

电液伺服系统的神经网络建模方法研究^①

童仲志^② 邢宗义 张 媛 高 强 贾利民*

(南京理工大学机械工程学院 南京 210014)

(* 北京交通大学交通运输学院 北京 100044)

摘 要 针对电液伺服系统固有的流量-压力特性等非线性因素使得采用传递函数等传统方法难以获得电液伺服系统的精确模型的问题,详细研究了电液伺服系统的神经网络建模方法。研究了两种最常见的神经网络,即多层感知器神经网络和径向基函数神经网络,采用 5 种典型学习算法构造了 3 种多层感知器神经网络和 2 种径向基函数神经网络,并结合自动定深电液伺服系统的工程实例,详细分析了这 5 种神经网络在电液伺服系统中的建模性能。研究结果表明,采用正交最小二乘算法的径向基函数神经网络最适合电液伺服系统的建模。

关键词 电液伺服系统,多层感知器神经网络(MLPNN),径向基函数神经网络(RBFNN),建模

0 引 言

电液伺服系统具有响应速度快、调速范围广、比功率大、耐用性高等优点,在车辆船舶、工程机械、武器系统等方面得到了广泛的应用。为了进行电液伺服系统的分析、仿真与控制,需要构造电液伺服系统的模型,但其固有的流量-压力特性、液体压缩、电磁转换、饱和摩擦等非线性因素,使得难以获得电液伺服系统的精确模型。

电液伺服系统最常用的建模方法是机理建模法,即通过对系统特性的完全理解,根据牛顿定律等物理法则,构造系统的数学模型^[1-4]。但机理建模法得到的模型,其精度较低,无法拟合电液伺服系统固有的非线性特性,因此其应用局限性较大。

近年来基于神经网络的电液伺服系统的建模得到了广泛关注^[5-8],因为神经网络具备复杂非线性系统的自学习能力,且不需要模型结构的先验知识。文献[5]采用 1 种线性模型和 4 种非线性模型对某电液伺服系统进行了建模和分析,结果表明,与其它模型相比,神经网络具有更好的建模精度和泛化能力。文献[6]将电液伺服系统分为已知的线性子系统和未知的非线性子系统,利用模糊神经网络在线估计未知子系统,从而提高了系统的建模精度。文

献[7]提出了利用神经网络构造电液伺服系统的模型,得出了神经网络模型的精确性高于线性模型的结论。文献[8]采用遗传算法离线训练多层感知器神经网络的结构和参数,采用改进的反向传播(back propagation, BP)算法在线调整网络权值,将神经网络作为辨识器来描述系统的动态特性。但到目前为止,众多研究者仅采用某一类神经网络及其对应的某一种学习算法,来实现电液伺服系统的建模,尚未系统地进行电液伺服系统的神经网络建模研究,因此本文采用两种最常见的神经网络——多层感知器神经网络(multi-layer perceptron neural networks, MLPNN)和径向基函数神经网络(radial basis function neural networks, RBFNN),及其对应的 5 种典型学习算法,来构造电液伺服系统的神经网络模型,并通过某电液伺服系统工程实例的建模,详细分析了不同类型的神经网络及其学习算法的性能,从而为实现电液伺服系统的控制和预测等目的奠定了基础。

1 神经网络的基础知识

1.1 多层感知器神经网络

多层感知器神经网络由输入层、隐层和输出层组成,其中隐层可由若干并列子层构成,但考虑简单性,且保留神经网络的万能逼近特性,本文采用单隐

① 国家自然科学基金(60674001),国家重点实验室开放课题基金(SK12008K010)和南京理工大学科技发展基金(XKF09003)资助项目。
② 男,1963年生,副教授;研究方向:伺服系统,智能控制;联系人, E-mail: xingzongyi@gmail.com
(收稿日期:2008-07-22)

层的多层感知器(MLP)神经网络。在 MLP 神经网络中,输入层仅负责将输入信号变换后传递到隐层,隐层从输入层接收信号,并进行最主要的数学处理后送至输出层,输出层负责将隐层的输出信号加权聚合为神经网络的输出信号。

