



(12) 发明专利申请

(10) 申请公布号 CN 104598984 A

(43) 申请公布日 2015. 05. 06

(21) 申请号 201410743621. 9

(22) 申请日 2014. 12. 08

(71) 申请人 北京邮电大学

地址 100876 北京市海淀区西土城路 10 号

(72) 发明人 郭少勇 熊翔 丰雷 元峰 徐键

张国翊 郑维维

(74) 专利代理机构 北京路浩知识产权代理有限公司 11002

代理人 李相雨

(51) Int. Cl.

G06Q 10/04(2012. 01)

G06N 3/02(2006. 01)

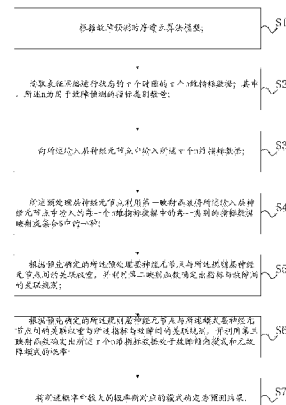
权利要求书4页 说明书7页 附图3页

(54) 发明名称

一种基于模糊神经网络的故障预测方法

(57) 摘要

本发明涉及一种基于模糊神经网络的故障预测方法，能够解决现有技术中无法进行在线故障预测的问题。所述基于模糊神经网络的故障预测方法包括：根据故障预测时序建立算法模型；读取表征网络运行状态的 τ 个时隙的 τ 个 n 维指标数据；向输入层神经元节点中输入 τ 个指标数据；预处理层神经元节点利用第一映射函数将每一个 n 维指标数据中的每一类别的指标数据映射成集合 S 中的一种；根据预先确定的预处理层神经元节点与规则层神经元节点间的关联权重确定出指标与故障间的关联规则；根据指标与故障间的关联规则确定出 τ 个指标数据处于故障倾向模式和无故障模式的概率；将概率中较大的概率所对应的模式确定为预测结果。本发明适用于需要进行故障预测的场合。



1. 一种基于模糊神经网络的故障预测方法，其特征在于，包括：

根据故障预测时序建立算法模型；其中，所述算法模型由输入层神经元节点、预处理层神经元节点、规则层神经元节点、模式层神经元节点和输出层神经元节点组成，所述输入层神经元节点与所述预处理层神经元节点之间连接，所述预处理层神经元节点与所述规则层神经元节点之间连接，所述规则层神经元节点与所述模式层神经元节点之间连接，所述模式层神经元节点与所述输出层神经元节点之间连接；

读取表征网络运行状态的 τ 个时隙的 τ 个 n 维指标数据；其中，所述 n 为用于故障预测的指标类别数量；

向所述输入层神经元节点中输入所述 τ 个 n 维指标数据；

所述预处理层神经元节点利用第一映射函数将所述输入层神经元节点中输入的每一个 n 维指标数据中的每一类别的指标数据映射成集合 $S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ 中的一种；其中，所述 N 表示正常状态，所述 A_{warning} 表示警告状态，所述 A_{minor} 表示次要告警状态，所述 A_{major} 表示主要告警状态，所述 A_{critical} 表示严重告警状态，所述 F 表示故障状态；

根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重，并利用第二映射函数确定出指标与故障间的关联规则；

根据预先确定的所述规则层神经元节点与所述模式层神经元节点间的关联权重与所述指标与故障间的关联规则，并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率；

将所述概率中较大的概率所对应的模式确定为预测结果。

2. 根据权利要求 1 所述的基于模糊神经网络的故障预测方法，其特征在于，所述 τ 个 n 维指标数据 $\bar{X} = (\overrightarrow{X_1}, \overrightarrow{X_2}, \dots, \overrightarrow{X_\tau})^T$ ，所述

$\overrightarrow{X_k} = (x_{k1}, x_{k2}, \dots, x_{kn})$ ($k \in (1, 2, \dots, \tau)$) 为第 k 个时隙的 n 维指标数据，所述 x_{ki} ($i \in (1, 2, \dots, n)$) 为第 k 个时隙的第 i 个指标类别的指标数据，

其中，所述预处理层神经元节点利用第一映射函数将所述输入层神经元节点中输入的每一个 n 维指标数据中的每一类别的指标数据映射成集合 $S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ 中的一种，包括：所述预处理层神经元节点将所述输入层神经元节点中输入的第 i 个时隙的 n 维指标数据中的第 j 个类别的指标数据按照公式

$$\text{degree}_{(i-1)*n+j} = \mu(x_{ij}) =$$

$$\frac{x_{ij}}{\max_{k \in \mathbb{N}^+, \text{且 } k \in [1, n]} (x_{ik})}$$

$\in S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ ($i = 1, 2, \dots, \tau$; $j = 1, 2, \dots, n$) 进行映射；其中，所述 $\text{degree}_{(i-1)*n+j}$ 为所述预处理层中第 $(i-1)*n+j$ 个神经元节点的输出。

3. 根据权利要求 2 所述的基于模糊神经网络的故障预测方法，其特征在于，所述输入层神经元节点数量为 τ ，所述预处理层神经元节点数量为 $\tau*n$ ，所述规则层神经元节点数

量为 $n+\tau+\varepsilon$ ($\varepsilon \in \mathbb{N}^+$),

其中,所述根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重确定出指标与故障间的关联规则,包括:根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则。

4. 根据权利要求 3 所述的基于模糊神经网络的故障预测方法,其特征在于,所述根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重,并利用第二映射函数确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则,包括:按照公式 $Rule_j = r(\sum_{i=1}^{n+\tau+\varepsilon} \omega_{ij} * degree_i - \theta_j); j=1,2,\dots,(n+\tau+\varepsilon)$ 依次确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则;其中,所述

$$r(x) = \frac{1}{1+e^{-x}},$$

所述 $Rule_j$ 为所述规则层第 j 个神经元节点的输出,所述 ω_{ij} 为所述预处理层第 i 个神经元节点与所述规则层第 j 个神经元节点间的关联权重,所述 θ_j 表示所述规则层中第 j 个神经元节点的阈值。

