

基于终态神经网络的冗余机械臂重复运动规划

孔 颖^{1,2} 孙明轩¹

(浙江工业大学信息工程学院 杭州 310023)¹ (浙江科技学院信息与电子工程学院 杭州 310023)²

摘 要 为解决冗余机械臂在运动过程中出现的关节角漂移现象,提出了一种终态吸引优化指标,形成冗余机械臂重复运动规划的二次优化方法。采用具有有限值激活函数的终态神经网络来求解,在初值位置偏移目标位置的情形下,实现冗余机械臂有限时间收敛的重复运动规划任务。同时,分别以新型的终态神经网络(TNN)和其加速网络(AT-NN)求解运动规划问题,该网络求解方法具有终态吸引特性,能够在有限的时间内得到有效解。相比具有渐近收敛动态特性的神经网络(ANN),终态神经网络方法不仅改变了收敛速度,而且提高了收敛的精度。基于冗余机械臂 PUMA560 的计算机仿真结果表明了所提方法的有效性和实时性。

关键词 终态神经网络,冗余机械臂,重复运动规划,有限时间收敛

中图法分类号 TP309.7 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.12.033

Repeatable Motion Planning of Redundant Manipulators Based on Terminal Neural Networks

KONG Ying^{1,2} SUN Ming-xuan¹

(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023, China)¹

(School of Information and Electronic Engineering, Zhejiang University of Science and Technology, Hangzhou 310023, China)²

Abstract To solve the joint-angle drift problems in cyclic motion of redundant robot manipulators, a kind of quadratic optimization models for redundant manipulators' trajectory planning based on terminal optimality criterion was proposed and analyzed. The terminal neural network models with limited value activation functions are applied to redundant manipulators to demonstrate the effectiveness of the proposed computing models in performing the repeatable motion planning tasks under the condition that the initial position deviates from the target position. New types of terminal neural network (TNN) and its accelerated form (ATNN) were proposed, which are of terminal attractor characteristics and can get effective solution for time-varying matrix in finite time. Compared with the asymptotic neural network (ANN), terminal neural network method not only accelerate the convergent rate, but also improve convergent precision. The simulation results on the model of PUMA560 show that the proposed method is effective and real-time.

Keywords Terminal neural networks, Redundant manipulators, Repeatable motion planning, Finite-time convergence

1 引言

冗余机械臂在许多工程领域中扮演着越来越重要的角色,其应用研究中的一个基础问题是冗余度解析问题,这与冗余机械臂的运动规划和控制紧密相关。鉴于其重要性,近年来众多学者对机械臂的冗余度解析给予了广泛关注,相应的冗余度解析方案也被开发并用于实现冗余机械臂的实时运动控制^[1-3]。通过采用特定的冗余度解析方案,使得冗余机械臂在完成给定的末端任务的同时,还可以躲避环境中的障碍物和自身的关节物理限制^[4-6]。

给定冗余机械臂末端执行器的轨迹,如何实时得到各个关节角和关节角速度值,是机械臂逆运动学中需要解决的关键问题。冗余机械臂末端执行器在笛卡尔操作空间做重复运动时,闭合的末端执行器的运动轨迹可能产生非闭合的关节

角轨迹,从而产生关节角偏差现象。这种非重复运动问题可能会引起机械臂在重复作业中出现不可预料的情况,基于伪逆的方法是求解该问题的一种常用方法^[7-9]。该方法将问题的解写成一个最小范数解加上一个同类解,其目标可以被指定到同类解上去控制机械手的自运动,以达到优化其他目标函数的目的^[10]。同一时期,Whitney 等^[11]提出了具有等式约束的最小速度范数性能指标作为运动规划的目标函数,其控制方法也是基于伪逆的冗余度解析方案。冗余机械臂运动过程中的非重复问题可能会引起机械臂在重复作业中出现不可预料的情况。一般来说,应用最为广泛的伪逆控制法不能获得重复性,无法完成原有的重复运动。通常采用自运动的方法弥补该缺点,而采用自运动进行调整时往往效率不高^[12]。