图 1 为 MLPNN 隐层第 m 个神经元进行数据处理的示意图。可见,所有输入通过权值相乘后,完成输入变换,然后加权求和后作为非线性函数(激励函数)的输入。本文中,神经元的阈值被作为一固定输入的权值来进行处理,激活函数采用 S 型对数函数,则隐层第 m 个神经元输出为

$$O_m = f\left(\sum_{l=0}^L w_{ml}x_l\right)$$

其中 $x_l (l = 1, \dots, L)$ 为第 l 个输入变量, w_{ml} 为输入层第 l 个输入与隐层第 m 个神经元之间的权值, $f(z) = 1/(1 + e^{-z})$ 为激励函数。输出层第 n 个神经元的输出为

$$O_n = \sum_{m=0}^M w_{nm}O_m$$

其中 w_{nm} 为隐层第 m 个输出与输出层第 n 个神经元之间的连接权值。




图 1 多层感知器神经网络隐层神经元

多层感知器神经网络的学习一般采用反向传播算法,它实质上是一种最速下降法,在本文中称其为最速反向传播(steepest descent back-propagation, SDBP)算法^[9]。由于 SDBP 算法存在收敛速度过慢等缺点,众多学者提出了很多改进的反向传播算法,其中附加动量项反向传播算法和自适应学习速率反向传播算法是两种典型的改进学习算法^[10]。本文将上述两种方法融合为附加动量项自适应学习速率反向传播(momentum variable learning back-propagation, MVBP)算法,并作为改进反向传播算法的代表。SDBP 算法和 MVBP 算法都是按梯度最快下降方向调整网络参数值,因此可以使得误差目标函数快速减小,但由于只采用了误差的一阶导数信息,因此收敛速度慢,为此本文同时采用了第三种神经网络学习算法,即 Levenberg-Marquardt (LM)算法^[11]。

LM 算法是最速下降法和高斯-牛顿法的综合,由于利用了误差的近似二阶导数信息,因此收敛速度快,并随着计算机硬件技术的发展,逐渐成为神经网络的主流学习算法。综上所述,针对多层感知器神经网络,本文采用了三种最常见的学习算法,即最速反传(SDBP)算法、附加动量项自适应学习速率反向传播(MVBP)算法和 Levenberg-Marquardt (LM)算法,构造了三种对应的 MLP 神经网络,即 MLP-SDBP、MLP-MVBP 和 MLP-LM。关于 SDBP 算法、MVBP 算法和 LM 算法的细节,请参考文献[9-11]。

1.2 径向基函数神经网络

与多层感知器神经网络一样,径向基函数神经网络也由输入层、隐层和输出层组成,且其各层功能与 MLP 神经网络对应层功能一致,但径向基函数(RBF)神经网络是单隐层的神经网络,且隐层神经元的数据处理方式与 MLP 神经网络不同。

图 2 为 RBFNN 隐层第 m 个神经元进行数据处理的示意图。首先输入向量与输入空间内已定义的中心进行欧式距离运算,完成输入变换,然后采用非线性函数(径向基函数)对得到的欧式距离进行处理。本文中,径向基函数采用高斯函数,则隐层第 m 个神经元的输出为

$$O_m = \exp\left(-\frac{\|x - v_m\|^2}{\sigma_m^2}\right)$$

其中 v_m 为输入空间内的中心,即高斯函数的中心, σ_m 为高斯函数的宽度。输出层第 n 个神经元的输出为

$$O_n = \sum_{m=0}^M w_{nm}O_m$$

其中 w_{nm} 为隐层第 m 个输出与输出层第 n 个神经元之间的连接权值。




图 2 径向基函数神经网络隐层神经元

径向基函数神经网络的学习算法一般采用两阶段学习算法^[12]。第一阶段是无教师学习阶段,根据所有的输入样本决定隐层各神经元高斯函数的中心。本文采用最常用的 K 均值(K-Means, KM)聚类算法^[13]来确定函数的中心。另外,径向基神经网络

