

基于中介轴承润滑效率的流道结构参数反向预测

朱冬磊¹, 陈国定¹, 李炎军², 张朝阳²

(1. 西北工业大学 机电学院, 西安 710072;

2. 中国航空发动机集团有限公司 四川燃气涡轮研究院, 成都 610500)

摘 要: 为了满足航空发动机中介轴承润滑系统设计需求,即在给出特定轴承润滑效率的前提下,获得与之匹配的合理的轴承润滑流道结构参数,提出了考虑各结构参数取值约束条件的轴承润滑效率——流道结构参数反向预测分析方法。根据轴承润滑效率神经网络模型,构造反映结构参数与润滑效率拟合关系的润滑效率函数;以润滑效率函数值与给定润滑效率误差最小为优化目标,通过考虑各结构参数取值范围的优化分析,获得满足给定润滑效率(误差最小)的流道结构参数。相较于目前已有分析方法,所提出的反向预测分析方法预测精度提高了 4.39%,平均计算时长缩短了 17.5min,且能同时实现多个参数的预测,为中介轴承润滑系统设计提供了一种思路。

关 键 词: 中介轴承; 润滑效率; 流道结构; 反向预测; 预测精度

中图分类号: V233.4 **文献标志码:** A

Inverse prediction of flow-path structure parameters based on intershaft bearing lubrication efficiency

ZHU Donglei¹, CHEN Guoding¹, LI Yanjun², ZHANG Chaoyang²

(1. School of Mechanical Engineering,
Northwestern Polytechnical University, Xi'an 710072, China;

2. Sichuan Gas Turbine Establishment,
Aero Engine Corporation of China, Chengdu 610500, China)

Abstract: An inverse prediction method considering the constraints of flow-path structure parameters was proposed to satisfy the designing requirements of aero-engine intershaft bearing lubrication system while obtaining feasible structure parameters corresponding to the given bearing lubrication efficiency. Lubrication efficiency function was constructed to demonstrate the fitting relation between structure parameters and lubrication efficiency according to the neural network model. By virtue of structure parameters optimization, the distraction between lubrication efficiency function values and the given lubrication efficiency was minimized, the constraints of each parameter were considered to obtain, the flow-path structure parameters satisfying the given lubrication efficiency (minimized distraction). In comparison

收稿日期: 2019-09-11

作者简介: 朱冬磊(1992—),男,博士生,主要从事轴承腔油气两相流动换热研究。

通讯作者: 陈国定(1956—),男,教授、博士生导师,博士,主要从事机械系统及装备的润滑与密封技术研究。
E-mail:gdchen@nwpu.edu.cn

引用格式: 朱冬磊,陈国定,李炎军,等. 基于中介轴承润滑效率的流道结构参数反向预测[J]. 航空动力学报, 2020, 35(2): 440-448.
ZHU Donglei, CHEN Guoding, LI Yanjun, et al. Inverse prediction of flow-path structure parameters based on intershaft bearing lubrication efficiency[J]. Journal of Aerospace Power, 2020, 35(2): 440-448.

with the present analytical methods, the proposed inverse prediction method could improve the prediction precision by 4.39%, shorten the average calculation time by 17.5 minutes, and predict multiple parameters simultaneously, providing an approach to the design of intershaft bearing lubrication system.

Key words: intershaft bearing; lubrication efficiency; flow-path structure; inverse prediction; prediction precision

作为航空发动机高低压转子间的机械耦合点,中介轴承以其在缩短支点跨距和减少发动机质量等方面的作用获得了广泛应用^[1]。随着发动机转子转速日益提高,中介轴承热负荷愈发增大,对于轴承润滑效率提出了更高要求,设计良好的润滑流道有助于提升轴承润滑效率^[2-4]。

中介轴承润滑流道结构主要包括环下供油孔、密封座供油孔,以及用于卸油需要和双转子结构设计需要的密封空隙。有关中介轴承润滑流道结构设计,目前多采用有限元技术进行数值仿真计算,以获得环下供油孔出口的滑油流量(轴承润滑效率),或是通过优化技术获得高轴承润滑效率的流道结构参数,有关这方面的研究业已十分成熟^[5]。

