映射,ELM-AE的隐层输出可用式(7)-式(8)表示。

$$[0053] \quad h = g(wx + b), w^T w = I, b^T b = I, \quad (7)$$

[0054] 式中, w, b 分别为输入层与隐含层之间的权重向量和偏置向量, T 为转置, I 为单位对角矩阵, x 为输入样本；

$$[0055] \quad h(x_i)\beta = x_i^T, i = 1, \dots, N, \quad (8)$$

[0056] ELM-AE隐层参数在随机生成后需要进行正交化。将输入数据映射到随机子空间。与ELM随机初始化输入权重和隐层偏置相比,正交化可以更好地捕获输入数据的各种边缘特征,从而使模型能够有效地学习数据的非线性结构。输出权重 β 可通过式(6)进行计算。

[0057] ML-ELM(Multilayer extreme learning machine,多层极限学习机)利用ELM-AE训练时,第 $i+1$ 个隐层的输入即为第 i 个隐层上的输出,如式(9)表示。

$$[0058] \quad H_{i+1} = g(H_i \beta_{i+1}^T), \quad (9)$$

[0059] 其中, H_i 为第 i 个隐层的输出,当 i 取值为1时,即为整个模型的输入, β_{i+1} 为ELM-AE对第 i 个隐层和第 $i+1$ 个隐层训练时的权值矩阵。

[0060] 步骤4:使用新型自适应状态转移算法对多层极限学习机检测模型进行参数优化,确定最佳检测模型

[0061] 首先使用状态变换算子、邻域与采样来产生候选解,然后通过选择和更新来替换当前最优解,最后采取交替轮换策略来实现不同状态变换算子的调用。状态变换算子主要有四种变换方式,分别是旋转变换算子、平移变换算子、伸缩变换算子和轴向变换算子。

[0062] 1) 旋转变换算子:

$$[0063] \quad \mathbf{v}_{k+1} = \mathbf{v}_k + a \frac{1}{n \|\mathbf{v}_k\|_2} R_r \mathbf{v}_k, \quad (10)$$

[0064] 式中, a 为旋转因子, \mathbf{v}_k 为超参数变量 k 时刻的状态,即当前状态, R_r 为元素服从 $[-1, 1]$ 均匀分布的随机矩阵, \mathbf{v}_{k+1} 为超参数变量 $k+1$ 时刻的状态, n 为随机矩阵 R_r 的维数。旋转变换算子能够产生在以 a 为半径的超球体内的候选解。

[0065] 2) 平移变换算子:

$$[0066] \quad \mathbf{v}_{k+1} = \mathbf{v}_k + b R_t \frac{\mathbf{v}_k - \mathbf{v}_{k-1}}{\|\mathbf{v}_k - \mathbf{v}_{k-1}\|_2}, \quad (11)$$

[0067] 式中, \mathbf{v}_{k+1} 为超参数变量 $k+1$ 时刻的状态, \mathbf{v}_k 为超参数变量 k 时刻的状态,即当前状态, \mathbf{v}_{k-1} 为超参数变量 $k-1$ 时刻的状态, $\|\mathbf{v}_k - \mathbf{v}_{k-1}\|_2$ 为超参数变量 k 时刻与 $k-1$ 时刻之差的2范数, R_t 为元素服从 $[0, 1]$ 均匀分布的随机数, b 为平移因子。平移变换算子能够实现现在 \mathbf{v}_{k-1} 到 \mathbf{v}_k 直线范围内以最大长度为 b 进行搜索的功能。

[0068] 3) 伸缩变换算子

$$[0069] \quad \mathbf{v}_{k+1} = \mathbf{v}_k + c R_e \mathbf{x}_k, \quad (12)$$

[0070] 式中, \mathbf{v}_k 为超参数变量 k 时刻的状态,即当前状态, \mathbf{v}_{k+1} 为超参数变量 $k+1$ 时刻的状态, c 为平移因子, R_e 为元素服从高斯分布的随机对角矩阵。伸缩变换算子将 \mathbf{v}_k 的每个元素进行 $[-\infty, +\infty]$ 范围内的放缩。

[0071] 4) 轴向变换算子

$$[0072] \quad \mathbf{v}_{k+1} = \mathbf{v}_k + d\mathbf{R}_a \mathbf{v}_k, \quad (13)$$

