DOI:10.16707/j.cnki.fjpc.2018.03.002

一种基于差分进化神经网络的模糊控制方法

刘 畅，何俊杰，肖 可，陈松岩
（厦门大学 物理科学与技术学院 福建 厦门 361001）

【摘 要】在模糊控制的实际应用中，隶属函数的选取往往依靠专家经验设定。这使得模糊控制由于隶属函数设定复杂，加大了实际应用的难度，往往达不到较好的控制效果。本文从 RBF 神经网络的特点出发，使用差分进化算法分成两个部分来优化 RBF 神经网络的参数，使之可以自动设置模糊控制的隶属函数。再通过模糊控制实时调整的 PID 控制器的三个参数，并分别对二阶系统和倒立摆系统进行仿真模拟。简化了模糊控制的设置方法，提高了进化算法在优化神经网络参数过程中的计算效率，取得了较好的控制效果。

【关键词】差分进化算法；RBF 神经网络；模糊逻辑控制；PID 控制器

0 引 言

从 1965 年 Zadeh 提出模糊理论[1]到 1974 年 Mamdani 首次将模糊逻辑应用在蒸汽机控制[2]。模糊理论在控制领域得到了迅速的发展和成功的应用，关于模糊控制方法的研究引起了学术界和工业界的广泛关注。与传统控制方法相比，模糊控制利用了专家的经验来进行控制，对于非线性、复杂系统的控制显示出了鲁棒性好、控制响应迅速的优点。

在应用模糊理论进行控制时，一个关键的问题就是隶属函数的构建，这也是应用模糊理论的难点之一，至今尚未完全解决。传统的模糊理论构造隶属函数主要是通过人类专家经验来获得。模糊控制通过设置模糊集合、模糊语言变量、模糊逻辑推理等一系列步骤来实现具体的应用，过程复杂，很大程度上依赖专家经验。使得模糊理论在控制领域上的应用受到诸多限制。

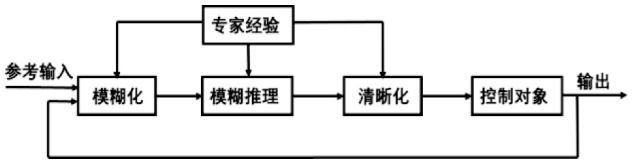

图 1 传统模糊控制结构

近年来，随着人工智能领域的快速发展。神经网络与进化算法（EA），由于其优化过程具有自学习、高维度、无需精确建模等特点。因此在控制领域中得到了很好的应用和发展，针对非线性高阶等复杂控制系统取得了较好的控制效果。值得注意的一点是，神经网络与进化算法虽然灵感都来源于现实世界中的生物活动，但神经网络本质上是一种具有建模能力的局部优化的算法，由于其采用梯度下降法调整参数因此易陷入局部最优，而进化算法本质上是一种具有全局优化能力的随机搜索算法，其本身并没有建模的能力。这两大类算法各有所长，因此后人也利用他们的特点在控制领域进行了许多结合的尝试。Teo, Marzuki 利用遗传算法（GA）调整模糊神经网络控制器[3]。Shuangxin, Dan 等人利用混沌粒子群算法（Chaotic PSO）优化 RBF-PID 控制器并将其应用在涡轮调节系统上[4]。

径向基神经网络（RBF 神经网络）是一种以高斯径向基函数（Gauss Radial Basis Function）作为激活函数的神经网络。它是一种局部逼近的神经网络，相比典型的 BP 神经网络具有更好的逼近能力、分类能力和学习速度。已证明 RBF 神经网络能以任意精度逼近任非线性函数[5]。虽然 RBF 神经网络诞生很早，但由于其良好的逼近性能和计算效率，使其一直都是控制领域的研究热点。Mingguang, Wenhui 利用 RBF 神经网络作为参考适应模型优化单神经元 PID 控制器[6]。Zhanshan, Zhengwei 等人将 RBF-PID 控制器应用在风力涡轮发电系统上取得了良好的效果[7]。