轴承润滑设计中也存在着另外一种需求:即在给出特定轴承润滑效率的前提下,获得与之匹配的合理的润滑流道结构参数,以对应不同润滑设计目标的要求。目前在其他领域虽有一些相近的研究工作,但轴承润滑设计中有关这一反向预测设计的研究鲜见报道,因此开展以轴承润滑效率为输入、合理的流道结构参数为输出的反向预测方法研究,具有契合工程实际需求的重要意义与价值。

国外学者提出了所谓的逆向神经网络方法以实现反向预测分析功能。其中一种方法是按照一定准则将逆向神经网络训练样本划分为若干子样本,利用子样本训练子逆模型,若子逆模型仍存在多值映射问题^[6],则重新划分训练样本直至此问题不再出现。通过合并各子逆模型即形成逆向神经网络模型。Kabir、Lakshmi、Dervenis 等^[7-9]将此方法用于螺旋电感的结构设计中,藉此获得对应给定品质因数的螺旋电感结构参数,但这一方法在其他工程领域的应用尚未见诸报告。应该指出,这个方法的主要问题在于人为干涉因素较多,确定训练样本划分和判断子逆模型多值映射问题均取决于设计者,随机不确定性较为强烈;此外,划分训练样本过程过于繁复,工程实用性比较差。

基于逆向神经网络思想的另一种方法则是根据神经网络模型,构建反映输入与输出变量拟合关系的显式函数,在其他输入变量固定的情况下,通过此拟合函数求解对应给定输出值的某个输入变量。应用此方法开展的研究工作有:Hamzaoui 等^[10-11]分别针对给定蒸汽轮机叶片寿命预测对应的共振应力,以及预测了化学需氧量(chemical oxygen demand, COD)移除过程中商用除草剂的化学反应时间。Labus 和 Laidi 等^[12-13]分别预测了吸收式制冷系统中的冷却水流量和太阳能辅助制冷系统的活性炭质量。Marquez-Nolasco 等^[14]预测了吸收式热转换器的蒸汽进口温度。同样需要指出的是,与待预测输入变量相关的其他输入变量,其数值的准确确定较为困难,这一缺陷限制了此方法的工程应用。此外,上述研究工作也未涉及到待预测输入变量的取值约束问题。

针对发动机中介轴承润滑设计的工程需求,本文提出了基于中介轴承润滑效率的流道结构参数反向预测方法。通过构建流道结构参数——轴承润滑效率神经网络,拟合出流道结构参数与轴承润滑效率的函数关系式(润滑效率函数),以给定润滑效率与润滑效率函数值的误差最小作为目标,通过优化分析获得满足给定润滑效率(误差最小)的流道结构参数。本文提出的反向预测方法自主适应能力强,可同时实现多个结构参数的预测,具有明显的工程应用意义。

1 中介轴承润滑流道结构及轴承润滑效率

图 1 示意性地给出了中介轴承润滑流道结构。涉及的主要结构参数有:环下供油孔直径 d_4 和数目 m_4 、密封座供油孔直径 d_5 和数目 m_5 、高压转子油孔直径 d_3 、篦齿密封和隙缝密封的节流间隙 δ_1 和 δ_2 、收油孔直径 d_1 和数目 m_1 、低压转子油孔直径 d_2 和数目 m_2 ,考虑到工程应用,各结构参数取值及其范围如表 1 所示。

经收油孔进入轴承润滑流道中的滑油在高低

压转子旋转离心作用下向流道各出口流动,流道出口有环下供油孔出口、密封座供油孔出口、篦齿密封^[15-16]和隙缝密封出口。各出口的滑油流量彼此之间互为相关,其中环下供油孔出口的滑油是润滑轴承的有效供给,为此定义中介轴承润滑效率为环下供油孔出口滑油流量与收油孔进油流量之比^[5]。




图 1 中介轴承润滑流道结构示意图

Fig. 1 Structure of intershaft bearing lubrication flow-path

表 1 结构参数及其取值

Table 1 Structure parameters and values

结构参数	取值范围
d_3	[1.5,5.5]
d_4/mm	[0.5,2]
m_4	[4,10]
d_5/mm	[0.5,3.5]
m_5	[4,8]
δ_1/mm	[0.05,0.35]
δ_2/mm	[0.05,0.35]
d_1/mm	8
d_2/mm	3.5
m_1	8
m_2	4

