

(12) 按照专利合作条约所公布的国际申请

(19) 世界知识产权组织
国际局

(43) 国际公布日
2020 年 12 月 10 日 (10.12.2020)



(10) 国际公布号
WO 2020/244346 A1

(51) 国际专利分类号:
G05B 13/04 (2006.01)

(21) 国际申请号: PCT/CN2020/087798

(22) 国际申请日: 2020 年 4 月 29 日 (29.04.2020)

(25) 申请语言: 中文

(26) 公布语言: 中文

(30) 优先权:
201910482044.5 2019年6月4日 (04.06.2019) CN

(71) 申请人: 佛山科学技术学院 (FOSHAN UNIVERSITY) [CN/CN]; 中国广东省佛山市禅城区江湾一路18号, Guangdong 528000 (CN)。

(72) 发明人: 张彩霞 (ZHANG, Caixia); 中国广东省佛山市禅城区江湾一路18号, Guangdong 528000 (CN)。王向东 (WANG, Xiangdong); 中国广东省佛山市禅城区江湾一路18号, Guangdong 528000 (CN)。

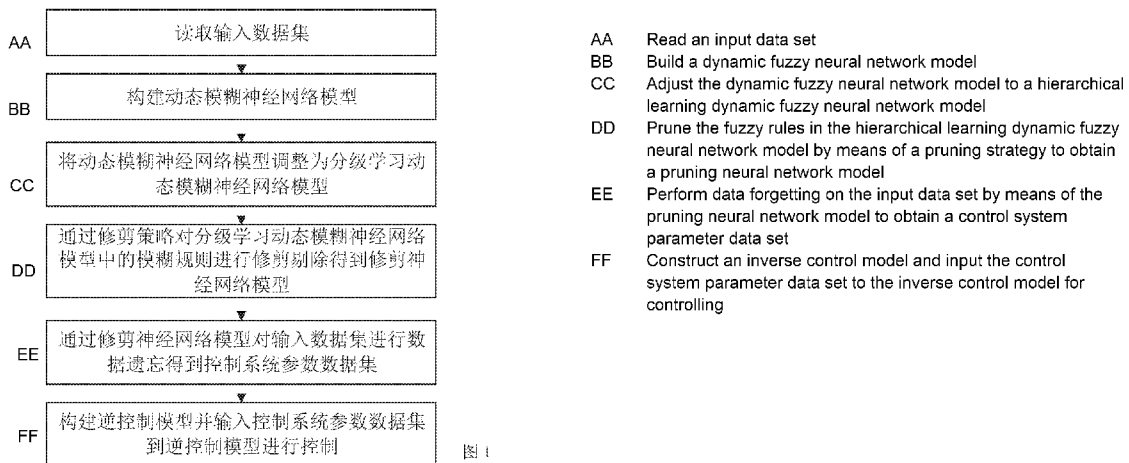
(74) 代理人: 广州嘉权专利商标事务所有限公司 (JIAQUAN IP LAW FIRM); 中国广东省广州市天河区黄埔大道西100号富力盈泰广场A栋910, Guangdong 510627 (CN)。

(81) 指定国(除另有指明, 要求每一种可提供的国家保护): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW。

(84) 指定国(除另有指明, 要求每一种可提供的地区保护): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 欧亚 (AM, AZ, BY, KG, KZ, RU, TJ, TM), 欧洲 (AL, AT, BE, BG,

(54) Title: D-FNN DIRECT INVERSE CONTROL METHOD AND SYSTEM BASED ON PRUNING STRATEGY

(54) 发明名称: 一种基于修剪策略的D-FNN直接逆控制方法及系统



(57) Abstract: Disclosed are a D-FNN direct inverse control method and system based on a pruning strategy. By means of hierarchical learning, a more concise structure and shorter learning time can be ensured. A major advantage of the hierarchical learning strategy is to alleviate the oscillation problem in the learning process. When disturbances occur in an external environment, a D-FNN has strong adaptability and robustness, so that the trajectory error can be quickly reduced to close to zero. The D-FNN can automatically generate or delete fuzzy rules according to the importance of the inverse control system and the complexity of the system. The model does not need to be preset during online learning, and an order can be set according to training data for learning adaptively, thereby compensating for non-linear system modeling errors to treat external disturbances. By means of simulation research, the dynamic fuzzy neural network will be applied in many real-time automatic control systems.

CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU,
IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT,
RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI,
CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG)。

根据细则4.17的声明：

— 发明人资格(细则4.17(iv))

本国际公布：

— 包括国际检索报告(条约第21条(3))。

(57) 摘要：本发明公开了一种基于修剪策略的D-FNN直接逆控制方法及系统，采用分级学习的能保证更简洁的结构和更短的学习时间，分级学习策略的一大好处是可以缓解学习过程中的震荡问题，当外部环境出现扰动时，D-FNN具有很强的自适应性和鲁棒性可以把轨迹误差迅速地减少到接近零。D-FNN可以根据对逆控制系统的重要性及系统的复杂性自动地产生或者删除模糊规则，在线学习时模型不需要预先设定，可以从训练数据设置次序自适应地学习，从而补偿了非线性系统建模误差处理外部扰动。通过仿真研究，动态模糊神经网络将会在许多实时自动控制系统中得到应用。

一种基于修剪策略的 D-FNN 直接逆控制方法及系统

技术领域

本公开涉及自动控制、人工智能和神经网络技术领域，具体涉及一种基于修剪策略的 D-FNN 直接逆控制方法及系统。

背景技术

一个训练好的神经网络可以看成是一种知识的表达，与模糊系统中使用 IF-THEN 规则表达局部知识不同，神经网络通过它的结构，更确定的说，通过它的连接权和局部处理单元，以一种分布式的或局部的方法来储存知识。神经网络中的前馈计算与模糊系统中的前向推理扮演同样的角色。这两种系统都能根据当前情况通过对存储知识的操作来执行任务，已得到期望输出，通过给定一个合适的行为来响应新情况是这两种系统的核心。可是，两者完成任务的方法是不同的。模糊系统是基于逻辑推论的插值推理，而神经网络是基于泛化能力的代数计算。模糊系统通常是从领域专家处获取知识，这个知识借助模糊逻辑理论融入系统。相反神经网络通常从样本中获取知识，这个知识通过训练被吸收到神经网络中。模糊系统和神经网络的结合就形成了模糊神经网络，这种网络致力于两种方法的优点同时避免它们各自的缺陷。把神经网络应用于模糊系统，可以解决模糊系统中提取模糊规则的问题，把模糊系统应用于神经网络，可以避免任意选择初值。

神经网络是模拟人脑结构，具有大规模并行及分布式信息处理能力，但它不能处理和描述模糊信息。模糊系统具有推理过程容易理解，但它很难实现自适应学习的功能。如果将神经网络与模糊系统结合起来，可起到取长补短的效果。

发明内容

为解决上述问题，本公开提供一种基于修剪策略的 D-FNN 直接逆控制方法及系统的技术方案，由于这种方法学习时结构和参数同时调整且学习速度快等优点，因此它一方面可以在模糊逻辑系统中包含低级的神经网络学习和计算功能，另一方面也可以为神经网络提供高级的类似人的思维和推理的模糊逻辑系统，D-FNN（动态模糊神经网络）具有实时学习和控制能力强，参数估计和结构辨识同时进行等优点。

为了实现上述目的，根据本公开的一方面，提供一种基于修剪策略的 D-FNN 直接逆控制方法，所述方法包括以下步骤：

步骤 1，读取输入数据集；

步骤 2，构建动态模糊神经网络模型；

步骤 3，将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型；

步骤 4，通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型；

步骤 5, 通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集;

步骤 6, 构建逆控制模型并输入控制系统参数数据集到逆控制模型进行控制。

进一步地, 在步骤 1 中, 输入数据集为在自然的未被控制的条件下获取的观测数据。

进一步地, 在步骤 2 中, 构建动态模糊神经网络模型的方法为:

$x_1, x_2, \dots, x_r$ 是输入数据, y 是输出数据, 则高斯函数表示的隶属函数:

$$\mu_{ij}(x_i) = \exp\left(-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right) \quad i = 1, 2, \dots, r, j = 1, 2, \dots, u \quad (1)$$

c_{ij} 是 x_i 的第 j 个高斯隶属函数的中心, σ_j 是 x_i 的第 j 个高斯隶属函数的宽度, r 为输入数据的个数, u 为隶属函数的个数;

$$N_j \text{ 为第 } j \text{ 个节点的输出: } \psi_j = \frac{\varphi_j}{\sum_{k=1}^u \varphi_k} \quad j = 1, 2, \dots, u \quad (2)$$

$$\varphi_k = \mu_k(x_i), \quad k = 1, 2, \dots, u; \quad \varphi_j = \mu_{ij}(x_i), \quad i = 1, 2, \dots, r;$$

$$y(X) = \sum_{k=1}^u w_k \cdot \psi_k \quad (3)$$

总输出信号:

其中, y 是输出信号,

$$\text{模糊规则 } w_k \text{ 为: } w_k = a_{k0} + a_{k1}x_1 + \dots + a_{kr}x_r \quad k = 1, 2, \dots, u \quad (4)$$

为动态模糊神经网络模型:

$$y(X) = \frac{\sum_{i=1}^u \left[(a_{i0} + a_{i1}x_1 + \dots + a_{ir}x_r) \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right) \right]}{\sum_{i=1}^u \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right)} \quad (5)$$

C_i 是第 i 个 RBF 单元的中心; a_i, a_k 均为多项式的系数。

进一步地, 在步骤 3 中, 将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型的方法为:

动态模糊神经网络模型的结构不仅由接收域决定还由系统误差决定, 尽管这两种方法都可以被划分为分级自组织方法, 由输出误差确定是否应该加入新模糊规则;

输出误差判断描述如下: (X_i, t_i) 是第 i 个输入数据, X_i 表示第 i 个输入向量, t_i 表示第 i 个期望的输出, 动态模糊神经网络输出为 y_i 。

$$\text{定义 } \|e_i\| = \|t_i - y_i\| \quad (6)$$

如果 $\|e_i\| > k_e$ 时, 动态模糊神经网络模型增加一条新的模糊规则, 最终得到分级学习动态模糊神经网络模型。 k_e 值是根据动态模糊神经网络期望的精度预先选定的。

分级学习能保证更简洁的结构和更短的学习时间。 k_e 是个变量:

$$k_e = \max[e_{\max} \times \beta^i, e_{\min}] \quad (7)$$

这里, 最大误差为 $e_{\max}$, 动态模糊神经网络的精度为 $e_{\min}$, 收敛常数是 $\beta (0 < \beta < 1)$, β^i 为第 i 个收敛常数。

进一步地, 在步骤 4 中, 通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型的方法为:

修剪策略采用的是误差下降率 (ERR) 方法。用 ERR、SVD(奇异值分解) 或 ED(特征值分解) 方法的不同的修剪策略将导致不同的动态模糊神经网络模型的结构, 即不同模糊规则数以及对于某个特定的性能, 每条规则的参数不同, 实验说明 ERR 方法具有明显的物理意义和稳定的数值计算, 这就是为什么该方法被广泛使用的原因。

$T = (t_1, t_2, \dots, t_n) \in R^n$ 为系统理想输出, Y 为系统实际输出。 $\Psi \in R^{(r+1)u \times n}$ 和 $T \in R^n$ 之间有如下关系:

$$Y = W \times \Psi \quad (8)$$

$$\tilde{E} = \|T - Y\| \quad (9)$$

$\tilde{E}^T \tilde{E}$ 表示误差能量, $\{X(i), t(i), i = 1, 2, \dots, n\}$ 为第 n 个输入-输出对, 把式 (8) 代入式 (9) 推导得到线性回归模型 $D = H\theta + E$ (10)

其中, 期望输出为 $D = T^T \in R^n$, 回归向量为 $H = \Psi^T = (h_1, \dots, h_v) \in R^{n \times v}$, $v = u \times (r+1)$, 实参数为 $\theta = W^T \in R^n$, 误差向量为 $E \in R^n$, 回归量为 h_i , 回归量为 q_i 。误差下降率为 $\text{err}_i = \frac{(q_i^T D)^2}{q_i^T q_i D^T D} \quad i = 1, 2, \dots, v$ (11)

err_i 值如果很大, 那么 q_i 和 D 的相似程度就很大, q_i 对于输出结果影响显著, 式 (11) 的几何意义也很显著, 向量 q_i 和 D 的夹角设为 φ_i ,

$$\text{则 } \cos^2 \varphi_i = \text{err}_i = \frac{(q_i^T D)^2}{q_i^T q_i D^T D} \quad i = 1, 2, \dots, v \quad (12)$$

若 $\varphi_i = 90^\circ$, $\text{err}_i = 0$, 表示两个向量正交, 意味着 q_i 对 D 无影响, 如果, 若 $\varphi_i = 0$, $\text{err}_i = 1$, 意味着 q_i 对 D 影响显著。 $\Delta = (\delta_1, \delta_2, \dots, \delta_u) \in R^{(r+1) \times u}$ 为 $\text{err}_i (i = 1, 2, \dots, (r+1)u)$ 重新排列的矩阵, Δ 的第 i 列 δ_i 是误差下降率。

$$\text{定义 } \eta_i = \sqrt{\frac{\delta_i^T \delta_i}{r+1}} \quad (13)$$

第 i 个模糊规则的重要性用 η_i 表达, 值 η_i 越大, 表示第 i 个模糊规则越重要, 假设

$$\eta_i < k_{\text{err}} \quad (14)$$

预先设置阈值为 k_{err} , 则第 i 个模糊规则可以剔除, 最终得到修剪神经网络模型。

未修剪时的训练误差总是比修剪后的误差小, 但是经过修剪, 无论是用 ERR 还是 SVD 或 ED 方法, 系统的测试误差 (用 RMSE 来评判) 总是小于未修剪的动态模糊神经网络模型。

进一步地, 在步骤 5 中, 通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集的方法为:

假定 u 个模糊规则是由 n 个观测数据产生的, 可以写成式 (15) N 节点的模糊规则矩阵输出形式:

$$\Psi = \begin{bmatrix} \psi_{11} & L & \psi_{1n} \\ M & M & M \\ \psi_{u1} & L & \psi_{un} \end{bmatrix} \quad (15)$$

$X_j(x_{1j}, x_{2j}, \Lambda, x_{rj})$ 是输入的观测数据, y_i 是系统的输出数据, 可写成式 (16) 表达形式:

$$W\Psi = Y \quad (16)$$

W 由下式给出:

$$W = (\alpha_{10}L \quad \alpha_{u0} \quad \alpha_{11}L \quad \alpha_{u1} \quad \alpha_{1r}L \quad \alpha_{ur}) \quad (17)$$

$W \in R^u$, $\Psi \in R^{u \times n}$ 。

如何使误差能量 $\tilde{E}^T \tilde{E}$ 最小, 决定于一个最优的系数向量 $W^* \in R^{(r+1)u}$ 。下式给出了利用线性最小二乘法 (LLS) 逼近的方法:

$$W^* \times \Psi = T \quad (18)$$

具有如下表达形式的 W^* 是属于最优的:

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T \quad (19)$$

其中, Ψ 的转置为 Ψ^T , Ψ 的广义逆为 $\Psi^+ = (\Psi^T \Psi)^{-1} \Psi^T$ 。

卡尔曼滤波算法用于确定以下权值:

$$\begin{aligned} W_i &= W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1}) \\ S_i &= S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{1 + \Psi_i S_{i-1} \Psi_i^T} \quad i = 1, 2, \Lambda, n \end{aligned} \quad (20)$$

其中, $W_0 = 0$ 和 $S_0 = \chi I$ 为初始条件。经过 i 次迭代后的系数矩阵为 W_i , 第 i 个观测数据的误差协方差矩阵为 S_i , χ 是一个正数, Ψ 的第 i 列为 Ψ_i , $u(r+1) \times u(r+1)$ 维单位矩阵为 I 。

给予最新的数据最大的加权，而最旧数据加权最小，乃至被遗忘。其实现方法是加入一个遗忘因子 λ ，修剪神经网络模型通过数据遗忘法的回归最小二乘法公式获得控制系统参数数据集。采用数据遗忘法的回归最小二乘法公式如下：

$$\begin{aligned} W_i &= W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1}) \\ S_i &= \frac{1}{\lambda} \left(S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{\lambda + \Psi_i S_{i-1} \Psi_i^T} \right) \quad i = 1, 2, \Lambda, n \end{aligned} \quad (21)$$

其中， $0 < \lambda < 1$ ， λ 越小，表明数据遗忘越快。

当收集到的数据越来越多时，线性最小二乘法的自适应能力将会大大降低。在这种情况下，就需要减少旧数据的影响。

进一步地，在步骤 6 中，构建逆控制模型的方法为：

令 Δp 为控制系统参数数据集， u 为控制系统参数的变化率，它之间关系的传递函数为：

$$\Delta p(s) = \frac{k e^{-T_i s} (1 + \alpha e^{-T_c s})}{1 + \tau s} u(s) \quad (22)$$