基于二次优化(Quadratic Optimization, QP)的冗余解析方案受到关注,Cheng 等^[13]最早提出关节无偏差性能指标。

为了高效地执行重复运动任务,Zhang 引入了重复运动指标作为优化准则,形成重复运动规划(Repetitive Motion Planning,RMP)方案,并使用二次优化(QP)和递归神经网络(RNN)来求解冗余度解析问题^[14]。以递归神经网络求解基于二次型优化描述的冗余度解析问题是非常有效的方法。通常的递归神经网络求解方法具有渐近收敛性能,在计算足够长的时间后能够获得有效解,且能应用于实时在线求解各类时变问题。

最近,具有有限时间收敛性能的递归神经网络被用于求解时变问题。相比于具有渐近收敛动态特性的递归神经网络,终态收敛动态特性具有有限时间收敛性,不仅能够改进收敛速度,而且能够达到较高的收敛精度。已有文献的有限时间神经网络未采用激活函数;即线性激活函数,或具有无限值激活函数,即输入量趋于无穷时,激活函数也趋于无穷^[15-17]。实际实现时,由于能量有限,需采用带有有限值激活函数的神经网络求解器,而无限值激活函数神经网络在实现时存在本质上的困难。

本文提出一种重复运动性能优化指标,即终态吸引优化指标,形成冗余机械臂轨迹规划的二次优化方法。以具有有限值激活函数的终态神经网络为求解器,在初始位置偏移的情形下,实现冗余机械臂有限时间收敛的重复运动规划任务。

2 重复运动冗余度解析方案

冗余机械臂所拥有的关节自由度向量 $\theta(t)$ ($\theta(t) \in R^n$) 和末端执行器位置向量 $r(t)$ ($r(t) \in R^m$) 之间存在如下关系:

$$r = f(\theta) \quad (1)$$

$f(\cdot)$ 是一个非线性函数,对于给定的冗余机械臂,给定末端执行器的运动路径,可以动态求解所对应各关节角的运动轨迹。由于 $m < n$,使得需要求解的机械臂的每个关节角存在多解的现象。因此,对式(1)两边求积分可得:

$$J(\theta) \dot{\theta} = \dot{r} \quad (2)$$

其中, $J(\theta) \in R^{m \times n}$ 是雅克比矩阵, $J(\theta) = \frac{\partial f(\theta)}{\partial \theta}$ 。

在实际运动过程中,冗余机械臂每个关节角的起始位置可能不在期望的路径上,在初始时刻各个关节角的实际起始位置和期望位置之间存在偏差。为了使得 $\|\theta(t) - \theta(0)\|_2$ 的值最小,各个关节角能够实现重复运动,当完成某一个任务后,仍然可以回到期望路径上,我们将冗余机械臂轨迹规划的优化指标设计为一种终态吸引的优化指标(Teminal Optimality Criterion, TOC),即:

$$\underset{\dot{\theta}(t)}{\text{minimize}} \frac{1}{2} (\dot{\theta}(t) + \beta_{\theta} c)^T (\dot{\theta}(t) + \beta_{\theta} c) \quad (3)$$

其中, $c = \sqrt{1 - \alpha^{|\theta(t) - \theta(0)|}} \text{sgn}(\theta(t) - \theta^*(0))$, θ 和 $\dot{\theta}$ 分别表示冗余机械臂的关节角度和角速度, $\theta^*(0)$ 是各个关节角的期望初始值, $0 < \alpha < 1$, $\beta_{\theta} > 0$ 是一设计参数,用于形成关节位移的动态性能, $\text{sgn}(\cdot)$ 为符号函数。

上述可重复运动优化方案的设计思想是期望获得下述动态方程:

$$\dot{\epsilon}(t) = -\beta_{\epsilon} \sqrt{1 - \alpha^{|\epsilon|}} \text{sgn}(\epsilon) \quad (4)$$

其中,关节角位移偏差 $\epsilon(t) = \theta(t) - \theta(0)$ 。此动态方程所表达的系统在有限时间内收敛于 0,需要的收敛时间 T 为:

$$T = \frac{\ln(1 - \sqrt{1 - \alpha^{|\epsilon(t)|}}) - \ln(1 + \sqrt{1 - \alpha^{|\epsilon(t)|}})}{\beta_{\epsilon} \ln \alpha}$$

