

DOI: 10.13382/j.jemi.B2306211

机理与数据驱动的软件手弯曲角度软测量模型^{*}

乔景慧 李洪达 陈宇曦 张 岩

(沈阳工业大学机械工程学院 沈阳 110870)

摘 要: 由于软体手材料强非线性,难以建立软体手弯曲角度精确的机理模型。针对以上难题,提出机理与数据驱动的软件手弯曲角度软测量模型。该模型由机理模型与信息素挥发及惯性权重的自适应块增量随机配置网络(ABSCN)补偿模型组成。采用最小二乘对机理模型进行参数辨识,针对高阶未建模动态,采用ABSCN预测补偿。通过对块增量随机配置网络(BSC)的增量块配置次数进行自适应优化,提高模型的紧凑性,减少模型的训练时间。最后通过混合模型的仿真实验与真实数据进行对比,结果表明所提方法在精度上有显著提升。

关键词: 软体手;混合模型;未建模动态;随机配置网络

中图分类号: TN911.7; TP24 **文献标识码:** A **国家标准学科分类代码:** 510.80

Soft sensor model of bending angle integrated mechanism and data for soft gripper

Qiao Jinghui Li Hongda Chen Yuxi Zhang Yan

(School of Mechanical Engineering, Shenyang University of Technology, Shenyang 110870, China)

Abstract: Due to the strong nonlinearity of material used in soft gripper, it is difficult to establish a precise mechanism model for measuring the bending angle of the soft gripper. To address this challenge, a mechanism and data-driven soft sensor model for the bending angle of the soft gripper is proposed. The model consists of a mechanism model and an adaptive block increment stochastic configuration networks (ABSCN) compensation model, which includes information scent evaporation and inertia weights. The mechanism model parameter is identified using least squares, and ABSCN is used to predict compensation for high order unmodeled dynamics. By adaptively optimizing the number of incremental block configurations in block incremental stochastic configuration networks (BSC), the compactness of the model is improved, and the training time is reduced. Finally, through simulation experiments and comparison with real data using a hybrid model, it is shown that the proposed method significantly improves the accuracy.

Keywords: soft gripper; hybrid model; unmodeled dynamics; stochastic configured network

0 引 言

在复杂工业过程中,对机器人的灵活性和安全性具有较高的要求^[1],软体手与刚性机械手相比,具有无限自由度,以更安全的方式对物体进行抓取和移动,且不会对被抓取物体的表面有实质性伤害。但由于软体材料的缺

陷,限制了对被抓取物体的重量。因此,软体手非常适用于家庭服务和部分复杂的生产环境中。

软体手在诸多领域得到了应用并提出了新的要求,包括人-机、机-环境的安全性、友好性及灵活性^[2-3],如抓取易碎柔软的轻质量物体:鸡蛋、蛋糕、水果等生物组织^[4],用作辅助中风或手部治疗患者术后的复健^[5],气动软体手被广泛使用^[6-8]。

软体手的力学建模中,机理建模大多采用实验模拟其软材料的模型,将实验中得到的参数数据应用到机理建模中,从而得到其弯曲模型和扭转模型等^[9]。Yuuki Torigoe 团队^[10]提出了一种简化的流体弹性体执行器 (fluidic elastomer actuator, FEA) 仿真模型。由一系列粘弹性接头连接的线段组成。将气动输入产生的力矩建模为作用于每个关节的主动力矩,建立拉格朗日动力学方程,提出一种基于优化的未知模型参数辨识方法来进行力学建模。韩非等^[11]利用多项式拟合与 LSTM 两种学习算法完成了软体手弯曲度感知的精确建模。

应用实验得出的参数数据进行机理建模的方法,并未考虑到由于制作的差异性引起的偏差,同时实验测试也存在不可忽视的误差,因此机理建模的精度较差。基于优化的未知模型参数辨识方法,理论推导过于复杂,虽然精度得到了提高,但在气动软体手低压输入时仍存在显著偏差。利用多项式拟合与 LSTM 两种学习算法对软体手弯曲角度的建模,虽然精度得到提高,但单一的数据建模有机理相关性弱、可解释性不强的缺点。

人工神经网络 (artificial neural network, ANN)^[12-15]和支持向量机 (support vector machine, SVM)^[16-17]已经广泛应用于预测和建模等领域。但应用于流程工业时仍然存在一些问题,例如训练阶段耗时、准确性和泛化性较低。随机配置网络在学习速度和实现简单性方面表现更好,其网络隐藏节点参数的范围自适应,对网络规模设置的人为干预较少,泛化性好。同时本文对其进行自适应块处理,在保存原始模型的诸多优点情况下,提高了模型的训练速度。

针对上述问题,本文提出机理与数据驱动^[18]的软体手弯曲角度软测量模型,在最小二乘法参数辨识基础上添加由数据模型训练得到的未建模动态值,从而获得精度较高的软测量模型。鉴于 SCNs 模型的收敛速度较差,本文基于 BSC 提出了一种自适应块增量的随机配置网络 ((adaptive block increment stochastic configuration networks, ABSCN),同时对模型每次迭代的最大配置次数进行自适应处理,使提出的 ABSCN 兼顾模型紧凑性、减少训练时间,提高了模型的总体性能。提高模型紧凑性,是指 ABSCN 对于 BSC 在达到同等目标精度情况下,所需的节点数更少,无用节点更少,模型的紧凑性更高。

1 软体手结构设计

1.1 手指弯曲原理

当气动软体手手指内部充入有压气体且约束其向指定方向的膨胀和伸长时,软体手指会向特定方向弯曲,当所有手指弯曲特定方向为同一点时,可以实现抓取物体和移动操作。

气动的差异决定了气动驱动手指的结构,驱动方式决定了软体手指内部呈封闭状态的单元化内腔结构。因此内腔采用呈半圆柱型的单元化内腔结构,各内腔之间通过通道相连通,并在其手指的底部位置嵌入不可伸缩材料,有利于软体手的弯曲变形,如图 1 所示。




