

DOI:10.19651/j.cnki.emt.2209091

# 基于 PSO 优化 LSTM 神经网络的 机械臂逆运动学求解研究\*

孙燕成 陈富安

(河南工业大学电气工程学院 郑州 450001)

**摘要:** 针对机械臂逆运动学求解时使用传统解法实时性差,使用传统神经网络求解精度不高的问题,本文提出了一种利用粒子群算法(PSO)优化长短期记忆神经网络(LSTM)的逆运动学求解模型。首先建立串联式六自由度机械臂的模型进行运动学分析,获取训练数据,然后利用粒子群算法对长短期记忆网络的隐藏层神经单元数和学习率迭代寻优,参数优化后的 LSTM 学习机械臂末端执行器位姿与关节变量的映射关系,最后通过训练好的 PSO-LSTM 模型对机械臂的关节变量值进行预测得到逆运动学解。实验结果表明,模型的逆运动学求解速度维持在 10 ms 以内,与传统解法相比提高了数十倍,且模型的均方误差低至 0.001,在提高求解速度的同时还能够保证求解精度。

**关键词:** 机械臂;逆运动学求解;粒子群算法;神经网络

**中图分类号:** TP242 **文献标识码:** A **国家标准学科分类代码:** 510.80

## Optimization of LSTM neural network based on PSO research on inverse kinematics solution of manipulator

Sun Yancheng Chen Fu'an

(School of Electrical Engineering, Henan University of Technology, Zhengzhou 450001, China)

**Abstract:** In order to solve the inverse kinematics of manipulator with poor real-time performance and low precision, a particle swarm optimization (PSO) algorithm for LSTM was proposed in this paper. Firstly, the model of the series 6-DOF manipulator is established for kinematic analysis, and the training data are obtained. Next, optimizing the quantity of hidden level neural units and learning percentage of the long-term and short-term memory network by PSO. LSTM after parameter optimization learns the mapping relationship between the position and pose of the manipulator's end effector and joint variables. Finally, the trained PSO-LSTM model is used to predict the joint variables of the manipulator to obtain the inverse kinematics solution. The experimental results show that the inverse kinematics solution speed of the model is kept within 10 ms, which is tens of times higher than that of the traditional solution, and the mean square error of the model is as low as 0.001, which can not only improve the solution speed but also ensure the solution accuracy.

**Keywords:** mechanical arm; inverse kinematics solution; particle swarm optimization; neural network

## 0 引言

随着机器人技术的不断发展,机械臂的应用已经深入到工业生产的各个方面。机械臂是一个复杂的机械装置,在执行任务时,需要对它工作的空间进行分析、对它的运动轨迹进行规划,要使机械臂的末端执行器位姿满足所执行任务的要求,就要快速、精确的得到它的各个关节角度,因此机械臂的逆运动学研究对于机械臂的

发展应用至关重要。目前,逆运动学求解的传统方法主要有代数法、几何法、迭代法<sup>[1]</sup>。代数法需要进行大量的三角换元,简化过程十分复杂<sup>[2]</sup>;几何法难于求解一般解,且通用性不强<sup>[3]</sup>;迭代解法通过大量数据反复迭代,计算量很大<sup>[4]</sup>。因此近年来大批研究人员尝试借助智能算法来获得机械臂的逆运动学解。常见的智能算法有遗传算法、粒子群算法和神经网络等<sup>[5]</sup>。杨惠珍等<sup>[6]</sup>提出一种基于改进自适应小生境遗传算法的逆运

收稿日期:2022-02-26

\* 基金项目:河南省科技攻关项目(182102210088)资助

动学求解方法,解决了逆运动学求解存在多解的问题;李文博等<sup>[7]</sup>建立 BP 神经网络模型对机械臂进行逆运动学求解,弥补了传统求解方法的不足,但求解精度较低、收敛速度较慢;陈睿等<sup>[8]</sup>使用 BP 与 RBF 并行的神经网络模型进行逆运动学求解,提高了求解的精度和速度,但易陷入局部最优;杨金鹏<sup>[9]</sup>通过思维进化算法优化 BP 神经网络对工业机器人逆运动学求解,求解精度高、泛化能力强,但算法较为复杂;周恒旭等<sup>[10]</sup>提出基于长短期记忆网络的机械臂逆运动学求解方法,首次将循环神经网络应用于机械臂逆解领域,模型泛化能力强,但模型训练参数由人为设置,求解精度难以得到保证。对于机械臂逆运动学求解问题,以上研究人员的方法都取得了一定成效,但还存在一定的提升空间。