当 TOC 值最小时,冗余机械臂的各个关节角可以回拢到期望的目标轨迹上。

冗余机械臂末端执行器的期望目标轨迹为 $r^*(t)$,其期望回拢的关节角度为 $\theta^*(0)$ 。给定冗余机械臂实际运动时的初始关节角度 $\theta(0)$ (以 $\theta(0)$ 为运动起始点),将冗余机械臂重复运动规划描述为二次规划问题,得到以下运动控制方案:

$$\underset{\dot{\theta}(t)}{\text{minimize}} \frac{1}{2} (\dot{\theta}(t) + \beta_{\theta} c)^T (\dot{\theta}(t) + \beta_{\theta} c) \quad (5)$$

$$\text{subject to } J(\theta) \dot{\theta} = \dot{r}^* + \beta_r (r^* - f(\theta))$$

其中, $\theta(t) - \theta^*(0)$ 表示各个关节角与初始期望关节角的位移偏差。 $\dot{r}^*$ 表示末端执行器期望的速度向量。由于机械臂的初始位置可能不在期望的轨迹上,通过减小末端执行器期望路径与实际运动轨迹位置间的误差 ($r^* - f(\theta)$),来改变末端执行器的运动方向。 $\beta_r > 0$ 表示位置的参数增益,用来调节末端执行器运动到期望路径的速率。 $J(\theta)$ 是冗余机械臂的雅可比矩阵。 $f(\theta)$ 是冗余机械臂的实际运动轨迹。

3 重复运动解析方案的二次规划求解

采用一种带有限值激活函数的终态神经网络模型(TNN)来求解基于新型优化方案的重复运动规划问题,该网络的动态方程如下:

$$\dot{E}(t) = -\beta_E \sqrt{1 - \alpha^{|\dot{E}(t)|}} \text{sgn}(E(t)) \quad (6)$$

其中, $\beta_E > 0$ 为一设计参数, E 为动态方程的收敛误差, $\phi(E(t)) = \sqrt{1 - \alpha^{|\dot{E}(t)|}} \text{sgn}(E(t))$, $\phi(\cdot): R^{n \times n} \rightarrow R^{n \times n}$ 为严格单调递增的激活函数,满足 $\phi(-\cdot) = -\phi(\cdot)$ 。在动态方程(6)中的激活函数 $\phi(\cdot)$ 能量有界,即满足:

$$\lim_{E \rightarrow \infty} \phi(E) < \infty$$

给定的激活函数 $\phi(x)$ 的曲线图如图 1 所示。




图 1 取不同 α 值时的终态神经网络激活函数 $\phi(\cdot)$

Fig. 1 Activation function $\phi(\cdot)$ for TNN with different α

从图 1 中可以看出, α 的取值范围为 0~1,在图中分别取 $\alpha = 0.2, 0.4, 0.6, 0.8, 0.9$,随着 α 增大,曲线在零点附近的收敛速度变慢。

3.1 稳定性说明

当 $x(t) \geq 0$ 时,由式(6)得:

$$\phi(E(t)) = \begin{cases} \sqrt{1 - \alpha^{E(t)}}, & E(t) \geq 0 \\ -\sqrt{1 - \alpha^{-E(t)}}, & E(t) < 0 \end{cases} \quad (7)$$

由式(7)可以得到 $\phi(E(t))$ 为奇函数,且满足:

$$\dot{\phi}(E(t)) = \begin{cases} \frac{1}{2} \frac{-\alpha^{E(t)}}{\sqrt{1-\alpha^{E(t)}}} \ln \alpha, & E(t) \geq 0 \\ \frac{1}{2} \frac{\alpha^{-E(t)}}{\sqrt{1-\alpha^{-E(t)}}} \ln \alpha, & E(t) < 0 \end{cases} \quad (8)$$

由前面的定义可知 $0 < \alpha < 1$ 。无论 $E(t)$ 取任何值, $\dot{\phi}(E(t)) > 0$, 且 $\phi(E(t))$ 均为单调递增函数。引入文献[16]中的研究结果,我们可以得到以下结论。