由于 RBF 神经网络采用梯度下降法反向传播调整网络权值，因此在优化过程中不可避免的会陷入局部最优解。为此，本文利用差分进化算法优化 RBF 神经网络的初始参数，将网络的初始参数优化到一个近似全局最优解的范围。

差分进化算法（DE）[5] 是一种新兴的随机实数全局优化算法，与遗传算法（GA），粒子群算法（PSO）都属于进化算法的分支。该算法最早在 1997 年第一届国际进化优化计算竞赛（ICEO）中表现突出，引起了很多学者的关注和研究，并取得许多新进展[6]。DE 与 GA 最大的不同之处在于，GA 算法采用基因数值的随机变化作为变异方法，而 DE 算法则是通过具体规则对不同个体间的差异进行随机组合进行变异。DE 算法相比于 GA 算法结构简洁，计算效率高，需要设置的参数更少，拥有更好的收敛速度。与 PSO 算法相比 DE 算法保持了良好的全局搜索能力[7][8][9]。同时 DE 算法以其出色的性能在控制领域得到了广泛关注。I.Chiha, J.Ghabi 等人从帕累托优化得到灵感，提出多目标 DE 算法（MODE）并利用其调整 PID 控制器，为多目标优化问题提供了一种全新的思路[10]。Rinki, Manisha 等人提出一种改进 DE 算法（IDE），通过一种新的变异算子进行 DE 算法变异，并利用其优化分数阶 PID 控制器，取得了较为理想的收敛速度和控制效果[11]。

本文从 RBF 神经网络本身的特点出发，提出一种基于 DE 算法的两步优化网络参数方法，利用其优化后的 RBF 神经网络作为模糊控制的隶属函数。提升了算法的计算效率和优化效果。并引入两种典型的控制系统进行仿真测试，取得了良好的控制结果。

1 基于差分进化算法的 RBF 神经网络控制器

1.1 径向基神经网络

基金项目 福建省高校产学合作项目（2016H6026）

RBF 神经网络由三层组成:输入层、隐含层和输出层。输入层的数值信息直接作用在隐含层上，隐含层的激活函数采用高斯径向基函数构成。每个隐含层包含一个中心向量 c_j,c_j 与输入向量 $x(t)$ 具有相同的维数,通过计算二者之间的欧氏距离 $\| x(t)-c_j(t) \|^2$ 作为径向基函数的输入向量。

$$h_j(t)=exp\left(-\frac{\| x(t)-c_j(t) \|^2}{2b_j^2}\right),\quad j=1,\cdots,m$$

其中,b_j 表示高斯径向基函数的宽度，是一个正标量;m 为隐含层节点数量。网络输出由隐层输出与权值的乘积求和构成。

$$y_i(t)=\sum_{j=1}^{m} w_{ji}h_j(t),\quad i=1,\cdots,n$$

其中,w 是输出层的权值;n 是输出节点个数;y 是神经网络输出。

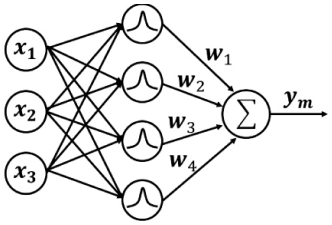

图 2　RBF 神经网络结构

RBF 神经网络采用梯度下降法反向传播调整网络参数(c,b,w)。这种学习方式很容易陷入局部最优。因此本文从 RBF 神经网络自身特点出发,利用差分进化算法的良好的全局并行搜索能力来优化 RBF 神经网络的参数,使其能够收敛到全局最优解,并减小在响应初始阶段的误差。

1.2 差分进化算法

差分进化算法是一种受达尔文进化论启发的进化算法,它的特点是不需要对优化对象进行精确建模就可以得到近似最优解,同时具有良好的并行全局搜索能力。可以避免陷入局部最优解。对高维优化问题有着良好的性能。DE 算法主要由以下几个部分组成。