[0073] 式中, \mathbf{v}_{k+1} 为超参数变量k+1时刻的状态, \mathbf{v}_k 为超参数变量k时刻的状态, 即当前状态, d 为轴向因子, \mathbf{R}_a 为非零元素服从高斯分布的稀疏随机对角矩阵。轴向变换算子的功能是增强单一维度的搜索。

[0074] 对变换因子进行调整, 使其前期取较大值来获得较大的下降率, 后期取较小值来增加算法寻优的成功率。加入自适应变换因子的新型状态转移算法的即加速了寻优过程, 也避免了优化算法陷入局部最优解。变换因子的非线性自适应调整策略表达式如下:

$$[0075] \quad \begin{cases} a = S_{a, \max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{a, \max})}} \right) \right) \\ b = S_{b, \max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{b, \max})}} \right) \right) \\ c = S_{c, \max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{c, \max})}} \right) \right) \\ d = S_{d, \max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{d, \max})}} \right) \right) \end{cases}, \quad (14)$$

[0076] 式中, $S_{a, \max}$ 、 $S_{b, \max}$ 、 $S_{c, \max}$ 、 $S_{d, \max}$ 分别为旋转因子的最大取值、平移因子的最大取值、伸缩因子的最大取值以及轴向因子的最大取值, t 为当前迭代次数, $T_{a, \max}$ 、 $T_{b, \max}$ 、 $T_{c, \max}$ 、 $T_{d, \max}$ 分别为旋转因子满足终止条件的最大迭代次数、平移因子满足终止条件的最大迭代次数、伸缩因子满足终止条件的最大迭代次数以及轴向因子满足终止条件的最大迭代次数, a 、 b 、 c 、 d 分别为旋转因子、平移因子、伸缩因子以及轴向因子。

[0077] 在多层正则化极限学习机中, 将隐含层的层数设定为3, 由于每一隐层的神经元个数 l_k , 正则化因子以及 L_1 和 L_2 正则化的权重系数 α 是影响多层核极限学习机对用户异常用电行为检测的重要因素, 本发明采用新型自适应状态转移算法对多层极限学习机检测模型进行参数优化, 寻找的最优的超参数 $\{l_{best1}, l_{best2}, l_{best3}, C_{best}, \alpha_{best}\}$, 使得多层正则化极限学习机模型对用户异常用电行为检测能力最佳。

[0078] 采用新型自适应状态转移算法对多层正则化极限学习机网络参数进行优化问题可用如下公式来表示:

$$[0079] \quad \begin{cases} \mathbf{v}_{k+1} = \mathbf{A}_k \mathbf{v}_k \\ F(\mathbf{v}_{k+1}) = 1 - \frac{N_{actual}}{N_{total}} \end{cases}, \quad (15)$$

[0080] 式中, \mathbf{v}_k 为变量空间中的当前状态, \mathbf{A}_k 为状态转移矩阵, N_{total} 为训练样本总数,

N_{actual} 为被正确检测样本的个数, $F(v_{k+1})$ 为适应度函数, 即为用户异常用电行为检测错误率。

[0081] 采用新型自适应状态转移算法对多层正则化极限学习机的网络结构参数寻优的过程如下:

[0082] 步骤A: 初始化种群的个数为 $N_{SE} = 50$, STA算法初始化参数, 旋转因子 $a_{max} = 1$, 平移因子 $b_{max} = 1$, 伸缩因子 $c_{max} = 1$, 轴向因子 $d_{max} = 1$, 最大迭代次数为100, 在可行域内随机均匀初始化 $\{l_1, l_2, l_3, C, \alpha\}$ 5个变量, 产生初始种群, 产生 N_{SE} 组初始可行解。

[0083] 步骤B: 由式(14)对变换因子进行更新。

[0084] 步骤C: 从当前种群中选择适应度函数 F 达到最小值的一组 $\{l_1, l_2, l_3, C, \alpha\}$ 值, 记为 v_{best} , 对应的适应度为 F_{best} , 将 v_{best} 复制为个体数为 N_{SE} 的群体, 记为 v_k , 按公式(12)进行伸缩变换得到新的种群, 经过伸缩变换后的种群中的最优个体为 $v_{newbest}$, 对应的适应度为 $F_{newbest}$, 如果 $F_{newbest} < F_{best}$, 则按式(11)对个体 $v_{newbest}$ 进行平移变换, 并更新平移变换后的 v_{best} 和 F_{best} , 否则不进行平移变换。