引理 1 当 $0 < \alpha < 1$ 时,任意给定初值 $E(0)$,终态神经网络(6)中 $E(t)$ 最终可以在有限时间 $T = \frac{\ln(1 - \sqrt{1 - \alpha^{|E(0)|}}) - \ln(1 + \sqrt{1 - \alpha^{|E(0)|}})}{\beta_e \ln \alpha}$ 内收敛到零。

为了提高收敛的速度,在终态神经网络的基础上给出其加速形式(ATNN):

$$\dot{E}(t) = -\beta_{E1} E(t) - \beta_{E2} \sqrt{1 - \alpha^{|E(t)|}} \operatorname{sgn}(E(t)) \quad (9)$$

其中, $\beta_{E1} > 0, \beta_{E2} > 0$ 。

相比终态神经网络(6),其加速形式在右边增加了 $\beta_{E1} E(t)$ 这一项,从式(9)中我们可以明显看到。当动态误差 $E(t)$ 远离平衡零点时,终态神经网络的收敛速度由式(9)右边的第一项即 $\beta_{E1} E(t)$ 控制。然而,当 $E(t)$ 慢慢收敛至平衡点零附近时,网络的收敛速度由 $\beta_{E2} \sqrt{1 - \alpha^{|E(t)|}} \operatorname{sgn}(E(t))$ 决定,因此加速终态神经网络加快了动态误差收敛速度,提高了收敛的精度。

3.2 二次规划问题的求解

对上述冗余机械臂重复运动规划方案(5)进行求解,建立拉格朗日函数:

$$L(\dot{\theta}(t), \lambda(t), t) = \frac{1}{2} (\dot{\theta}(t) + \beta_{\theta c})^T (\dot{\theta}(t) + \beta_{\theta c}) + \lambda(t)^T (J(\theta) \dot{\theta} - \dot{r} - \beta_r (r^* - f(\theta)))$$

其中, $\lambda(t) \in R^m$ 为拉格朗日乘子向量, λ^T 是 $\lambda(t)$ 向量的转置。通过拉格朗日函数对各个变量求导,并令其为 0,可得下述矩阵方程:

$$W(t) y(t) = v(t) \quad (10)$$

其中:

$$W = \begin{bmatrix} I & J^T(\theta) \\ J(\theta) & 0 \end{bmatrix}$$
$$v = [-\beta_{\theta c}, \dot{r}^* + \beta_r (r^* - f(\theta))]^T$$

其中, I 为具有相应维数的单位矩阵, $y = [\dot{\theta}, \lambda]^T$ 。

将上述有限时间收敛的可重复运动规划方案求解问题转化为时变矩阵等式(10)的计算问题,即求解时变矩阵 $y(t)$ 。时变矩阵方程(10)的理论解可以写成:

$$y^*(t) = W^{-1}(t) v(t)$$

定义以下向量误差函数:

$$E(t) = W(t) y(t) - v(t) \quad (11)$$

以终态神经网络式(6)求解式(11)可得:

$$\dot{y}(t) = -\dot{W}(t) y(t) - W(t) \dot{y}(t) + \dot{v}(t) + \beta_E \sqrt{1 - \alpha^{|W(t) y(t) - v(t)|}} \operatorname{sgn}(W(t) y(t) - v(t)) + \dot{y}(t)$$

构建的仿真模块如图 2 所示。




图 2 以终态神经网络(12)求解的方框图

Fig. 2 Diagram structure solved by TNN model (12)

由终态神经网络式(9)求解式(11)可得:

$$\dot{y}(t) = -\dot{W}(t) y(t) - W(t) \dot{y}(t) + \dot{v}(t) + \beta_{E1} (W(t) y(t) - v(t)) + \beta_{E2} \sqrt{1 - \alpha^{|W(t) y(t) - v(t)|}} \operatorname{sgn}(W(t) y(t) - v(t)) + \dot{y}(t) \quad (13)$$

构建的仿真模块如图 3 所示。




图 3 以终态神经网络(13)求解的方框图

Fig. 3 Diagram structure solved by TNN model (13)

4 冗余机械臂 PUMA560 的运动轨迹规划

本节中,PUMA560 空间冗余机械臂执行圆形轨迹任务,通过与渐近网络求解方法相比较,来验证具有有限时间收敛特性的重复运动冗余度解析方案的有效性和实时性。该冗余机械臂由 1 个基座、3 个连接杆构成,包含关节 1—关节 6。

