

基于深度信念网络的船用燃气轮机自适应控制

欧阳慈, 黄向华

(南京航空航天大学 能源与动力学院, 南京市 210016)

摘要:针对船用燃气轮机非线性强、惯性大和负载多变等特点,提出 1 种基于深度信念网络的自适应控制器。该控制器结合了深度信念网络 and 传统 PID 控制器,利用深度信念网络对燃气轮机的转速误差信息以及负载状态提取实时特征,在线调节 PID 参数,并将参数传递给 PID 控制器,由其输出控制量。通过数字仿真验证表明:该控制器满足燃气轮机转速控制的要求,并且具有良好的自适应性,在不同工况下,能够对燃气轮机转速进行准确控制,使得系统快速响应的同时无超调量。

关键词: 船用燃气轮机;深度信念网络;自适应控制;仿真

中图分类号: V233.7+52

文献标识码: A

doi: 10.13477/j.cnki.aeroengine.2018.04.008

Adaptive Control of the Marine Gas Turbine Based on Deep Belief Network

OU Yang-ci, HUANG Xiang-hua

(College of Energy and Power Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China)

Abstract: According to the characteristics of marine gas turbine such as strong nonlinearity, large inertia and changeable load, an adaptive controller was proposed based on deep belief network. Based on the traditional PID controller, the deep belief network was used to extract the speed fault information and load state of the gas turbine real time. It adjusted the PID parameters online and passed the parameters to the PID controller which outputs the control quantity. The results of digital simulation show that the controller meets the requirement of gas turbine speed control and has good adaptability. It can accurately control the speed of gas turbine, so that the system can respond quickly without overshoot at the same time.

Key words: marine gas turbine; deep belief network; adaptive control; simulation

0 引言

燃气轮机广泛应用于舰船、地面发电和工业驱动等多个领域^[1],近年来随着燃气轮机参数不断提高,其性能要求也越来越高,对于燃气轮机控制系统,无论在算法的先进性还是在运行的稳定性方面都提出了更高要求^[2]。燃气轮机一般长期工作在负载状态,控制动力涡轮转速就相当于控制输出功率,尤其对于发电用燃气轮机来说,其动力转子转速决定着发电的质量^[3],因此燃气轮机的转速控制至关重要。从性能控制的角度出发,燃气轮机转速控制应满足的基本指标^[4]为:稳态精度 $\pm 0.2\%$; 加减速时,允许转速变化不超过 $\pm 2\%$,载荷突变 50%或以上时,转速变化不超过 $\pm 3\%$ 。

目前,船用燃气轮机控制主要采用 PID 控制器^[5],但是面对其复杂的工作状况,PID 控制往往不能满足基本指标。国外学者在燃气轮机控制方面,也大多采用 PID 控制或者对其进行改进,如 Mohsen 等采用 1 种进化算法的 PID 控制器用于发电燃气轮机控制^[6]; Lalit 等采用萤火虫算法对 PID 的增益选择进行优化^[7]。虽然上述研究对整个 PID 控制算法进行了优化,但对于 PID 参数整定仍然依靠经验。在实际应用中,PID 控制算法的参数整定尚未得到较好解决,并且燃气轮机经常变工况运行,在负载发生变化的情况下,控制难度进一步加大。另外,船用燃气轮机惯性较大,响应时间和超调量很难协调,要想减小超调量,就会大幅度延长响应时间,而要想缩短响应时间,就会使超调

收稿日期:2017-12-15 基金项目:国家自然科学基金(51576097)资助

作者简介:欧阳慈(1993),男,在读硕士研究生,研究方向为燃气轮机建模、控制与仿真;E-mail:oyc003@163.com。

引用格式: 欧阳慈, 黄向华. 基于深度信念网络的船用燃气轮机自适应控制 [J]. 航空发动机, 2018, 44 (4): 45-50. OU Yangci, HUANG Xianghua. Adaptive control of the marine gas turbine based on deep belief network [J]. Aeroengine, 2018, 44(4): 45-50.