其中，循环延时为 T_c ，初始传送延时为 T_i ，控制系统参数的敏感性表示 k ，滞后时间常数为 τ ，循环系数为 α 。

根据式 (23)，在控制系统参数影响下给出控制系统参数在 k 状态时变化的离散数学模型：

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (23)$$

参数 m 、 a_0 、 b_0 、 b_1 和 d 在采样时间下通过计算式 (18) 连续时间模型得到。

检测修剪神经网络模型能否逼近一个动态时变的系统。采用直接逆控制方法。所谓直接逆控制法，就是基于系统的参考模型，模糊神经网络学习或逼近该模型的逆系统模型，并作为控制器与控制对象简单串接在一起，使合成的系统能够在期望响应 $r(t)$ 和被控系统的输出 $y(t)$ 之间形成一个一致的映射。其中参考模型的作用是用来产生训练样本数据。

在系统中修剪神经网络模型作为控制器时，为了使输出值 $y(t)$ 逼近期望值 $r(t)$ ，目标是要得到适当的控制行为 $u(t)$ 。这个仿真实验需要两个阶段即学习阶段与应用阶段。在学习阶段，修剪神经网络模型辨识了潜伏在对象的时变动态逆模型。在应用阶段，修剪神经网络模型作为控制器产生控制行为。

通常由 NARX（带外输入的自回归非线性模型）模型经过简单的推导得到：

$$u(t) = f^{-1}[y(t+1), y(t), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)] \quad (24)$$

由式 (24)，可以看到计算 $u(t)$ 的值需要知道 $y(t+1)$ 的值，而 $y(t+1)$ 是未来值。为了解决这个问题，一般情况下用 $r(t+1)$ 代替 $y(t+1)$ 。由于 $r(t)$ 与参考信号有关联，这个代替是合理的。

可以用 NARX 模型直接构造如下的逆控制模型：

$$u(t) = g[y(t+1), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)] \quad (25)$$

取 $g \approx f^{-1}$ 。实际上 g 不是 f 的准确逆模型，它只是数学上逼近这个逆映射。

本发明还提供了一种基于修剪策略的 D-FNN 直接逆控制系统，所述系统包括：存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序，所述处理器执行所述计算机程序运行在以下系统的单元中：

数据集采集单元，用于读取输入数据集；

神经网络模型构建单元，用于构建动态模糊神经网络模型；

分级学习构建单元，用于将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型；

模型修剪单元，用于通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型；

数据遗忘单元，用于通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集；

逆控制模型控制单元，用于构建逆控制模型并输入控制系统参数数据集到逆控制模型进行控制。

本公开的有益效果：本发明提供一种基于修剪策略的 D-FNN 直接逆控制方法及系统：采用分级学习的思想能保证更简洁的结构和更短的学习时间，分级学习策略的一大好处是可以缓解学习过程中的震荡问题。实验结果表明，D-FNN（动态模糊神经网络）的逆控制器具有强大的在线学习能力，特别是当外部环境出现扰动时，D-FNN 具有很强的自适应性和鲁棒性可以把轨迹误差迅速地减少到接近零。D-FNN 可以根据对逆控制系统的重要性及系统的复杂性自动地产生或者删除模糊规则，在线学习时模型不需要预先设定，可以从训练数据设置次序自适应地学习，从而补偿了非线性系统建模误差处理外部扰动。通过仿真研究，动态模糊神经网络将会在许多实时自动控制系统中得到应用。

附图说明

通过对结合附图所示出的实施方式进行详细说明，本公开的上述以及其他特征将更加明显，本公开附图中相同的参考标号表示相同或相似的元素，显而易见地，下面描述中的附图仅仅是本公开的一些实施例，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，在附图中：

图 1 所示为一种基于修剪策略的 D-FNN 直接逆控制方法的流程图；

图 2 所示为训练阶段期望和实际注射的差别中的训练阶段期望；

图 3 所示为血压的的实际的变化和期望的变化；

图 4 所示为 D-FNN 控制器训练阶段的期望和实际输出比较；

图 5 所示为训练时均方根误差；

图 6 所示为训练阶段的输出误差；

图 7 所示为药物注射率和血压之间的关系；

图 8 所示为 D-FNN 控制器的实际与期望的 MAP 血压变化比较；

图 9 所示为期望的血压变化；

图 10 所示为噪声环境下的药物注射率；

图 11 所示为一种基于修剪策略的 D-FNN 直接逆控制系统图。

具体实施方式

以下将结合实施例和附图对本公开的构思、具体结构及产生的技术效果进行清楚、完整的描述，以充分地理解本公开的目的、方案和效果。需要说明的是，在不冲突的情况下，本申请中的实施例及实施例中的特征可以相互组合。

如图 1 所示为根据本公开的一种基于修剪策略的 D-FNN 直接逆控制方法的流程图，下面结合图 1 来阐述根据本公开的实施方式的一种基于修剪策略的 D-FNN 直接逆控制方法。

本公开提出一种基于修剪策略的 D-FNN 直接逆控制方法，具体包括以下步骤：

步骤 1，读取输入数据集；

步骤 2，构建动态模糊神经网络模型；

步骤 3，将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型；

步骤 4，通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型；

步骤 5，通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集；

步骤 6，构建逆控制模型并输入控制系统参数数据集到逆控制模型进行控制。

进一步地，在步骤 1 中，输入数据集为在自然的未被控制的条件下获取的观测数据。

进一步地，在步骤 2 中，构建动态模糊神经网络模型的方法为：

$x_1, x_2, \dots, x_r$ 是输入数据， y 是输出数据，则高斯函数表示的隶属函数：

$$\mu_{ij}(x_i) = \exp\left(-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right) \quad i = 1, 2, \dots, r, j = 1, 2, \dots, u \quad (1)$$

c_{ij} 是 x_i 的第 j 个高斯隶属函数的中心， σ_j 是 x_i 的第 j 个高斯隶属函数的宽度， r 为输入数据的个数， u 为隶属函数的个数；

$$N_j \text{ 为第 } j \text{ 个节点的输出：} \quad \psi_j = \frac{\varphi_j}{\sum_{k=1}^u \varphi_k} \quad j = 1, 2, \dots, u \quad (2)$$

$$\varphi_k = \mu_k(x_i), \quad k = 1, 2, \dots, u; \quad \varphi_j = \mu_j(x_i), \quad i = 1, 2, \dots, r;$$

总输出信号:

$$y(X) = \sum_{k=1}^u w_k \bullet \psi_k \quad (3)$$

其中, y 是输出信号,

模糊规则 w_k 为: $w_k = a_{k0} + a_{k1}x_1 + \dots + a_{kr}x_r \quad k=1,2,\dots,u$ (4)

为动态模糊神经网络模型:

$$y(X) = \frac{\sum_{i=1}^u \left[(a_{i0} + a_{i1}x_1 + \dots + a_{ir}x_r) \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right) \right]}{\sum_{i=1}^u \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right)} \quad (5)$$

C_i 是第 i 个 RBF 单元的中心; a_i, a_k 均为多项式的系数。

进一步地, 在步骤 3 中, 将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型的方法为:

动态模糊神经网络模型的结构不仅由接收域决定还由系统误差决定, 尽管这两种方法都可以被划分为分级自组织方法, 由输出误差确定是否应该加入新模糊规则;

输出误差判断描述如下: (X_i, t_i) 是第 i 个输入数据, X_i 表示第 i 个输入向量, t_i 表示第 i 个期望的输出, 动态模糊神经网络输出为 y_i 。

$$\text{定义 } \|e_i\| = \|t_i - y_i\| \quad (6)$$

如果 $\|e_i\| > k_e$ 时, 动态模糊神经网络模型增加一条新的模糊规则, 最终得到分级学习动态模糊神经网络模型。 k_e 值是根据动态模糊神经网络期望的精度预先选定的。

分级学习能保证更简洁的结构和更短的学习时间。 k_e 是个变量:

$$k_e = \max[e_{\max} \times \beta^i, e_{\min}] \quad (7)$$

这里, 最大误差为 $e_{\max}$, 动态模糊神经网络的精度为 $e_{\min}$, 收敛常数是 $\beta(0 < \beta < 1)$, β^i 为第 i 个收敛常数。

进一步地, 在步骤 4 中, 通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型的方法为:

修剪策略采用的是误差下降率 (ERR) 方法。用 ERR、SVD(奇异值分解) 或 ED(特征值分解) 方法的不同的修剪策略将导致不同的动态模糊神经网络模型的结构, 即不同模糊规则数以及对于某个特定的性能, 每条规则的参数不同, 实验说明 ERR 方法具有明显的物理意义和稳定的数值计算, 这就是为什么该方法被广泛使用的原因。