PUMA560 连杆长度 $l = [0.4318, 0.4318, 0.25625]^T$ (单位:m),建立基于 D-H 参数的机械手 PUMA560 运动学模型,在整个实验的过程中只考虑机械臂末端执行器的运动位置。表 1 列出了 PUMA560 空间机械臂的 D-H 参数。

表 1 冗余机械臂 PUMA560 的 D-H 参数

Table 1 D-H parameters for redundant manipulator PUMA560

关节	$\hat{\alpha}/\text{rad}$	a_i/m	d_i/m
θ_1	$\pi/2$	0	0
θ_2	0	0.4318	0
θ_3	$-\pi/2$	0.0203	0.4318
θ_4	$\pi/2$	0	0.4318
θ_5	$-\pi/2$	0	0
θ_6	0	0	0.25625

下面分别利用 ANN,TNN 和 ATNN 网络结构实现 PUMA560 空间机械臂的运动轨迹规划。设定冗余机械臂 PUMA560 期望回绕的关节角度 $\theta^*(0) = [0, 0, 0, 0, 0, 0]^T$,确定圆轨迹的圆心坐标 $(x=0, y=\sqrt{3}/10, z=0.1)$,将圆的半径设定为 0.2m,其圆面与 X 轴的夹角为 $\pi/6 \text{ rad}$,末端执行器完成圆轨迹的时间 $T=10 \text{ s}$ 。考虑到冗余机械臂 PUMA560 的初始位置可能不在期望的运动轨迹上,将机械臂的 6 个关节角度的初值设为 $\theta(0) = [0, 0, 0, 0, 0 + 1, 0]^T$ 。为了方便对比,在

3 种网络中取相同的参数, $\beta_\theta = 1, \beta_E = 1, \alpha = 0.5, \beta_{E1} = 100, \beta_{E2} = 1$ 。

图 4—图 7 分别是冗余机械臂 PUMA560 在重复运动二次规划方案(5)、有限值终态神经网络 TNN 和加速网络 ATNN 作用下的仿真效果图。经过 10 s 后, 冗余机械臂 PUMA560 各关节角的终值误差达到 10^{-5} , 所有的关节轨迹基本闭合, 其轨迹如图 4 所示。




图 4 冗余机械臂 PUMA560 的各个关节角轨迹
Fig. 4 Joint trajectories for redundant manipulator PUMA560

机械臂的末端执行器在空间中的运动轨迹如图 5 所示。图 5 中给出目标圆轨迹(黑色实线)及机械臂末端执行器运动轨迹(分别用虚线、点划线表示)。从图 5 中可以看出, 末端执行器的初始位置不在期望的轨迹上, 随着时间的增加, 末端执行器逐渐向期望轨迹靠拢, 其中黑色运动轨迹线靠近期望轨迹的速度快于黑色虚线轨迹, 最终和期望轨迹基本吻合。




图 5 冗余机械臂 PUMA560 末端执行器的运动轨迹
Fig. 5 End-effector trajectories for redundant manipulator PUMA560

利用 TNN 求解二次规划问题, 得到末端执行器各终值位置的误差轨迹, 如图 6 所示。从图 6 中可以看到, 以终态神经网络求解时, 末端执行器的终值位置误差精度在 3 个方向即 X, Y, Z 轴上达到 10^{-4} 。




图 6 冗余机械臂 PUMA560 末端执行器的各位置误差轨迹
Fig. 6 Position error trajectories for redundant manipulator PUMA560

为了验证终态吸引优化指标 TOC 在重复运动规划中的有效性, 机械臂 PUMA560 末端执行器完成圆轨迹过程中可得到关节角瞬态轨迹和角速度瞬态轨迹。当 $T = 10$ s 时, 机械臂运动前后各关节角与其期望关节角位置之间的最大偏差

为 5.299×10^{-5} , 用递归神经网络求解得到的各个关节角的终值误差最大偏差为 7.7989×10^{-4} , 如表 2 所列。

表 2 冗余机械臂 PUMA560 末端执行器各关节角的终值误差
Table 2 Joint-angle displacements of redundant manipulator PUMA560 solved by TNN, ANN and ATNN