5. 根据权利要求 4 所述的基于模糊神经网络的故障预测方法,其特征在于,所述模式层神经元节点数量为 2,所述规则层神经元节点与所述模式层神经元节点之间全连接,

其中,所述根据所述规则层神经元节点与所述模式层神经元节点间的关联权重与所述指标与故障间的关联规则,并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率,包括:

按照公式 $P_j = f(\sum_{i=1}^{n+\tau+\varepsilon} v_{ij} * Rule_i - \mathcal{G}_j)$ ($j=1,2$) 确定出所述 τ 个 n 维指标数据处于故障倾向模式的概率 P_1 和无故障模式的概率 P_2 ;所述

$$f(x) = \frac{1}{1+e^{-x}},$$

所述 P_j 为所述模式层第 j 个神经元节点的输出,所述 v_{ij} 为所述规则层第 i 个神经元节点与所述模式层第 j 个神经元节点间的关联权重,所述 \mathcal{G}_j 表示所述规则层中第 j 个神经元节点的阈值。

6. 根据权利要求 1 至 5 任一项所述的基于模糊神经网络的故障预测方法,其特征在于,在所述根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重,并利用第二映射函数确定出指标与故障间的关联规则之前,还包括:

对所述预处理层神经元节点与所述规则层神经元节点间的关联权重、所述规则层中神经元节点的阈值、所述规则层神经元节点与所述模式层神经元节点间的关联权重以及所述规则层中神经元节点的阈值进行初始化。

7. 根据权利要求 6 所述的基于模糊神经网络的故障预测方法,其特征在于,所述对所

述预处理层神经元节点与所述规则层神经元节点间的关联权重、所述规则层中神经元节点的阈值、所述规则层神经元节点与所述模式层神经元节点间的关联权重以及所述规则层中神经元节点的阈值进行初始化,包括:

按照公式 $\omega_{ij} = \sigma_{ij} + \delta_{ij} + \varphi_{ij}$ ($i=1,2,\dots, n^* \tau$; $j=1,2,\dots, (n+\tau+\varepsilon)$) 确定出所述预处理层第 i 个神经元节点与所述规则层第 j 个神经元节点间的初始关联权重,按照公式

$$\theta_i = \frac{1}{n+\tau+\varepsilon}$$

($i = 1, 2, \dots, (n+\tau+\varepsilon)$) 确定出所述规则层中第 i 个神经元节点的初始阈值,确定所述规则层神经元节点与所述模式层神经元节点间的初始关联权重为区间 $[0, 1]$ 间的任意随机数,确定所述模式层中神经元节点的初始阈值为 0.5;其中,所述

$$\sigma_{ij} = \exp\left[\left(-\frac{\tau-i}{\tau}\right) \times \ln(\text{factor}_i)\right]$$

factor_i 为用于表示不同时隙的指标对故障预测的影响的标量值),所述 $\delta_{ij} \propto \frac{n_i \gamma_i}{\Delta \tau_i}$

($\Delta \tau_i$ 表示所述 n 维指标数据的第 i 个指标类别超过阈值连续产生告警的时间间隔, n_i 表示所述 n 维指标数据的第 i 个指标类别超过阈值连续产生告警的时间间隔内告警发生的次数, γ_i 表示所述 n 维指标数据的第 i 个指标类别超过阈值连续产生告警的时间间隔内发生故障的比例),所述 φ_{ij} 为预设的值。

8. 根据权利要求 1 至 5 任一项所述的基于模糊神经网络的故障预测方法,其特征在于,还包括:

判断所述预测结果是否满足预设的误差条件;

若所述预测结果满足所述预设的误差条件,输出所述预测结果,否则,重新计算所述预处理层神经元节点与所述规则层神经元节点间的关联权重和所述规则层神经元节点与所述模式层神经元节点间的关联权重,依次启动根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重,并利用第二映射函数确定出指标与故障间的关联规则、根据预先确定的所述规则层神经元节点与所述模式层神经元节点间的关联权重与所述指标与故障间的关联规则,并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率和将所述概率中较大的概率所对应的模式确定为预测结果的步骤重新进行预测。

9. 根据权利要求 8 所述的基于模糊神经网络的故障预测方法,其特征在于,所述判断所述预测结果是否满足预设的误差条件,包括:

按照公式

$$\text{Error} = \frac{1}{2} \sum_{i=1}^2 (P_i - d_i)^2$$

(d_i 为所述模式层第 i 个神经元节点的期望输出) 计算出所述算法模型的输出误差;

判断所述输出误差是否小于第一阈值,若所述输出误差小于所述第一阈值,则确定所述预测结果满足所述预设的误差条件,否则,确定所述预测结果不满足所述预设的误差条件。

10. 根据权利要求 9 所述的基于模糊神经网络的故障预测方法, 其特征在于, 所述重新计算所述预处理层神经元节点与所述规则层神经元节点间的关联权重和所述规则层神经元节点与所述模式层神经元节点间的关联权重, 包括:

按照公式 $w_{ij}(t+1) = w_{ij}(t) + \eta * \zeta_j * degree_i$ ($t=0; i=1, 2, \dots, n * \tau; j=1, 2, \dots, (n + \tau + \varepsilon)$) 和 $w_{ij}(t+1) = w_{ij}(t) + \eta * \zeta_j * degree_i + \alpha(w_{ij}(t) - w_{ij}(t-1))$ ($t = 1, 2, \dots, \tau - 1; i = 1, 2, \dots, n * \tau; j = 1, 2, \dots, (n + \tau + \varepsilon)$) 重新计算出所述预处理层第 i 个神经元节点与所述规则层第 j 个神经元节点间的关联权重, 按照公式 $v_{ij}(t+1) = v_{ij}(t) + \eta * \zeta_j * Rule_i$ ($t = 0; i = 1, 2, \dots, (n + \tau + \varepsilon); j = 1, 2$) 和 $v_{ij}(t+1) = v_{ij}(t) + \eta * \zeta_j * Rule_i + \alpha(v_{ij}(t) - v_{ij}(t-1))$ ($t = 1, 2, \dots, \tau - 1; i = 1, 2, \dots, (n + \tau + \varepsilon); j = 1, 2$) 重新计算出所述规则层第 i 个神经元节点与所述模式层第 j 个神经元节点间的关联权重; 其中, $\zeta_j = Rule_j * (Rule_j) * \sum_{k=1}^2 \delta_k v_{jk}$, $\zeta_j = P_j(1 - P_j)(d_j - P_j)$, $\eta \in (0, 1)$, $\alpha \in (0, 1)$ 。

一种基于模糊神经网络的故障预测方法

技术领域

[0001] 本发明涉及网络故障预测技术领域,尤其涉及一种基于模糊神经网络的故障预测方法。

背景技术

[0002] 为了有效应对复杂网络环境出现的故障,网络自管理要求分析网络运行状态并发现网管系统中指标和故障的关联关系,并在故障发生前能够预测即将发生故障的可能性。

[0003] 目前,已经出现了一种故障预测方法,包括层次分析法,模糊评价法等,其核心是将该领域专家的经验判断予以量化,从而为决策者提供定量形式的决策依据,但是,需要人为给定每个指标的权值并且需要专家参与,无法实现在线故障预测的特殊需求。

发明内容

[0004] 有鉴于此,本发明实施例提供一种基于模糊神经网络的故障预测方法,能够解决现有技术中无法进行在线故障预测的问题。

[0005] 为达到上述目的,本发明的实施例采用如下技术方案:

[0006] 本发明提出了一种基于模糊神经网络的故障预测方法,包括:

[0007] 根据故障预测时序建立算法模型;其中,所述算法模型由输入层神经元节点、预处理层神经元节点、规则层神经元节点、模式层神经元节点和输出层神经元节点组成,所述输入层神经元节点与所述预处理层神经元节点之间连接,所述预处理层神经元节点与所述规则层神经元节点之间连接,所述规则层神经元节点与所述模式层神经元节点之间连接,所述模式层神经元节点与所述输出层神经元节点之间连接;

[0008] 读取表征网络运行状态的 τ 个时隙的 τ 个 n 维指标数据;其中,所述 n 为用于故障预测的指标类别数量;

[0009] 向所述输入层神经元节点中输入所述 τ 个 n 维指标数据;

[0010] 所述预处理层神经元节点利用第一映射函数将所述输入层神经元节点中输入的每一个 n 维指标数据中的每一类别的指标数据映射成集合 $S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ 中的一种;其中,所述 N 表示正常状态,所述 A_{warning} 表示警告状态,所述 A_{minor} 表示次要告警状态,所述 A_{major} 表示主要告警状态,所述 A_{critical} 表示严重告警状态,所述 F 表示故障状态;

[0011] 根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重,并利用第二映射函数确定出指标与故障间的关联规则;

[0012] 根据预先确定的所述规则层神经元节点与所述模式层神经元节点间的关联权重与所述指标与故障间的关联规则,并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率;

[0013] 将所述概率中较大的概率所对应的模式确定为预测结果。

[0014] 本发明实施例提供的基于模糊神经网络的故障预测方法,先根据预先确定的预处

理层神经元节点与规则层神经元节点间的关联权重,利用第二映射函数确定出指标与故障间的关联规则,然后再根据预先确定的规则层神经元节点与模式层神经元节点间的关联权重与上述指标与故障间的关联规则,利用第三映射函数确定出 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率,并将所述概率中较大的概率所对应的模式确定为预测结果,因而能够解决现有技术中不能进行在线故障预测的问题。

附图说明

[0015] 通过参考附图会更加清楚的理解本发明的特征和优点,附图是示意性的而不应该理解为对本发明进行任何限制,在附图中:

[0016] 图 1 为本发明基于模糊神经网络的故障预测方法一实施例的流程示意图;

[0017] 图 2 为故障预测时序图;

[0018] 图 3 为模糊神经网络结构图;

[0019] 图 4 为本发明基于模糊神经网络的故障预测方法另一实施例的部分流程示意图;

[0020] 图 5 为图 4 中 S8 一实施例的流程示意图。

具体实施方式

[0021] 下面将结合附图对本发明的实施例进行详细描述。

[0022] 参看图 1 至图 3,本发明的实施例提供一种基于模糊神经网络的故障预测方法,包括:

[0023] S1、根据故障预测时序建立算法模型;其中,所述算法模型由输入层神经元节点、预处理层神经元节点、规则层神经元节点、模式层神经元节点和输出层神经元节点组成,所述输入层神经元节点与所述预处理层神经元节点之间连接,所述预处理层神经元节点与所述规则层神经元节点之间连接,所述规则层神经元节点与所述模式层神经元节点之间连接,所述模式层神经元节点与所述输出层神经元节点之间连接;

[0024] S2、读取表征网络运行状态的 τ 个时隙的 τ 个 n 维指标数据;其中,所述 n 为用于故障预测的指标类别数量;

[0025] S3、向所述输入层神经元节点中输入所述 τ 个 n 维指标数据;

[0026] S4、所述预处理层神经元节点利用第一映射函数将所述输入层神经元节点中输入的每一个 n 维指标数据中的每一类别的指标数据映射成集合 $S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ 中的一种;其中,所述 N 表示正常状态,所述 A_{warning} 表示警告状态,所述 A_{minor} 表示次要告警状态,所述 A_{major} 表示主要告警状态,所述 A_{critical} 表示严重告警状态,所述 F 表示故障状态;