图 1 软体手手指结构

Fig. 1 Structure diagram of the finger of the soft gripper

1.2 软体手指的制备

所设计的软体手主要由 smooth-on 公司 Ecoflex 00-50 制成, Ecoflex 系列橡胶是铂催化硅胶,用途广泛且易于使用,按重量或体积 1A : 1B 制成。固化橡胶非常柔软且坚固,拉伸多次后其原始大小不变且无任何撕裂迹象,并会反弹到原来的形状没有任何形变。制作完成后的手指由上下两部分组成,然后用特定的 Sil-Poxy 硅胶粘合剂将其粘合。Ecoflex 00-50 硅胶的常规参数如表 1 所示^[19]。

软体手的整体制作方法主要有浇注法、软光刻法、微注射成型法、形状沉积法 (shape deposition manufacturing, SDM) 和 3D 打印 (又称增材制造) 等。

考虑到经费和制作难易程度等因素,采用浇注法制作软体手指。其中软体手指设计要满足合理性;用 3D 打印机制作出实验所需的模具;倒入硅胶时注意不要产生气泡,损坏软体手指的结构完整性,静置 3 h 以上。将完全固化好的各部分硅胶手指用指定的硅胶粘结剂粘合,过程中注意粘合的气密性,保证手指内腔处于封闭状态。为了方便软体手实验数据的获取,在软体手指制作过程中,将弯曲传感器嵌入其中,以便精确测量手指弯曲角度;并在所搭建的实验平台中加入气压传感器测量手指内的充入的气压大小。

1.3 软体手的总体设计


考虑到蛋糕、苹果等截面近似为圆形,为尽量使气道数量和气动系统简单化,减少成本,选用手指数量为 3 指的软体手结构。

为使软体手在抓取时保持最优抓取姿态,采用自动调节抓取直径方法,分别在每个软体手指的夹具上放置型号相同的微型电机。当外界相机向控制器输入被抓物体信息后,控制器经过计算,从而控制电机带动手指移动到相应的抓取直径,进行抓取等操作。电机与手指夹具采用齿轮齿条传动实现软体手指往复移动。如图 2 所示。

表 1 Ecoflex 00-50 硅胶参数信息

Table 1 Ecoflex 00-50 Silicone Parameter Information

材料名称	邵氏硬度	颜色	贮存期/ min	固化时间/ min	比重/ (g/cc)	抗拉强度/ psi	断裂伸长 率/%	收缩率/ (in./in)	弹性模量/ Gpa
Ecoflex 00-50	00-50	半透明	18	180	1.07	12	980	<0.01	1



1-法兰盘连接件,2-手指夹具,3-软体手指,
4-相机支架,5-电机,6-轴承

图 2 软体手结构

Fig. 2 Structure diagram of the soft gripper

2 机理与数据驱动的软件手弯曲角度软测量模型

为了使软体手弯曲角度建模更加精确,本文提出机理与数据驱动的弯曲角度软测量模型,混合驱动模型具体流程如图 3 所示。




图 3 机理与数据驱动的软件手弯曲角度建模

Fig. 3 Mechanism and data-driven modeling
of soft gripper bending angles

成,采用最小二乘法对机理模型进行参数辨识,针对高阶未建模动态,引入补偿值,由 ABCSN 模型预测得到。

本文取一个软体手指进行力学建模及分析,并做出如下假设:

- 1) 硅胶材料看作不可压缩,为超弹性材料,且遵循 Neo-Hookean 模型;
- 2) 手指顶层与底层材料都有各向同性的性质,并且在充气弯曲过程中,其气腔的外壁厚度和半径保持不变;
- 3) 手指充放气过程中,忽略相关的力学问题,并假设每个腔室弯曲的曲率都为相等的常数;
- 4) 周向应变忽略不计。

为便于以后的理论分析,将软体手指弯曲变形时的力学模型简化,选择 Neo-Hookean 模型对软体手进行以下分析,其材料的应变能密度函数如下:

$$W = \frac{\mu}{2}(I_1 - 3)$$
 (1)

式中: μ 为所选材料的初始剪切模量; $I_1 = \lambda_1^2 + \lambda_2^2 + \lambda_3^2$ 为变形张量不变量,其中, $\lambda_i(i = 1, 2, 3)$ 分别为轴向、周向和径向的主延伸率,不仅用于度量软体手的变形大小,还用于定义软体手的应变势能。

软体手的弯曲模型在 3 个方向上的名义应力可以由其组成材料的应变能函数 W 、主伸长率 λ_i 和拉格朗日乘子 p 所结合的函数表示,表达式为:

$$\sigma_i = \frac{\partial W}{\partial \lambda_i} - p\lambda_i^{-1}$$
 (2)

式中: $\sigma_i(i = 1, 2, 3)$ 分别为软体手指弯曲变形时,轴向、周向和径向 3 个方向上的名义应力。

设单个气腔的弯曲角度为 ϕ ,总弯曲角度 θ 为: $\theta = n \cdot \phi$,其中, $n = 9$ 为气腔的数量。示意图如图 4 所示。




图 4 软体手弯曲角度示意图

Fig. 4 Diagram of the bending angle of the soft gripper

遵循上面假设,忽略其周向的延伸形变,故 $\lambda_2 = 1$ 。又因为上面的假设(1),硅橡胶为不可压缩型材料,因此 $\lambda_1 \cdot \lambda_2 \cdot \lambda_3 = 1$,设轴向延伸率 $\lambda_1 = \lambda$,可得到径向延伸率