[0085] 步骤D: 将 v_{best} 复制为个体数为 N_{SE} 的群体, 然后按照公式(10)进行旋转变换得到新的种群, 选择新种群中的最优个体 $v_{newbest}$, 计算其对应的适应度 $F_{newbest}$ 。如果 $F_{newbest} < F_{best}$, 按照式(11)进行平移变换, 并更新平移变换后的 v_{best} 和 F_{best} , 否则不进行平移变换。

[0086] 步骤E: 采取与步骤C类似的种群选择和更新过程, 不同的是通过式(13)轴向变换来产生新的种群, 然后采取与步骤C一样的做法来更新平移变换后的 v_{best} 和 F_{best} 。

[0087] 步骤F: 判断适应度函数是否满足最小要求或是否达到最大迭代次数, 否则, 重复步骤(B)至(E)。达到终止条件, 输出种群中的最优个体作为多层正则化极限学习机的网络结构参数。

[0088] 步骤5: 模型评估

[0089] 采用新型自适应状态转移算法对多层正则化极限学习机的网络结构参数进行寻找后, 按照最优网络结构参数建立多层极限学习机检测模型, 然后通过训练集对检测模型再进行训练, 最后利用测试集来验证模型的检测性能。采取划分的测试集上对性能最优的多层极限学习机检测模型进行准确度测试, 结果表明本发明提出的采用新型自适应状态转移算法优化后的检测模型在精确度、f1得分(f1 score)和AUC(Area Under Curve)这些综合评价指标上有显著的提升。模型在测试集上的表现和时间效率上, 均显示了基于新型自适应状态转移算法寻优后的多层极限学习机检测模型在用户异常用电检测中的有效性。

[0090] 将在线采集的数据经过数据预处理, 输入到训练之后的检测模型, 获取模型检测结果, 判定是否发生异常用电。

[0091] 请参阅图3, 其示出了本申请的一种基于多层正则化极限学习机的用电行为检测系统的结构框图。

[0092] 如图3所示,用电行为检测系统200,包括训练模块210、寻优模块220以及输出模块230。

[0093] 其中,训练模块210,配置为获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得到多层极限学习机检测模型,其中所述多层正则化极限学习机的目标函数为:

$$\min L = \frac{C}{2} \|Y - H\beta\|^2 + \left\{ \frac{\alpha}{2} \|\beta\|_2^2 + (1-\alpha) \|\beta\|_1 \right\},$$

式中, C 为调节经验风险和结构风险的参数, α 为L2正则化和L1正则化的加权系数, $\min L$ 为最小化目标函数, Y 为输出数据样本集合, H 为隐含层输出矩阵, β 为隐含层输出权重, $\|\beta\|_2$ 为L2正则化的输出权重向量范数, $\|\beta\|_1$ 为L1正则化的向量范数;寻优模块220,配置为基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数,其中输出所述最优网络结构参数的过程包括:基于非线性自适应调整策略对变换因子进行更新,其中所述变换因子包括旋转因子、平移因子、伸缩因子以及轴向因子,所述非线性自适应调整策略的表

$$\text{达式: } \begin{cases} a = S_{a,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{a,\max})}} \right) \right) \\ b = S_{b,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{b,\max})}} \right) \right) \\ c = S_{c,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{c,\max})}} \right) \right) \\ d = S_{d,\max} \times \left(1.5 - \left(\frac{1}{1 + e^{-5 \times (t/T_{d,\max})}} \right) \right) \end{cases},$$

式中, $S_{a,\max}$ 、 $S_{b,\max}$ 、 $S_{c,\max}$ 、 $S_{d,\max}$ 分别为旋转因子的最大取值、平移因子的最大取值、伸缩因子的最大取值以及轴向因子的最大取值, t 为当前迭代次数, $T_{a,\max}$ 、 $T_{b,\max}$ 、 $T_{c,\max}$ 、 $T_{d,\max}$ 分别为旋转因子满足终止条件的最大迭代次数、平移因子满足终止条件的最大迭代次数、伸缩因子满足终止条件的最大迭代次数以及轴向因子满足终止条件的最大迭代次数, a 、 b 、 c 、 d 分别为旋转因子、平移因子、伸缩因子以及轴向因子;从当前种群中选择适应度函数 F 达到最小值的一组 $\{l_1, l_2, l_3, C, \alpha\}$ 值,记为 v_{best} ,对应的适应度为 F_{best} ,将 v_{best} 复制为个体数为初始化种群的个数 N_{SE} 的群体,记为 v_k ,根据伸缩变换算子、旋转变换算子或轴向变换算子进行伸缩变换得到新的种群,经过伸缩变换后的种群中的最优个体为 $v_{newbest}$,对应的适应度为 $F_{newbest}$,如果 $F_{newbest} < F_{best}$,则根据平移变换算子对个体 $v_{newbest}$ 进行平移变换,并更新平移变换后的 v_{best} 和 F_{best} ,否则不进行平移变换,其中, l_1 为多层极限学习机检测模型第一层神经元