2 反向预测分析模型

2.1 轴承润滑效率函数

为获取流道结构参数——轴承润滑效率神经网络模型所需的计算样本组,首先结合流道结构参数对轴承润滑效率的影响分析开展单因素试验

设计。在此基础上,为进一步保证样本数目的充足性和选样的科学性,采用了广泛应用于参数影响研究中,具有很好样本选择科学性的正交试验设计方法,通过正交试验设计进一步补充了更多的计算样本量。

根据单因素和正交试验设计获得的多组流道结构参数,利用文献[5]中的 CFD 有限元仿真方法,计算出各组流道结构参数对应的轴承润滑效率,由此形成流道结构参数——轴承润滑效率计算样本库,通过样本库训练获得相应的神经网络模型^[17-18]。

图 2 给出了流道结构参数——轴承润滑效率神经网络结构示意图。由于神经网络的输入层和输出层通过各层神经元(变量)以权值和阈值相连接,故而对于变量数目多和变量关系复杂的情况,利用由神经网络训练得到的权值和阈值进行函数拟合,较之多项式拟合更为优越。




图 2 神经网络结构示意图

Fig. 2 Structure of neural network

神经网络中的输入层变量 $I_n (n=1, \dots, N)$ 代表流道结构参数,隐含层首层变量 $H_{1,m} (m=1, \dots, M)$ 通过输入层变量 I_n 及其与首层隐含层的连接权值 $w_{n,m}^i$ 求得

$$H_{1,m} = \sum_{n=1}^N (I_n w_{n,m}^i) \tag{1}$$

隐含层第二层变量 $H_{2,m} (m=1, \dots, M)$ 通过隐含层首层变量 $H_{1,m}$ 及两层隐含层之间的阈值 $b_{1,m}$ 求得

$$H_{2,m} = \frac{2}{1 + \exp[-2(H_{1,m} + b_{1,m})]} - 1 \tag{2}$$

将式(1)代入式(2)得

$$H_{2,m} = \frac{2}{1 + \exp\left\{-2\left[\sum_{n=1}^N (I_n w_{n,m}^i) + b_{1,m}\right]\right\}} - 1 \tag{3}$$

输出层的首层变量 η_1 由隐含层第二层变量 $H_{2,m}$ 及其与首层输出层的连接权值 w_m^o 求得

$$\eta_1 = \sum_{m=1}^M (H_{2,m} w_m^o) \tag{4}$$

将式(3)代入式(4)得

$$\eta_1 = \sum_{m=1}^M \left\{ \frac{2}{1 + \exp \left[-2 \left(\sum_{n=1}^N (I_n w_{n,m}^i) + b_{1,m} \right) \right]} - 1 \right\} w_m^o \tag{5}$$

输出层的第二层变量 η (轴承润滑效率)通过输出层首层变量 η_1 及两个输出层之间的阈值 b_2 求得

$$\eta = \eta_1 + b_2 \tag{6}$$

将式(5)代入式(6),得到反映流道结构参数 I_n 与轴承润滑效率 η 拟合关系的润滑效率函数表达式

$$\eta(I_1, \dots, I_N) = \sum_{m=1}^M \left\{ \frac{2}{1 + \exp \left[-2 \left(\sum_{n=1}^N (I_n w_{n,m}^i) + b_{1,m} \right) \right]} - 1 \right\} w_m^o + b_2 \tag{7}$$

将输入层变量及其与首层隐含层变量的连接权值以向量形式表示为 $\mathbf{I} = (I_1, \dots, I_N)$, $\mathbf{w}_m^i = (w_{1,m}^i, \dots, w_{N,m}^i)$, 则式(7)可以进一步写为

$$\eta(\mathbf{I}) = \sum_{m=1}^M \left\{ \frac{2}{1 + \exp[-2(\mathbf{I} \cdot (\mathbf{w}_m^i)^T + b_{1,m})]} - 1 \right\} w_m^o + b_2 \tag{8}$$

式(8)即为通过流道结构参数——轴承润滑效率神经网络模型获得的润滑效率函数。式(8)的准确性验证,在反向预测分析实例中通过对式(12)的验证实现,因为当神经网络连接权值和阈值确定后,式(8)就转化为式(12),而连接权值和阈值是在已知多组流道结构参数和计算出对应的轴承润滑效率后确定的。