图 3 所示,该模型由机理模型与 ABCSN 数据模型组

$$\lambda_3 = \frac{1}{\lambda} \quad (3)$$

软体手充气形变主要在其轴向伸长弯曲方面,因此在其气体经过内腔时对内腔径向的腔壁应力几乎为 0,即 $\sigma_3 = 0$ 。联立式(1)~(3)和 $I_1 = \lambda_1^2 + \lambda_2^2 + \lambda_3^2$ 得到:

$$\sigma_1 = \frac{\partial W}{\partial \lambda_1} - p\lambda_1^{-1} = \mu(\lambda - \frac{1}{\lambda^3}) \quad (4)$$

$$\sigma_2 = \frac{\partial W}{\partial \lambda_2} - p\lambda_2^{-1} = \mu(\lambda - \frac{1}{\lambda^3}) \quad (5)$$

$$\sigma_3 = \frac{\partial W}{\partial \lambda_3} - p\lambda_3^{-1} = \mu\lambda_3 - p\lambda_3^{-1} = 0 \quad (6)$$

$$p = \mu\lambda_3^2 = \frac{\mu}{\lambda^2} \quad (7)$$

软体手模型的主延伸率 $1 \leq \lambda < 1.5$, 因此由式(4)和(5)可知 $\sigma_2 \ll \sigma_1$, 又因为 $\sigma_3 = 0$, 故可将轴向应力 σ_2 近似看作软体抓手的唯一应力。

以软体手弯曲模型其中一个内腔变形为例, 当手指弯曲变形时会产生与其弯曲方向相同的弯矩 M_α 。又因制作材质的因素, 会产生阻止手指向下弯曲的弯矩 M_θ , 方向与 M_α 方向相反, 如图 5 所示, 弯矩是相对于 O 点产生的, 故 O 点周围的力矩保持平衡, 因此得到:

$$M_\theta = M_\alpha \quad (8)$$




图 5 软体手弯曲受力分析

Fig. 5 Bending force analysis of the soft gripper

图 5 中, P 为输入气压值, S 表示相邻气腔之间距离, L 表示气腔厚度, R 表示手指弯曲时对应的半径值, σ_b 为底层的限制应变层限制弯曲所产生的应力, 顶层的腔壁所产生的应力由 σ_t 表示, 弯矩 M_θ 等于底层厚度产生的应力 σ_b 与顶层厚度产生的应力 σ_t 的合力矩。

内腔气压对 O 点产生的弯矩 M_α 为:

$$M_\alpha = 2P \int_0^{\frac{\pi}{2}} (a \sin \varphi + b) a^2 \cos^2 \varphi d\varphi = \frac{4a^3 + 3\pi a^2 b}{6} \cdot P \quad (9)$$

底层的限制应变层和顶层对 O 点产生的力矩 M_θ 为:

$$M_\theta = 2 \int_0^t \left(\int_0^{\frac{\pi}{2}} \sigma_t ((a + \tau)^2 \sin \varphi + b(a + \tau)) d\varphi \right) d\tau + \int_0^b \sigma_b \cdot 2(a + t) \beta d\beta \quad (10)$$

式中: a, b 为手指内腔半径和限制层厚度, β 为底部限制应变层引入的厚度变量, 则手指的纵向伸长量 λ_β 可以得到:

$$\lambda_\beta = \frac{\beta + R}{R} = \frac{\beta + L/\phi}{L/\phi} = \frac{\beta\phi}{L} + 1 \quad (11)$$

根据式(4)得到 σ_β :

$$\sigma_\beta = \mu(\lambda_\beta - \frac{1}{\lambda_\beta^3}) \quad (12)$$

联立式(8)~(11)并代入式(7)中得到软体手的弯曲角度 θ 与充入气压 P 之间的关系:

$$\theta = \frac{P(4a^3 + 3\pi a^2 b) \cdot 3nL^3 \theta^2 \cdot (\beta\theta + nL)^2 - 36nL^3 \theta^2 \cdot (\beta\theta + nL)^2 \cdot \int_0^t \left(\int_0^{\frac{\pi}{2}} \sigma_t ((a + \tau)^2 \sin \varphi + b(a + \tau)) d\varphi \right) d\tau - (a + t)(2\beta^5 L^4 \theta^5 + 7n\beta^4 L^5 \theta^4) + 8n^2 \beta^3 L^6 \theta^3 + 3n^3 \beta^2 L^7 \theta^2 + 3n^5 L}{6n^4 \beta \cdot (a + t)} \quad (13)$$

式中: P 为外部充入手指内腔的压力。由式(13)知, 弯曲角度 θ 与充入气压 P 之间存在隐式关系:

$$\theta = f(P, \theta) \quad (14)$$

便于下面推导工作, 将充入气压 P 以输入 u 表示, 弯曲角度以输出 y 表示。

上述的力学模型, 基本过程是一个以充入绝对气压为输入, 以软体手手指弯曲角度为输出的单输入单输出系统(SISO)。此离散系统的动态模型可描述为:

$$y(k) = f[y(k-1), \dots, y(k-n), u(k-d), \dots, u(k-d-m)] \quad (15)$$

式中: $0 < |u(k)|, |y(k)| < \infty$, d 为延时, m, n 为模型输入输出的阶次, k 代表时间尺度下的样本时间段, f 是未知非线性函数。令:

$$\varphi(k-d) = [y(k-1), \dots, y(k-n), u(k-d), \dots, u(k-d-m)]^T \quad (16)$$

式中: $\varphi(k-d)$ 是维数为 $m+n+1$ 的数据向量。因此, 式(15)可表示为:

$$y(k) = f[\varphi(k-d)] \quad (17)$$

假设工作点在原点,即 $y=0, u=0$ 。对于式(17),将 $f[\varphi(k-d)]$ 在原点附近进行 Taylor 展开,并令其在该点处的一阶 Taylor 系数分别为:

$$c_i = \frac{-\partial f[\varphi(k-d)]}{\partial y(k-i)} \Big|_{y=0, u=0}, i=1, \dots, n \quad (18)$$

$$d_j = \frac{-\partial f[\varphi(k-d)]}{\partial u(k-d-j)} \Big|_{y=0, u=0}, j=1, \dots, m \quad (19)$$

由式(16)、(17)组成 z^{-1} 的多项式 C 和 D 的系数:

$$\begin{cases} C = 1 + c_1 z^{-1} + \dots + c_n A z^{-n} \\ D = d_0 + d_1 z^{-1} + \dots + d_m B z^{-m} \end{cases} \quad (20)$$