个数, l_2 为多层极限学习机检测模型第二层神经元个数, l_3 为多层极限学习机检测模型第三层神经元个数; 判断适应度函数是否满足最小要求或是否达到最大迭代次数, 若适应度函数满足最小要求或达到最大迭代次数, 输出种群中的最优个体作为最优网络结构参数; 输出模块230, 配置为将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中, 使输出用电异常用户。

[0094] 应当理解, 图3中记载的诸模块与参考图1中描述的方法中的各个步骤相对应。由此, 上文针对方法描述的操作和特征以及相应的技术效果同样适用于图3中的诸模块, 在此不再赘述。

[0095] 在另一些实施例中, 本发明实施例还提供了一种计算机可读存储介质, 其上存储有计算机程序, 所述程序指令被处理器执行时, 使所述处理器执行上述任意方法实施例中的基于多层正则化极限学习机的用电行为检测方法;

[0096] 作为一种实施方式, 本发明的计算机可读存储介质存储有计算机可执行指令, 计算机可执行指令设置为:

[0097] 获取配电网系统电力用户的原始用电数据, 并基于所述原始用电数据对预设的多层正则化极限学习机进行训练, 使得到多层极限学习机检测模型;

[0098] 基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优, 使输出最优网络结构参数;

[0099] 将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中, 使输出用电异常用户。

[0100] 计算机可读存储介质可以包括存储程序区和存储数据区, 其中, 存储程序区可存储操作系统、至少一个功能所需要的应用程序; 存储数据区可存储根据基于多层正则化极限学习机的用电行为检测系统的使用所创建的数据等。此外, 计算机可读存储介质可以包括高速随机存取存储器, 还可以包括存储器, 例如至少一个磁盘存储器件、闪存器件、或其他非易失性固态存储器件。在一些实施例中, 计算机可读存储介质可选包括相对于处理器远程设置的存储器, 这些远程存储器可以通过网络连接至基于多层正则化极限学习机的用电行为检测系统。上述网络的实例包括但不限于互联网、企业内部网、局域网、移动通信网及其组合。

[0101] 图4是本发明实施例提供的电子设备的结构示意图, 如图4所示, 该设备包括: 一个处理器310以及存储器320。电子设备还可以包括: 输入装置330和输出装置340。处理器310、存储器320、输入装置330和输出装置340可以通过总线或者其他方式连接, 图4中以通过总线连接为例。存储器320为上述的计算机可读存储介质。处理器310通过运行存储在存储器320中的非易失性软件程序、指令以及模块, 从而执行服务器的各种功能应用以及数据处理, 即实现上述方法实施例基于多层正则化极限学习机的用电行为检测方法。输入装置330可接收输入的数字或字符信息, 以及产生与基于多层正则化极限学习机的用电行为检测系统的用户设置以及功能控制有关的键信号输入。输出装置340可包括显示屏等显示设备。

[0102] 上述电子设备可执行本发明实施例所提供的方法, 具备执行方法相应的功能模块和有益效果。未在本实施例中详尽描述的技术细节, 可参见本发明实施例所提供的方法。

[0103] 作为一种实施方式, 上述电子设备应用于基于多层正则化极限学习机的用电行为检测系统中, 用于客户端, 包括: 至少一个处理器; 以及, 与至少一个处理器通信连接的存储

器;其中,存储器存储有可被至少一个处理器执行的指令,指令被至少一个处理器执行,以使至少一个处理器能够:

[0104] 获取配电网系统电力用户的原始用电数据,并基于所述原始用电数据对预设的多层正则化极限学习机进行训练,使得到多层极限学习机检测模型;

[0105] 基于新型自适应状态转移算法对所述多层极限学习机检测模型进行网络参数寻优,使输出最优网络结构参数;