针对上述问题,本文提出一种利用粒子群算法(PSO)优化长短期记忆神经网络(LSTM)的机械臂逆运动学求解模型。机械臂通过每个关节的角度变化控制其末端执行器的位姿变化,它的运动过程是时序性的。虽然 LSTM 擅长处理时序预测问题,但预测效果很大程度上依赖于参数设置,而模型的参数通常由研究人员根据经验决定,选取不当会导致模型预测效果不佳。因此通过粒子群算法对 LSTM 部分参数寻优,经过样本训练得到一个多输入、多输出的机械臂逆运动学求解模型。经过对比分析,本文模型相较于传统解法求解速度更快,相较于 BP、单 LSTM 神经网络求解精度更高,泛化能力更强。

## 1 运动学分析

选用时代超群 A630 串联式六自由度机械臂为本文研究对象,建立符合机械臂各连杆间约束关系的运动学模型,其结构如图 1 所示。




图 1 A630 结构

首先用  $a_i, \alpha_i, d_i, \theta_i$  四个运动学参数构建机械臂的 D-H 参数如表 1 所示。

把 A630 串联式六自由度机械臂的 D-H 参数代入式(1)可以得到各相邻连杆的位姿变换矩阵。

表 1 A630 的 D-H 参数

连杆编号	$a_i/cm$	$\alpha_i/(^\circ)$	$d_i/cm$	$\theta_i/rad$
连杆 1	8	90	13	$\theta_1$
连杆 2	24	0	0	$\theta_2$
连杆 3	7	90	0	$\theta_3$
连杆 4	0	90	28	$\theta_4$
连杆 5	0	90	0	$\theta_5$
连杆 6	0	180	11	$\theta_6$

$${}^i{}_{i-1}\mathbf{T} = \begin{bmatrix} C\theta_i & -S\theta_i C\alpha_i & S\theta_i S\alpha_i & a_i C\theta_i \\ S\theta_i & C\theta_i C\alpha_i & -C\theta_i S\alpha_i & a_i S\theta_i \\ 0 & S\alpha_i & C\alpha_i & d_i \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (1)$$

式中:  $a_i, \alpha_i, d_i$  为常量,取决于机械臂的结构参数,  $\theta_i$  为关节变量,  $C$  和  $S$  分别为余弦函数和正弦函数。

根据式(1)可求得 6 个位姿变换矩阵,将这 6 个位姿变换矩阵按式(2)进行计算得到机械臂的末端执行器位姿矩阵如式(3)所示。

$${}^0{}_{6}\mathbf{T} = {}^0{}_{1}\mathbf{T}{}^1{}_{2}\mathbf{T}{}^2{}_{3}\mathbf{T}{}^3{}_{4}\mathbf{T}{}^4{}_{5}\mathbf{T}{}^5{}_{6}\mathbf{T} \quad (2)$$

$${}^0{}_{6}\mathbf{T} = \begin{bmatrix} r_{11} & r_{12} & r_{13} & P_x \\ r_{21} & r_{22} & r_{23} & P_y \\ r_{31} & r_{32} & r_{33} & P_z \\ 0 & 0 & 0 & 1 \end{bmatrix} = \begin{bmatrix} n_x & o_x & a_x & P_x \\ n_y & o_y & a_y & P_y \\ n_z & o_z & a_z & P_z \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

在已知机械臂各关节结构的姿态位置时,求解机械臂末端执行机构的姿态位置称为正运动学分析<sup>[11]</sup>。机械臂的逆运动学求解就是已知末端执行器的姿态矩阵  $\mathbf{R}(n_x, n_y, n_z, o_x, o_y, o_z, a_x, a_y, a_z)$  和位置矩阵  $\mathbf{P}(p_x, p_y, p_z)$ , 去求使机械臂满足已知位姿的关节变量值<sup>[12]</sup>。