量大幅度增加^[8]。此外,由于实际工作环境和使用寿命的变化,导致部件性能退化,而控制参数是基于理想额定工况进行设计,因此控制系统更希望能自动调节相应的控制参数来消除性能退化的影响^[9]。

针对上述问题,本文引入深度学习中的深度信念网络^[10](Deep Belief Network, DBN)模型,利用深度学习逼近任意非线性函数的优势来实时提取燃气轮机相关信息,在线调节 PID 参数,同时结合传统 PID 控制算法,提出 1 种适用于船用燃气轮机转速控制的自适应算法。

1 深度信念网络

深度学习的概念由 Hinton 等在 2006 年提出,起源于人工神经网络的研究,其目的在于模拟人脑思维方式与学习机制来处理各类型数据,通过构建深层次神经网络完成特征学习过程,从而实现原始数据到特征识别的转变。深度学习在图像识别、文字处理、语音识别^[11]等诸多领域都有广泛应用。深度信念网络由若干层受限玻尔兹曼机^[12](Restricted Boltzmann Machines, RBM)和 1 层 BP 神经网络组成,是目前研究和应用都比较广泛的深度学习结构^[13]。

1.1 限制性玻尔兹曼机模型

单层 RBM 只有 2 层神经元:1 层叫做可视层(visible layer),用于输入训练数据;另 1 层叫做隐藏层(hidden layer),用作特征检测器(feature detectors)。RBM 网络结构由 m 个可视节点和 n 个隐藏节点组成,如图 1 所示。




图 1 限制性玻尔兹曼机模型

其能量函数 $E(v, h)$ 定义为

$$E(v, h|\theta) = - \sum_{i=1}^m \sum_{j=1}^n v_i w_{ij} h_j - \sum_{i=1}^m b_i v_i - \sum_{j=1}^n c_j h_j \quad (1)$$

式中: w_{ij} 为可视节点 i 与隐藏节点 j 之间权重; b_i 为可视层的偏移量; c_j 为隐藏层偏移量。

(v, h) 的联合概率密度为

$$p(v, h|\theta) = \frac{1}{Z(\theta)} e^{-E(v, h|\theta)} \quad (2)$$

$$Z(\theta) = \sum_{v, h} e^{-E(v, h|\theta)} \quad (3)$$

式中: $Z(\theta)$ 为归一化因子。

由于可视节点与隐藏节点的状态相互独立,因此二者的边缘概率密度为

$$p(v|h) = \prod_{i=1}^m p(v_i|h) \quad (4)$$

$$p(h|v) = \prod_{j=1}^n p(h_j|v) \quad (5)$$

利用可视层构建隐藏层,则隐藏层的第 j 个节点的激活概率为

$$p(h_j=1|v, \theta) = \sigma(c_j + \sum_i v_i w_{ij}) \quad (6)$$

式中: $\sigma(x) = \frac{1}{1+e^{-x}}$, 为激活函数。

同样,把隐藏层当作输入可以重构可视层,则可视层的第 i 个节点的激活概率为

$$p(v_i=1|h, \theta) = \sigma(b_i + \sum_j h_j w_{ji}) \quad (7)$$

1.2 深度信念网络模型

深度信念网络由多个限制玻尔兹曼机组成,常见的网络结构由若干层 RBM 和 1 层 BP 神经网络组成,如图 2 所示。

从图中可见,原始数据从第 1 层 RBM 的可视层输入,每层 RBM 的隐藏层也是下 1 个 RBM 的可




图 2 深度信念网络模型

视层,利用多层 RBM 可以增强数据特征抽取的能力。顶层再设置 1 层 BP 神经网络,有监督地将误差信息自顶向下传播至每层 RBM,反向微调整个网络的权值,克服了传统神经网络因随机初始化权值而易陷入局部最优和训练时间长等缺点。