$T = (t_1, t_2, \dots, t_n) \in R^n$ 为系统理想输出, Y 为系统实际输出。 $\Psi \in R^{(r+1)u \times n}$ 和 $T \in R^n$ 之间有如下关系:

$$Y = W \times \Psi \quad (8)$$

$$\tilde{\mathbf{E}} = \|\mathbf{T} - \mathbf{Y}\| \quad (9)$$

$\tilde{\mathbf{E}}^T \tilde{\mathbf{E}}$ 表示误差能量, $\{X(i), t(i), i=1, 2, \Lambda, n\}$ 为第 n 个输入-输出对, 把式 (8) 代入式 (9) 推导得到线性回归模型 $\mathbf{D} = \mathbf{H}\boldsymbol{\theta} + \mathbf{E}$ (10)

其中, 期望输出为 $\mathbf{D} = \mathbf{T}^T \in R^n$, 回归向量为 $\mathbf{H} = \boldsymbol{\Psi}^T = (\mathbf{h}_1 \mathbf{L} \mathbf{h}_v) \in R^{n \times v}$, $v = u \times (r+1)$, 实参数为 $\boldsymbol{\theta} = \mathbf{W}^T \in R^n$, 误差向量为 $\mathbf{E} \in R^n$, 回归量为 $\mathbf{h}_i$, 回归量为 $\mathbf{q}_i$ 。误差下降率为 $\text{err}_i = \frac{(\mathbf{q}_i^T \mathbf{D})^2}{\mathbf{q}_i^T \mathbf{q}_i \mathbf{D}^T \mathbf{D}} \quad i=1, 2, \Lambda, v$ (11)

err_i 值如果很大, 那么 $\mathbf{q}_i$ 和 $\mathbf{D}$ 的相似程度就很大, $\mathbf{q}_i$ 对于输出结果影响显著, 式 (11) 的几何意义也很显著, 向量 $\mathbf{q}_i$ 和 $\mathbf{D}$ 的夹角设为 φ_i ,

$$\text{则 } \cos^2 \varphi_i = \text{err}_i = \frac{(\mathbf{q}_i^T \mathbf{D})^2}{\mathbf{q}_i^T \mathbf{q}_i \mathbf{D}^T \mathbf{D}} \quad i=1, 2, \Lambda, v \quad (12)$$

若 $\varphi_i = 90^\circ$, $\text{err}_i = 0$, 表示两个向量正交, 意味着 $\mathbf{q}_i$ 对 $\mathbf{D}$ 无影响, 如果, 若 $\varphi_i = 0$, $\text{err}_i = 1$, 意味着 $\mathbf{q}_i$ 对 $\mathbf{D}$ 影响显著。 $\Delta = (\delta_1, \delta_2, \mathbf{L}, \delta_u) \in R^{(r+1) \times u}$ 为 $\text{err}_i (i=1, 2, \Lambda, (r+1)u)$ 重新排列的矩阵, Δ 的第 i 列 δ_i 是误差下降率。

$$\text{定义 } \eta_i = \sqrt{\frac{\delta_i^T \delta_i}{r+1}} \quad (13)$$

第 i 个模糊规则的重要性用 η_i 表达, 值 η_i 越大, 表示第 i 个模糊规则越重要, 假设

$$\eta_i < k_{\text{err}} \quad (14)$$

预先设置阈值为 k_{err} , 则第 i 个模糊规则可以剔除, 最终得到修剪神经网络模型。

未修剪时的训练误差总是比修剪后的误差小, 但是经过修剪, 无论是用 ERR 还是 SVD 或 ED 方法, 系统的测试误差 (用 RMSE 来评判) 总是小于未修剪的动态模糊神经网络模型。

进一步地, 在步骤 5 中, 通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集的方法为:

假定 u 个模糊规则是由 n 个观测数据产生的, 可以写成式 (15) N 节点的模糊规则矩阵输出形式:

$$\boldsymbol{\Psi} = \begin{bmatrix} \psi_{11} & \mathbf{L} & \psi_{1n} \\ \mathbf{M} & \mathbf{M} & \mathbf{M} \\ \psi_{u1} & \mathbf{L} & \psi_{un} \end{bmatrix} \quad (15)$$

$\mathbf{X}_j(x_{1j}, x_{2j}, \Lambda, x_{rj})$ 是输入的观测数据, y_i 是系统的输出数据, 可写成式 (16) 表达形式:

$$\mathbf{W}\boldsymbol{\Psi} = \mathbf{Y} \quad (16)$$

$\mathbf{W}$ 由下式给出:

$$W = (\alpha_{10}L \quad \alpha_{u0} \quad \alpha_{11}L \quad \alpha_{u1} \quad \alpha_{1r}L \quad \alpha_{ur}) \quad (17)$$

$$W \in R^u, \quad \Psi \in R^{u \times n}。$$

如何使误差能量 $\tilde{E}^T \tilde{E}$ 最小，决定于一个最优的系数向量 $W^* \in R^{(r+1)u}$ 。下式给出了利用线性最小二乘法（LLS）逼近的方法：

$$W^* \times \Psi = T \quad (18)$$

具有如下表达形式的 W^* 是属于最优的：

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T \quad (19)$$

其中， Ψ 的转置为 Ψ^T ， Ψ 的广义逆为 $\Psi^+ = (\Psi^T \Psi)^{-1} \Psi^T$ 。

卡尔曼滤波算法用于确定以下权值：

$$\begin{aligned} W_i &= W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1}) \\ S_i &= S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{1 + \Psi_i S_{i-1} \Psi_i^T} \quad i = 1, 2, \Lambda, n \end{aligned} \quad (20)$$

其中， $W_0 = 0$ 和 $S_0 = \chi I$ 为初始条件。经过 i 次迭代后的系数矩阵为 W_i ，第 i 个观测数据的误差协方差矩阵为 S_i ， χ 是一个正数， Ψ 的第 i 列为 Ψ_i ， $u(r+1) \times u(r+1)$ 维单位矩阵为 I 。

给予最新的数据最大的加权，而最旧数据加权最小，乃至被遗忘。其实现方法是加入一个遗忘因子 λ ，修剪神经网络模型通过数据遗忘法的回归最小二乘法公式获得控制系统参数数据集。采用数据遗忘法的回归最小二乘法公式如下：

$$\begin{aligned} W_i &= W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1}) \\ S_i &= \frac{1}{\lambda} \left(S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{\lambda + \Psi_i S_{i-1} \Psi_i^T} \right) \quad i = 1, 2, \Lambda, n \end{aligned} \quad (21)$$

其中， $0 < \lambda < 1$ ， λ 越小，表明数据遗忘越快。

当收集到的数据越来越多时，线性最小二乘法的自适应能力将会大大降低。在这种情况下，就需要减少旧数据的影响。

进一步地，在步骤 6 中，构建逆控制模型的方法为：

令 Δp 为控制系统参数数据集， u 为控制系统参数的变化率，它之间关系的传递函数为：

$$\Delta p(s) = \frac{k e^{-T_i s} (1 + \alpha e^{-T_c s})}{1 + \tau s} u(s) \quad (22)$$

其中，循环延时为 T_c ，初始传送延时为 T_i ，控制系统参数的敏感性表示 k ，滞后时间常数为 τ ，循环系数为 α 。

根据式(23)，在控制系统参数影响下给出控制系统参数在 k 状态时变化的离散数学模型：

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (23)$$

参数 m 、 a_0 、 b_0 、 b_1 和 d 在采样时间下通过计算式(18)连续时间模型得到。

检测修剪神经网络模型能否逼近一个动态时变的系统。采用直接逆控制方法。所谓直接逆控制法，就是基于系统的参考模型，模糊神经网络学习或逼近该模型的逆系统模型，并作为控制器与控制对象简单串接在一起，使合成的系统能够在期望响应 $r(t)$ 和被控系统的输出 $y(t)$ 之间形成一个一致的映射。其中参考模型的作用是用来产生训练样本数据。

在系统中修剪神经网络模型作为控制器时，为了使输出值 $y(t)$ 逼近期望值 $r(t)$ ，目标是要得到适当的控制行为 $u(t)$ 。这个仿真实验需要两个阶段即学习阶段与应用阶段。在学习阶段，修剪神经网络模型辨识了潜伏在对象的时变动态逆模型。在应用阶段，修剪神经网络模型作为控制器产生控制行为。

通常由 NARX（带外输入的自回归非线性模型）模型经过简单的推导得到：

$$u(t) = f^{-1}[y(t+1), y(t), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)] \quad (24)$$