网络求解器	ANN	TNN	ATNN
$\theta_1(10) - \theta_1(0)$	-0.000651	0.00005299	0.000004085
$\theta_2(10) - \theta_2(0)$	0.0009115	0.00001669	0.0000467
$\theta_3(10) - \theta_3(0)$	0.0002271	-0.00001798	-0.00000739
$\theta_4(10) - \theta_4(0)$	-0.0007989	-0.0003679	-0.0000681
$\theta_5(10) - \theta_5(0)$	-0.0001696	-0.00009885	-0.00001264
$\theta_6(10) - \theta_6(0)$	1.617e-09	-2.022e-09	-2.162e-09

为比较渐近收敛网络与终态神经网络的收敛性能, 定义计算误差 $J_E(t) = \|W(t)y(t) - v(t)\|_2$ 。图 7 给出了分别用有限值终态神经网络和递归神经网络求解二次规划问题的误差收敛轨迹。从中可以看出, 利用 ATNN 求解, 当时间 t 接近 0.1 s 时, 误差收敛精度达到 5×10^{-4} ; 利用 TNN 求解, 当 t 接近 0.5 s 时, 误差收敛精度达到 4×10^{-4} ; 而利用 ANN 求解, 当时间接近 1 s 时, 误差仍然没有收敛, 精度只达到 0.002, 误差收敛的精度有待提高。




图 7 以有限值终态神经网络和递归神经网络求解时的误差轨迹
Fig. 7 Convergent error trajectories solved by TNN and ANN

结束语 本文提出了有限时间收敛的冗余机械臂重复运动规划方案, 通过有限值终态神经网络求解方法对其二次规划问题进行求解, 并应用于冗余机械臂 PUMA560 的轨迹规划任务中。为了充分地说明新方法的有效性和实时性, 以 TNN, ATNN 和 ANN 3 种不同网络模型计算方法进行求解, 实验结果证明了新型重复运动控制方案(5)和有限值终态神经网络方法在求解冗余机械臂轨迹规划问题中的有效性。

参 考 文 献

[1] PAN H, XIN M. Nonlinear robust and optimal control of robot manipulators[J]. Nonlinear Dynamics, 2014, 76(1): 237-254.
[2] TAHRIRI F, MOUSAVI M. Optimizing the robot arm movement time using virtual reality robotic teaching system[J]. International Journal of Simulation Modelling, 2015, 14(1): 28-38.
[3] GARCIA F, BORDONS C. Optimal economical schedule of hydrogen-based microgrids with hybrid storage using model predictive control[J]. IEEE Transactions on Industrial Electronics, 2015, 62(8): 5195-5207.
[4] LEE K K, BUSS M. Obstacle avoidance for redundant robots using Jacobian transpose method[C]// Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems, 2007: 3509-3514.

[5] ZHANG Y N,XIAO Z L,GUO D S. Singularity-conquering tracking control of a class of chaotic systems using Zhang-gradient dynamics[J]. IEEE Transactions on Control Theory & Applications,2015,9(6):871-881.

[6] ROSSI R,SANTAMARIA-NAVARRO A. Trajectory generation for unmanned aerial manipulators through quadratic programming[J]. IEEE Robotics & Automation Letters,2016,2(2):389-396.

[7] ZHANG H. A finite iterative algorithm for solving the complex generalized coupled Sylvester matrix equations by using the linear operators[J]. Journal of the Franklin Institute, 2017, 354(4): 1856-1874.

[8] JIN L,LI S. Distributed task allocation of multiple robots:a control perspective[J]. IEEE Transactions on Systems, Man, and Cybernetics,2016,PP(99):1-10.

[9] MIN K,FREEMAN C,KANG H. The regulation by phenolic compounds of soil organic matter dynamics under a changing environment[J]. Journal of Biomedicine and Biotechnology,2015,2015(6849):433-458.

[10] DUGULEANA M,BARBUCEANU F G. Obstacle avoidance of redundant manipulators using neural networks based reinforcement learning [J]. Robotics and Computer-Integrated Manufacturing,2012,28(2):132-146.

[11] WHITNEY D E. Resolved motion rate control of manipulators and human prostheses[J]. IEEE Transactions on Man Machine Systems,1969,10(2):47-53.