的中心选择可以等效为线性回归中子模型的选择问题,可以采用正交最小二乘法(orthogonal least square, OLS)^[14],对正交向量的误差下降速率进行排序,然后根据误差要求,确定径向基函数的数目及中心,实现基于“信息-贡献”准则的中心优选。第二阶段是有教师学习阶段,根据输入输出样本计算隐层和输出层之间的连接权值,本文采用最小二乘法确定输出权值。针对 RBF 神经网络,本文采用两种常见的学习算法训练,即 K 均值(KM)聚类法和正交最小二乘法(OLS),构造了两种对应的 RBF 神经网络,即 RBF-KM 和 RBF-OLS。关于 KM 算法和 OLS 算法的细节,请参考文献[12-14]。

2 自动定深电液伺服系统

本文以某型号武器中扫雷犁的自动定深电液伺服系统作为神经网络建模的实验对象。自动定深电液伺服系统主要由比例阀、液压缸、仿形靴、轴角传感器、犁刀等环节组成。在该型号武器行进过程中,处于犁体前方的仿形靴感应凹凸不平的地面信号,并通过其上安装的轴角传感器测量犁臂与水平面的夹角,从而计算出犁刀的实际入土深度,然后根据预先设定的入土深度计算出伺服阀的控制信号,由比例阀控制液压缸活塞的伸缩,实现犁刀入土深度自动控制,达到在复杂地形扫雷的目的。

在自动定深电液伺服系统中,输入信号为比例阀控制信号,其取值范围为 $[-8\ 8]$ 伏,输出信号为液压缸活塞的位移,其输出值范围为 $[0\ 0.45]$ m。共采集数据 1000 组,其中前 600 组用于模型训练,后 400 组用于模型检验,如图 3 所示。图 3(a)为伺服阀输入电压信号,图 3(b)为液压缸活塞位移信号。




图 3 自动定深电液伺服系统的输入输出数据

3 实验与分析

3.1 多层感知器神经网络

在多层感知器神经网络中,隐节点数的选择非常重要,本文采用试探法确定隐节点数目,首先根据经验确定隐节点数目范围(一般为 $[2, 2 \sim 3N]$, N 为输入变量个数),然后在此范围内逐个构造不同隐节点数目的神经网络,并最终选择检验误差最小的神经网络的隐节点数目为最优隐节点数目。

图 4 给出了采用 SDBP 算法确定 MLP 神经网络隐节点数目的示意图。当隐节点数目为 6 时,MLP 神经网络具有最小的训练误差和检验误差,采用 MVBP 和 LM 算法也可得到相同结果。因此本文所构造的 MLP 神经网络,其隐节点数目统一为 6 个。




图 4 MLP 神经网络的隐节点数目与误差的关系

多层感知器神经网络在进行训练时,会受到随机初始权值和局部最小等因素的影响,使得每次学习的性能均会有所不同,因此本文将 SDBP、MVBP 和 LM 三种训练算法各运行 50 次,从而分析不同算法的性能。图 5、图 6 和图 7 分别直观地给出了利用 SDBP、MVBP 和 LM 算法运行 50 次得到的神经网络训练误差和测试误差的分布图。从中可以看出:(1) SDBP 算法误差最大,其训练误差和检验误差的平均值分别为 0.0302 和 0.0328, MVBP 算法误差小于 SDBP,其训练误差和检验误差的平均值分别为 0.0263 和 0.0285, LM 算法误差最小,其训练误差和检验误差的平均值分别为 0.0180 和 0.0210,可见 LM 算法的训练误差和检验误差均明显小于其它两种算法。(2) SDBP 算法训练误差和检验误差分布的标准差分别为 0.065 和 0.073, MVBP 算法训练误差和检验误差分布的标准差分别为 0.041 和 0.042,

LM 算法训练误差和检验误差分布的标准差分别为 $3.27\text{e-}4$ 和 $9.82\text{e-}4$, 可见 SDBP 算法和 MVBP 算法容易受随机初始权值等因素的影响, 容易陷入局部最小, LM 算法基本上不受上述因素的影响。




图5 MLP神经网络中SDBP算法的误差分布




图6 MLP神经网络中MVBP算法的误差分布




图7 MLP神经网络中LM算法的误差分布

从上述分析可以看出, 不同的随机初始权值, 对多层感知器神经网络的性能影响较大, 那么在已构造的多个神经网络中, 究竟选择哪一个网络来衡量算法的性能, 目前大部分研究没有明确给出答案, 或仅采用误差最小的神经网络衡量算法性能。