由式(24)，可以看到计算 $u(t)$ 的值需要知道 $y(t+1)$ 的值，而 $y(t+1)$ 是未来值。为了解决这个问题，一般情况下用 $r(t+1)$ 代替 $y(t+1)$ 。由于 $r(t)$ 与参考信号有关联，这个代替是合理的。

可以用 NARX 模型直接构造如下的逆控制模型：

$$u(t) = g[y(t+1), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)] \quad (25)$$

取 $g \approx f^{-1}$ 。实际上 g 不是 f 的准确逆模型，它只是数学上逼近这个逆映射。

本公开的一种实施例，将本公开的方法应用与生物医学工程应用算法程序，针对药物注射系统的直接逆控制案例进行了仿真：仿真结果说明：D-FNN 具有实时学习和控制能力强，参数估计和结构辨识同时进行等优点

在注射系统标准时不变模型与注射系统（注射液为硝普钠）参数变化模型仿真研究中，通过对血压的控制来验证 D-FNN 逼近能力及所提控制方案的有效性。

$$\Delta p \text{ 是血压的变化, SNP 是硝普钠, } u \text{ 为 SNP 注射率, 它之间关系的传递函数为: } \Delta p(s) = \frac{ke^{-T_i s}(1 + \alpha e^{-T_c s})}{1 + \tau s} u(s),$$

其中，循环延时为 T_c ，初始传送延时为 T_i ，硝普钠的敏感性表示 k ，滞后时间常数为 τ ，循环系数为 α 。

根据式(23)，在硝普钠影响下给出了 MAP（平均动脉血压）的离散数学模型：

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k),$$

参数 m 、 a_0 、 b_0 、 b_1 和 d 在采样时间下通过计算式(19)连续时间模型得到。

检测 D-FNN 能否逼近一个动态时变的系统。采用直接逆控制方法。所谓直接逆控制法，就是基于系统的参考模型，模糊神经网络学习或逼近该模型的逆系统模型，并作为控制器与控制对象简单串接在一起，使合成的系统能够在期望响应 $r(t)$ 和被控系统的输出 $y(t)$ 之间形成一个一致的映射。D-FNN 作为直接逆控制方法的原理图如图 2 所示，图 2 所示为训练阶段期望和实际注射的差别中的训练阶段期望。其中参考模型的作用是用来产生训练样本数据。

在系统中 D-FNN 作为控制器时，为了使输出值 $y(t)$ 逼近期望值 $r(t)$ ，目标是要得到适当的控制行为 $u(t)$ 。这个仿真实验需要两个阶段即学习阶段与应用阶段。在学习阶段，D-FNN 辨识了潜伏在对象的时变动态逆模型。在应用阶段，D-FNN 作为控制器产生控制行为。

逆模型通常由 NARX（带外输入的自回归非线性模型）模型经过简单的推导得到：

$$u(t) = f^{-1}[y(t+1), y(t), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)]$$

由式(25)，可以看到计算 $u(t)$ 的值需要知道 $y(t+1)$ 的值，而 $y(t+1)$ 是未来值。为了解决这个问题，一般情况下用 $r(t+1)$ 代替 $y(t+1)$ 。由于 $r(t)$ 与参考信号有关联，这个代替是合理的。

可以用 NARX 模型直接构造如下的逆模型： $u(t) = g[y(t+1), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)]$

取 $g \approx f^{-1}$ 。实际上 g 不是 f 的准确逆模型，它只是数学上逼近这个逆映射。

在注射系统标准时不变模型与注射系统参数变化模型仿真研究中，通过对血压的控制来验证 D-FNN 逼近能力及所提控制方案的有效性。

(1) 注射系统标准时不变模型

病人响应的数学模型表达如下：

$$\Delta p(k) = 0.742\Delta p(k-1) + 0.188u(k-3) + 0.076u(k-6) \quad (26)$$

为了产生训练数据，药物注射率 $u(k)$ 取为：

$$u(k) = |A \sin(2\pi k / 250)| \quad (27)$$

设 $A = 50$ ，初始条件为：当 $t \leq 0$ 时 $\Delta p(t) = 0, u(t) = 0$ ，根据式(26)和式(27)提取 200 个样本。式(26)的逆模型取为：

$$\hat{u}(k) = f(\Delta p(k), \Delta p(k-3))$$

其中， f 是 D-FNN，它代表式(22)的逆映射。D-FNN 预定义的参数选择如下： $d_{\min} = 2, d_{\max} = 35, e_{\min} = 0.5,$

$$e_{\max} = 50e_{\min}, \gamma = \left(\frac{d_{\min}}{d_{\max}}\right)^{2.5/200}, \beta = \left(\frac{e_{\min}}{e_{\max}}\right)^{1/100}, \sigma_0 = 35, k = 2.5, k_w = 1.05, k_{err} = 0.0007$$

训练结果如图 2 所示，图 2 所示是训练阶段期望和实际注射的差别中的训练阶段期望(图 2 中的形状“—”)和实际注射率(图

2 中的形状“o”)比较。

控制器采样间隔是 15s, 高血压病人的血压设定为 140mmHg, D-FNN 控制器训练好后用于控制对象, 最后病人的血压要求降低到 100mmHg, 如图 3 所示为血压的的实际的变化和期望的变化, 期望的血压变化中含有方差为 1mmHg 的白噪声。可以看到血压随着硝普钠注射的变化而平稳地变化, 并没有发生时延和震荡, 这表明 D-FNN 很好地学习了模型的特性, 对系统进行了很好的建模。修剪技术对于动态时变非线性系统的辨识是非常必要的, 如果在学习进行时, 检测到不活跃的模糊规则并加以剔除, 则可获得更为紧凑的系统结构以及快速的学习速度。

仿真的结果如下:

$$\Delta p_{\max} = 5.91; \Delta MAP_{\max} = 2.61; MAP_{\min} = 97.1$$

由上述仿真结果可以看到: D-FNN 控制器能使得血压平稳的变化, 能够满足实际的要求。

(2) 注射系统参数变化模型

根据式 (26), 得到了病人在 SNP 作用下, MAP 的离散数学模型:

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (28)$$

设定初始条件为: 当 $t \leq 0$ 时 $u(t) = 0, y(t) = 0$ 。用训练 D-FNN 的样本数据的产生, 根据输入式 $u(k) = |A \sin(2\pi k / 250)|$ 来选择训练样本, 且取 $A=15$, 逆模型为 $\hat{u}(t) = f(\Delta p(k), \Delta p(k-3))$ 。

为了观察药物注射系统参数变化模型的时变特性, 使用一个移动窗口。设置移动窗口的宽度 $w = 120$ 。

其中药物注射系统变化模型的训练结果如图 4 所示。图 4 所示为 D-FNN 控制器训练阶段的期望(图 4 中的形状“+”)和实际(图 4 中的形状“o”)输出比较, 图 5 所示为训练时均方根误差, 图 6 所示为训练阶段的输出误差。

其中变化模型的测试结果见图 7, 图 7 所示为药物注射率和血压之间的关系, 图 8 所示为 D-FNN 控制器的实际与期望的 MAP 血压变化比较, 图 9 所示为期望的血压变化, 图 10 所示为噪声环境下的药物注射率, 其中扰动选择方差为 1mmHg 的白噪声。

表 1 是文献《Indirect adaptive nonlinear control of drug delivery systems》中的 IANC 方法与 D-FNN 中的仿真性能比较结果。IANC 方法与 D-FNN 方法相比, D-FNN 的仿真结果(图 7)非常理想, 即使在扰动选择方差为 1mmHg 的白噪声环境下也没有大的延迟和振荡。用最大误差 $\Delta p_{\max}$ 来评估期望和实际 MAP(平均动脉血压)变化的 D-FNN 控制器的性能, IANC 方法与 D-FNN 方法相比较的结果列于表 1 中。

表 1 D-FNN 与 IANC 的性能比较

方法	$\Delta p_{\max}$ (mmHg)	方法	$\Delta p_{\max}$ (mmHg)
D-FNN	9.01	IANC	10.1

仿真时应注意到, 移动窗的宽度 w 在辨识时变系统中有着重要的作用。宽度 w 较小时将会遗漏一些重要的数据,

而宽度 w 较大收集到的样本数据越来越多 D-FNN 逐渐进入饱和而失去调整功能, 使得时变参数无法辨识。

通过使用不同移动窗宽度, 做了多次的仿真。根据 RMSE (均方误差) 和 $\Delta p_{\max}$ 进行评估 D-FNN 的性能, 仿真结果表明, 最优宽度 w 的范围是 $90 \leq \text{宽度 } w \leq 110$ 。