1.3 深度信念网络的训练

深度信念网络的训练主要分为 2 个阶段:第 1 阶段是预训练,无监督地训练每层 RBM 网络,尽可能多地抽取原始数据的特征信息。第 2 阶段是微调,利用

顶层的 BP 神经网络接收 RBM 输出的特征向量,并根据误差信息,有监督的反向调节整个网络的参数。

对于单层 RBM 训练,Hinton 提出了 1 种快速训练法——对比散度法^[14](Contrastive Divergence, CD)。已知 1 个训练样本 X_0 ,学习速率 α ,最大训练周期 k ,具体步骤如下:

(1)初始化:令可视层初始状态 $v^{(1)}=X_0$,连接权值 w 、可视层偏置 b 、隐藏层偏置 c 为较小的随机数;

(2)训练:For $j=1,2,K,n$ (对所有隐藏节点)计算 $p(h_j=1|v^{(1)})=\sigma(c_j+\sum_i v_i^{(1)} w_{ij})$;从 $p(h_j=1|v^{(1)})$ 中采样出 $h_j^{(1)} \in \{0,1\}$;

End For

For $i=1,2,K,m$ (对所有可视节点)

计算 $p(v_i=1|h^{(1)})=\sigma(b_i+\sum_j w_{ij} h_j^{(1)})$;

从 $p(v_i=1|h^{(1)})$ 中采样出 $v_i^{(2)} \in \{0,1\}$;

End For

For $j=1,2,K,n$ (对所有隐藏节点)

计算 $p(h_j=1|v^{(2)})=\sigma(c_j+\sum_i v_i^{(2)} w_{ij})$;

从 $p(h_j=1|v^{(2)})$ 中采样出 $h_j^{(2)} \in \{0,1\}$;

End For

其中采样是采用吉布斯采样,具体过程见文献[15]。

(3)参数更新:

$$w=w+\alpha[p(h_i=1|v^{(1)})(v^{(1)})^T-p(h_i=1|v^{(2)})(v^{(2)})^T] \quad (8)$$

$$b=b+\alpha(v^{(1)}-v^{(2)}) \quad (9)$$

$$c=c+\alpha[p(h_j=1|v^{(1)})-p(h_j=1|v^{(2)})] \quad (10)$$

(4)重复(2)、(3),直到完成 k 次迭代更新。

对于整个 DBN 网络来说,充分训练好 1 层 RBM 后,再以其隐藏层状态作为输入,进行下 1 层 RBM 的训练,依此类推,直到完成整个网络的预训练。微调阶段,通常在 DBN 网络最后设置 1 层 BP 神经网络,进行有监督的训练以达到分类识别、调优等目的。

2 基于深度信念网络的 PID 控制器设计

PID 控制器以其简单、实用、鲁棒性强等优点,在燃气轮机控制中广泛使用,但是对于燃气轮机这样复杂的非线性系统来说,普通 PID 控制难以达到理想效

果。想要控制效果好,就需要处理好比例、积分和微分这 3 种参数相互制约的关系,而这种关系在复杂控制系统中已不是简单的线性组合关系,因此需要对 PID 控制加以改进。本文利用深度信念网络能够逼近任意非线性函数、稳定可靠以及训练较快等优势,结合传统 PID 控制算法,设计出基于 DBN-PID 的燃气轮机自适应控制器,其结构如图 3 所示。




图3 DBN-PID 控制器结构

基于深度信念网络的 PID 控制器分为 2 个模块,分别是 DBN-PID 控制算法模块与燃油限制保护模块。其中 DBN-PID 控制算法模块又分为 2 部分:第 1 部分是 DBN 网络,由 2 层 RBM 和 1 层 BP 网络组成,整个网络的作用是根据燃气轮机当前运行状态,在线计算出使得控制系统达到性能要求的 PID 参数;第 2 部分是增量 PID 控制器,其作用根据 DBN 实时输出的 3 个控制参数,计算输出当前控制量。