于是,模型(15)在平衡点(0, 0)处的等价模型为:

$$Cy(k) = Du(k-d) + v[\varphi(k-d)] \quad (21)$$

$$Y = \begin{bmatrix} y(1) \\ y(2) \\ \vdots \\ y(M) \end{bmatrix}, \quad \Phi = \begin{bmatrix} \varphi^T(1) \\ \varphi^T(2) \\ \vdots \\ \varphi^T(M) \end{bmatrix} = \begin{bmatrix} y(0) & \cdots & y(1-n) & u(1-d) & \cdots & u(m-d) \\ y(1) & \cdots & y(2-n) & u(2-d) & \cdots & u(1+m-d) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ y(M-1) & \cdots & y(M-n) & u(M-d) & \cdots & u(M+1-m+d) \end{bmatrix} \quad (24)$$

系统参数的最小二乘估计为:

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y \quad (25)$$

寻找估计值 $\hat{\theta}$, 使 Y 与由 $\hat{\theta}$ 确定的估计测量值 $\hat{Y} = \Phi \hat{\theta}$ 之差的平方和最小。

由此得到机理建模的最终模型。考虑到未建模动态的影响,采用数据建模对其进行数据补偿,从而进一步提高建模精度。

将最终的机理模型引入补偿值后得到下式:

$$\theta = y(k) + v[\varphi(k)] \quad (26)$$

式中: $y(k)$ 为最终机理建模中得到的手指弯曲数据, $v[\varphi(k)]$ 为未建模动态,即补偿值。将绝对气压 P 作为模型 ABSCN 的输入,补偿值 $v[\varphi(k)]$ 作为输出,将训练后模型得出的补偿值与函数 $y(k)$ 的和作为最终预测的弯曲角度值。ABSCN 算法由第4节给出。

由机理建模后的数据得出的弯曲角度值与实验值之间的偏差非线性较强,对其进行线性拟合,可得其相关系数为: $R=0.010\ 812\ 36, R^2=0.011\ 690\ 712\ 876\ 96$ 。

3 数据建模准备工作

由于软体材料的非线性特性和软体手存在无限自由度,使得针对软体手的力学建模较为复杂。因此由机理模型与 ABSCN 补偿模型组成的混合模型实现,针对实际的环境,适应性更强。

3.1 随机配置网络

随机配置网络是由随机配置(SC)算法增量生成,称为随机配置网络(SCNs),结构与单层前馈神经网络(SLFNN)相同。在算法上,SCNs 利用监督机制随机分配

式中: $v[\varphi(k-d)]$ 即未建模动态。设 $d=1$, 于是模型(21)可写为:

$$Cy(k+1) = Du(k) + v[\varphi(k)] \quad (22)$$

式中: $y(k+1)$ 是系统输出量的第 $k+1$ 次观测值。针对式(22),先对模型进行最小二乘法参数辨识,得到线性模型;对于未建模动态项 $v[\varphi(k)]$,进行 ABSCN 估计,从而对上述的力学模型进行辨识。

忽略未建模动态 $v[\varphi(k)]$, 模型(22)可化为最小二乘格式:

$$y(k) = \varphi^T(k) \theta \quad (23)$$

式中: θ 为带估参数, $\theta = [c_0, \dots, c_n, d_0, \dots, d_m]^T$ 。

令 $k=1, 2, \dots, M$, 有:

隐藏节点的输入权重和偏置,并且其输出权重根据构造函数进行评估选择^[20-21],从而确保其通用逼近特性。

BSC 增加隐藏节点的方法与 SCNs 的点增量相比,以削减模型紧凑性的前提下提高了模型的收敛速度,但 BSC 会产生过多的冗余节点,并且当块大小达到一定的数值时,算法的收敛能力会下降。

SCNs 始于一个小型的 SLFNN,然后通过不等式约束自适应得到接下来隐藏节点的参数分配;再通过全局最小二乘法得到输出权重;最后,当达到预先设定的最大节点数或期望的网络精度时,结束模型学习。

令 $\Gamma = \{g_1, g_2, g_3, \dots\}$ 表示一组示值函数, $\text{span}(\Gamma)$ 表示 Γ 张成的函数空间;令 $L_2(D)$ 表示定义在 $D \in \mathbf{R}^d$ 上所有勒贝格可测函数 $f = [f_1, f_2, \dots, f_m]: \mathbf{R}^d \rightarrow \mathbf{R}^m$ 的空间。

给定一个目标函数 $f: \mathbf{R}^d \rightarrow \mathbf{R}^m$, 假设存在一个建立好的带有 $L-1$ 个隐含层节点的 SLFNN, 那么 SLFNN 的输出可表示为:

$$f_{L-1}(x) = \sum_{j=1}^{L-1} \beta_j g_j(\omega_j^T x + b_j), f_0 = 0 \quad (27)$$

式中: $L=1, 2, \dots, \omega_j, b_j$ 和 g_j 分别为第 j 个隐含层节点的输入权重、偏置和激活函数, $\beta_j = [\beta_{j1}, \beta_{j2}, \dots, \beta_{jm}]^T$ 为第 j 个隐含层节点的输出权值。

由式(27)得到网络残差 e_{L-1} :

$$e_{L-1} = f - f_{L-1} = [e_{L-1,1}, e_{L-1,2}, \dots, e_{L-1,m}] \quad (28)$$

SCNs 将为增加的第 L 个隐含层节点构造约束条件,其形式如式(29)所示:

$$\langle e_{L-1,q}, g_L \rangle^2 \geq b_g^2 \delta_{L,q}, q=1, 2, \dots, m \quad (29)$$

式中: $\forall g \in \Gamma, b_g \in \mathbf{R}^+$, 使得 $0 < \|g\| < b_g$ 成立, δ_L 如式(30)所示:

$$\delta_L = \sum_{q=1}^m \delta_{L,q}, \delta_{L,q} = (1 - r - u_L) \|e_{L-1,q}\|^2 \quad (30)$$

式中: $0 < r < 1, u_L$ 满足 $\lim_{L \rightarrow +\infty} u_L = 0$ 和 $0 < u_L \leq (1 - r)$ 。

SCNs 中性能最佳的 SCN-III 算法采用全局最小二乘法计算得到输出权重, 如式(31)所示:

$$[\beta_1^*, \beta_2^*, \dots, \beta_L^*] = \operatorname{argmin} \|f - \sum_{j=1}^L \beta_j g_j\| \quad (31)$$