从仿真结果来看, 由于使用了修剪技术与移动窗技术, 使得网络结构没有持续增长, 可获得更为紧凑的 D-FNN 结构, 因而确保了系统的泛化能力。

实验结果表明, D-FNN 控制器具有强大的在线学习能力, 特别是当外部环境出现扰动时, D-FNN 具有很强的自适应性和鲁棒性可以把轨迹误差迅速地减少到接近零。D-FNN 可以根据对控制系统的重要性及系统的复杂性自动地产生或者删除模糊规则, 在线学习时模型不需要预先设定, 可以从训练数据设置次序自适应地学习, 从而补偿了非线性系统建模误差处理外部扰动。通过仿真研究, 动态模糊神经网络将会在许多实时自动控制系统中得到应用, D-FNN 学习的快速性未来还有进一步改进的空间。

本公开的实施例提供一种基于修剪策略的 D-FNN 直接逆控制系统, 如图 11 所示为本公开的一种基于修剪策略的 D-FNN 直接逆控制系统图, 该实施例的一种基于修剪策略的 D-FNN 直接逆控制系统包括: 处理器、存储器以及存储在所述存储器中并可在所述处理器上运行的计算机程序, 所述处理器执行所述计算机程序时实现上述一种基于修剪策略的 D-FNN 直接逆控制系统实施例中的步骤。

所述系统包括: 存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序, 所述处理器执行所述计算机程序运行在以下系统的单元中:

数据集采集单元, 用于读取输入数据集;

神经网络模型构建单元, 用于构建动态模糊神经网络模型;

分级学习构建单元, 用于将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型;

模型修剪单元, 用于通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型;

数据遗忘单元, 用于通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集;

逆控制模型控制单元, 用于构建逆控制模型并输入控制系统参数数据集到逆控制模型进行控制。

所述一种基于修剪策略的 D-FNN 直接逆控制系统可以运行于桌上型计算机、笔记本、掌上电脑及云端服务器等计算设备中。所述一种基于修剪策略的 D-FNN 直接逆控制系统, 可运行的系统可包括, 但不限于, 处理器、存储器。本领域技术人员可以理解, 所述例子仅仅是一种基于修剪策略的 D-FNN 直接逆控制系统的示例, 并不构成对一种基于修剪策略的 D-FNN 直接逆控制系统的限定, 可以包括比例子更多或更少的部件, 或者组合某些部件, 或者不同的部件, 例如所述一种基于修剪策略的 D-FNN 直接逆控制系统还可以包括输入输出设备、网络接入设备、总线等。

所称处理器可以是中央处理单元(Central Processing Unit, CPU), 还可以是其他通用处理器、数字信号处理器(Digital Signal Processor, DSP)、专用集成电路(Application Specific Integrated Circuit, ASIC)、现成可编程门阵列

(Field-Programmable Gate Array, FPGA)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等,所述处理器是所述一种基于修剪策略的 D-FNN 直接逆控制系统运行系统的控制中心,利用各种接口和线路连接整个一种基于修剪策略的 D-FNN 直接逆控制系统可运行系统的各个部分。

所述存储器可用于存储所述计算机程序和/或模块,所述处理器通过运行或执行存储在所述存储器内的计算机程序和/或模块,以及调用存储在存储器内的数据,实现所述一种基于修剪策略的 D-FNN 直接逆控制系统的各种功能。所述存储器可主要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、至少一个功能所需的应用程序(比如声音播放功能、图像播放功能等)等;存储数据区可存储根据手机的使用所创建的数据(比如音频数据、电话本等)等。此外,存储器可以包括高速随机存取存储器,还可以包括非易失性存储器,例如硬盘、内存、插接式硬盘,智能存储卡(Smart Media Card, SMC),安全数字(Secure Digital, SD)卡,闪存卡(Flash Card)、至少一个磁盘存储器件、闪存器件、或其它易失性固态存储器件。

尽管本公开的描述已经相当详尽且特别对几个所述实施例进行了描述,但其并非旨在局限于任何这些细节或实施例或任何特殊实施例,而是应当将其视作是通过参考所附权利要求考虑到现有技术为这些权利要求提供广义的可能性解释,从而有效地涵盖本公开的预定范围。此外,上文以发明人可预见的实施例对本公开进行描述,其目的是为了提供有用的描述,而那些目前尚未预见的对本公开的非实质性改动仍可代表本公开的等效改动。

权 利 要 求 书

1. 一种基于修剪策略的 D-FNN 直接逆控制方法, 其特征在于, 所述方法包括以下步骤:

步骤 1, 读取输入数据集;

步骤 2, 构建动态模糊神经网络模型;

步骤 3, 将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型;

步骤 4, 通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型;

步骤 5, 通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集;

步骤 6, 构建逆控制模型并输入控制系统参数数据集到逆控制模型进行控制。

2. 根据权利要求 1 所述的一种基于修剪策略的 D-FNN 直接逆控制方法, 其特征在于, 在步骤 2 中, 构建动态模糊神经网络模型的方法为:

$x_1, x_2, \dots, x_r$ 是输入数据, y 是输出数据, 则高斯函数表示的隶属函数:

$$\mu_{ij}(x_i) = \exp\left(-\frac{(x_i - c_{ij})^2}{\sigma_j^2}\right) \quad i = 1, 2, \dots, r, j = 1, 2, \dots, u \quad (1)$$

c_{ij} 是 x_i 的第 j 个高斯隶属函数的中心, σ_j 是 x_i 的第 j 个高斯隶属函数的宽度, r 为输入数据的个数, u 为隶属函数的个数; N_j 为第 j 个节点的输出:

$$\psi_j = \frac{\varphi_j}{\sum_{k=1}^u \varphi_k} \quad j = 1, 2, \dots, u \quad (2)$$

其中, $\varphi_k = \mu_{ik}(x_i)$, $k = 1, 2, \dots, u$; $\varphi_j = \mu_{ij}(x_i)$, $i = 1, 2, \dots, r$;

$$y(X) = \sum_{k=1}^u w_k \bullet \psi_k \quad (3)$$

总输出信号:

其中, y 是输出信号,

$$\text{模糊规则 } w_k \text{ 为: } w_k = a_{k0} + a_{k1}x_1 + \dots + a_{kr}x_r \quad k = 1, 2, \dots, u \quad (4)$$

为动态模糊神经网络模型:

$$y(X) = \frac{\sum_{i=1}^u \left[(a_{i0} + a_{i1}x_1 + \dots + a_{ir}x_r) \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right) \right]}{\sum_{i=1}^u \exp\left(-\frac{\|X - C_i\|^2}{\sigma_i^2}\right)} \quad (5)$$

C_i 是第 i 个 RBF 单元的中心; a_i, a_k 均为多项式的系数。

3. 根据权利要求 2 所述的一种基于修剪策略的 D-FNN 直接逆控制方法, 其特征在于, 在步骤 3 中, 将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型的方法为:

将输出误差判断描述如下: (X_i, t_i) 是第 i 个输入数据, X_i 表示第 i 个输入向量, t_i 表示第 i 个期望的输出, 动态模糊神经网络输出为 y_i ;

$$\text{定义 } \|e_i\| = \|t_i - y_i\| \quad (6)$$

如果 $\|e_i\| > k_e$ 时, 动态模糊神经网络模型增加一条新的模糊规则, 最终得到分级学习动态模糊神经网络模型, k_e 值是根据动态模糊神经网络期望的精度预先选定的,

分级学习能保证更简洁的结构和更短的学习时间, k_e 是个变量:

$$k_e = \max[e_{\max} \times \beta^i, e_{\min}] \quad (7)$$

这里, 最大误差为 $e_{\max}$, 动态模糊神经网络的精度为 $e_{\min}$, 收敛常数是 $\beta(0 < \beta < 1)$, β^i 为第 i 个收敛常数。

4. 根据权利要求 3 所述的一种基于修剪策略的 D-FNN 直接逆控制方法, 其特征在于, 在步骤 4 中, 通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型的方法为:

$T = (t_1, t_2, \dots, t_n) \in R^n$ 为系统理想输出, Y 为系统实际输出, $\Psi \in R^{(r+1)u \times n}$ 和 $T \in R^n$ 之间有如下关系:

$$Y = W \times \Psi \quad (8)$$

$$\tilde{E} = \|T - Y\| \quad (9)$$

$\tilde{E}^T \tilde{E}$ 表示误差能量, $\{X(i), t(i), i = 1, 2, \dots, n\}$ 为第 n 个输入-输出对, 把式 (8) 代入式 (9) 推导得到线性回归模型 $D = H\theta + E$ (10)

其中, 期望输出为 $D = T^T \in R^n$, 回归向量为 $H = \Psi^T = (h_1^T \dots h_v^T) \in R^{n \times v}$, $v = u \times (r+1)$, 实参数为 $\theta = W^T \in R^n$,