[0027] S5、根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重,并利用第二映射函数确定出指标与故障间的关联规则;

[0028] S6、根据预先确定的所述规则层神经元节点与所述模式层神经元节点间的关联权重与上述指标与故障间的关联规则,并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率;

[0029] S7、将所述概率中较大的概率所对应的模式确定为预测结果。

[0030] 本实施例中,如图 2 所示,若在时刻 t 执行故障预测,即基于预测模型以及在时间

窗 τ 内获得的指标信息,预测在 $(t+\Delta t_1, t+\Delta t_1+\Delta t_p)$ 是否会发生故障。其中, τ 是进行故障预测的时间窗; Δt_1 是预测执行时间, Δt_w 为告警时间,代表 Δt_1 的最小可能取值; Δt_p 表征预测持续的时间。本专利中可以将连续时间进行离散化处理,取某个时间间隔作为一个时隙。本专利中所指时间长短用这段时间所包含的时隙个数来表示,对应的时间点用所在的时隙位置表示。图 3 所示为模糊神经网络结构图。

[0031] 本发明实施例提供的基于模糊神经网络的故障预测方法,先根据预先确定的预处理层神经元节点与规则层神经元节点间的关联权重,利用第二映射函数确定出指标与故障间的关联规则,然后再根据预先确定的规则层神经元节点与模式层神经元节点间的关联权重与上述指标与故障间的关联规则,利用第三映射函数确定出 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率,并将所述概率中较大的概率所对应的模式确定为预测结果,因而能够解决现有技术中不能进行在线故障预测的问题。

[0032] 可选地,参看图 3,在本发明基于模糊神经网络的故障预测方法的另一实施例中,

所述 τ 个 n 维指标数据 $\vec{X} = (\vec{X}_1, \vec{X}_2, \dots, \vec{X}_\tau)^T$, 所述 $\vec{X}_k = (x_{k1}, x_{k2}, \dots, x_{kn})$ ($k \in (1, 2, \dots, \tau)$) 为第 k 个时隙的 n 维指标数据,所述 x_{ki} ($i \in (1, 2, \dots, n)$) 为第 k 个时隙的第 i 个指标类别的指标数据,

[0033] 其中,所述预处理层神经元节点利用第一映射函数将所述输入层神经元节点中输入的每一个 n 维指标数据中的每一类别的指标数据映射成集合 $S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ 中的一种,包括:

[0034] 所述预处理层神经元节点将所述输入层神经元节点中输入的第 i 个时隙的 n 维

指标数据中的第 j 个类别的指标数据按照公式 $degree_{(i-1)*n+j} = \mu(x_{ij}) = \frac{x_{ij}}{\max_{k \in N^+, \text{且 } k \in [1, n]} (x_{ik})}$

$\in S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ ($i = 1, 2, \dots, \tau; j = 1, 2, \dots, n$) 进行映射;其中,

所述 $degree_{(i-1)*n+j}$ 为所述预处理层中第 $(i-1)*n+j$ 个神经元节点的输出。

[0035] 本实施例中,正常 (Normal) 表示网络系统的运行指标处于正常状态;告警 (Alarm) 表示网络中出现部分指标异常的情况,但该情况还不足以导致错误的产生并影响系统正常运行,可分为严重告警 (Critical)、主要告警 (Major)、次要告警 (Minor)、警告 (Warning) 四个等级。故障 (Failure) 表示系统处于无法正常工作状态。此处为方便数值计算处理,将 $N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F$ 分别对应为具体的数值 0、1、2、3、4 和 5。 $\mu(x_{ij})$ 用于将 x_{ij} 离散化映射为集合 $S = \{N, A_{\text{warning}}, A_{\text{minor}}, A_{\text{major}}, A_{\text{critical}}, F\}$ 所对应的数值集合 $\{0, 1, 2, 3, 4, 5\}$ 中的一个值。如图 3 所示,为实现对输入层输入的 τ 个 n 维指标数据的模糊映射,预处理层对应了 $\tau * n$ 神经元节点。

[0036] 可选地,参看图 3,在本发明基于模糊神经网络的故障预测方法的另一实施例中,所述输入层神经元节点数量为 τ ,所述预处理层神经元节点数量为 $\tau * n$,所述规则层神经元节点数量为 $n + \tau + \varepsilon$ ($\varepsilon \in N^+$),

[0037] 其中,所述根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重确定出指标与故障间的关联规则,包括:

[0038] 根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则。

[0039] 本实施例中,如图 3 所示,描述指标及故障间的关联规则,从以下几个方面进行:
a) 不同时隙下相同类别的指标同故障的关联规则 (n 个时序规则分析神经元中每个时序规则分析神经元和预处理层中分别处理不同时隙某一类别指标的 τ 个神经元连接);
b) 同一时隙下不同类别的指标同故障的关联关系 (τ 个指标规则分析神经元中每个指标规则分析神经元和预处理层中分别处理某一时隙各个指标的 n 个神经元连接);
c) 不同时隙下不同类别的指标同故障可能的关联关系 (不同时隙下不同类别的指标同故障的关联规则有多种可能性,要全覆盖这种关联规则需要数目庞大的神经元,此处取 ε 个其它规则分析神经元,并建立该 ε 个其它规则分析神经元中每个其它规则分析神经元和预处理层中 ε 个神经元的全连接)。由此,规则层处理指标同故障的关联规则的神经元节点共有 $(n+\tau+\varepsilon)$ 个。其中,参数 n 、 τ 和 ε 分别代表规则层处理上述 3 种指标和故障关联规则的神经元个数。

[0040] 本实施例中,根据预先确定的,预处理层神经元节点与规则层神经元节点间的关联权重确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则,能够便于基于当前及历史指标数据预测未来故障发生的可能性。

[0041] 可选地,在本发明基于模糊神经网络的故障预测方法的另一实施例中,所述根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重,并利用第二映射函数确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则,包括:

[0042] 按照公式 $Rule_j = r(\sum_{i=1}^{n+\tau} \omega_{ij} * degree_i - \theta_j)$; $j = 1, 2, \dots, (n+\tau+\varepsilon)$ 依次确定出 n 个不同时隙下相同类别的指标同故障的关联规则、 τ 个同一时隙下不同类别的指标同故障的关联规则和 ε 个不同时隙下不同类别的指标同故障的关联规则;其中,所述

$$[0043] \quad r(x) = \frac{1}{1+e^{-x}},$$

[0044] 所述 $Rule_j$ 为所述规则层第 j 个神经元节点的输出,所述 ω_{ij} 为所述预处理层第 i 个神经元节点与所述规则层第 j 个神经元节点间的关联权重,所述 θ_j 表示所述规则层中第 j 个神经元节点的阈值。

[0045] 可选地,在本发明基于模糊神经网络的故障预测方法的另一实施例中,所述模式层神经元节点数量为 2,所述规则层神经元节点与所述模式层神经元节点之间全连接,

[0046] 其中,所述根据所述规则层神经元节点与所述模式层神经元节点间的关联权重与所述指标与故障间的关联规则,并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率,包括:

[0047] 按照公式 $P_j = f(\sum_{i=1}^{n+\tau+\varepsilon} v_{ij} * Rule_i - \mathcal{G}_j)$ ($j = 1, 2$) 确定出所述 τ 个 n 维指标数据处于故障倾向模式的概率 P_1 和无故障模式的概率 P_2 ;所述

$$[0048] \quad f(x) = \frac{1}{1+e^{-x}},$$

[0049] 所述 P_j 为所述模式层第 j 个神经元节点的输出, 所述 v_{ij} 为所述规则层第 i 个神经元节点与所述模式层第 j 个神经元节点间的关联权重, 所述 θ_j 表示所述规则层中第 j 个神经元节点的阈值。

[0050] 可选地, 在本发明基于模糊神经网络的故障预测方法的另一实施例中, 在所述根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重, 并利用第二映射函数确定出指标与故障间的关联规则之前, 还包括:

[0051] 对所述预处理层神经元节点与所述规则层神经元节点间的关联权重、所述规则层中神经元节点的阈值、所述规则层神经元节点与所述模式层神经元节点间的关联权重以及所述规则层中神经元节点的阈值进行初始化。

[0052] 本实施例中, 通过进行初始化, 能够明确算法收敛方向, 加速算法收敛速度, 使得算法训练时间较之其他预测技术明显减少, 同时可有效避免过度拟合。

[0053] 可选地, 在本发明基于模糊神经网络的故障预测方法的另一实施例中, 所述对所述预处理层神经元节点与所述规则层神经元节点间的关联权重、所述规则层中神经元节点的阈值、所述规则层神经元节点与所述模式层神经元节点间的关联权重以及所述规则层中神经元节点的阈值进行初始化, 包括:

[0054] 按照公式 $\omega_{ij} = \sigma_{ij} + \delta_{ij} + \varphi_{ij}$ ($i = 1, 2, \dots, n * \tau$; $j = 1, 2, \dots, (n + \tau + \varepsilon)$) 确定出所述预处理层第 i 个神经元节点与所述规则层第 j 个神经元节点间的初始关联权重, 按照公式

$$[0055] \quad \theta_i = \frac{1}{n + \tau + \varepsilon}$$

[0056] ($i = 1, 2, \dots, (n + \tau + \varepsilon)$) 确定出所述规则层中第 i 个神经元节点的初始阈值, 确定所述规则层神经元节点与所述模式层神经元节点间的初始关联权重为区间 $[0, 1]$ 间的任意随机数, 确定所述模式层中神经元节点的初始阈值为 0.5; 其中, 所述

$$[0057] \quad \sigma_{ij} = \exp\left[-\frac{\tau - i}{\tau}\right] \times \ln(\text{factor}_i)$$

[0058] factor_i 为用于表示不同时间隙的指标对故障预测的影响的标量值), 所述 $\delta_{ij} \propto \frac{n_i \gamma_i}{\Delta \tau_i}$

[0059] ($\Delta \tau_i$ 表示所述 n 维指标数据的第 i 个指标类别超过阈值连续产生告警的时间间隔, n_i 表示所述 n 维指标数据的第 i 个指标类别超过阈值连续产生告警的时间间隔内告警发生的次数, γ_i 表示所述 n 维指标数据的第 i 个指标类别超过阈值连续产生告警的时间间隔内发生故障的比例), 所述 φ_{ij} 为预设的值。

[0060] 本实施例中, 为了体现指标的时效性, 设计时间影响因子 factor_i 用以表达不同时间隙获得的指标对未来故障预测的不同影响。距离当前时间越近, 指标可信性越大, 对未来故障预测的影响越大。通过 ω_{ij} 的初始化, 能够便于确定算法收敛方向。

[0061] 可选地, 参看图 4, 在本发明基于模糊神经网络的故障预测方法的另一实施例中, 还包括:

[0062] S8、判断所述预测结果是否满足预设的误差条件；

[0063] S9、若所述预测结果满足所述预设的误差条件，输出所述预测结果，否则，重新计算所述预处理层神经元节点与所述规则层神经元节点间的关联权重和所述规则层神经元节点与所述模式层神经元节点间的关联权重，依次启动根据预先确定的所述预处理层神经元节点与所述规则层神经元节点间的关联权重，并利用第二映射函数确定出指标与故障间的关联规则、根据预先确定的所述规则层神经元节点与所述模式层神经元节点间的关联权重与所述指标与故障间的关联规则，并利用第三映射函数确定出所述 τ 个 n 维指标数据处于故障倾向模式和无故障模式的概率和将所述概率中较大的概率所对应的模式确定为预测结果的步骤重新进行预测。