[0106] 将在线检测数据输入至基于所述最优网络结构参数建立的多层极限学习机检测模型中,使输出用电异常用户。

[0107] 通过以上的实施方式的描述,本领域的技术人员可以清楚地了解到各实施方式可借助软件加必需的通用硬件平台的方式来实现,当然也可以通过硬件。基于这样的理解,上述技术方案本质上或者说对现有技术做出贡献的部分可以以软件产品的形式体现出来,该计算机软件产品可以存储在计算机可读存储介质中,如ROM/RAM、磁碟、光盘等,包括若干指令用以使得一台计算机设备(可以是个人计算机,服务器,或者网络设备)执行各个实施例或者实施例的某些部分的方法。

[0108] 最后应说明的是:以上实施例仅用以说明本发明的技术方案,而非对其限制;尽管参照前述实施例对本发明进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本发明各实施例技术方案的精神和范围。

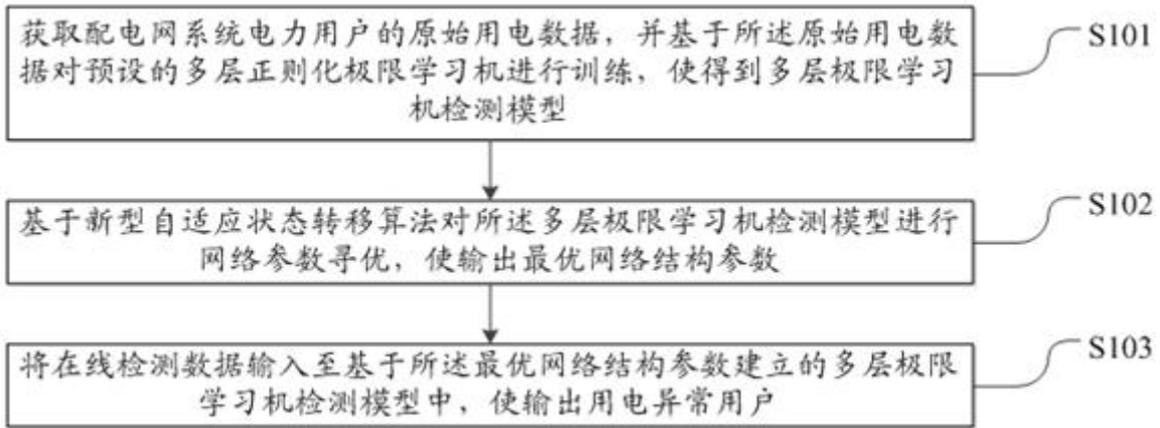


图1

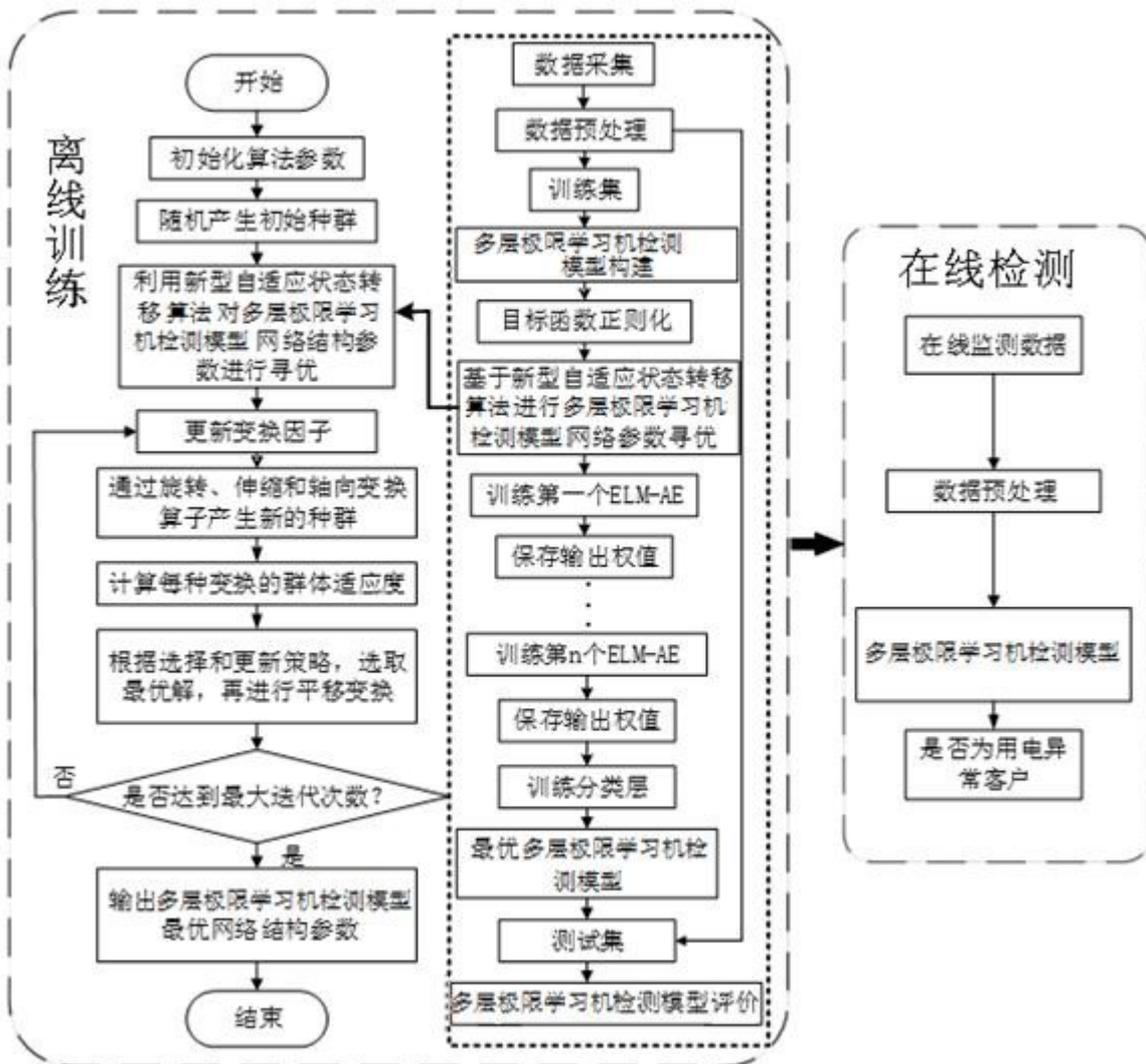


图2

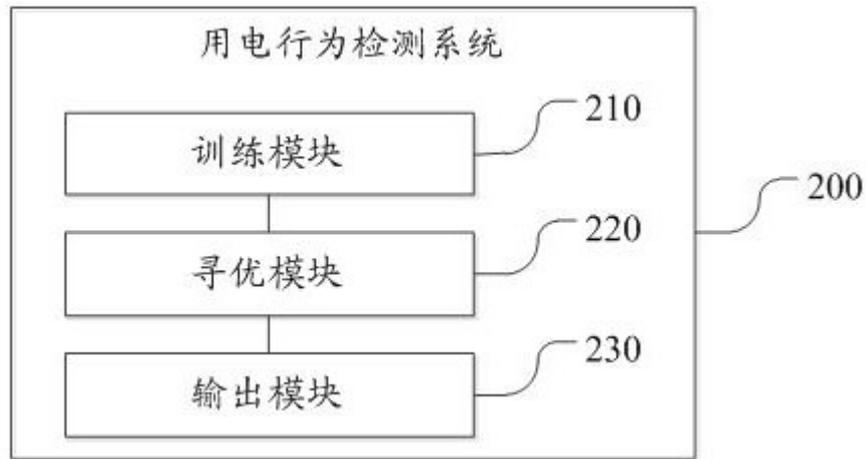


图3

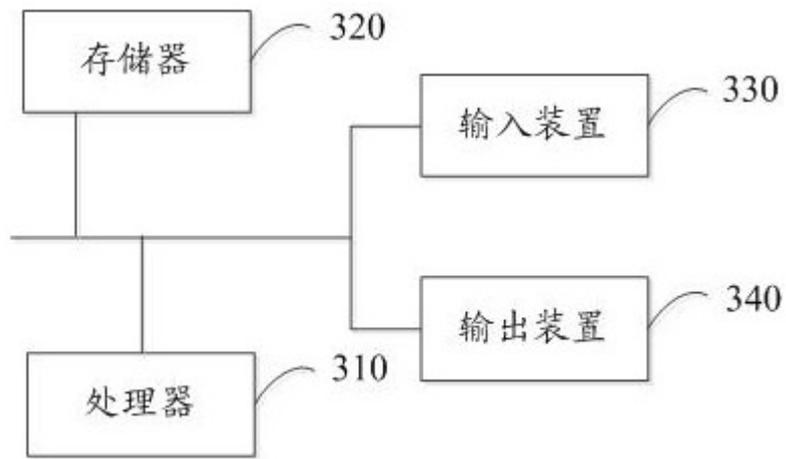


图4