本研究的训练数据集通过正运动学求解来得到,具体操作如下:在 MATLAB 上建立机械臂正向运动学模型,利用蒙特卡洛方法随机生成在其工作范围内的 6 个关节变量数据,将关节变量数据带入到正向运动学模型中计算出其位姿矩阵。然后把位姿矩阵中的位置矩阵转置为  $1 \times 3$  的数组,姿态矩阵  $\mathbf{R}$  经过坐标变换后化为  $\alpha, \beta, \gamma$  构成欧拉角数组,变换公式为:

$$\alpha = \arctan2(a_y, a_x) \quad (4)$$

$$\beta = \arctan2(a_x \cos\alpha + a_y \sin\alpha, a_z) \quad (5)$$

$$\gamma = \arctan2(-n_x \sin\alpha + n_y \cos\alpha, o_x \cos\alpha - o_y \sin\alpha) \quad (6)$$

将关节变量数据、位置数组和欧拉角数组按顺序生成 CSV 格式的文件保存下来,共 12 000 组数据。由于输入的数据量纲不同,数值差异较大,需要根据式(7)对数据进行标准化。

$$x_k = (x - x_{mean})/x_{var} \quad (7)$$

式中:  $x_k$  为标准化后的数据;  $x_{mean}, x_{var}$  分别为数据的均值和方差。

## 2 PSO-LSTM 逆运动学求解模型

### 2.1 长短期记忆神经网络

长短期记忆神经网络(LSTM)引入了门控机制,比传统的循环神经网络更擅长处理时序问题<sup>[13]</sup>,LSTM的单元结构如图2所示。图中 $f_t, i_t, o_t$ 分别表示遗忘门、输入门和输出门, $c_t$ 表示神经元状态, $h_t$ 表示隐藏层状态, $x_t$ 表示LSTM单元的输入向量, $\sigma$ 和 $\tanh$ 分别表示sigmoid和tanh激活函数。机械臂通过每个关节的角度变化控制其末端执行器的位姿变化,它的运动过程是时序性的,故通过LSTM将机械臂的末端执行器位姿与其关节变量拟合具有可行性。

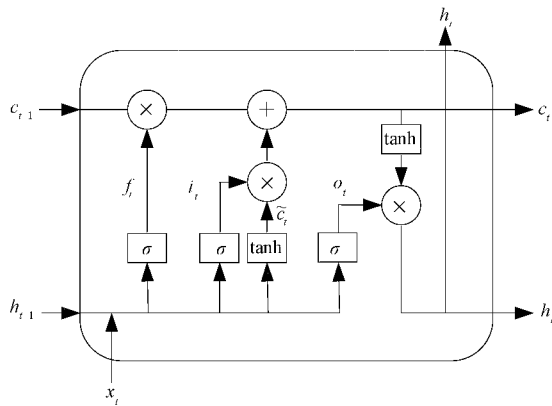


图 2 LSTM 单元结构

LSTM 的核心部分是细胞状态和门结构,细胞状态可以看作是信息传递的通道,使信息连续传递;门结构不断地在训练过程中学习该保存或遗忘哪些信息。输入门确定当前输入中的重要信息,进而更新细胞状态;遗忘门决定应丢弃或保留的信息<sup>[14]</sup>;输出门用来确定新隐藏状态 $h_t$ ,并把新细胞状态 $c_t$ 和新隐藏状态 $h_t$ 传到下一个LSTM单元。LSTM 神经元内信息传递遵循的公式如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (8)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (9)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (10)$$

$$c_t = f_t c_{t-1} + i_t \tilde{c}_t \quad (11)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (12)$$

$$h_t = o_t \tanh(c_t) \quad (13)$$

其中, $W$ 表示权重, $b$ 表示各门控单元偏置量。

### 2.2 粒子群优化算法

粒子群算法(PSO)可以通过粒子间的信息交互快速寻优,算法中的粒子是同时运动的,所有粒子都会在运动过程中产生记忆与经验,任一单个粒子在寻找最优解的过程中将自身经验与其他粒子所提供的经验进行对比,使自身不断地处于最优解中。

粒子群算法具体描述如下:

$D$ 维空间中有 $m$ 个粒子构成一个种群 $X = \{x_1,$

$x_2, \dots, x_m\}$ ,在这个种群中的任意一个 $x_i = [x_{i1}, x_{i2}, \dots, x_{id}]$ ,设 $t$ 时刻 $x_i$ 的位置 $X_i^t = [x_{i1}^t, x_{i2}^t, \dots, x_{id}^t]^T$ ,速度 $V_i^t = [v_{i1}^t, v_{i2}^t, \dots, v_{id}^t]^T$ ,个体最优位置 $P_i^t = [p_{i1}^t, p_{i2}^t, \dots, p_{id}^t]^T$ ,全局最优位置 $P_g^t = [p_{g1}^t, p_{g2}^t, \dots, p_{gd}^t]^T$ 。

速度和位置更新公式如下:

$$\begin{cases} v_{id}^{t+1} = \omega v_{id}^t + c_1 r_1^t (p_{id}^t - x_{id}^t) + c_2 r_2^t (p_{gd}^t - x_{id}^t) \\ x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1} \end{cases} \quad (14)$$

式中: $\omega$ 为惯性权重,粒子随着 $\omega$ 的逐渐增大侧重于全局搜索,随着 $\omega$ 的逐渐减小而侧重于局部搜索<sup>[15]</sup>;  $c_1$ 和 $c_2$ 为学习因子,决定粒子向个体最优位置和全局最优位置运动的最大步长; $r_1$ 和 $r_2$ 为位于 $[0, 1]$ 区间上的随机数,二者互无关系,用来增强搜索的随机性。

### 2.3 PSO-LSTM 模型

1) PSO-LSTM 网络模型整体结构和算法流程

LSTM 虽解决了循环神经网络的梯度消失和爆炸问题,但在引入门结构的同时使参数数量变多,模型参数的设置通常源于研究人员的经验,而通过粒子群算法确定最优的关键参数值可以使模型达到最佳预测效果。本研究通过粒子群算法对LSTM模型的隐藏层单元数和学习率进行参数寻优,寻优完成后以最优参数建立LSTM机械臂逆运动学求解模型,PSO-LSTM网络模型整体结构如图3所示。

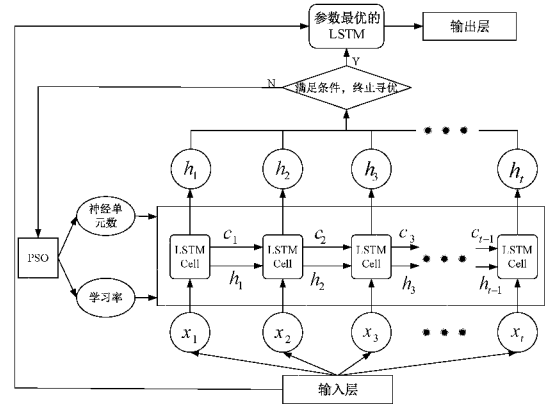


图 3 PSO-LSTM 整体结构

模型算法流程如下:

(1)将实验数据按5:1的比例划分为训练集和测试集,数据标准化。

(2)将LSTM的隐藏层单元数和学习率设置为寻优参数,初始化粒子群。

(3)以PSO-LSTM模型的预测误差为粒子的适应度值,适应度值随着迭代次数变化,单个粒子根据适应度值更新个体最优位置和全局最优位置,然后根据式(14)更新自身的速度和位置。

(4)当粒子的适应度值趋于稳定时停止迭代更新,确定隐藏层单元数和学习率的数值。

(5)将最优参数输入模型训练,预测。

## 2)模型评价指标

随着迭代进行,粒子群算法不断优化更新隐藏层单元数和学习率,以逐次优化的参数建立模型进行训练并预测,用在测试集上对关节变量值预测的平均绝对百分比误差(MAPE)来体现粒子适应度的变化,MAPE 的值越低,说明此次迭代寻得的参数越优,进而确定最优参数,MAPE 的计算公式如式(15)所示。