[0064] 本实施例中，在预测结果不满足预设的误差条件时，进行重新进行参数初始化的模型训练过程，能够便于获得较准确的预测结果。

[0065] 可选地，参看图 5，在本发明基于模糊神经网络的故障预测方法的另一实施例中，所述判断所述预测结果是否满足预设的误差条件 (S8)，包括：

[0066] S80、按照公式

$$[0067] \quad Error = \frac{1}{2} \sum_{i=1}^2 (P_i - d_i)^2$$

[0068] (d_i 为所述模式层第 i 个神经元节点的期望输出) 计算出所述算法模型的输出误差；

[0069] S81、判断所述输出误差是否小于第一阈值，若所述输出误差小于所述第一阈值，则确定所述预测结果满足所述预设的误差条件，否则，确定所述预测结果不满足所述预设的误差条件。

[0070] 本实施例中，通过判断算法模型的输出误差是否小于第一阈值，能够便于确定出预测结果是否满足预设的误差条件。

[0071] 可选地，在本发明基于模糊神经网络的故障预测方法的另一实施例中，所述重新计算所述预处理层神经元节点与所述规则层神经元节点间的关联权重和所述规则层神经元节点与所述模式层神经元节点间的关联权重，包括：

[0072] 按照公式 $w_{ij}(t+1) = w_{ij}(t) + \eta * \zeta_j * degree_i$ ($t = 0 ; i = 1, 2, \dots, n * \tau ; j = 1, 2, \dots, (n + \tau + \epsilon)$) 和 $w_{ij}(t+1) = w_{ij}(t) + \eta * \zeta_j * degree_i + \alpha(w_{ij}(t) - w_{ij}(t-1))$ ($t = 1, 2, \dots, \tau - 1 ; i = 1, 2, \dots, n * \tau ; j = 1, 2, \dots, (n + \tau + \epsilon)$) 重新计算出所述预处理层第 i 个神经元节点与所述规则层第 j 个神经元节点间的关联权重，按照公式 $v_{ij}(t+1) = v_{ij}(t) + \eta * \zeta_j * Rule_i$ ($t = 0 ; i = 1, 2, \dots, (n + \tau + \epsilon) ; j = 1, 2$) 和 $v_{ij}(t+1) = v_{ij}(t) + \eta * \zeta_j * Rule_i + \alpha(v_{ij}(t) - v_{ij}(t-1))$ ($t = 1, 2, \dots, \tau - 1 ; i = 1, 2, \dots, (n + \tau + \epsilon) ; j = 1, 2$) 重新计算出所述规则层第 i 个神经元节点与所述模式层第 j 个神经元节点间的关联权重；其中， $\zeta_j = Rule_j * (Rule_j) * \sum_{k=1}^2 \delta_k v_{jk}$ ， $\zeta_j = P_j(1 - P_j)(d_j - P_j)$ ， $\eta \in (0, 1)$ ， $\alpha \in (0, 1)$ 。

[0073] 本实施例中， t 表示训练次数， $w_{ij}(0)$ 表示预处理层第 i 个神经元节点与规则层第 j 个神经元节点间的关联权重的初始化值， $v_{ij}(0)$ 表示规则层第 i 个神经元节点与模式层第 j 个神经元节点间的关联权重的初始化值。 η 为学习因子， α 为平滑因子。本实施例中，关联权重修正方案可保证算法收敛快，关联权重平滑变化。

[0074] 虽然结合附图描述了本发明的实施方式,但是本领域技术人员可以在不脱离本发明的精神和范围的情况下做出各种修改和变型,这样的修改和变型均落入由所附权利要求所限定的范围之内。