图 3　DE 算法优化步骤

1.2.1 初始化

首先对需要优化的问题进行实数编码,确定解的格式。每个解相当于一个生物个体,它由若干个染色体组成。每个染色体用一个实数表示。解中染色体的数量代表了求解问题的维度。然后需要确定种群数量 Np，也就是每代中生物个体的数量,更大的种群数量会提高全局搜索能力,随之而来的是计算量的提升。接下来需要设置变异算子 F、交叉算子 Cr。最后设定最大进化代数 Gm(即迭代次数)和终止条件,只要种群中的最优解满足终止条件或者迭代次数达到最大进化代数,则算法结束。

1.2.2 变异

在生物学上,“变异”指的是染色体的基因特征发生突然变化。在 DE 算法中,突变就是通过一系列操作使得种群中个体的实数组成发生突然变化。DE 算法的突变过程与遗传算法不同,这也是其独特的一点。

具体对于个体 $\overrightarrow{X}_{i,G}$ 来说,i 代表当前个体的编码,G 代表当前个体所处的代数。首先随机从[1,Np]范围中随机选取 r_1^i、r_2^i、r_3^i 三个整数，同时这三个整数要与其对应的原始个体下标 i 不同,分别将三个整数对应的个体 $\overrightarrow{X}_{r_1^i,G}$、$\overrightarrow{X}_{r_2^i,G}$、$\overrightarrow{X}_{r_3^i,G}$ 带入下面的公式。

$$\overrightarrow{V}_{i,G}=\overrightarrow{X}_{r_1^i,G}+F\cdot(\overrightarrow{X}_{r_2^i,G}+\overrightarrow{X}_{r_3^i,G})$$

其中 F 为变异算子,这样我们就得到了代表全新的变异个体的 $\overrightarrow{V}_{i,G}$,对应于原始 $\overrightarrow{X}_{i,G}$。

相比于遗传算法,DE 算法的变异程度更大。这种变异方法提高了算法的搜索能力。

1.2.3 交叉

因为 $\overrightarrow{V}_{i,G}$ 与 $\overrightarrow{X}_{i,G}$ 完全不同，在实际的生物进化过程中,突变往往是生物个体小范围内的变化,这样既保留了前一代的基因特性,同时又为下一代进化提供了可能性。因此在突变过程的后面引入了交叉过程,交叉过程就是通过一定的概率(交叉概率)将变异后的染色体和原始的染色体随机交叉组成新的个体 $\overrightarrow{U}_{i,G}$。

$$\vec{U}_{j,i,G}=\begin{cases}\vec{V}_{j,i,G} & if(rand_{i,j}[0,1]\le Cr\ \ or\ \ j=j_{rand})\\ \vec{X}_{j,i,G} & otherwise\end{cases}$$

j 代表个体重染色体的编码,i 代表个体编码,G 代表当前代数。代表新一代的个体 $\overrightarrow{U}_{j,i,G}$。

1.2.4 选择

根据具体需要解决的问题,设置相对应的评估函数。在本文中选用误差绝对值积分(IAE)作为评估个体适应度的指标。对经过变异交叉的所有个体进行评估,评估以后若当前个体的适应度超过前一代的对应个体,说明对此个体而言此次变异交叉的操作是成功的,则保留当前的个体。若经过评估后发现个体适应度不如前一代,说明对此个体而言,变异和交叉是不成功的。则依旧保留前一代较为优秀的个体进入下一代。最后从所有个体中选取适应度最好的个体作为此代个体的最优值,若达到终止条件或者最高迭代次数则进化停止。否则进入下一轮迭代。

1.3 基于差分进化神经网络的模糊控制策略

本文采用 RBF 神经网络辨识控制系统,得到系统的雅可比值后作为 PID 控制器参数的隶属函数。为了避免 RBF 神经网络陷入局部最优,采用 DE 算法对其进行初始优化。使 PID 控制器可以在控制过程中动态调整参数,达到理想的控制效果。

RBF 神经网络以高斯径向基函数(RBF 函数)为激活函数,每个隐层单元代表一个聚类的中心,cj 代表隐含层第 j 个神经元的 RBF 函数中心点坐标向量,bj 代表隐含层第 j 个神经元的 RBF 函数宽度。通过计算输入与每个隐层中心的欧氏距离带入 RBF 函数中得到隐含层的输出。