为此, 本文提出代表误差的概念: 在神经网络训练过程中, 当误差下降到某特定数值时, 则终止网络的训练, 并认为此时的神经网络可以用来衡量算法的性能, 我们称该特定数值的误差为代表误差。代表误差可以采用如下方法来确定: 首先对多次运行得到的一组误差进行正态分布的假设检验, 如果误差符合正态分布, 则用概率 p 来计算逆累积分布函数值, 该值即为代表误差值。

以 0.01 的显著性水平对本文三种算法得到的误差进行正态分布的假设检验, 结果均符合正态分布。本文取 $p = 0.7$, 可以计算出 SDBP、MVBP 和 LM 三种算法的代表误差分别为 0.0336、0.0285 和 0.0181。

采用 SDBP、MVBP 和 LM 三种算法分别进行多层感知器神经网络的训练, 并以代表误差作为终止网络训练的条件。表 1 给出了所得到的三种神经网络的性能指标。从中可以看出三种神经网络的测试数据的性能指标均接近但稍劣于对应的训练数据的性能指标, 说明所训练的神经网络具有较强的泛化能力, 同时说明以代表误差作为算法终止条件可以避免网络训练的过拟合现象; 另外从测试数据的性能指标可以看出, MLP-MVBP 网络的性能指标稍优于 MLP-SDBP 网络, 而 MLP-LM 网络的性能明显优于其它两种神经网络。

表1 MLP神经网络的性能指标

网络类型	训练数据			测试数据		
	RMSE	VAF%	r	RMSE	VAF%	r
SDBP	0.0336	93.24	0.9659	0.0344	94.18	0.9705
MVBP	0.0285	95.14	0.9754	0.0300	95.56	0.9776
LM	0.0181	98.04	0.9901	0.0202	97.98	0.9899

RMSE: 均方根误差; VAF: 信号间方差比; r : 相关系数

为直观地表示算法的性能, 图 8、图 9 和图 10 分别给出了 MLP-SDBP、MLP-MVBP 和 MLP-LM 神经网络的模型输出与测量输出的回归分析, 从图中也可以明显看出, MLP-LM 神经网络的性能明显优于其它两种神经网络。




图 8 MLP-SDBP 网络性能分析




图 9 MLP-MVBP 网络性能分析




图 10 MLP-LM 网络性能分析

3.2 径向基神经网络

与多层感知器神经网络一样,径向基神经网络的训练也首先需要确定隐节点的个数。本文采用 3.1 节的方法确定隐节点数目。图 11 给出了采用 KM 算法构造的一组径向基神经网络的误差,当隐节点数目为 40 时,检验误差最小,因此本文所构造

的径向基神经网络的隐节点个数取值为 40。




图 11 RBF 神经网络的隐节点数目与误差的关系

由于聚类算法初始中心值的随机性,采用 KM 算法学习径向基神经网络,每次的训练误差会有所不同。图 12 给出了 KM 算法训练误差和检验误差的分布,可以看出,KM 算法受初始条件影响很小。以 0.05 的显著性水平对 KM 算法的误差进行正态分布的假设检验,得出 KM 算法训练误差符合正态分布的结论。取误差概率 $p = 0.7$,可计算得 RBF 神经网络代表误差的数值为 0.0194。




图 12 KM 算法的误差分布

采用 KM 算法对具有 40 个隐节点的径向基神经网络进行训练,得到满足代表误差条件的 RBF-KM 网络,其性能指标如表 2 所示,在代表误差为 0.0194 时,RBF-KM 网络的测试误差为 0.0225。为直观起见,图 13 给出了 RBF-KM 神经网络输出与测量输出的回归分析。

表 2 RBF 神经网络的性能指标

网络类型	训练数据			测试数据		
	RMSE	VAF%	r	RMSE	VAF%	r
KM	0.0194	97.75	0.9887	0.0225	97.49	0.9874
OLS ₄₀	0.0187	97.91	0.9895	0.0224	97.50	0.9874
OLS ₃₀	0.0194	97.74	0.9887	0.0219	97.62	0.9881