[12] TCHON K,JANIAK M. Repeatable approximation of the Jacobian pseudo-inverse [J]. Systems and Control Letters,2009,58(12):849-856.

[13] CHENG F,CHEN T,SUN Y. Resolving manipulator redundancy under inequality constraints[J]. IEEE Transactions on Robotics Automation,1994,10(1):65-71.

[14] ZHANG Y,LI W. Physical-limits-constrained minimum velocity norm coordinating scheme for wheeled mobile redundant manipulators[J]. Robotica,2015,33(2):1325-1350.

[15] LI S. Accelerating a recurrent neural network to finite-time convergence for solving time-varying sylvester equation by using a sign-bi-power activation function[J]. Neural Processing Letters,2013,37(2):189-205.

[16] LIN X,LIAO B. A convergence-accelerated Zhang neural network and its solution application to Lyapunov equation[J]. Neurocomputing,2016,193(2):213-218.

[17] ZHANG Y, YOU Q X, LUO Y, et al. Robot arm remote control based on trajectory planning in joint space [J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition),2012,24(1):104-108. (in Chinese)
张毅,游群霞,罗元,等. 基于关节空间轨迹规划的机械臂远程控制[J]. 重庆邮电大学学报(自然科学版),2012,24(1):104-108.

(上接第 181 页)

[12] REHN M,SOMMER F T. A network that uses few active neurons to code visual input predicts the diverse shapes of cortical receptive fields[J]. Journal of Computational Neuroscience,2007,22(2):135-146.

[13] LENNIE P. Supplemental Data The Cost of Cortical Computation[J]. Current Biology,2003,13(6):493-497.

[14] HUANG Y,DUAN X S,SUN S Y, et al. Research on training algorithm of deep neural networks based on improved sigmoid activation function [J]. Computer Measurement and Control,2017,25(2):126-129. (in Chinese)
黄毅,段修生,孙世宇,等. 基于改进 sigmoid 激活函数的深度神经网络训练算法研究[J]. 计算机测量与控制,2017,25(2):126-129.

[15] GLOROT X,BORDES A,BENGIO Y. Deep sparse rectifier neural networks[C]//International Conference on Artificial Intelligence and Statistics,2012:315-323.

[16] JARRETT K,KAVUKCUOGLU K,RANZATO M, et al. What is the Best Multi-Stage Architecture for Object Recognition?[C]//IEEE International Conference on Computer Vision,2009:2146-2153.

[17] OLSHAUSEN B A,FIELD D J. Sparse coding with an overcomplete basis set:a strategy employed by V1[J]. Vision Research,1997,37(23):3311.

[18] KRIZHEVSKY A,SUTSKEVER I,HINTON G E. ImageNet classification with deep convolutional neural networks[C]//International Conference on Neural Information Processing Systems, Curran Associates Inc.,2012:1097-1105.

[19] MAAS A L,QI P,HANNUN A Y, et al. Building DNN acoustic models for large vocabulary speech recognition[J]. Computer Speech & Language,2017,41(C):195-213.

[20] SZEGEDY C,LIU W,JIA Y, et al. Going deeper with convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition, IEEE,2015:1-9.

[21] HE K,ZHANG X,REN S, et al. Delving Deep into Rectifiers: Surpassing Human—Level Performance on ImageNet Classification[C]//2015 IEEE International Conference on Computer Vision (ICCV). IEEE,2015.

[22] XU B,WANG N,CHEN T, et al. Empirical Evaluation of Rectified Activations in Convolutional Network[J/OL]. <https://arxiv.org/abs/1505.00853>.

[23] POGGIO T,GIROSI F. Networks for approximation and learning[J]. Proceedings of the IEEE,1990,78(9):1481-1497.

[24] SU H,LI G,YU D, et al. Error back propagation for sequence training of Context-Dependent Deep Networks for conversational speech transcription[C]//IEEE International Conference on Acoustics, Speech and Signal Processing, IEEE,2013:6664-6668.

[25] VEDALDI A,LENC K. MatConvNet:Convolutional Neural Networks for MATLAB[C]//ACM International Conference on Multimedia, ACM,2015:689-692.