根据预先设定的期望误差判断是否停止 SCN-III 模型的学习, 当模型学习结果误差在期望误差之内时, 停止迭代。

3.2 块增量随机配置网络

BSC^[22] 与 SCNs 的不同只在于每次迭代节点的添加数量不同, 成块添加节点意味着 BSC 与原本 SCNs 的约束条件和各项参数只存在维度上的差别, 其逼近特性依然成立。

便于算法描述, 将输出函数重新定义为 $f_L = H_L \beta = f_{L-1} + h_L \beta_L^T$, 其中 $H_L = [h_1, \dots, h_L]_{N \times L}$, β 的格式与式(31)相同, 并且 $h_L = g_L^T$ 。

输出权重如下式所示:

$$\beta_{\Delta_k, q} = (H_{\Delta_k}^T H_{\Delta_k})^\dagger H_{\Delta_k}^T e_{L-\Delta_k, q} \quad (32)$$

式中: Δ_k 表示第 k 次迭代添加隐含层节点的个数, $(H_{\Delta_k}^T H_{\Delta_k})^\dagger$ 为 $H_{\Delta_k}^T H_{\Delta_k}$ 的 Moore-Penrose 广义矩阵。

并确定中间值 $\tilde{\beta}_{\Delta_k, q} = (H_{\Delta_k}^T H_{\Delta_k})^\dagger H_{\Delta_k}^T e_{L-\Delta_k, q}^*$ 求得

$$\tilde{e}_L = e_{L-\Delta_k}^* - H_{\Delta_k} \tilde{\beta}_{\Delta_k, q}$$

引理 1 假设 $\operatorname{span}(\Gamma)$ 在 L_2 空间中是稠密的。给定 $0 < r < 1$ 和一个非负实数序列 $\{u_L\}$, 其中 $\lim_{L \rightarrow +\infty} u_L = 0$ 且 $u_L \leq (1 - r)$ 。对于 $L = 1, 2, \dots, \Delta_k, \Delta_k \in \{L\}, k = 1, 2, \dots$, 有

$$\delta_{L,q}^* = (1 - r - u_L) \|e_{L-\Delta_k, q}^*\|^2, q = 1, 2, \dots, m \quad (33)$$

如果生成隐藏输出块 H_{Δ_k} 满足不等式, 即监督机制的块形式:

$$\langle e_{L-\Delta_k, q}^*, H_{\Delta_k} \tilde{\beta}_{\Delta_k, q} \rangle \geq \delta_{L,q}^*, q = 1, 2, \dots, m \quad (34)$$

输出权重与式(31)相同。模型学习的停止条件与点增量 SCNs 相同。

4 自适应随机配置网络的数据建模

对于 BSC 来说, 越大尺寸的增量块导致收敛速度变快的前提下, 也会导致模型的紧凑性下降, 可能会产生过拟合。鉴于此, 受到蚁群优化算法 (ant colony optimization, ACO) 信息素挥发思想和粒子群优化算法 (particle swarm optimization, PSO) 中更新权重的方式启发, 提出了一种自适应调节块增量大小的 SCNs。同时,

还针对该模型每次迭代的最大配置次数进行自适应处理, 可以有效的减少模型的计算时间, 使模型在保证其紧凑性, 提高训练速度。得到自适应块增量随机配置网络 (ABSCN)。

4.1 基于信息素挥发的自适应块增量随机配置网络

定理 1 给定误差序列 $\{e_k\}$ 存在 $\lim_{k \rightarrow +\infty} e_k = 0$, 引

入信息素挥发率 ρ , 且 $0 < \rho < 1$, 令 $\operatorname{cost} = \sum_{i=1}^N (1 - \rho)^{k-N+i} |e_{k-N+i}|$ 且 $\lim_{k \rightarrow +\infty} \operatorname{cost} = 0$, 存在一取整函数 τ , 使得 $1 \leq \tau(\operatorname{cost}) = \Delta_k \leq P$ 。其中 k 为迭代次数, Δ_k, e_k 为第 k 次迭代的块尺寸和计算得到的偏差, N 为观测窗口尺寸。

定理 1 中的取整函数 τ 如式(35)所示:

$$\tau = \operatorname{floor}(\eta \Delta_k + q \cdot e^{\operatorname{cost}}) \quad (35)$$

式中: $\operatorname{floor}(\cdot)$ 是一个向 $-\infty$ 取整的函数, Δ_k 为第 k 次迭代时增加块的大小, η 为惯性权重, 对实时更新增加块的大小起辅助作用, 具体形式如式(36)所示。当 cost 值较大时, Δ_k 也是一个较大的值, 帮助模型快速收敛; 当 $\operatorname{cost} \rightarrow 0$ 时, Δ_k 会快速收敛到 1, 防止出现过多的冗余节点导致模型性能变差甚至过拟合。

$$\eta = \eta_{\max} - (\eta_{\max} - \eta_{\min}) \frac{L}{L_{\max}} \quad (36)$$

式中: $\eta_{\max}, \eta_{\min}$ 为惯性权重的最大最小值, L 为当前已添加的隐含层节点数, $L_{\max}$ 为设置的隐含层节点数量最大值。具体结构如图 6 所示。




图 6 ABSCN 结构图

Fig. 6 Structure diagram of ABSCN

4.2 收敛性证明

BSC 的收敛性证明与 SCNs 的证明大体相似, 即定理 1 的具体证明如下式所示:

$$\delta_{L,q}^* = (1 - r - u_L) \|e_{L-\Delta_k, q}^*\|^2, q = 1, 2, \dots, m \quad (37)$$

$$\langle e_{L-\Delta_k, q}^*, H_{\Delta_k} \tilde{\beta}_{\Delta_k, q} \rangle \geq \delta_{L,q}^*, q = 1, 2, \dots, m \quad (38)$$

由式(32)计算得到输出权重。

独立重复试验得到。参数选择： $N=5$ 、 $\eta_{\max}=0.55$ 、 $\eta_{\min}=0.1$ 、 $q=0.4$ 、 $\rho=0.3$ 、 $l=0.4$ 、最大节点数 $L_{\max}=100$ ，最大配置次数及其他参数均在下文实验中给出。