图 13 RBF-KM 网络性能分析

在 OLS 算法中,径向基函数的宽度值取为 KM 算法中宽度的平均值,即宽度为 12。采用 OLS 算法训练 RBF 神经网络,逐次增加隐节点数目至 30 后,得到的 RBF-OLS₃₀网络的训练误差满足代表误差的条件,其性能指标如表 2 所示。为方便与 40 个隐节点的 RBF-KM 网络进行比较,本文以选择 40 个隐节点作为 OLS 算法的终止条件,所得到的 RBF-OLS₄₀网络的性能指标见表 2。可见具备 40 个隐节点的 RBF-OLS₄₀网络的检验误差大于 30 个隐节点的 RBF-OLS₃₀神经网络的检验误差,可见当隐节点个数大于 30 时,RBF-OLS 网络发生了过拟合现象,泛化能力下降。因此对 OLS 算法训练的 RBF 神经网络,其隐节点个数选择为 30。图 14 直观给出 RBF-OLS₃₀网络输出与测量输出的回归分析。




图 14 RBF-OLS 网络性能分析

为更直观明了地比较多层前向神经网络及其学习算法的特性,表 3 给出了多层感知器神经网络和径向基神经网络及其学习算法所构造的 5 种神经网络的性能。除了均方根误差 RMSE、相关系数 r 和信号间方差比 VAF 外,表 3 同时给出了衡量算法收敛性的标准差 d ,和衡量算法计算量的运行时间 t 。除了运行时间 t 为训练数据的性能指标外,其它四个性能指标均为测试数据的性能指标。

表 3 MLPNN 和 RBFNN 的性能指标

性能指标	MLPNN			RBFNN	
	SDBP	MVBP	LM	KM ₄₀	OLS ₃₀
RMSE	0.0344	0.0300	0.0202	0.0225	0.0219
VAF%	94.18	95.56	97.98	97.49	97.62
r	0.9659	0.9754	0.9901	0.9874	0.9887
d	0.073	0.042	9.8e-4	1.4e-3	0
t	13.75	3.46	2.08	0.18	2.13

从表 3 可以看出,以均方根误差 RMSE、相关系数 r 和信号间方差比 VAF 这三个主要的性能指标对构造的 5 种神经网络进行性能优劣排序,可以明显看出,SDBP-NN 网络最差,而 MLP-LM 网络最优,在这 5 种神经网络中 RBF-KM、RBF-OLS 和 MLP-LM 性能较为接近,且明显优于其它两种神经网络。以标准差来衡量神经网络训练的收敛性,可以看出,MLP-SDBP 最差,而 RBF-OLS 最优,在 5 种神经网络中 RBF-KM、RBF-OLS 和 MLP-LM 三种神经网络基本上不受初值的影响,而 SDBP-NN 和 MVBP-NN 则明显受随机初始权值的影响。表 3 同时给出了这 5 种神经网络的训练时间,虽然其具体数值在不同的计算环境有不同的数值,但本文在相同的硬件环境和软件环境下给出的数值,具有一定的参考意义,可以看出,MLP-SDBP 网络具有最长的学习时间,而 RBF-KM 网络的学习时间最短,其它三种神经网络具有大致相同的学习时间。

4 结 论

本文详细讨论了电液伺服系统的神经网络建模,针对两类最常见的神经网络,即多层感知器神经网络和径向基神经网络,采用 5 种学习算法构造了 5 种具体的神经网络模型,并结合具体的电液伺服系统实例,对其性能进行了详细分析。

所构造的神经网络模型,均能够较真实地反映实际的电液伺服系统特性,能够较好地实现电液伺

服系统的建模。

多层感知器神经网络的 SDBP 算法和 MVBP 算法的性能均劣于 LM 算法,因此对多层感知器神经网络而言,应该选择 LM 学习算法,来构造电液伺服系统的神经网络模型。