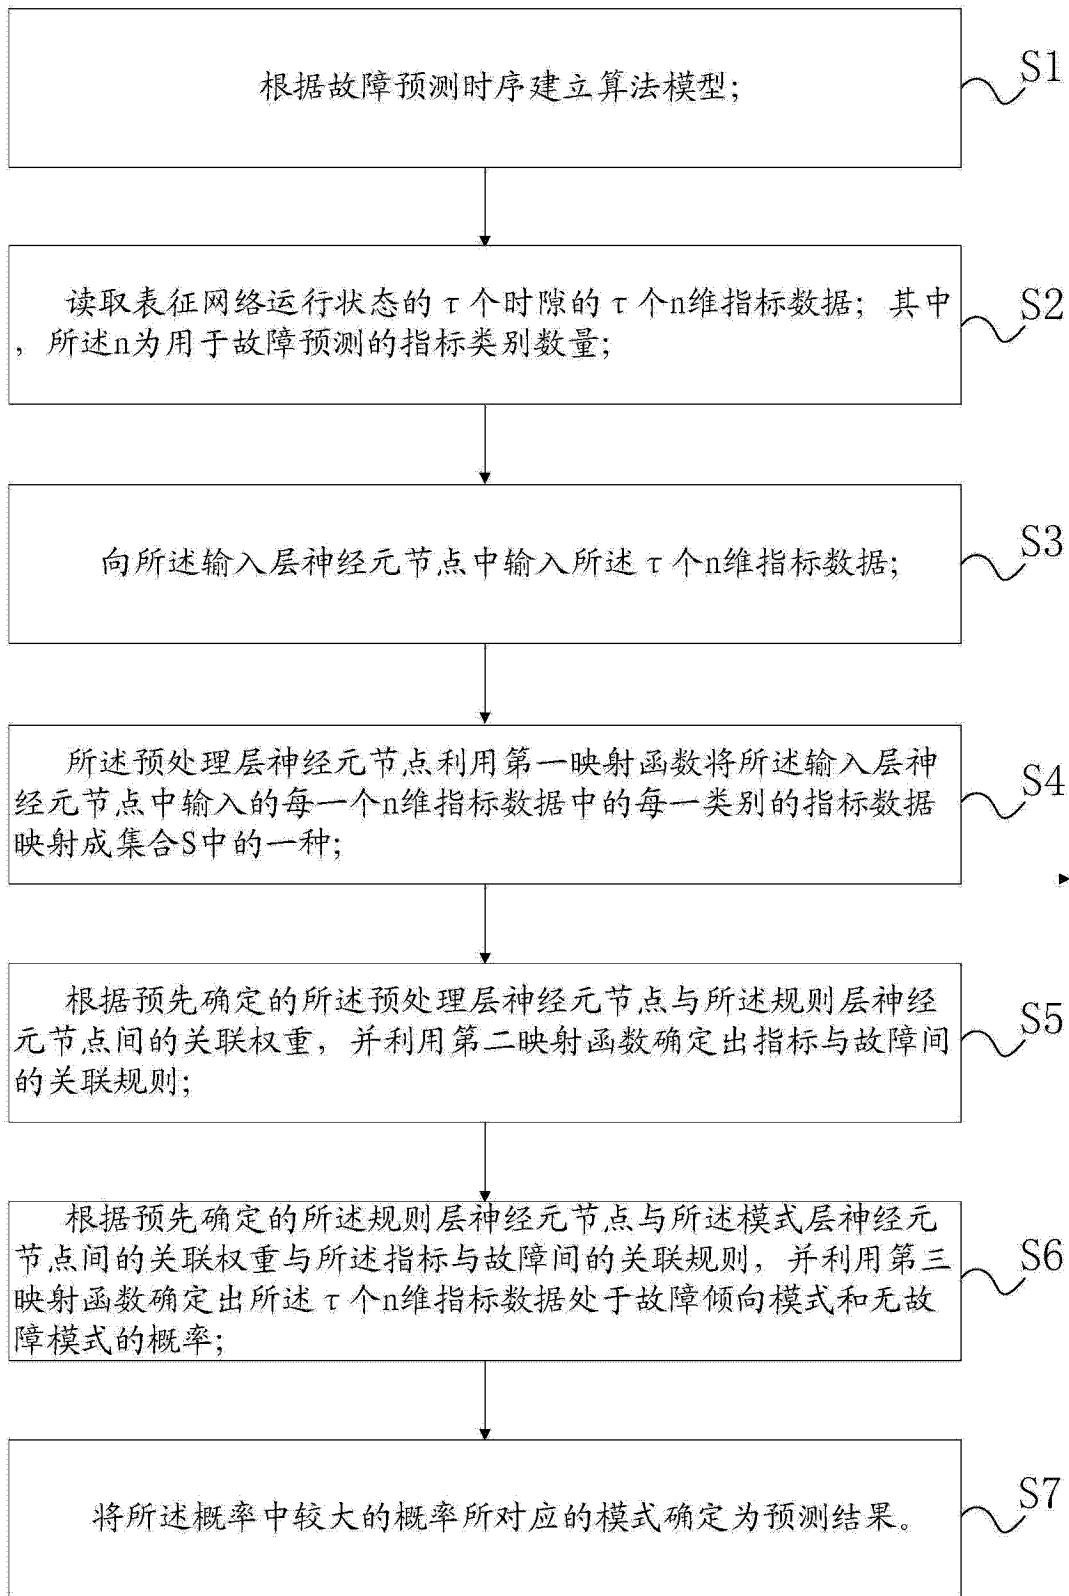


图 1




图 2

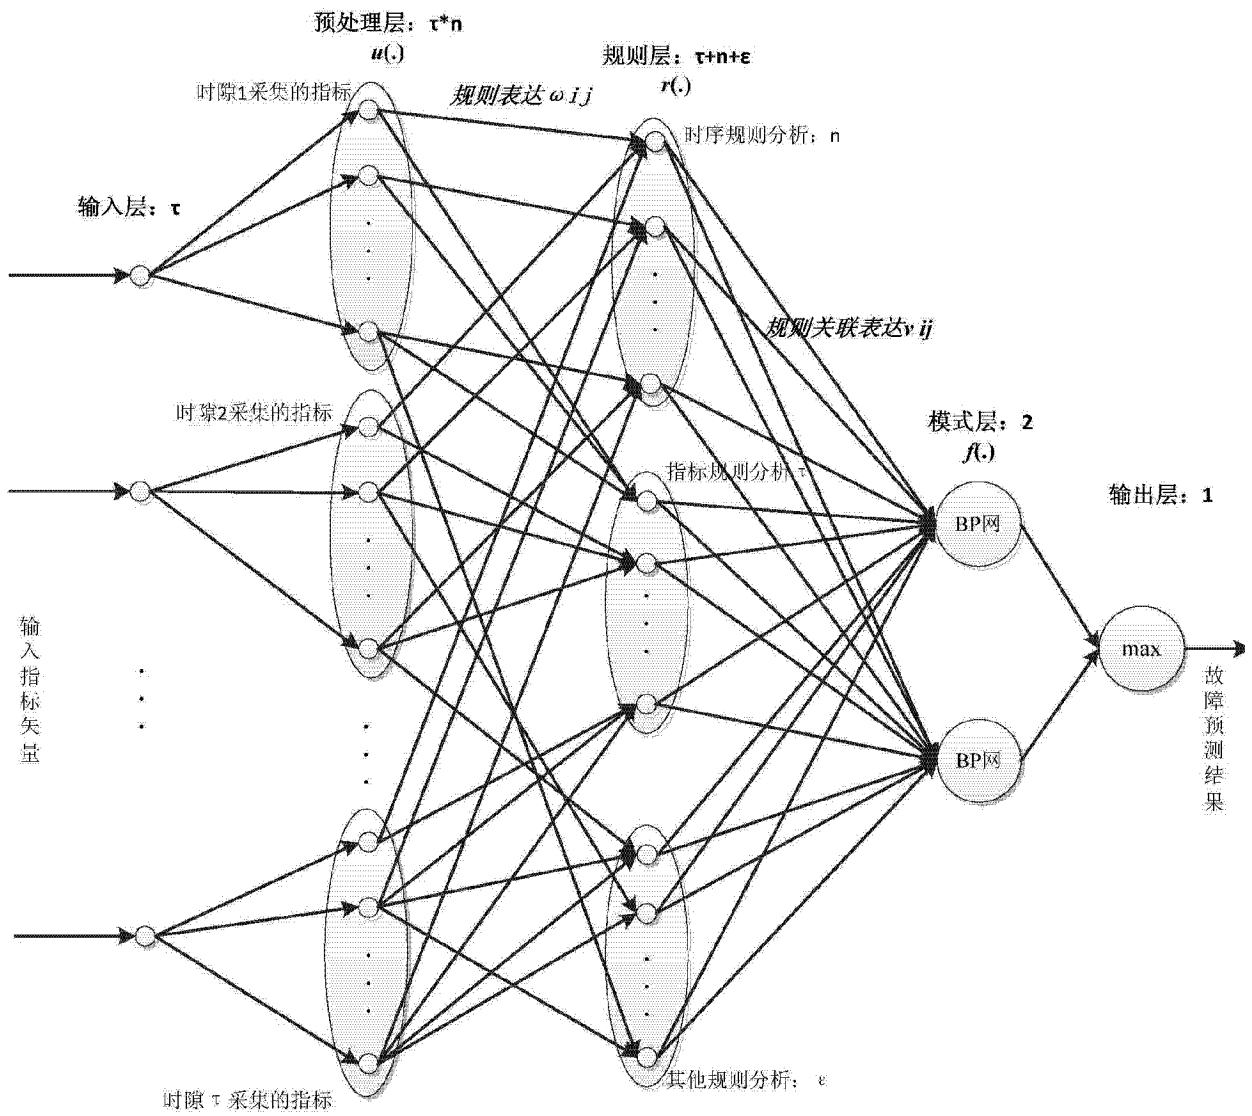