5.1 ABSCN 性能验证

本节使用式(44)所示的逼近函数,选择超参数 $\lambda=[0.5\ 1\ 5\ 10\ 50\ 100\ 150\ 200\ 250\ 300]$,对 ABSCN、BSC-II 和 SCN-III 采用不同初始增量块尺寸 Δ_1 ,为了方便对比,将算法相关参数保持一致。得到结果如表 3 所示。

表 3 ABSCN、BSC-II 与 SCN-III 性能对比

Table 3 Performance comparison of ABSCN, BSC-II and SCN-III				
算法	块大小	L	k	RMSE
SCN-III	1	64.52	64.52	0.003 5
	5	75.28	32.42	0.003 8
BSC-II	10	81.50	25.48	0.004 0
	1	62.34	62.34	0.004 1
ABSCN	5	68.86	45.92	0.004 3
	10	70.42	44.04	0.003 9

表 4 ABSCN、BSC-II 和 SCN-III 训练时间对比

Table 4 Comparison of training time of ABSCN, BSC-II and SCN-III

算法	块大小	$T_{\max}$ (最大配置次数)	训练时间/s				
			①	②	③	④	⑤
SCN-III	1	100	47.502 202	48.666 121	47.189 726	47.757 902	47.124 154
		200	97.446 230	96.295 799	99.198 626	97.211 847	99.305 783
BSC-II	5	100	28.553 037	26.979 410	26.919 008	27.940 898	30.061 658
		200	53.713 878	56.789 547	53.610 142	49.765 161	54.482 982
	10	100	22.527 088	23.055 879	22.593 667	23.445 701	23.704 128
		200	46.573 233	43.515 874	47.445 315	44.842 593	41.231 447
ABSCN	1	100	29.368 039	29.675 067	28.356 679	28.315 502	28.593 341
		200	46.063 167	46.039 640	45.109 130	43.579 167	49.470 932
	5	100	24.174 796	24.808 757	24.448 711	22.665 860	23.169 461
		200	34.892 347	35.423 113	36.186 934	36.701 384	35.256 110
	10	100	22.754 096	21.500 974	23.028 857	21.386 396	22.926 908
		200	36.963 383	37.833 821	37.116 941	36.268 108	35.252 314

结合表 3、4 得到:当初始块增量大小 $\Delta_1=10$,最大配置次数取 100 条件下,两模型的训练时间相差无几,当最大配置次数取为 200 时,ABSCN 模型的训练速度要明显优于 BSC-II 模型,又根据 5.1 节中得出的结论,BSC-II 模型较 ABSCN 更容易产生冗余节点。SCN-III 训练时间过长,暂不考虑其性能。

综上所述,ABSCN 模型在同等参数条件下模型结构比 BSC-II 更紧凑,训练速度更快。

5.3 基准数据集

针对两个基准数据集模型,将 ABSCN、BSC-I 和 SCN-III 3 种算法进行对比,设定超参数为 $\lambda=[0.5\ 1\ 5\ 10\ 50\ 100\ 150\ 200\ 250\ 300]$ 。目标精度 ε 已在上述描述中

$$y(x)=0.2e^{-(10x-4)^2}+0.5e^{-(80x-40)^2}+0.3e^{-(80x-40)^2},x\in[0,1]$$

(44)

表 3 中, L 和 k 分别对应各模型的隐含层节点数和迭代次数,由此可以看出:随着初始块 Δ_1 数量增加,模型训练得到的隐含层节点数增加,迭代次数减少;再看 ABSCN,当 $\Delta_1=1$ 时,隐含层节点数相比最小,但迭代次数最多,故此模型最紧凑且训练时长最长;当 $\Delta_1=10$ 时,效果恰好相反,此时与 BSC-II 比较来看,隐含层节点数小于 BSC-II 模型,迭代次数要高过 BSC-II,因此得出:BSC-II 存在更多的冗余节点,更容易产生过拟合。两者训练速度对比在下节给出。

5.2 BSC-II 与 ABSCN 训练速度对比

针对 4.3 节所描述的网络训练残差的变化而变化的最大配置次数。下面比较 ABSCN、BSC-II 和 SCN-III 3 种算法在相同初始增量块尺寸 Δ_1 下,不同最大配置次数得到的训练时间,具体参数如表 4 所示。

给出($\varepsilon_1=0.072$ 、 $\varepsilon_2=0.018$)。

由表 5 可以看出:最大配置次数越大,模型训练时间越长,对于 SCN-III 模型,虽然隐含层节点数较 BSC-II 和 ABSCN 两模型更少,但优势并不明显,而且在训练时间方面相较于其他两模型明显过长,会降低模型的总体性能;再看 BSC-II 与 ABSCN,除初始块大小 $\Delta_1=10$ 时的初始最大配置次数 $T_1=100$ 和 $T_1=200$ 两模型之间的隐含层节点相差较明显之外,其他情况下训练得到的隐含层节点数量基本相似,但从模型的训练时间来看,BSC-II 与 ABSCN 在相同初始块大小的条件下,初始最大配置次数为 $T_1=200$ 的 ABSCN 模型与最大配置次数为 $T_{\max}=100$ 的 BSC-II 模型的训练时间相差不多。

表 5 ABSCN、BSC-II 与 SCN-III 基准数据集训练性能对比

Table 5 Comparison of training performance on ABSCN, BSC-II and SCN-III benchmark datasets

数据集	算法	块大小	$T_{\max}$ (最大配置 次数)	L	训练时 间/s	数据集	算法	块大小	$T_{\max}$ (最大配置 次数)	L	训练时间/s
DB1	SCN-III	1	100	62.86	89.699	DB2	SCN-III	1	100	32.42	10.651
			200	60.18	157.32				200	31.44	23.310
	BSC-II	5	100	69.56	53.896		BSC-II	5	100	35.88	7.668
			200	66.20	83.893				200	34.52	9.369
		10	100	75.00	38.303			10	100	43.88	3.062
			200	70.44	61.839				200	41.56	4.670
	ABSCN	1	100	69.62	36.659		ABSCN	1	100	35.80	4.495
			200	66.68	47.438				200	33.28	6.215
		5	100	69.96	35.655			5	100	36.20	4.199
			200	66.76	47.117				200	33.84	5.687
		10	100	70.62	33.978			10	100	37.72	3.516
			200	67.52	41.839				200	36.08	4.733