径向基神经网络的 OLS 算法与 KM 算法相比,可以用更少的隐节点个数达到相同的训练误差和更小的检验误差,因此针对径向基神经网络,除非需要快速建模的场合,应采用 OLS 算法来构造电液伺服系统的神经网络模型。

采用 LM 算法构造的多层感知器神经网络(MLP-LM)和采用 OLS 算法构造的径向基神经网络(RBF-OLS)具有基本相同的性能指标。LM 算法存在局部最小值问题,算法一致性较差,多次独立训练得到的一组 MLP-LM,其最优网络的性能指标优于 RBF-OLS,但最劣网络的性能指标远劣于 RBF-OLS,因此针对电液伺服系统的神经网络建模,可以优先考虑采用 RBF-OLS 神经网络。

参考文献

- [1] Ziaei K, Sepehri N. Modeling and identification of electrohydraulic servos. *Mechatronics*, 2000, 10: 761-772
- [2] 王永昌,李杰,赵静一. 压滤机新型电液控制系统的建模与仿真研究. *中国机械工程*, 2005, 16(19): 1750-1753
- [3] He Q H, Zhang D Q, Hao P, et al. Modeling and control of hydraulic excavator's arm. *Journal of Central South University*

Technology, 2006, 13(4): 422-427

- [4] Kemmetmuller W, Muller S, Kugi A. Mathematical modeling and nonlinear controller design for a novel electrohydraulic power-steering system. *IEEE Transaction on Mechatronics*, 2007, 12(1): 85-97
- [5] 邢宗义,张媛,侯远龙. 电液伺服系统的建模方法研究与应用. *系统仿真学报*, 2009, 21(6)
- [6] 张秀玲. 液压弯辊系统的优化神经网络内模控制. *中国机械工程*, 2007, 18(20): 2419-2421
- [7] He S, Sepehri N. Modeling and prediction of hydraulic servo actuators with neural networks. In: *Proceeding of American Control Conference*, San Diego, USA, 1999. 3708-3712
- [8] 张友旺,钟向明,黄元峰. 电液位置伺服系统的自适应模糊神经网络控制. *中国机械工程*, 2004, 15(8): 681-684, 749
- [9] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back propagating errors. *Nature*, 1986, 323(9): 533-536
- [10] 戴葵. 神经网络设计. 北京: 机械工业出版社, 2002. 227-244
- [11] Hagan M T, Menhaj M B. Training feedforward networks with the marquardt algorithm. *IEEE Transaction on Neural Networks*, 1994, 5(6): 989-993
- [12] 钟路,饶文碧,邹承明. 人工神经网络及其融合应用技术. 北京: 科学出版社, 2007
- [13] MacQueen J B. Some Methods for classification and Analysis of Multivariate Observations. In: *Proceeding of 5th Berkeley Symposium on Mathematical Statistics and Probability*, Berkeley, USA, 1967, 281-297
- [14] Chen S, Cowan C F N, Grant P M. Orthogonal least squares learning algorithm for radial basis function networks. *IEEE Transaction on Neural Networks*, 1991, 2(2): 302-309

Neural networks modeling of electrohydraulic systems

Tong Zhongzhi, Xing Zongyi, Zhang Yuan, Gao Qiang, Jia Limin

(School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094)

(* School of Traffic and Transportation, Beijing Jiaotong University, Beijing 100044)

Abstract

Aiming at the problem that construction of an accurate model of an electrohydraulic system based on traditional linear methods remains a difficult task due to its nonlinear characteristics including flow/pressure relation, etc, the paper presents a thorough study on modeling of electrohydraulic systems using different types of neural networks. The two widely used neural networks, i.e. the multilayer perceptron neural network (MLPNN) and the radial basis function neural network (RBFNN) were investigated, and three MLPNNs and two RBFNNs were constructed using their five typical training algorithms. All these techniques were then applied to an automatic depth control electrohydraulic system, and the modeling performance of the five networks in the electrohydraulic system was analyzed. The results clearly indicated that the radial basis function neural network with the orthogonal least square training algorithm is prior to other neural networks for modeling of electrohydraulic systems.

Key words: electrohydraulic system, multilayer perceptron neural networks (MLPNN), radial basis function neural networks (RBFNN), modeling