每一个隐层的聚类中心 c 和中心宽度 b，都代表了神经网络对一个高维解区域的映射能力。若干个隐层的输出与权值相乘以后叠加起来,构成了 RBF 神经网络的输出。正是因为这种特殊的结构设置,使得 RBF 神经网络相比于典型的 BP 神经网络拥有了更好的逼近能力、分类能力和学习速度。

从 RBF 神经网络输入的角度来看,当聚类中心 c 与中心宽度 b 的范围选取不当时,RBF 神经网络就会出现一些问题。当

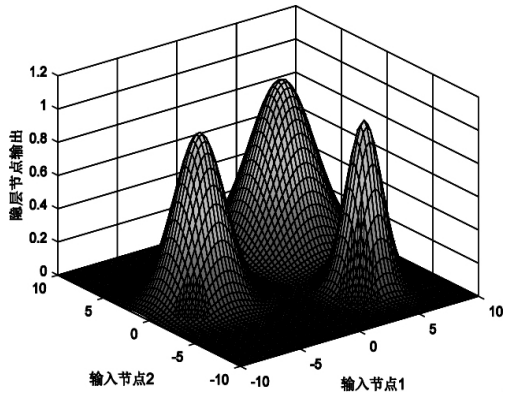

图 4　2- 3- 1 结构神经网络隐层示意

范围选取过小时，很容易陷入局部最优解。当范围选取过大时，会使得神经网络的收敛速度变慢。因此避免 RBF 神经网络陷入局部最优的有效方法是选取合适的聚类中心 c 与中心宽度 b，从而保证了对解空间的有效映射。

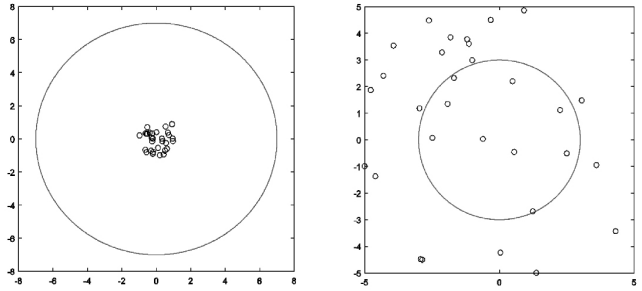

a.范围过大　　b.范围过小

图 5　不同范围下对解的映射效果

从 RBF 神经网络输出的角度来看，其作为隶属函数直接作用在 PID 控制器上。而在实际的 PID 控制中，三个参数的数值范围往往相差很大。在这种情况下如果使用相同的学习速率来调整这三个参数的话，会使数值较大的参数迟迟达不到最优，数值较小的参数又有可能因为不合适的学习速率导致震荡。

传统的 RBF 神经网络是先随机初始化网络中的 ci、bi、wi 参数（往往是一组 0–1 之间的随机数），然后通过梯度下降法将误差反向传播调整网络中的参数。这种随机初始化的问题是在系统运行的初始阶段会产生较大的误差。后人引入 GA、PSO 等进化算法来优化 ci、bi、wi 的初始值。这样能一定程度上的减小系统在初始阶段的误差。但这种方法的问题在于，需要优化的参数维度过高，例如以 3–6–1 结构的 RBF 网络为例，需要优化的参数维度达到 30。由于进化算法随机变异的特点，往往计算很久都无法达到较为理想的结果。

