

DOI:10.3969/j.issn.1001-4551.2013.10.011

# 基于信息优化的加工过程神经网络控制

张 毅

(广东交通职业技术学院 机电工程系, 广东 广州 510800)

**摘要:** 为了提高加工过程生产率和保证加工精度,以加工过程的恒切削力控制作为研究对象,将信息论原理和神经网络智能控制理论应用于加工过程控制,以信息熵作为加工过程智能控制系统的性能测度能统一各级性能指标,将神经网络作为加工过程控制输入和系统输出的信息传输通道,确定了神经网络基于信息优化的目标函数,推导出了信息优化的三层BP神经网络学习算法,提出了恒力切削过程中基于信息优化的神经网络控制系统框架。通过加工过程的仿真实例证明,与传统自适应神经网络控制方法相比,基于信息优化的神经网络控制方法收敛精确,速度快,振荡小,系统超调量小,具有较好的综合性能。研究结果为信息理论应用于加工过程控制提供了有效途径。

**关键词:** 加工过程; 信息熵; 神经网络; 智能控制

**中图分类号:** TH166

**文献标识码:** A

**文章编号:** 1001-4551(2013)10-1214-04

## Information-optimization based neural network of force control in cutting process

ZHANG Yi

(Department of Mechanical & Electrical Engineering, Guangdong Communication Polytechnic,  
Guangzhou 510800, China)

**Abstract:** In order to improve productivity and ensure precision of machining process, information principle and neural network were applied in control of machining process with the constant force control as study object. The neural network was used as information-transmission channel for inputs and outputs of machining process control with information entropy as unified performance indexes at various levels of the intelligent control system. The objective function of neural network based on information-optimization was confirmed and learning algorithm of the three-layer BP neural network was derived. The information-optimization based neural network control system of constant force in machining process was proposed. Simulation instance of machining process proves that, compared with self-adaptive neural network control, the proposed control is of faster and more accurate convergence, less vibration and less overshoot, and behaves with better comprehensive properties. The research result provides effective way for information theory to be applied in control process of machining.

**Key words:** machining process; information entropy; neural network; intelligent control

## 0 引 言

以信息为基础的宏观方法对系统科学和智能控制基础理论的形成具有重大影响。Zaborszky<sup>[1]</sup>提出了用信息测度作为系统辨识的统一性能指标。Wei-

demann (1969)<sup>[2]</sup>用信息熵讨论了反馈控制系统。Saridis 在文献[3]中指出:“智能随控制的精度增加而降低”,这一著名的智能控制原则与信息处理过程是一致的,因此利用信息理论来研究智能控制问题是自然的。

收稿日期: 2013-04-15

作者简介: 张 毅(1977-),男,湖北黄冈人,讲师,博士研究生,主要从事制造系统的计算机控制方面的研究. E-mail: mec\_yzhang@163.com

切削过程恒力控制对于提高生产率、保证加工精度至关重要。目前常见的研究方法有模型参考自适应控制<sup>[4]</sup>、神经网络控制<sup>[5-6]</sup>、模糊控制<sup>[7-8]</sup>等。金属切削加工过程具有典型的非线性和时变性;神经网络有充分逼近复杂的非线性映射关系和学习系统的动态特性,是金属切削加工过程建模的理想工具。

本研究将信息优化理论与神经网络相结合,对车削加工过程进行研究,提出恒力车削过程中基于信息优化的神经网络控制。与之前将信息理论与加工过程控制理论结合的相关研究<sup>[9-11]</sup>不同,本研究不是简单将信息熵函数作为神经网络的优化目标,而是将神经网络作为加工过程控制输入和输出的信息优化通道,控制目标在神经网络的隐层和输出层都进行优化,仿真结果显示该系统控制方法具有一定的优越性。

## 1 信息优化原理

智能控制与信息处理过程具有相似性,信息能够减少和消除人们认识上的不确定性。美国科学家申农(Claude Elwood Shannon)将熵作为一个度量信息状态不确定性的尺度,产生了信息熵的概念。一个智能控制系统在多大程度上成功克服不确定性和复杂性表明了该智能系统智能水平的高低,所以引入信息熵概念作为智能控制系统的统一测度是合理的。

### 1.1 信息熵

(1) 离散信息的熵。

设有离散信息的信息熵记为 $H(X)$ :

$$H(X) = -\sum_i p(x_i) \log p(x_i) \quad (1)$$

(2) 连续信息的信息熵为:

$$H(X) = -\int \omega(x) \log \omega(x) dx \quad (2)$$

式中:  $p(x_i)$ ,  $\omega(x)$ —对应变量的概率分布函数。

信息熵是在平均意义上来表征信息的总体特征的,它表达了信息的不确定程度;而信息量就是解除不确定度所需的信息的度量,也就是获得这样大的信息量后,信息的不确定度就被解除。