由上面的分析可以得到:在保证模型紧凑性的前提下,ABSCN 比 BSC-II 具有更快的训练时间优点,在以训练时间为标准的前提下,ABSCN 比 BSC-II 模型紧凑型更高。综上所述,ABSCN 模型无论其网络最大配置次数取上述何种,考虑总体性能,ABSCN 模型总是优于 BSC-II 模型。

5.4 软件手弯曲角度软测量

由 AIC 准则得到模型的阶数,选取延迟步数 $d = 1$, 得到可行阶次 $[n, m, d] = [5, 8, 1]$, 其中模型参数为: $C = [1.362\ 0.433\ 6\ 0.550\ 5 - 0.671\ 4\ 0.040\ 39\ 0.892\ 9 - 0.623\ 6\ 0.114\ 2]^T, D = [1.276\ -2.222\ 0.654\ 0.244\ 7\ 0.049\ 95]^T$ 。

由本章前 3 小节的实验仿真已经充分证明了 ABSCN 算法的有效性。下面本节是将所提出的方法应用到实际的工业案例中,对软件手中所充入的气体压强得到弯曲角度的估计。在实际的操作现场中采集 456 个样本进行建模所需的数据,其中 366 个样本为训练集,90 个样本为测试集,设计目标精度为 $\varepsilon = 3 \times e^{-2}$, 初始最大配置次数 $T_1 = 100$,其余参数与上述相同,初始块大小分别设置为 $\Delta_1 = 1$ 和 $\Delta_1 = 5$ 。

图 8 和 9 中,初始块大小为 $\Delta_1 = 1$ 的 ABSCN 模型最终训练得到隐含层节点数为 $L = 85$,迭代次数为 $k = 52$ 。图 9 中初始块大小为 $\Delta_1 = 5$ 的 ABSCN 模型最终训练得到隐含层节点数为 $L = 87$,迭代次数为 $k = 50$ 。两者模型训练 50 次的时间分别为 15.387 449 s 和 13.987 839 s。

在图 8 和 9 中可以得到:模型输出和真实值基本吻合,大部分数据均满足实验要求。由图 10 得到:本文提出的方法可以对软件手弯曲角度进行准确的估计;并且提出的 ABSCN 模型网络结构简单,总体性能较高,泛化性能良好。




图 8 初始块大小为 $\Delta_1 = 1$ 时的模型逼近特性和模型收敛曲线

Fig. 8 Approximation characteristics and convergence curve of the model when the initial block size is $\Delta_1 = 1$




图 9 初始块大小为 $\Delta_1 = 5$ 时的模型逼近特性和模型收敛曲线

Fig. 9 Approximation characteristics and convergence curve of the model when the initial block size is $\Delta_1 = 5$




图 10 软体手气压-弯曲角度实验数据与预测数据对比

Fig. 10 Comparison between experimental data and predicted data for air pressure-bending angle of the soft gripper

6 结 论

本文的软体手弯曲角度软测量,针对机理模型预测结果不够精确,数据模型可解释性不强,提出了数据与机理混合驱动的软测量模型,利用最小二乘法对机理模型进行线性化参数辨识。对未建模动态,引入了补偿值,针对原有的 SCNs 和 BSC 算法进行改进,提出了一种自适应块增量随机配置网络模型,并对本模型的最大配置次数进行优化处理,在保证模型具有足够紧凑性的前提下拥有较快的训练速度,混合模型精度也得到了明显提升。同时证明了 ABSN 算法的泛化能力,SCNs 相比,具有更高的模型紧凑性和较快的训练速度,对于较大的数据集,性能凸显更为明显。

ABSAN 还可以根据使用者的需要通过调节参数来进行模型紧凑性和训练速度的取舍;可以根据需要获得更紧凑的模型;也可以获得训练速度更快的模型;或者紧凑性与训练速度兼得,获得总体性能更好的模型,但需要牺牲一定的紧凑性和训练时间。经过验证分析,所提出的算法具有收敛速度快、模型尺寸小、训练速度快、泛化性能好等优点。

参考文献

[1] LASCHI C, MAZZOLAI B, CIANCHETTI M. Soft robotics: Technologies and systems pushing the boundaries of robot abilities[J]. Science Robot, 2016, 1(1): 1-11.

[2] 张进华, 王韬, 洪军, 等. 软体机械手研究综述[J]. 机械工程学报, 2017, 53(13): 19-28.

ZHANG J H, WANG T, HONG J, et al. Research review of soft manipulator[J]. Journal of Mechanical Engineering, 2017, 53(13): 19-28.

[3] 谷可欣, 李红, 李坤阳, 等. 软体仿生机械手柔性触觉感知技术研究进展[J]. 电子测量与仪器学报, 2022, 36(8): 13-27.

GU K X, LI H, LI K Y, et al. Research progress of flexible tactile sensing technology for soft biomimetic manipulator[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 13-27.

[4] DEIMEL R, BROCK O. A novel type of compliant and underactuated robotic hand for dexterous grasping[J]. The International Journal of Robotics Research, 2016, 35(1-3): 161-185.

[5] POLYGERINOS P, WANG Z, GALLOWAY K C, et al. Soft robotic glove for combined assistance and at-home rehabilitation[J]. Robotics and Autonomous Systems, 2015, 73: 135-143.