因此本文引入尺度系数的概念，从 RBF 网络的特点出发，将初始优化分成两部分进行，并使用 DE 算法来进行优化。大幅提高了算法的优化效率。

具体操作如下，首先针对神经网络的输入，分别 ci、bi 对加入尺度系数 $xiteci$、$xitebi$。这样可以快速的调整神经网络对输入的映射能力。然后针对输出，分别对引 wi、Kp、Ki、Kd 加入尺度系数 ηwi、ηKp、ηKi、ηKd，这样可以快速的调整系统对输出的映射能力。将这 6 个参数实数编码作为第一部分优化的内容。通过将高维优化问题减小到 6 维，大幅提高了系统的学习效率。减小了系统的稳态误差。

$$ci = \eta ci * rands(i,j)$$
$$bi = \eta bi * ones(i,j)$$
$$wi = \eta wi * rand(i,j)$$
$$Kp(k) = Kp(k-1) + \eta Kp * e(k) * dyout * xc(1)$$
$$Ki(k) = Ki(k-1) + \eta Ki * e(k) * dyout * xc(2)$$
$$Kd(k) = Kd(k-1) + \eta Kd * e(k) * dyout * xc(3)$$

通过第一部分的优化，系统的已经具备了良好的性能。但是由于没有针对系统的初始参数进行具体的初始优化，所以系统在运行的初始阶段会产生较大的误差。因此第二部分对神经网络的 ci、bi、wi 分别进行优化。以减小系统在初始阶段的误差。

这样分两步走的优点就在于，第一步首先将神经网络的输入输出的数值范围确定出来，接下来第二步再对神经网络的所有参数进行高维优化时，因为数值区间已经控制在一个合适的范围内，可以很快的将误差控制在比较小的范围内。

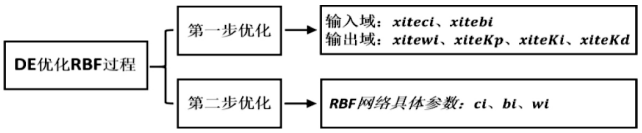

图 6　DE 算法优化 RBF 的过程

本文采用的 RBF 神经网络结构为 3–6–1，由 DE 算法对网络中的权值 wi、中心 ci、中心范围 bi 进行调优。

为了得到理想的控制效果，本文采用误差绝对值积分准则（IAE）作为 DE 算法评估函数的一部分。为了防止控制能量过大导致系统不稳定，在评估函数中加入控制输入的平方积分项。为了防止超调，本文加入超调误差 $e_{ct}(k)$ 的积分项。取 ω_1=1，ω_2=0.001，ω_3=100。

$$Fit = \omega_1 \int_0^\infty |e(k)|dt + \omega_2 \int_0^\infty u^2(t)dt + \omega_3 \int_0^\infty |e_{ct}(k)|dt$$

用 RBF 神经网络得到模糊 PID 的隶属函数，并分别对 Kp、Ki、Kd 三个参数进行动态调整。

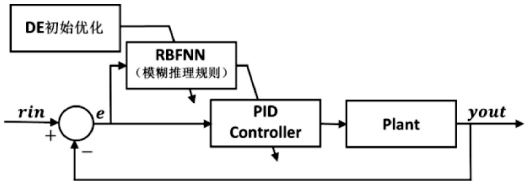

图 7　DE- RBF 模糊 PID 控制器结构图

2 仿真实例

本文首先以二阶系统为例进行仿真。二阶系统的传递函数为：

$$G(s) = \frac{25}{s^2 + 4s + 25}$$

采用 RBF神经网络未初始化直接作为 PID 的模糊隶属函数时的仿真结果如图所示，此时 IAS 为 0.73。

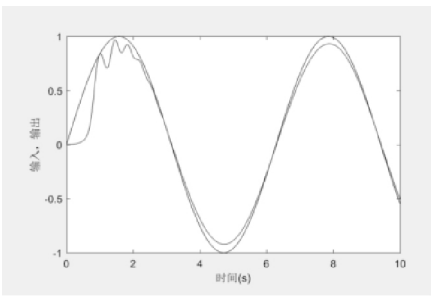

图 8　未经优化的 RBF 模糊 PID 控制二阶系统

采用本文提出的 DE–RBF 模糊控制策略，对 RBF 神经网络的所有参数进行初始优化。设置种群大小 Np=50，进化代数 Gm=50，变异率 F0=0.5，交叉概率 CR=0.35。所得误差下图线如图所示，仿真结果如图所示。此时 IAS 为 0.13。