### 1.2 基于信息优化的神经网络

一个具有单隐层BP网络的拓扑结构如图1所示,为简化讨论,本研究以具有一个隐层的BP网络为对象,对于多隐层的BP网络同理类推。图1所示的网络中有 $M$ 个输入元, $K$ 个隐元和 $N$ 个输出元; $x_k(k=1, \dots, M)$ ,  $u_j(j=1, \dots, K)$ ,  $y_i(i=1, \dots, N)$ 分别为输入、隐层输出和网

络输出。




图1 BP网络的拓扑结构

为了保证网络从训练样本中获得的信息量最多,在网络的学习过程中,就应该保证隐层的信息量尽可能大,同时还要使网络的输出值和理想输出值相匹配。为了同时保证这两个目标,可定义神经网络的目标函数为<sup>[12]</sup>:

$$E = \sum_{r=1}^R C^r - \alpha \sum_{r=1}^R I^r = \sum_{r=1}^R \sum_{i=1}^N \left\{ \sigma_i^r \ln \frac{\sigma_i^r}{y_i^r} + (1 - \sigma_i^r) \ln \frac{1 - \sigma_i^r}{1 - y_i^r} \right\} - \alpha \sum_{r=1}^R \sum_{j=1}^K p_j^r \ln p_j^r - \alpha R \ln K \quad (3)$$

式中:  $\alpha$ —常系数,  $\alpha > 0$ 。

其中,神经网络的输出值 $y_i^r$ 和理想输出值 $\sigma_i^r$ 的互熵为:

$$C^r = \sum_{i=1}^N \left\{ \sigma_i^r \ln \frac{\sigma_i^r}{y_i^r} + (1 - \sigma_i^r) \ln \frac{1 - \sigma_i^r}{1 - y_i^r} \right\} \quad (4)$$

神经网络隐层所含的信息量为:

$$I^r = \ln K + \sum_{j=1}^K p_j^r \ln p_j^r \quad (5)$$

式中:  $p_j^r$ —第 $j$ 个隐元输出 $u_j$ 的概率。

在学习过程中,只需保证 $E \rightarrow \min$ ,即可获得隐层信息量较大而输出层互熵较小以满足给定的误差范围的BP网络。

### 1.3 神经网络学习算法

式(3)所定义的目标函数对于网络权系数的导数为:

(1) 对于隐层—输出层。

设输出层第 $n$ 个神经元输入为:

$$v_i^r(n) = \sum_{j=1}^K w_{ij}(n) u_j(n) \quad (6)$$

输出为:

$$y_i^r = \varphi(v_i^r(n)) \quad (7)$$

式中:  $\varphi()$ —Sigmoid函数。

以式(3)所定义的 $E$ 为目标函数,则隐层-输出层权系数为:

$$\begin{aligned} \frac{\partial E}{\partial w_{ij}} &= \sum_{r=1}^R \left\{ \sigma_i' \frac{y_i^r}{\sigma_i'} \sigma_i^r \left( -\frac{1}{y_i^r} \right)^2 + (1 - \sigma_i') \frac{1 - y_i^r}{1 - \sigma_i'} \left( -1 \right)^2 \frac{1 - \sigma_i^r}{(1 - y_i^r)^2} \right\} \cdot \\ \varphi'(v_i^r(n)) \frac{\partial v_i^r(n)}{\partial w_{ij}} &= \sum_{r=1}^R \left\{ -\frac{\sigma_i^r}{y_i^r} + \frac{1 - \sigma_i^r}{1 - y_i^r} \right\} \frac{\partial y_i^r}{\partial v_i^r} \frac{\partial v_i^r(n)}{\partial w_{ij}} = \\ \sum_{r=1}^R \frac{-\sigma_i^r + \sigma_i^r y_i^r + y_i^r - \sigma_i^r y_i^r}{y_i^r(1 - y_i^r)} y_i^r (1 - y_i^r) u_j^r &= \\ \sum_{i=1}^R (y_i^r - \sigma_i^r) u_j^r & \end{aligned} \quad (8)$$

传统BP神经网络算法以训练集中样本总数的平方误差均值作为目标函数:

$$E_{AV} = \frac{1}{N} \sum_{i=1}^N E(n) \quad (9)$$

得到隐层-输出层的权系数为:

$$\frac{\partial E_{AV}}{\partial w_{ij}} = \sum_{r=1}^R y_i^r (1 - y_i^r) (y_i^r - \sigma_i^r) u_j^r \quad (10)$$