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (15)$$

式中:  $N$  是样本数量,  $y_i$  表示真实值,  $\hat{y}_i$  表示预测值。

寻优完成后以最优参数建立模型并进行训练,通过计算模型对测试集上关节变量的预测值与真实值的均方误差(MSE)来检验所提出的 PSO-LSTM 逆运动学求解模型的求解精度。作为反映估计量与真实值之间差异程度的一种度量, MSE 的值越低,说明模型的逆运动学求解精度越高,因此把它作为衡量模型预测精度的指标,计算公式如式(16)所示。

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (16)$$

式中:  $N$  是样本数量,  $y_i$  表示真实值,  $\hat{y}_i$  表示预测值。

## 3 仿真分析

为验证 PSO-LSTM 模型的逆运动学求解性能,首先与传统解法对比,然后通过关节变量值预测实验和 200 次迭代训练得到的均方误差变化图与 BP 神经网络模型和单 LSTM 神经网络模型进行对比分析。

### 3.1 模型参数设置


PSO-LSTM 模型的初始化参数设置如表 2 所示,待优化的隐藏层单元数取值范围为  $[2, 20]$ , 学习率取值范围为  $[0.0001, 0.01]$ 。

表 2 PSO-LSTM 初始参数


参数	初始值
种群数量	30
学习因子 $c_1$	1.5
学习因子 $c_2$	1.5
迭代次数	200
惯性权重	0.8
批处理大小	50
隐藏层单元数	10
学习率	0.001

将隐藏层单元数和学习率的最大迭代寻优次数设置为 200 次,图 4(a)~(c)体现了随着迭代次数的增加,隐藏层单元数和学习率的寻优过程,最后得到寻优结果如下:隐藏层神经单元数最优为 12,学习率最优为 0.0013。为保证对


比的有效性,用于对比的单 LSTM 模型的参数和表 2 中 LSTM 模型的初始参数一致,单 LSTM 模型隐藏层单元数设置为 10,学习率设置为 0.001。



(a) 粒子适应度曲线



(b) 隐藏层神经单元个数曲线



(c) 学习率曲线

图 4 参数寻优结果图

### 3.2 对比分析

在测试集随机抽取 3 组数据,和传统的迭代法进行逆运动学求解对比,求解结果如表 3 所示。由表 3 可知,本文模型求解精度已可媲美传统算法,并且求解速度大幅提高。

为进一步验证 PSO-LSTM 模型的逆运动学求解性能,随机抽取 20 组位姿数据依次编号,分别用 BP 神经网络、LSTM 神经网络和 PSO-LSTM 神经网络模型预测机械臂的第 1 个关节变量值,关节变量值采用弧度制表示,3 种模型预测值与真实值的对比如图 5 所示。

表 3 逆运动学解对比表

组号	求解方法	$\theta_1$ /rad	$\theta_2$ /rad	$\theta_3$ /rad	$\theta_4$ /rad	$\theta_5$ /rad	$\theta_6$ /rad	t/s
1	迭代法	1.625 0	0.498 5	0.128 4	-1.110 2	-0.627 0	0.614 1	0.125
	PSO-LSTM	1.624 9	0.507 6	0.122 8	-1.114 3	-0.615 6	0.615 4	0.004
2	迭代法	-0.604 7	1.674 1	0.000 0	-1.474 8	0.408 3	-0.733 9	0.168
	PSO-LSTM	-0.609 1	1.669 7	0.010 1	-1.470 7	0.409 7	-0.724 4	0.006
3	迭代法	0.854 6	0.598 1	1.129 1	0.948 4	-0.517 1	-2.170 0	0.104
	PSO-LSTM	0.856 2	0.599 5	1.125 0	0.938 6	-0.517 3	-2.183 5	0.003




图 5 求解效果对比图

由图 5 中可以看出, BP 模型在多数样本数据点对第 1 个关节变量的预测误差较大, 单 LSTM 模型在个别点的预测误差较大, 而 PSO-LSTM 模型的预测值都较为接近真实值。为了更直观地体现粒子群算法优化参数对机械臂逆运动学求解精度的影响, 绘制测试集上 3 种模型的均方误差对比曲线如图 6 所示。