2.2 基于润滑效率误差的反向预测分析

在构造润滑效率函数值与给定润滑效率的误差函数时,基于工程实际需要,以及考虑通过对误差函数最小的优化获得满足给定润滑效率的流道结构参数,将这一误差函数表示为

$$E(\mathbf{I}) = 0.5 \times [\eta(\mathbf{I}) - \eta_e]^2 \tag{9}$$

式中 η_e 为给定的轴承润滑效率。

根据轴承润滑流道各结构参数的取值约束,引入罚因子 r 形成包含误差函数和约束条件的优化目标函数

$$P(\mathbf{I}, r) = E(\mathbf{I}) - r \times \sum_{n=1}^N \left(\frac{1}{a_n - I_n} + \frac{1}{I_n - b_n} \right) \tag{10}$$

式中 b_n 和 a_n 分别为流道结构参数 I_n 取值范围的上、下限($n=1, \dots, N$); $r \times \sum_{n=1}^N \left(\frac{1}{a_n - I_n} + \frac{1}{I_n - b_n} \right)$ 为惩罚项。

优化目标函数 $P(\mathbf{I}, r)$ 的极小值点为其一阶导函数 $\nabla P(\mathbf{I}, r)$ 的零点,即方程组 $\nabla P(\mathbf{I}, r) = 0$ 的解 $\mathbf{I}_e$ 。由于 $\mathbf{I}_e$ 的解析解难以直接求得,故采用牛顿法进行若干次迭代计算以使流道结构参数 $\mathbf{I}^{(k)}$ (k 为目标函数最小值的求解迭代次数),趋近于其准确解 $\mathbf{I}_e$,迭代公式如下:

$$\mathbf{I}^{(k+1)} = \mathbf{I}^{(k)} - [\mathbf{H}(\mathbf{I}^{(k)}, r)]^{-1} \nabla P(\mathbf{I}^{(k)}, r) \tag{11}$$

式中 $\mathbf{H}(\mathbf{I}^{(k)}, r)$ 为海塞矩阵。

由于优化目标函数 $P(\mathbf{I}, r)$ 包含误差函数和惩罚项,因此其导函数 $\nabla P(\mathbf{I}, r) = 0$ 不代表误差函数 $E(\mathbf{I})$ 的导函数也为 0 (误差函数取值最小),故还需进行罚因子迭代计算以使惩罚项趋近于 0,此时 $P(\mathbf{I}, r)$ 函数值近似等于 $E(\mathbf{I})$ 函数值, $\nabla P(\mathbf{I}, r) = 0$ 的解即为 $\nabla E(\mathbf{I}) = 0$ 的解。

$\nabla E(\mathbf{I}) = 0$ 的解为润滑效率函数值与给定润滑效率误差最小时的流道结构参数,亦即给定润滑效率对应的结构参数。

图 3 给出了基于轴承润滑效率的流道结构参数反向预测分析流程,整个流程包括优化目标函数构造模块和优化求解模块,流道结构参数的迭代及罚因子的迭代计算流程见优化求解模块。




图 3 反向预测分析流程

Fig. 3 Flow diagram of inverse prediction analysis

3 反向预测分析实例及与相关分析方法的对比

3.1 反向预测分析实例

根据文中第 2.1 节所给润滑效率函数构造方

$$\eta(d_3, \cdots, \delta_2) =$$

$$\sum_{m=1}^{12} \left\{ \left\{ \frac{2}{1 + \exp[-2(d_3 w_{1,m}^i + d_4 w_{2,m}^i + m_4 w_{3,m}^i + d_5 w_{4,m}^i + m_5 w_{5,m}^i + \delta_1 w_{6,m}^i + \delta_2 w_{7,m}^i + b_{1,m})]} - 1 \right\} w_m^o \right\} \tag{12}$$

式中 $d_3, d_4, m_4, d_5, m_5, \delta_1$ 和 δ_2 为流道结构参数; $w_{n,m}^i (n=1, \cdots, 7), w_m^o, b_{1,m}$ 分别为神经网络输入层与首层隐含层、第二层隐含层与首层输出层之

法,对图 1 所示的流道结构参数进行相关计算,获得反映流道结构参数与轴承润滑效率拟合关系的润滑效率函数表达式:

间的连接权值和两个隐含层之间阈值,如表 2~表 4 所示。

表 2 神经网络输入层与首层隐含层的连接权值 $w_{n,m}^i$

Table 2 Weights between input layer and the first hidden layer of neural network ($w_{n,m}^i$)

n	$w_{n,m}^i$											
	m=1	m=2	m=3	m=4	m=5	m=6	m=7	m=8	m=9	m=10	m=11	m=12
1	−0.05	0.28	−0.48	−1.08	−0.12	0.13	−0.54	0.26	0.18	0.53	−0.59	−0.35
2	0.19	0.33	−0.59	0.44	−0.39	−0.75	−0.76	0.02	−0.10	−0.32	−0.65	−0.77
3	0.50	0.67	−0.26	0.20	0.32	0.09	−0.15	0.76	−0.23	0.55	−0.98	−0.75
4	−0.05	0.13	−0.49	0.66	0.02	−0.84	0.11	0.42	0.86	−0.01	−0.07	−0.58
5	−0.75	0.17	−0.33	−0.81	−0.55	0.48	−0.53	0.51	−0.26	−0.38	−0.08	0.37
6	−0.30	−0.28	0.54	0.21	−0.22	0.97	0.47	−0.39	−0.75	0.32	0.66	−0.61
7	−0.73	0.26	0.11	0.01	−0.70	0.24	0.74	0.50	−0.63	−0.24	−0.04	0.31

表 3 两个隐含层之间的阈值 $b_{l,m}$

Table 3 Biases between two hidden layers ($b_{l,m}$)

参数	m=1	m=2	m=3	m=4	m=5	m=6	m=7	m=8	m=9	m=10	m=11	m=12
$b_{l,m}$	−1.71	−1.25	−0.92	0.74	−0.56	−0.12	0.129	−0.63	−0.86	1.05	−1.02	−1.58

表 4 第二层隐含层与首层输出层的连接权值 w_m^o

Table 4 Weights between the second hidden layer and the first output layer (w_m^o)

参数	m=1	m=2	m=3	m=4	m=5	m=6	m=7	m=8	m=9	m=10	m=11	m=12
w_m^o	0.604	−0.63	−0.549	−0.74	−0.37	0.54	−0.39	−0.74	0.74	0.042	−0.33	−0.42

对式(12)进行正确性验证。在表 1 给出的结构参数取值范围内,再选取了另外 10 组流道结构参数(不同于单因素和正交试验设计的计算样本),分别通过 CFD 有限元仿真方法和式(12)计算出对应的轴承润滑效率。对比结果如图 4 所示。可以看出各组结构参数对应的润滑效率有限元仿真值和式(12)计算值相差不大,表明了润滑效率计算式(12)的正确性,也证明了式(8)的正确性。

根据式(9)构造润滑效率函数值与给定润滑效率的误差函数

$$E(d_3,\cdots,\delta_2)=0.5\times[\eta(d_3,\cdots,\delta_2)-\eta_e]^2$$

(13)

根据各结构参数取值约束,形成包含误差函数和约束条件的优化目标函数

$$P(d_3,\cdots,\delta_2,r)=E(d_3,\cdots,\delta_2)-r\times\left(\frac{1}{1.5-d_3}+\frac{1}{d_3-5.5}+\frac{1}{0.5-d_4}+\frac{1}{d_4-2}+\frac{1}{4-m_4}+\right.\\ \left.\frac{1}{m_4-10}+\frac{1}{0.5-d_5}+\frac{1}{d_5-3.5}+\frac{1}{4-m_5}+\frac{1}{m_5-8}+\frac{1}{0.05-\delta_1}+\frac{1}{\delta_1-0.35}+\right.\\ \left.\frac{1}{0.05-\delta_2}+\frac{1}{\delta_2-0.35}\right)$$

(14)




图 4 轴承润滑效率的有限元仿真与式(12)计算结果对比

Fig. 4 Comparison between the bearing lubrication efficiency calculated by finite element method and the formula (12)

利用式(11)对流道结构参数 $d_3, \dots, \delta_2$ 进行迭代,以求解方程组 $\nabla P(d_3, \dots, \delta_2, r) = 0$,并对罚因子 r 进行迭代,得到 $\nabla E(d_3, \dots, \delta_2) = 0$ 的解,即对应误差函数取值最小的流道结构参数,亦即对应给定润滑效率 η_e 的结构参数。