式(10)与式(8)相比较,该式中多了一项 $y_i^r(1 - y_i^r)$ ,而 $y_i^r(1 - y_i^r) < 1$ ,同时当 $y_i^r \rightarrow 0$ 或 $y_i^r \rightarrow 1$ 时会使权系数值趋于0,从而降低学习的收敛速度。因此,使用式(3)作为神经网络目标函数,会加快网络的收敛速度。

(2) 对于输入层-隐层。

与隐层-输出层权系数推导方法相同,可得到输入层-隐层的权系数为:

$$\begin{aligned} \frac{\partial E}{\partial w_{jk}} &= \frac{\partial E}{\partial y_i^r} \frac{\partial y_i^r}{\partial u_j^r} \frac{\partial u_j^r}{\partial w_{jk}} \frac{\partial v_j^r}{\partial w_{jk}} = \\ \sum_{r=1}^R \sum_{i=1}^N \left\{ \sigma_i' \frac{y_i^r}{\sigma_i'} \left( -\frac{\sigma_i^r}{(y_i^r)^2} \right) + (1 - \sigma_i') \frac{1 - y_i^r}{1 - \sigma_i'} \left( -1 \right)^2 \frac{1 - \sigma_i^r}{(1 - y_i^r)^2} \right\} \varphi_i'(v_i^r) w_{ij} \varphi_j'(v_j^r) x_k^r - \\ \alpha \sum_{i=1}^R \left[ \left( p_j' \frac{1}{p_j'} + \ln p_j' \right) \frac{\sum_{s=1}^K u_s^r - u_j^r}{\left( \sum_{s=1}^K u_s^r \right)^2} + \sum_{s \neq j} \left( p_s' \frac{1}{p_s'} + \ln p_s' \right) \frac{-u_s^r}{\left( \sum_{s=1}^K u_s^r \right)^2} \right] \varphi_j'(v_j^r) x_k^r = \\ - \sum_{r=1}^R u_j^r (1 - u_j^r) x_k^r \sum_{i=1}^N w_{ij} (\sigma_i^r - y_i^r) - \alpha \sum_{i=1}^R (\ln p_j' - \sum_{s=1}^K p_s' \ln p_s') p_j' (1 - u_j^r) x_k^r \end{aligned} \quad (11)$$

式中: $v_j^r(n)$ —神经网络隐层第 $n$ 个神经元的输入, $v_j^r(n) = \sum_{k=1}^M w_{jk}(n) x_k^r(n)$ ;  $u_j^r$ —神经网络隐层第 $n$ 个神经元的输出, $u_j^r = \varphi_j(v_j^r(n))$ ;  $\varphi_i(\cdot)$ 和 $\varphi_j(\cdot)$ —Sigmoid函数。

根据 $\partial E / \partial w_{jk}$ 和 $\partial E / \partial w_{ij}$ 的值,如果按常用的最速下降法来调整权系数,收敛速度很慢。本研究采用附加动量法和自适应学习速率法来调整权系数,以提高收敛速度。在学习过程中,常数 $\alpha$ 值的选取应保证

使 $\alpha l$ 和 $C^r$ 的大小相匹配,一般取 $0.1 < \alpha < 0.2$ 。

## 2 加工过程控制

加工过程模型可以表示为如下传递函数<sup>[13]</sup>:

$$\frac{F(s)}{u(s)} = \frac{K \omega_n^2}{s^2 + 2\xi \omega_n s + \omega_n^2} \quad (7)$$

式中: $\omega_n$ —伺服系统的自然频率,rad/s; $\xi$ —阻尼系数; $K$ —加工过程总增益,加工过程模型的增益 $K$ 随切削深度、主轴转速和进给量的变化而变化。

金属切削加工过程具有非线性和时变性。下面以车削加工过程为例,当刀具切削深度在1 mm~5 mm之间发生变化时,用上述信息优化的神经网络来完成加工过程的恒切削力控制。

研究对象如图2所示。




图2 工件切深变化

基于信息优化的加工过程的神经网络控制系统如图3所示,基于信息优化的神经网络模型完成对被控对象的系统辨识,建立被控对象模型;神经网络控制器NNC实现切削加工参数的自适应调节。NNC为3层BP网络,输入层和中间隐层的神经元数都为5,输出层神经元数为1。




图3 基于信息优化的加工过程神经网络控制系统图

$F_r$ —设定的神经网络需要跟踪的恒定切削力大小; $F$ —系统实际输出的切削力大小; $u$ —电机驱动电压; $e = \text{abs}(E)$ —式(3)目标函数的绝对值