误差向量为 $E \in R^n$, 回归量为 h_i , 回归量为 q_i , 误差下降率为 $\text{err}_i = \frac{(q_i^T D)^2}{q_i^T q_i D^T D}$ $i = 1, 2, \dots, v$

(11)

err_i 值如果很大, 那么 q_i 和 D 的相似程度就很大, q_i 对于输出结果影响显著, 式 (11) 的几何意义也很显著, 向量 q_i 和 D 的夹角设为 φ_i ,

$$\text{则 } \cos^2 \varphi_i = \text{err}_i = \frac{(q_i^T D)^2}{q_i^T q_i D^T D} \quad i = 1, 2, \dots, v \quad (12)$$

若 $\varphi_i = 90^\circ$, $\text{err}_i = 0$, 表示两个向量正交, 意味着 q_i 对 D 无影响, 如果, 若 $\varphi_i = 0$, $\text{err}_i = 1$, 意味着 q_i 对 D 影

响显著, $\Delta = (\delta_1, \delta_2, \dots, \delta_u) \in R^{(r+1) \times u}$ 为 $\text{err}_i (i=1, 2, \dots, (r+1)u)$ 重新排列的矩阵, Δ 的第 i 列 δ_i 是误差下降率,

$$\text{定义 } \eta_i = \sqrt{\frac{\delta_i^T \delta_i}{r+1}} \quad (13)$$

第 i 个模糊规则的重要性用 η_i 表达, 值 η_i 越大, 表示第 i 个模糊规则越重要, 假设

$$\eta_i < k_{\text{err}} \quad (14)$$

预先设置阈值为 k_{err} , 则第 i 个模糊规则可以剔除, 最终得到修剪神经网络模型。

5. 根据权利要求 4 所述的一种基于修剪策略的 D-FNN 直接逆控制方法, 其特征在于, 在步骤 5 中, 通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集的方法为:

假定 u 个模糊规则是由 n 个观测数据产生的, 可以写成式 (15) N 节点的模糊规则矩阵输出形式:

$$\Psi = \begin{bmatrix} \psi_{11} & L & \psi_{1n} \\ M & M & M \\ \psi_{u1} & L & \psi_{un} \end{bmatrix} \quad (15)$$

$X_j(x_{1j}, x_{2j}, \dots, x_{rj})$ 是输入的观测数据, y_j 是系统的输出数据, 可写成式 (16) 表达形式:

$$W\Psi = Y \quad (16)$$

W 由下式给出:

$$W = (\alpha_{10} L \quad \alpha_{u0} \quad \alpha_{11} L \quad \alpha_{u1} \quad \alpha_{1r} L \quad \alpha_{ur}) \quad (17)$$

$$W \in R^u, \quad \Psi \in R^{u \times n};$$

如何使误差能量 $\tilde{E}^T \tilde{E}$ 最小, 决定于一个最优的系数向量 $W^* \in R^{(r+1)u}$, 下式给出了利用线性最小二乘法逼近的方法:

$$W^* \times \Psi = T \quad (18)$$

具有如下表达形式的 W^* 是属于最优的:

$$W^* = T(\Psi^T \Psi)^{-1} \Psi^T \quad (19)$$

其中, Ψ 的转置为 Ψ^T , Ψ 的广义逆为 $\Psi^+ = (\Psi^T \Psi)^{-1} \Psi^T$;

卡尔曼滤波算法用于确定以下权值:

$$\begin{aligned} W_i &= W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1}) \\ S_i &= S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{1 + \Psi_i S_{i-1} \Psi_i^T} \quad i=1, 2, \dots, n \end{aligned} \quad (20)$$

其中, $W_0 = 0$ 和 $S_0 = \chi I$ 为初始条件, 经过 i 次迭代后的系数矩阵为 W_i , 第 i 个观测数据的误差协方差矩阵为 S_i , χ 是一个正数, Ψ 的第 i 列为 Ψ_i , $u(r+1) \times u(r+1)$ 维单位矩阵为 I ;

给予最新的数据最大的加权, 而最旧数据加权最小, 乃至被遗忘, 其实现方法是加入一个遗忘因子 λ , 修剪神经网络模型通过数据遗忘法的回归最小二乘法公式获得控制系统参数数据集, 采用数据遗忘法的回归最小二乘法公式如下:

$$\begin{aligned} W_i &= W_{i-1} + S_i \Psi_i^T (T_i - \Psi_i W_{i-1}) \\ S_i &= \frac{1}{\lambda} \left(S_{i-1} - \frac{S_{i-1} \Psi_i^T \Psi_i S_{i-1}}{\lambda + \Psi_i S_{i-1} \Psi_i^T} \right) \quad i = 1, 2, \Lambda, n \end{aligned} \quad (21)$$

其中, $0 < \lambda < 1$, λ 越小, 表明数据遗忘越快,

当收集到的数据越来越多时, 线性最小二乘法的自适应能力将会大大降低, 在这种情况下, 就需要减少旧数据的影响。

6. 根据权利要求 5 所述的一种基于修剪策略的 D-FNN 直接逆控制方法, 其特征在于, 在步骤 6 中, 构建逆控制模型的方法为:

令 Δp 为控制系统参数数据集, u 为控制系统参数的变化率, 它之间关系的传递函数为:

$$\Delta p(s) = \frac{k e^{-T_i s} (1 + \alpha e^{-T_c s})}{1 + \tau s} u(s) \quad (22)$$

其中, 循环延时为 T_c , 初始传送延时为 T_i , 控制系统参数的敏感性表示 k , 滞后时间常数为 τ , 循环系数为 α ;

根据式 (23), 在控制系统参数影响下给出控制系统参数在 k 状态时变化的离散数学模型:

$$\Delta p(k) = a_0 \Delta p(k-1) + b_0 u(k-d) + b_1 u(k-m) + n(k) \quad (23)$$

参数 m 、 a_0 、 b_0 、 b_1 和 d 在采样时间下通过计算式 (18) 连续时间模型得到;

检测修剪神经网络模型能否逼近一个动态时变的系统, 采用直接逆控制方法, 所谓直接逆控制法, 就是基于系统的参考模型, 模糊神经网络学习或逼近该模型的逆系统模型, 并作为控制器与控制对象简单串接在一起, 使合成的系统能够在期望响应 $r(t)$ 和被控系统的输出 $y(t)$ 之间形成一个一致的映射, 其中参考模型的作用是用来产生训练样本数据;

在系统中修剪神经网络模型作为控制器时, 为了使输出值 $y(t)$ 逼近期望值 $r(t)$, 目标是要得到适当的控制行为 $u(t)$; 这个仿真实验包括学习阶段与应用阶段: 在学习阶段, 修剪神经网络模型辨识了潜伏在对象的时变动态逆模型, 在应用阶段, 修剪神经网络模型作为控制器产生控制行为;

通常由 NARX 模型经过简单的推导得到:

$$u(t) = f^{-1}[y(t+1), y(t), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)] \quad (24)$$

由式(24), 可以看到计算 $u(t)$ 的值需要知道 $y(t+1)$ 的值, 而 $y(t+1)$ 是未来值, 为了解决这个问题, 一般情况下用 $r(t+1)$ 代替 $y(t+1)$, 由于 $r(t)$ 与参考信号有关联, 这个代替是合理的;

可以用 NARX 模型直接构造如下的逆控制模型:

$$u(t) = g[y(t+1), \Lambda, y(t-n_y), u(t-1), \Lambda, u(t-n_u)] \quad (25)$$

取 $g \approx f^{-1}$, 实际上 g 不是 f 的准确逆模型, 它只是数学上逼近这个逆映射。

7. 一种基于修剪策略的 D-FNN 直接逆控制系统, 其特征在于, 所述系统包括: 存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序, 所述处理器执行所述计算机程序运行在以下系统的单元中:

数据集采集单元, 用于读取输入数据集;

神经网络模型构建单元, 用于构建动态模糊神经网络模型;

分级学习构建单元, 用于将动态模糊神经网络模型调整为分级学习动态模糊神经网络模型;

模型修剪单元, 用于通过修剪策略对分级学习动态模糊神经网络模型中的模糊规则进行修剪剔除得到修剪神经网络模型;

数据遗忘单元, 用于通过修剪神经网络模型对输入数据集进行数据遗忘得到控制系统参数数据集;

逆控制模型控制单元, 用于构建逆控制模型并输入控制系统参数数据集到逆控制模型进行控制。




图 1




图 2




图 3




图 4




图 5




图 6




图 7




图 8




图 9




图 10




图 11

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2020/087798

A. CLASSIFICATION OF SUBJECT MATTER

G05B 13/04(2006.01)i

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)