[6] MOSADEGH B, POLYGERINOS P, KEPLINGER C, et

- al. Pneumatic networks for soft robotics that actuate rapidly [J]. *Advanced Functional Materials*, 2014, 24(15): 2163-2170.
- [7] BARTLETT N W, TOLLEY M T, OVERVELDE J T, et al. A 3D-printed, functionally graded soft robot powered by combustion [J]. *Science*, 2015, 349 (6244): 161-165.
- [8] CONNOLLY F, POLYGERINOS P, WALSH C J, et al. Mechanical programming of soft actuators by varying fiber angle[J]. *Soft Robotics*, 2015, 2(1): 26-32.
- [9] 冯乃诗, 王宏, 胡佛, 等. 软体机器人纤维增强式三腔体结构设计与分析[J]. *东北大学学报(自然科学版)*, 2019, 40(10): 1461-1466.
- FENG N SH, WANG H, HU F, et al. Design and analysis of fiber-reinforced three-cavity structure for soft robotic hand [J]. *Journal of Northeastern University (Natural Science Edition)*, 2019, 40(10): 1461-1466.
- [10] WANG Z, HIRAI S. Soft gripper dynamics using a line-segment model with an optimization-based parameter identification method[J]. *IEEE Robotics and Automation Letters*, 2017, 2(2): 624-631.
- [11] 韩非, 张道辉, 赵新刚. 基于弯曲度预测模型的软体手人机交互控制[J]. *自动化与仪表*, 2022, 37(7): 43-47.
- HAN F, ZHANG D H, ZHAO X G. Human-computer interaction control of soft hand based on bending prediction model [J]. *Automation & Instrumentation*, 2022, 37(7): 43-47.
- [12] 蔡奇志, 苗荣霞, 樊逸飞, 等. 基于粒子群优化神经网络的电梯群控算法[J]. *国外电子测量技术*, 2019, 38(5): 114-119.
- CAI Q ZH, MIAO R X, FAN Y F, et al. Elevator group control system based on improved PSO [J]. *Foreign Electronic Measurement Technology*, 2019, 38(5): 114-119.
- [13] 李渊朴, 王秀玲. 基于改进遗传算法和神经网络的大棚环境预测[J]. *电子测量技术*, 2020, 43(7): 46-49, 166.
- LI Y P, WANG X L. Greenhouse environment prediction based on improved genetic algorithm and neural network [J]. *Electronic Measurement Technology*, 2020, 43(7): 46-49, 166.
- [14] 赵泽宇, 杜明星. 多数据驱动人工神经网络的 IGBT 结温在线估计方法[J]. *电子测量与仪器学报*, 2022, 36(7): 223-229.
- ZHAO Z Y, DU M X. On line estimation of IGBT junction temperature based on multi data driven artificial neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(7): 223-229.
- [15] 张志勇, 陆金桂, 张猛. 基于 WOA-BP 神经网络的磨煤机出粉量估算[J]. *电子测量技术*, 2022, 45(22): 157-161.
- ZHANG ZH Y, LU J G, ZHANG M. Estimation of powder output of coal mill based on WOA-BP neural network[J]. *Electronic Measurement Technology*, 2022, 45(22): 157-161.
- [16] 金秀章, 史德金, 乔鹏. 基于沙地猫群优化-最小二乘支持向量机的动态 NO_x 排放预测[J/OL]. *中国电机工程学报*: 1-9.
- JIN X ZH, SHI D J, QIAO P. Dynamic NO_x emission prediction based on sandcat swarm optimization-least squares support vector machine [J/OL]. *Proceedings of the CSEE*: 1-9.
- [17] 陈泽慧, 李博, 李博. 基于多模型软测量技术的扭矩在线测量方法[J]. *电子测量技术*, 2021, 44(23): 146-150.
- CHEN Z H, LI B, LI B. Research on on-line torque measurement method based on multi-model soft-sensing technology [J]. *Electronic Measurement Technology*, 2021, 44(23): 146-150.
- [18] 乔景慧, 潘忠, 熊宁康, 等. 数据与机理驱动的检定系统建模与参数辨识[J]. *仪器仪表学报*, 2022, 43(6): 280-289.
- QIAO J H, PAN ZH, XIONG N K, et al. Modeling and parameter identification integrated data and mechanism for verification system[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(6): 280-289.
- [19] MARECHAL L, BALLAND P, LINDENROTH L, et al. Toward a common framework and database of materials for soft robotics[J]. *Soft Robot*, 2021, 8(3): 284-297.
- [20] WANG D H, LI M. Stochastic configuration networks: Fundamentals and algorithms[J]. *IEEE Transactions on Cybernetics*, 2017, 47(10): 3466-3479.
- [21] 代伟, 李德鹏, 杨春雨, 等. 一种随机配置网络的模型与数据混合并行学习方法[J]. *自动化学报*, 2021, 47(10): 2427-2437.
- DAI W, LI D P, YANG CH Y, et al. A model and data hybrid parallel learning method for randomly configured networks [J]. *Chinese Journal of Automation*, 2021, 47(10): 2427-2437.
- [22] DAI W, LI D P, ZHOU P, et al. Stochastic configuration networks with block increments for data modeling in process industries[J]. *Information Sciences*, 2019, 484: 367-386.

作者简介



乔景慧, 2002 年于沈阳建筑大学获得学士学位, 2005 年于东北大学获得硕士学位, 2012 年于东北大学获得博士学位, 现为沈阳工业大学副教授, 主要研究方向为复杂工业过程建模与智能控制、智能视觉与机器学习。

E-mail: qiaojh2002@163.com

Qiao Jinghui received his B. Sc. degree from Shenyang Jianzhu University in 2002, M. Sc. degree from Northeastern University in 2005 and Ph. D. degree from Northeastern University in 2012, respectively. Now he is an associate professor with the School of Mechanical Engineering, Shenyang University of Technology. His main research interests include modeling and

intelligent control for complex industry systems, intelligent vision, and machine learning.



李洪达(通信作者), 2020 年于沈阳工程学院机械学院获得学士学位, 现为沈阳工业大学硕士研究生, 主要研究方向为复杂工业过程建模与智能控制、机器学习。

E-mail: 993440023@qq.com

Li Hongda (Corresponding author) received his B. Sc. degree from the School of Mechanical Engineering, Shenyang Institute of Engineering in 2020. Now he is a M. Sc. candidate at Shenyang University of Technology. His main research interests include modeling and intelligent control for complex industry systems, machine learning.