## 3 加工过程的控制仿真

### 3.1 仿真参数

根据前述加工过程模型,本研究对车削加工过程


进行仿真。主要参数如表1所示。

表1 加工过程的主要参数


| 参数名                                                        | 参数值   |
|------------------------------------------------------------|-------|
| 主轴转速 $n/(\text{r}\cdot\text{min}^{-1})$                    | 600   |
| 系统阻尼系数 $\xi$                                               | 0.8   |
| 伺服系统的自然频率 $\omega_n/(\text{rad}\cdot\text{s}^{-1})$        | 20    |
| 伺服增益 $K_m/(\text{mm}\cdot\text{V}^{-1}\cdot\text{s}^{-1})$ | 1     |
| 切削比力 $K/(\text{N}\cdot\text{mm}^{-2})$                     | 1 670 |
| 测力仪转换系数 $k_d$                                              | 1.5   |
| 切削力指数 $m$                                                  | 0.7   |
| 刀具齿数 $p$                                                   | 1     |
| 背吃刀量 $a_p/\text{mm}$                                       | 1~5   |
| 参考切削力 $F_r/\text{N}$                                       | 1 000 |

### 3.2 仿真结果及分析

基于信息优化的加工过程的神经网络控制响应结果如图4所示,图4中分别显示了加工过程的切削力变化及切削进给的变化曲线。粗点曲线对应的是作为对照曲线的自适应神经网络控制;细实线曲线对应的是基于信息优化的神经网络控制。



(a) 加工过程的切削力变化曲线



(b) 加工过程的切削进给变化曲线

图4 基于信息优化的神经网络控制

从图4中可以看到,基于信息优化的神经网络控制在背吃刀量发生突变时,加工系统输出的切削力的超调量远小于传统神经网络自适应控制,而且基于信息优化的神经网络控制的系统输出对给定的恒切削力目标的跟踪更加准确,收敛更快,振荡更小。这样有利于在加工过程中刀具和工件,改善机床运行环境,延长机床使用寿命。

## 4 结束语

本研究分析了加工过程智能控制的新方法,将信息熵理论与神经网络理论相结合,利用神经网络作为加工过程控制输入和输出的信息优化通道,使用信息熵作为加工过程智能控制的性能测度,提出了恒力切削加工过程中基于信息优化的神经网络控制,实现了车削加工过程的神经网络预测控制的计算机仿真,并对仿真结果进行了比较分析。控制结果表明,该方法是有用的,并且具有一定的优越性,对采用信息理论的宏观综合方法来研究复杂系统控制问题的途径做出了有益的尝试。

### 参考文献(References):

- [1] ZABORSZKY J. An information theory viewpoint for the general identification problem[J]. *IEEE Transactions on AC*, 1966, 11(1): 130-131.
- [2] MATSUSHIMA K, STATA T. Development of intelligent machine tool[J]. *J.Faculty Eng., Univ. Tokyo*, 1980, 35(3): 293-314.
- [3] SARIDIS G N. Entropy formation of optimal and adaptive control[J]. *IEEE Trans. on Auto Contr*, 1988, 33(8): 713-721.
- [4] DAMESHMEND L K, Pak H A. Model reference adaptive control of cutting in milling[C]// *Dynamic Systems: Modeling and Control* Edited by Donath M ASME, New York: [s. n.], 1985: 43-50.
- [5] 王立岩, 聂建华. 加工过程的神经网络自适应控制[J]. *安徽工业大学学报*, 2006(4): 178-181.
- [6] 梁 爽, 姚锡凡. 加工过程的神经网络模型参考自适应控制[J]. *微计算机信息*, 2009(25): 10-11, 35.
- [7] 姚锡凡, 李伟光. 加工过程的模糊控制[J]. *组合机床与自动化加工技术*, 2004(12): 71-73.
- [8] 苏 丹, 梁昔明. 有约束的恒力铣削过程自适应模糊控制研究[J]. *机电产品开发与创新*, 2007(5): 176-177, 185.
- [9] 张 毅, 卢小春, 姚锡凡. 加工过程中基于最大熵的自适应控制[J]. *现代制造工程*, 2004(5): 47-49.
- [10] 姚锡凡, 张 毅, 董绍强, 等. 不确定信息的度量及其在制造中的应用示例[J]. *计算机集成制造系统*, 2004, 10(11): 1466-1470.
- [11] 常少莉, 姚锡凡. 变切深加工过程中的信息熵控制[J]. *组合机床与自动化加工技术*, 2005(10): 59-61.
- [12] 孟 建, 屈梁生. 基于信息优化的前馈神经网络及其应用[J]. *中国机械工程*, 1997, 8(2): 54-57.
- [13] 姚锡凡. 智能加工系统的模糊与神经自适应控制[D]. 广州: 华南理工大学机械与汽车工程学院, 1999: 13-16.

[编辑: 张 翔]