当 η_e 取值为70%、75%、80%和85%时,采用上述方法预测得到对应的流道结构参数如图5所示。

根据文献[5]可知,轴承润滑效率 η 随高压转子油孔直径 d_3 、环下供油孔直径 d_4 和数目 m_4 的增加而增大,随密封座供油孔直径 d_5 、数目 m_5 和篦齿密封、隙缝密封节流间隙 δ_1 、 δ_2 的增加而减小。图4所示结果与这一变化规律相契合,即在较高的轴承润滑效率下,结构参数 d_3 、 d_4 、 m_4 较大,而 d_5 、 m_5 、 δ_1 和 δ_2 较小,这表明了本文所提出反向预测分析方法的可行性和合理性。

3.2 反向预测分析方法与相关分析方法的对比

根据本文引言中对于国内外相关研究现状的分析可知,目前已有的两种相关分析方法均存在





图 5 4 种给定润滑效率下的流道结构参数
Fig. 5 Structure parameters of flow-path corresponding to the four given lubrication efficiencies

一定不足:方法1(基于子逆模型的逆向神经网络预测方法)的人为干涉因素多,随机不确定性强烈,同时存在工程实用性差的弊端^[7];方法2(基于显式函数的反向预测方法)不能同时实现多个输入变量的预测^[10],无法藉此开展对应给定轴承润滑效率的多个流道结构参数预测分析。因此这里仅进行方法1与本文反向预测分析方法的对比,以体现本文所提出方法的先进性。主要处理流程见下文。

给定4种轴承润滑效率(η_e 分别为70%、75%、80%和85%),分别利用本文的反向预测方法和方法1预测出各自对应的流道结构参数,如表5所示;然后针对这两种预测方法获得的流道结构参数,通过CFD有限元仿真分别求得各自的轴承润滑效率;对比反向预测方法获得之流道结构参数下的轴承润滑效率仿真计算值 η' 与给定的轴承润滑效率 η_e ,以及对比由方法1获得的流

表 5 4 种给定轴承润滑效率下本文反向预测方法和方法 1 预测所得流道结构参数

Table 5 Structure parameters of flow-path obtained by the inverse prediction method of this paper and the approach 1 corresponding to the four given bearing lubrication efficiency								
$\eta_e / \%$	预测方法	d_3 / mm	d_4 / mm	m_4	d_5 / mm	m_5	δ_1 / mm	δ_2 / mm
70	本文方法	1.35	2.92	8	1.10	6	0.19	0.16
	方法 1	1.40	2.85	8	1.19	6	0.25	0.20
75	本文方法	1.47	3.14	8	0.85	4	0.17	0.12
	方法 1	1.39	2.90	8	0.96	4	0.20	0.17
80	本文方法	1.87	3.71	10	0.56	4	0.14	0.11
	方法 1	1.49	3.11	10	0.75	4	0.18	0.12
85	本文方法	1.98	3.95	10	0.50	4	0.10	0.086
	方法 1	1.57	3.32	10	0.62	4	0.13	0.10

道结构参数下的轴承润滑效率仿真计算值 η'' 与给定轴承润滑效率 η_e , 以体现本文提出的反向预测方法在预测准确性方面的优势。

依据上述处理流程获得的计算结果如图 6 所示。可以看出,相较于方法 1 获得的 4 组流道结构参数的润滑效率 η'' , 由反向预测方法获得的 4 组流道结构参数的润滑效率 η' 更接近润滑效率给定值 η_e , 表明了反向预测方法更为准确。通过计算,反向预测方法的预测精度比方法 1 的预测精度提高了 4.39%。

表 6 给出了本文的反向预测方法和方法 1 在流道结构参数预测过程中的计算用时。可以看出,在预测 4 种轴承润滑效率对应的流道结构参数时,方法 1 的计算用时在 20~25 min 之间波动,而本文方法的计算用时较短且稳定在 5 min。其原因是方法 1 需对逆向神经网络训练样本进行划分,若子样本仍存在多值映射问题,还需重新划

分样本,这极大地增加了方法 1 的计算时长,制约着该方法在工程中的应用。




图 6 4 组流道结构参数对应的润滑效率 η_e 、 η' 和 η''
Fig. 6 Lubrication efficiency (η_e, η', η'') corresponding to the four groups of flow-path structure parameters

表 6 方法 1 和本文方法的计算用时
Table 6 Calculation time by approach 1 and the proposed approach of this paper

预测方法	计算用时/min				平均用时/min
	$\eta_e=70\%$	$\eta_e=75\%$	$\eta_e=80\%$	$\eta_e=85\%$	
方法 1	22	25	23	20	22.5
本文方法	5	5	5	5	5