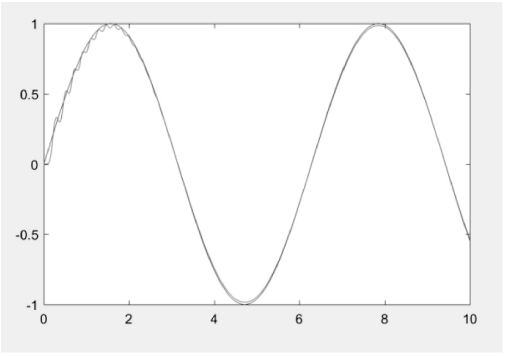

图 9　DE 算法优化的 RBF 模糊 PID 控制二阶系统

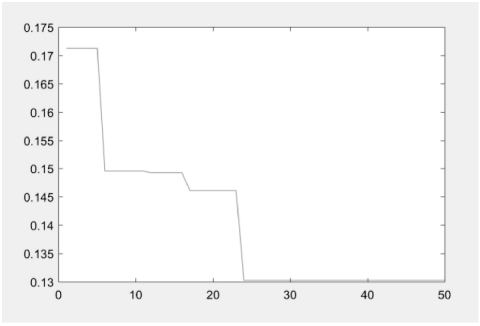

图 10　DE 算法优化过程的误差下降

2.1 针对倒立摆系统建模仿真

本文针对一级倒立摆进行建模，对 DE–RBF 算法的性能进行验证。

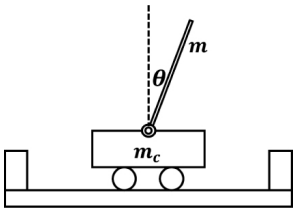

图 11　倒立摆示意图

设小车质量 m_c=1kg，摆的质量 m=0.1kg，摆长 L=1m。联立微分方程可得到一级倒立摆的数学模型。

$$\begin{cases} \dot{x_1} = x_2 \\ \dot{x_2} = f(x) + g(x)u \\ f(x) = \dfrac{gsinx_1 - mlx_2^2 cosx_1 sinx_1/(m_c+m)}{\left(\frac{L}{2}\right)\left(\frac{4}{3} - \frac{mcos^2 x_1}{m_c+m}\right)} \\ g(x) = \dfrac{cosx_1/(m_c+m)}{\left(\frac{L}{2}\right)\left(\frac{4}{3} - \frac{mcos^2 x_1}{m_c+m}\right)} \end{cases}$$