控制算法模块的 DBN 网络采用预训练与微调相结合的方法进行训练,2 层 RBM 运用上一节介绍的 CD 方法进行预训练,训练获得利于全局收敛的初始化参数。再通过顶端的 BP 网络结合性能指标进行有监督的训练,本文主要采用如下性能指标

$$J_1=\frac{1}{2}(n_{pr}-n_p)^2 \quad (11)$$

式中: n_{pr} 为动力涡轮指令转速; n_p 为动力涡轮转速。

BP 网络采用文献 [15] 的方法进行训练,整个 DBN-PID 模块算法流程如下:

(1)初始化 DBN 网络的输入节点与数量以及隐含层层数。本文输入节点取转速误差 n_{error} 、转速误差的变化 dn_{error} 与负载扭矩 M_p ,隐藏层数取 2。

(2)采样得到 $r_{in}(k)$ 、 $y_{out}(k)$ 。计算出 $n_{error}(k)=y_{out}(k)-r_{in}(k)$ 、 $dn_{error}(K)=n_{error}(k)-n_{error}(k-1)$ 。

(3)将 $n_{error}(k)$ 、 $dn_{error}(k)$ 、 $M_p(k)$ 输入 DBN 网络,DBN 网络根据性能指标进行训练,在线更新权值系

数^[16],再与PID增益系数相乘得到PID参数值。

(4)计算输出控制量 $u(k)$ 。

(5)变量 $k=k+1$,返回到(2)循环执行,直到满足控制精度。

此外,还采用性能指标 J_2, J_3 辅助调节超调量和调节时间。

$$J_2 = \frac{1}{2} (\sigma_r - \sigma)^2 \quad (12)$$

$$J_3 = \frac{1}{2} (t_r - t)^2 \quad (13)$$

式中: σ_r 为期望超调量; σ 为实际超调量; t_r 为期望调节时间; t 为实际调节时间。

在DBN网络外面再嵌套1层BP网络,通过或调节乘以PID参数前的3个增益系数,以达到控制超调量或调节时间的要求,其训练流程如图4所示。由于辅助调节训练需要反复迭代模型,严重影响仿真的实时性,因此本文对外层辅助调节的BP网络进行离线训练,根据不同工况制成PID增益系数关于动力涡轮转速 n_p 、负载扭矩 M_p (以及期望超调量 σ_r (或调节时间 t_r) 的插值表,并嵌入DBN网络模块中辅助其进行PID参数的在线自适应调节。




图4 网络训练流程

燃油限制保护模块也是该控制器的重要组成部分,其作用是保证燃气轮机稳定工作,防止燃气轮机发生超温、超转、喘振、熄火等故障。通过试验得到该船用燃气轮机各稳定边界的燃油量与折合转速关系,包括起动过程、过渡状态与稳态,如图5所示。图中绿





图5 稳定边界

色部分为留有裕度的稳定运行区域,数字仿真时用来限制燃油量以保证各状态下燃气轮机的稳定性。

以负载扭矩 $M_p=2700 \text{ daN}\cdot\text{m}$ 时的加减速控制为例,转速控制效果如图6所示,给定如图6(a)中的指令,调节时间约为6s,无超调量,并且PID3个参数是在线实时调节的,达到了转速控制稳定可靠且响应迅速的效果。



(a) 动力涡轮转速控制

(b) PID 3 参数自适应调整

(归一化后)

图6 加减速控制效果

3 仿真与结果分析

针对船用燃气轮机动力涡轮转速控制进行研究,在Simulink仿真平台中开展不同负载下加减速、加减速时转速和载荷突变时转速控制仿真,来验证DBN-PID算法的控制效果。

3.1 动力涡轮转速控制仿真原理

仿真对象为燃气轮机动力涡轮的转速控制,由控制器、执行机构、燃气轮机模型等部分组成,如图7所示。在数字仿真中,为了简化执行机构模型,采用1阶惯性环节代替,燃气轮机模型为非线性部件级数学模型。给定指令转速后,DBN-PID模块会根据误差等信息计算控制量,保护模块根据燃气发生器的折合转速确定当前上下限油量,对控制量进行限制后输出,再经过1阶惯性环节后传递给模型,模型计算后反馈,形成燃气轮机动力涡轮转速的闭环控制。