图 6 均方误差对比图

由图 6 中可以看出, 3 种模型的均方误差值随着迭代次数增加都会最终收敛, PSO-LSTM 模型收敛速度最快且收敛时的均方误差值最低, 两种 LSTM 模型稳定时的均方误差值都低于 BP 神经网络模型。表明 LSTM 模型比 BP 神经网络模型有更高的求解精度, 而 PSO-LSTM 模型的均方误差值更低, 相较于单 LSTM 模型求解精度进一步提高, 这说明通过粒子群算法对关键参数寻优可以有效提高

求解精度。

### 4 结 论

本文提出了一种利用粒子群算法(PSO)优化长短期记忆神经网络(LSTM)的机械臂逆运动学求解模型。LSTM 相比于传统神经网络具有更强的非线性映射能力, 通过粒子群算法对 LSTM 的隐藏层神经元数和学习率进行优化, 经过仿真实验对比发现, 本文模型对机械臂的逆运动学求解效果相较于传统解法速度大幅提高, 可以满足工业机械臂的实时性要求; 相较于 BP、单 LSTM 神经网络求解精度更高, 泛化能力更强, 可以应用到高精度作业场景中。

### 参考文献

- [1] 臧庆凯, 李春贵, 钟宛余. 基于三个并行 BP 神经网络的机器人逆运动学求解[J]. 计算机测量与控制, 2012, 20(8): 2244-2247.
- [2] 李光, 肖帆, 杨加超, 等. 基于唯一域方法的机器人逆向运动学求解[J]. 农业机械学报, 2019, 50(10): 386-394.
- [3] 金玉阳, 高庆吉, 胡丹丹, 等. 基于换面法的飞机表面清洗臂逆运动学的几何解[J]. 机械设计, 2015, 32(3): 86-89.
- [4] KINOSHITA K, MURAKAMI K, ISSHIKI M. Solution of inverse kinematics by PSO based on split and m-erge of particles[M]. Artificial Intelligence and Soft Computing, Berlin: Springer, 2013: 108-117.
- [5] 顾嘉伟, 吴功平, 彭向阳, 等. 云模型遗传蚁群算法的机器人逆运动学求解[J]. 机械设计与制造, 2021(6): 164-168.
- [6] 杨惠珍, 刘西洋. 基于改进自适应小生境遗传算法的机械臂逆运动学求解[J]. 西北工业大学学报, 2019, 37(3): 488-495.
- [7] 李文博, 曹兵, 张云波. 基于 BP 神经网络的排爆机械臂逆运动学分析[J]. 计算机测量与控制, 2016, 24(1): 207-211.
- [8] 陈容, 闵华松. 基于 BP 和 RBF 神经网络的机器人逆运动学算法[J]. 机床与液压, 2019, 47(23): 22-27.
- [9] 杨金鹏. 基于 MEA-BP 神经网络的 6DOF 工业机器人

- 逆运动学研究[J]. 机床与液压, 2021, 49(11): 57-60, 74.
- [10] 周恒旭, 何志敏, 周燕. 基于长短期记忆网络的机械臂逆运动学解[J]. 机械与电子, 2020, 38(6): 74-80.
- [11] 王凤祥, 张志杰, 陈昊泽. 六自由度机械臂系统设计与控制方式研究[J]. 电子测量技术, 2021, 44(4): 1-8.
- [12] 李昕, 刘路. 基于视觉与 RFID 的机器人自定位抓取算法[J]. 计算机工程, 2012, 38(23): 158-161, 165.
- [13] 蒋敏兰, 吴沛伦, 陈昊然. 基于多层 LSTM 的海兰褐蛋鸡产蛋率回归模型[J]. 江苏农业科学, 2020, 48(22): 248-251.
- [14] 刘琼, 李能. 深度学习在大坝变形预测中的应用研究[J]. 测绘与空间地理信息, 2020, 43(3): 201-203, 207, 210.
- [15] 黄建江, 须文波, 董洪伟. 一种不规则零件排样的新粒子群优化策略[J]. 计算机工程与应用, 2007(19): 64-67, 70.

#### 作者简介

孙燕成, 硕士研究生, 主要研究方向为机器人控制。

E-mail: 1647114736@qq.com

陈富安(通信作者), 教授, 硕士生导师, 主要研究方向为智能测控技术及应用、电动汽车能量控制。

E-mail: chenfuan@163.com