将得到的数学模型作为 DE 算法的评估函数，对 RBF 模糊 PID 控制器系统进行优化。

采用 RBF 神经网络未初始化直接作为 PID 的模糊隶属函数对倒立摆系统进行控制，仿真结果如图所示，此时 IAS 为 0.0122。

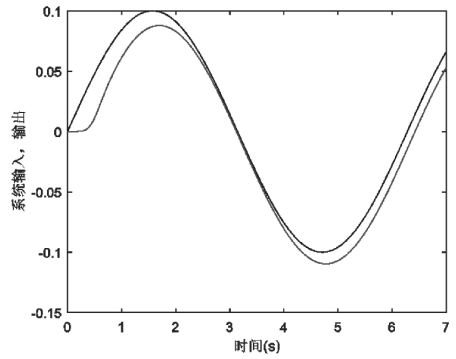

图 12　未经优化的 RBF 模糊 PID 控制倒立摆系统

采用本文提出的 DE–RBF 模糊控制策略，对倒立摆系统进行控制。所得仿真结果如图所示。此时 IAS 为 0.0065。

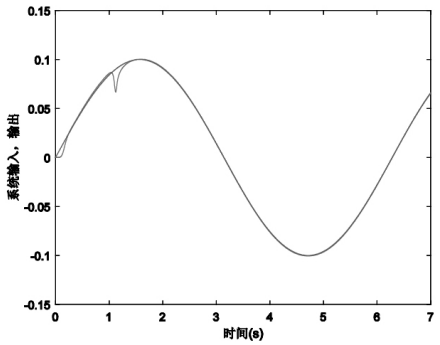

图 13　DE 算法优化的 RBF 模糊 PID 控制倒立摆系统

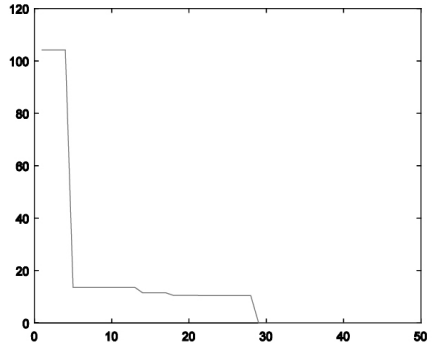

图 14　DE 算法优化过程的误差下降

从仿真结果可以看出，经过 DE 优化过后的 RBF 模糊 PID 控制系统在控制精度上有了较好的响应效果。从初始阶段就可以将误差控制在较小的范围。整个系统响应误差相比未优化之前有了显著下降。

3 结束语

为了解决模糊控制中隶属函数设置的问题，本文提出使用 DE 算法优化 RBF 神经网络自适应逼近模糊隶属函数。利用 DE 算法良好的并行全局寻优能力，同时结合 RBF 神经网络自身的特点进行网络参数优化。较好的解决了传统 RBF 神经网络容易陷入局部最优解的问题。为模糊控制的应用提供了一种全新的思路。并对两种典型的控制模型进行仿真。结果表明 DE–RBF 具有更快的的响应速度和更小的响应误差。对于非线性高阶的控制系统具有良好的控制效果。 （下转第 167 页）

馈,掌握学生的接受知识程度,根据具体情况有效的调整教学进度,这种动态式的互动也可以很好的带动整个课堂的氛围,调动班级整体的学习兴趣。虽然多媒体技术的应用和发展为物理课堂教学带来了一定程度的便利,它自身也具有着良好的交互性,但是这种交互性更多的是人机之间的交互,师生之间的直接交流沟通则被严重的削弱,因此师生间的情感交流也会被淡化,这是多媒体技术广泛应用阶段的一处弊端。

2.2 对老师在课堂上的主导地位和多样风格形成了一定的冲击

教师在课堂教学过程中一直处于主导地位,对课堂起着支配的作用,但随着多媒体技术的出现以及对它使用的依赖性的增强,教师的绝对支配者的地位受到了动摇。多媒体技术的使用越来越多的趋向程序化和规范化,为了配合它的使用,教师讲解的过程也需要按着既定的模式和流程进行,这势必会在一定程度上削弱教师对于课堂的掌控力度。长此以往,教师灵活应对课堂变化能力和及时反馈调整能力得不到锻炼,便会慢慢变弱,这对于教学质量来说影响较坏。例如,一些教师过分的依赖于多媒体技术,形象风趣、变化多样的讲课活动变成了一场场幻灯片的放映活动,以计算机为代表的多媒体技术占据了课堂主角的地位,教师却仿佛沦为了一个配角,这种本末倒置的现象实在是不可取。还有一些教师不会或者是自己懒于利用多媒体技术针对自己所要讲解的物理知识有特色地进行设计,而是选择从网上零散的下载一些内容然后进行拼接,这样出来的成果必然不系统不全面,而且更不会有进步、创新之处值得借鉴,教师和学生的思维也会被这种模式所固化,教师的课堂模式和风格也会面临着趋同的风险,失去个性化。

2.3 容易让学生产生惰性和依赖性

多媒体技术的便利性是有目共睹的,它对于物理知识、问题、现象的展示是直观清晰的,这种过多的便利性会对学生的主动思考能力带来一些不利的影响。学生们依赖于多媒体的展示,自己的主动思考、想象力度就会减弱,形成思维的惰性,不利于创新性想法的形成,多媒体的程序化固定模式,也有着将学生思维变得单项、机械、被动的风险。