图7 动力涡轮转速控制仿真

3.2 加减速控制

船用燃气轮机由于动力轴牵引的负载较大,所以其惯性较大、响应较慢,工作需要稳定可靠,具体需要

满足超调量尽可能小,且响应快速,稳态精度 $\pm 0.2\%$ 。为进一步验证该方法自适应性能,取不同负载状态,对该方法和传统PID算法控制效果进行比较。在仿真前,对传统PID算法进行参数调节,确保在某一状态下PID控制效果极佳,这样2种方法的对比才有意义。本文在负载扭矩 $M_T=4700 \text{ daN}\cdot\text{m}$ 时,人为调节PID参数达到快速响应和微小超调的效果,然后对2种方法进行该负载下和 $M_T=3700 \text{ daN}\cdot\text{m}$ 时的加减速仿真,结果对比如图8、9所示。




图8 加减速控制效果对比($M_T=4700 \text{ daN}\cdot\text{m}$)




图9 加减速控制效果对比($M_T=3700 \text{ daN}\cdot\text{m}$)

从图8中可见,经过人为反复调节PID参数后,传统PID控制与DBN-PID控制效果几乎差不多,调

节时间都约为6s,但是相比而言,DBN-PID无超调量,传统的PID还有微小的超调量,并且调节参数过程也较为复杂。改变负载为 $M_T=3700 \text{ daN}\cdot\text{m}$,保持原来传统控制器3参数不变,再进行加减速控制仿真(图9)。

从图9中可见2种控制算法效果的差异,DBN-PID控制下动力涡轮转速依旧快速响应且无超调,而保持之前调整好参数的传统PID控制超调量较大。从图9(b)中可见,刚开始时,DBN-PID响应速度要比传统PID的快,而到快接近目标转速时,又逐渐变缓最后收敛,不同状态下的动力轴转速都能够被平稳快速地控制,因此该算法具有良好的自适应性。

3.3 加减速控制

对于船用燃气轮机来说,稳态下大部分时间是负载状态,并且随着工作状态不同,负载常常会发生改变,为了保证燃气轮机稳定运行,加减速时,允许转速变化不超过 $\pm 0.2\%$ 。加减速仿真结果如图10所示。




图10 加减速仿真结果

从图中可见,从64%加载到94%时,动力涡轮转速发生微小波动,转速变化不超过 $\pm 0.05\%$;而从94%减载到74%时,转速变化不超过 $\pm 0.04\%$ 。因此在缓慢加载时,DBN-PID算法完全满足燃气轮机控制要求。但是随着加减速速度增大,转速变化也会增大,在燃气轮机实际运行中,有时也会发生负载突变。为了保证燃气轮机在负载突变时保持稳定运行,因此燃气轮机转速需要满足:载荷突变50%或以上时,转速变化不超过 $\pm 3\%$ 。针对负载突变情况进行燃气轮机转速控制仿真,如图11所示。仿真结果表明,当负载




图11 负载突变时转速控制

突变 50%以上时,动力涡轮的转速变化为 $\pm 3\%$,满足载荷突变时的控制要求。通过改变性能指标 J_2 进行训练可以进一步减少负载突变时的超调量,但是由于受燃油保护模块的限制,并不能无限减少超调量。

4 结束语

(1)将深度信念网络与传统 PID 控制相结合,提出 1 种适用于船用燃气轮机转速控制的自适应控制器。

(2)该控制器能够针对燃气轮机不同工作状态在线调节 PID 参数,具有良好的自适应性能。

(3)加减速、加减载控制等仿真结果表明,该控制器能够满足燃气轮机转速控制的性能要求,并且与传统 PID 控制器相比,具有无超调量、在线调节参数等优势。

参考文献:

- [1] 王登.燃气轮机仿真技术研究[D].南京:南京航空航天大学,2011.
WANG Deng. Research on simulation technology of gas turbine [D]. Nanjing: Nanjing University of Aeronautics & Astronautics, 2011.(in Chinese)
- [2] 郭庆,刘月,刘尚明. 某重型燃气轮机燃料控制仿真平台的搭建与研究[J]. 热力透平,2016,45(2):127-131.
GUO Qing,LIU Yue,LIU Shangming. Construction and research on fuel control simulation platform for certain heavy-duty gas turbine[J]. Theraml Turbine,2016,45(2):127-131.(in Chinese)
- [3] 徐立新,强文义,王玉琛,等. 发电用重型燃气轮机的模糊自适应控制[J]. 哈尔滨工程大学学报, 2005,26(2):156-160.
XU Lixin,QIANG Wenyi,WANG Yuchen,et al. Adaptive fuzzy control for heavy single shift gas turbine [J]. Journal of Harbin Engineering University,2005,26(2):156-160. (in Chinese)
- [4] 薛银春, 孙健国. 燃气轮机控制技术综述 [J]. 航空动力学报, 2005,20(6):1066-1071.
XUE Yinchun,SUN Jianguo. A survey of gas turbine control technique [J]. Journal of Aerospace Power,2005,20 (6):1066-1071. (in Chinese)
- [5] 余又红,邬健,贺星. 船舶发电用三轴燃气轮机控制仿真研究[J]. 计算机仿真,2016,33(5):10-14.
YU Youhong,WU Jian,HE Xing. Simulation study of marine three-shaft gas turbine controlling for power generation [J]. Computer Simulation,2016,33(5):10-14.(in Chinese)
- [6] Khalilpour M,Valipour K,Shayeghi H,et al. Designing a robust and adaptive PID controller for gas turbine connected to the generator[J]. Research Journal of Applied Sciences Engineering & Technology, 2013,5(5):1543-1551.
- [7] Saikia L C,Sahu S K. Automatic generation control of a combined cycle gas turbine plant with classical controllers using fire-fly algorithm [J]. International Journal of Electrical Power & Energy Systems, 2013,53(1):27-33.
- [8] 江永胜. 大扰动条件下的大惯性系统的测量及控制 [J]. 机电技术, 2005,28(1):26-28.
JIANG Yongsheng. Measurement and control of large inertial system under large disturbance [J]. Mechanical & Electrical Technology, 2005,28(1):26-28.(in Chinese)
- [9] 刘尚明,何皓,蒋洪德. 重型燃气轮机控制发展趋势及未来关键技术[J].热力透平,2013,42(4):217-224.
LIU Shangming, HE Ai, JIANG Hongde. Development trend of heavy-duty gas turbine control technology [J]. Theraml Turbine, 2013,42(4):217-224.(in Chinese)
- [10] Hinton G E,Osindero S,Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation,2006,18(7):1527.
- [11] Chen Y,Chen Y,Wang X,et al. Deep learning face representation by joint identification-verification[C]//International Conference on Neural Information Processing Systems:MIT Press,2014:1988-1996.
- [12] 单外平.基于深度信念网络的变速器故障分类识别研究[D].广州:华南理工大学,2015.
SHAN WaiPing. Classification and recognition of transmission fault based on deep belief network[D]. Guangzhou: South China University of Technology, 2015.(in Chinese)
- [13] Ji S,Yang M,Yu K. 3D convolutional neural networks for human action recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2013,35(1):221-231.
- [14] Hinton G E. A practical guide to training restricted boltzmann machines[J]. Momentum, 2012,9(1):599-619.
- [15] Smith A F M,Roberts G O. Bayesian computation via the gibbs sampler and related markov chain monte carlo methods [J]. Journal of the Royal Statistical Society. Series B (Methodological),1993,55(1):3-23.
- [16] 陈宇,郑德权,赵铁军. 基于 Deep Belief Nets 的中文名实体关系抽取[J]. 软件学报,2012,23(10):2572-2585.
CHEN Yu, ZHENG Dequan, ZHAO Tiejun. Chinese relation extraction based on deep belief nets [J].Journal of Software,2012,23(10):2572-2585.(in Chinese)

(编辑:刘 亮)