图 3

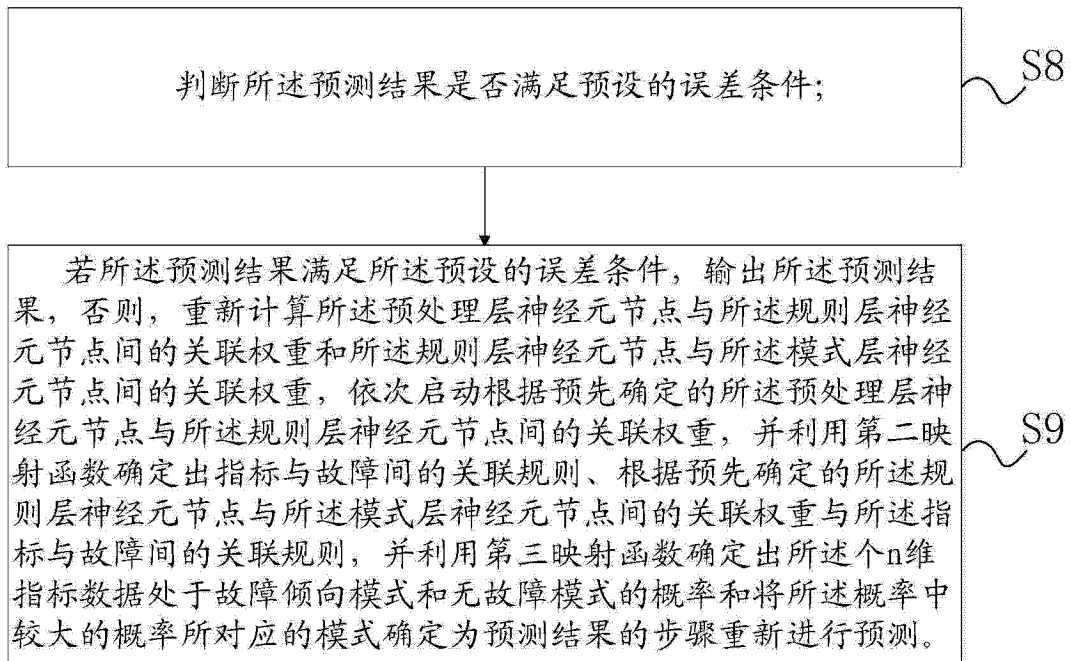


图 4

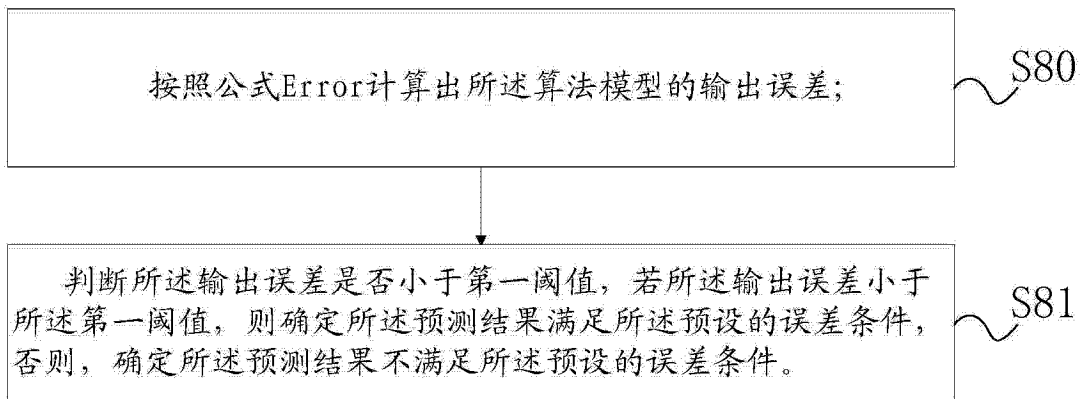


图 5