3 总结

从上述各个方面的利弊分析中,可以看出多媒体技术不断地融入了高职物理教学的方方面面,利弊共存。从整体上来看,多媒体技术在高职物理教学中的作用和影响还是利大于弊的,若高职学校的广大物理教师能够做到合理应用,不盲目地跟随大潮流,则可以更进一步地消除一些现阶段多媒体技术使用中存在和显露的弊端。现代技术的发展日益强大,在不断的摸索和探究的过程中挖掘出多媒体技术的更广阔的应用发展空间,发扬扩大它的实用价值,发挥出它的科学性和必要性,不断消除各种弊端,尽全力地应用出它的实际价值。

参考文献:

[1] 王晓军.高职物理教学中多媒体技术应用利弊探讨[J].课程教育研究,2016,(31):175- 176.DOI:10.3969/j.issn.2095- 3089.2016.31.192.

[2] 曾秀丽.将多媒体教学技术应用到高职院校物理课程教学中的相关研究[J].科技展望,2015,25(31):292.DOI:10.3969/j.issn.1672- 8289.2015.31.252.

[3] 李伟欣.高职物理教学中新型网络媒体技术的具体应用[J].新教育时代电子杂志(教师版),2016,(29):203- 203.

(上接第 6 页)

参考文献:

[1] Zadeh L A. Fuzzy sets[C]// Fuzzy Sets, Fuzzy Logic, & Fuzzy Systems. World Scientific Publishing Co. Inc. 1996:394- 432.

[2] Mamdani E H. Application of fuzzy algorithms for control of simple dynamic plant [J]. Proceedings of the Institution of Electrical Engineers, 1974, 121(121):1585 - 1588.

[3] Seng T L, Bin K M, Yusof R. Tuning of a neuro- fuzzy controller by genetic algorithm [J]. IEEE Transactions on Systems Man & Cybernetics Part B Cybernetics A Publication of the IEEE Systems Man & Cybernetics Society, 1999, 29(2):226.

[4] Wang S, Lv D, Li Z, et al. A novel RBF- PID control strategy for turbine governing system based on chaotic PSO [C]// Intelligent Control and Automation. IEEE, 2011:130- 135.

[5] Park J, Sandberg I W. Universal approximation using radial- basis- function networks[J]. Neural Computation, 2014, 3(2):246- 257.

[6] Zhang M G, Li W H. Single Neuron PID Model Reference Adaptive Control Based on RBF Neural Network[C]// International Conference on Machine Learning and Cybernetics. IEEE, 2009:3021- 3025.

[7] Wang Z, Shen Z, Cai C, et al. Adaptive control of wind turbine generator system based on RBF- PID neural network [C]// International Joint Conference on Neural Networks. IEEE, 2014:538- 543.

[8] Storn R, Price K. Differential Evolution A Simple and Efficient Heuristic for global Optimization over Continuous Spaces [J]. Journal of Global Optimization, 1997, 11(4):341- 359.

[9] Das S, Suganthan P N. Differential Evolution: A Survey of the State- of- the- Art [J]. IEEE Transactions on Evolutionary Computation, 2011, 15(1):4- 31.

[10] Das S, Abraham A, Chakraborty U K, et al. Differential evolution using a neighborhood- based mutation operator [J]. IEEE Transactions on Evolutionary Computation, 2009, 13(3):526- 553.

[11] Rahnamayan S, Tizhoosh H R, Salama M M A. Opposition- Based Differential Evolution [M]// Advances in Differential Evolution. Springer Berlin Heidelberg, 2008:64- 79.

[12] Vesterstrom J, Thomsen R. A comparative study of differential evolution, particle swarm optimization, and evolutionary algorithms on numerical benchmark problems [C]// Evolutionary Computation, 2004. CEC2004. Congress on. IEEE, 2004:1980- 1987 Vol.2.

[13] Chiha I, Ghabi J, Liouane N. Tuning PID controller with multi- objective differential evolution [C]// International Symposium on Communications Control and Signal Processing. IEEE, 2012:1- 4.

[14] Maurya R, Bhandari M. Fractional Order PID Controller with an Improved Differential Evolution Algorithm [C]// International Conference on Micro- Electronics and Telecommunication Engineering. IEEE, 2017: 550- 554.