G05B13

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)

CNABS; CNTXT; VEN; USTXT; WOTXT; EPTXT; CNKI; IEEE Xplore; Patents: 佛山科学技术学院, 张彩霞, 王向东, 王新东, 曾平, 动态模糊神经网络, 修剪, 逆控制, D-FNN, dynamic, fuzzy, neural network, pruning, inverse control

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
PX	CN 110361968 A (FOSHAN UNIVERSITY) 22 October 2019 (2019-10-22) description, paragraphs 4-23	1-7
X	张彩霞 等 (ZHANG, Caixia et al.). "基于修剪策略的D-FNN直接逆控制算法研究 (Research on D-FNN Direct Inverse Control Algorithm Based on Pruning Strategy)" <i>Acta Automatica Sinica</i> , Vol. 45, No. 8, 28 April 2019 (2019-04-28), ISSN: 0254-4156, pp. 1599-1604	1-7
Y	马莉 等 (MA, Li et al.). "基于动态模糊神经网络的生物工程算法研究 (A Bio-Engineering Algorithm Research Based on Dynamic Fuzzy Neural Networks)" <i>Computer Engineering & Science</i> , Vol. 32, No. 3, 31 March 2010 (2010-03-31), ISSN: 1007-130X, pp. 138-140	1-7



Further documents are listed in the continuation of Box C.



See patent family annex.

* Special categories of cited documents:

"A" document defining the general state of the art which is not considered to be of particular relevance

"E" earlier application or patent but published on or after the international filing date

"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)

"O" document referring to an oral disclosure, use, exhibition or other means

"P" document published prior to the international filing date but later than the priority date claimed

"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention

"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone

"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art

"&" document member of the same patent family

Date of the actual completion of the international search

20 May 2020

Date of mailing of the international search report

28 July 2020

Name and mailing address of the ISA/CN

China National Intellectual Property Administration (ISA/
CN)
No. 6, Xitucheng Road, Jimenqiao Haidian District, Beijing
100088
China

Authorized officer

Facsimile No. (86-10)62019451

Telephone No.

INTERNATIONAL SEARCH REPORT

International application No.

PCT/CN2020/087798

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y	张德丰 等 (ZHANG, Defeng et al.). "列主元SVD-QR方法修剪策略参数调整的D-FNN算法研究 (Research on D-FNN Algorithm with the Combination of Column Pivot SVD-QR Method Pruning Strategy and Parameters Adjustment)" <i>中山大学学报(自然科学版)</i> (<i>Acta Scientiarum Naturalium Universitatis Sunyatseni</i>), Vol. 52, No. 2., 31 March 2013 (2013-03-31), ISSN: 0529-6579, pp. 9-12	1-7
Y	Shiqian Wu et al. "Dynamic Fuzzy Neural Networks—A Novel Approach to Function Approximation" <i>IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS</i> , Vol. 30, No. 2., 30 April 2000 (2000-04-30), ISSN: 1083-4419, pp. 358-363	3-6
A	CN 101452258 A (XIDIAN UNIVERSITY) 10 June 2009 (2009-06-10) entire document	1-7
A	CN 103034122 A (SHANGHAI JIAO TONG UNIVERSITY) 10 April 2013 (2013-04-10) entire document	1-7
A	US 2011125685 A1 (RIZVI SYED Z et al.) 26 May 2011 (2011-05-26) entire document	1-7
A	WO 2016010601 A2 (UNIV FLORIDA STATE RES FOUND et al.) 21 January 2016 (2016-01-21) entire document	1-7

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/CN2020/087798

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)			Publication date (day/month/year)
CN	110361968	A	22 October 2019	None			
CN	101452258	A	10 June 2009	None			
CN	103034122	A	10 April 2013	None			
US	2011125685	A1	26 May 2011	US	8346712	B2	01 January 2013
WO	2016010601	A2	21 January 2016	WO	2016010601	A3	30 June 2016
				US	2017017212	A1	19 January 2017

国际检索报告

国际申请号

PCT/CN2020/087798

A. 主题的分类

G05B 13/04(2006.01)i

按照国际专利分类(IPC)或者同时按照国家分类和IPC两种分类

B. 检索领域

检索的最低限度文献(标明分类系统和分类号)

G05B13

包含在检索领域中的除最低限度文献以外的检索文献

在国际检索时查阅的电子数据库(数据库的名称, 和使用的检索词(如使用))

CNABS;CNTXT;VEN;USTXT;WOTXT;EPTXT;CNKI;IEEE XPIore;Patentics:佛山科学技术学院, 张彩霞, 王向东, 王新东, 曾平, 动态模糊神经网络, 修剪, 逆控制, D-FNN, dynamic, fuzzy, neural network, pruning, inverse control

C. 相关文件

类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求
PX	CN 110361968 A (佛山科学技术学院) 2019年 10月 22日 (2019 - 10 - 22) 说明书第4-23段	1-7
X	张彩霞 等. “基于修剪策略的D-FNN直接逆控制算法研究” 自动化学报, 第45卷, 第8期, 2019年 4月 28日 (2019 - 04 - 28), ISSN: 0254-4156, 第1599-1604页	1-7
Y	马莉 等. “基于动态模糊神经网络的生物工程算法研究” 计算机工程与科学, 第32卷, 第3期, 2010年 3月 31日 (2010 - 03 - 31), ISSN: 1007-130X, 第138-140页	1-7
Y	张德丰 等. “列主元SVD-QR方法修剪策略参数调整的D-FNN算法研究” 中山大学学报(自然科学版), 第52卷, 第2期, 2013年 3月 31日 (2013 - 03 - 31), ISSN: 0529-6579, 第9-12页	1-7

☒ 其余文件在C栏的续页中列出。☒ 见同族专利附件。

* 引用文件的具体类型:

“A” 认为不特别相关的表示了现有技术一般状态的文件

“E” 在国际申请日的当天或之后公布的在先申请或专利

“L” 可能对优先权要求构成怀疑的文件, 或为确定另一篇引用文件的公布日而引用的或者因其他特殊理由而引用的文件(如具体说明的)

“O” 涉及口头公开、使用、展览或其他方式公开的文件

“P” 公布日先于国际申请日但迟于所要求的优先权日的文件

“T” 在申请日或优先权日之后公布, 与申请不相抵触, 但为了理解发明之理论或原理的在后文件

“X” 特别相关的文件, 单独考虑该文件, 认定要求保护的发明不是新颖的或不具有创造性

“Y” 特别相关的文件, 当该文件与另一篇或者多篇该类文件结合并且这种结合对于本领域技术人员为显而易见时, 要求保护的发明不具有创造性

“&” 同族专利的文件

国际检索实际完成的日期

2020年 5月 20日

国际检索报告邮寄日期

2020年 7月 28日

ISA/CN的名称和邮寄地址

中国国家知识产权局(ISA/CN)

中国北京市海淀区蓟门桥西土城路6号 100088

传真号 (86-10)62019451

授权官员

左良军

电话号码 86-(0512)-88996621

C. 相关文件

类 型*	引用文件, 必要时, 指明相关段落	相关的权利要求
Y	Shiqian Wu 等. "Dynamic Fuzzy Neural Networks—A Novel Approach to Function Approximation" IEEE TRANSACTIONS ON SYSTEMS, MAN, AND CYBERNETICS—PART B: CYBERNETICS, 第30卷, 第2期, 2000年 4月 30日 (2000 - 04 - 30), ISSN: 1083-4419, 第358-363页	3-6
A	CN 101452258 A (西安电子科技大学) 2009年 6月 10日 (2009 - 06 - 10) 全文	1-7
A	CN 103034122 A (上海交通大学) 2013年 4月 10日 (2013 - 04 - 10) 全文	1-7
A	US 2011125685 A1 (RIZVI SYED Z等) 2011年 5月 26日 (2011 - 05 - 26) 全文	1-7
A	WO 2016010601 A2 (UNIV FLORIDA STATE RES FOUND等) 2016年 1月 21日 (2016 - 01 - 21) 全文	1-7

国际检索报告
关于同族专利的信息

国际申请号

PCT/CN2020/087798

检索报告引用的专利文件			公布日 (年/月/日)	同族专利			公布日 (年/月/日)
CN	110361968	A	2019年 10月 22日	无			
CN	101452258	A	2009年 6月 10日	无			
CN	103034122	A	2013年 4月 10日	无			
US	2011125685	A1	2011年 5月 26日	US	8346712	B2	2013年 1月 1日
WO	2016010601	A2	2016年 1月 21日	WO	2016010601	A3	2016年 6月 30日
				US	2017017212	A1	2017年 1月 19日