4 结 论

- 1) 本文提出的反向预测分析方法,即构造反映结构参数与润滑效率拟合关系的润滑效率函数,并以润滑效率函数值与给定润滑效率的误差最小为优化目标,通过优化分析获得满足给定润滑效率(误差最小)的流道结构参数。
- 2) 4 种轴承润滑效率下的反向预测分析结果表明:高润滑效率对应的高压转子直径、环下供油孔直径及数目较大,而密封座供油孔直径、数目与篦齿密封、隙缝密封节流间隙较小。
- 3) 本文所提反向预测分析方法与相关分析方法的对比表明:本文方法的预测精度提高了 4.39%,平均计算耗时缩短了 17.5 min,有较好的工程应用价值。

参考文献:

[1] 胡绚,罗贵火,高德平. 航空发动机中介轴承的特性分析[J]. 航空动力学报,2007,22(3):439-443.
HU Xuan,LUO Guihuo,GAO Deping. Performance analy-

sis of aero-engine intershaft bearing[J]. Journal of Aerospace Power,2007,22(3):439-443. (in Chinese)

[2] KRUG M B,PEDUTO D,KURZ W, et al. Experimental investigation into the efficiency of an aero engine oil jet supply system[R]. ASME Paper GT2014-26208,2014.

[3] SANTHOSH R,HEE J L,SIMMONS K, et al. Experimental investigation of oil shedding from an aero-engine ball bearing at moderate speeds [R]. ASME Paper GT2017-63815,2017.

[4] HEE J L,SANTHOSH R,SIMMONS K, et al. Oil film thickness measurements on surfaces close to an aero-engine ball bearing using optical techniques[R]. ASME Paper GT2017-63813,2017.

[5] 朱冬磊,陈国定,李炎军,等. 中介轴承环下流道滑油流动及润滑效率分析[J]. 航空学报,2019,40(11):309-323.
ZHU Donglei,CHEN Guoding,LI Yanjun, et al. Inner ring oil flow and lubrication efficiency analysis of intershaft bearing[J]. Acta Aeronautica et Astronautica Sinica,2019,40(11):309-323. (in Chinese)

[6] RAYAS-SANCHEZ J E. EM-based optimization of microwave circuits using artificial neural networks;the state-of-the-art[J]. IEEE Transactions on Microwave Theory and Techniques,2004,52(1):420-435.

[7] KABIR H,WANG Y,YU M, et al. Neural network in-

verse modeling and applications to microwave filter design [J]. IEEE Transactions on Microwave Theory and Techniques, 2008, 56(4): 867-879.

[8] LAKSHMI K S R K J, REDDY N D L P. A neural network inverse modeling approach for the design of spiral inductor[J]. International Journal of Computer Science and Engineering Technology, 2018, 2(3): 54-62.

[9] DERVENIS N, ALEXANDRIDIS G, STAFYLOPATIS A. Neural network specialists for inverse spiral inductor design[C] // Proceedings of International Conference on Tools with Artificial Intelligence (ICTAI). Volos, Greece: IEEE, 2018: 60-64.

[10] HAMZAOUI Y E, RODRIGUEZ J A, HERNANDEZ J A, et al. Optimization of operating conditions for steam turbine using an artificial neural network inverse[J]. Applied Thermal Engineering, 2015, 75: 648-657.

[11] HAMZAOUI Y E, HERNANDEZ J A, SILVA-MARTINEZ S, et al. Optimal performance of COD removal during aqueous treatment of alazine and gesaprim commercial herbicides by direct and inverse neural network[J]. Desalination, 2011, 277(1/2/3): 325-337.

[12] LABUS J, HERNANDEZ J A, BRUNO J C, et al. Inverse neural network based control strategy for absorption chillers[J]. Renewable Energy, 2012, 39(1): 471-482.

[13] LAIDI M, HANINI S. Optimal solar COP prediction of a solar-assisted adsorption refrigeration system working with activated carbon/methanol as working pairs using direct and inverse artificial neural network[J]. International Journal of Refrigeration, 2013, 36(1): 247-257.

[14] MARQUEZ-NOLASCO A, CONDE-GUTIERREZ R A, HERNANDEZ J A, et al. Optimization and estimation of the thermal energy of an absorber with graphite disks by using direct and inverse neural network[J]. Journal of Energy Resources Technology, 2018, 140(2): 020906. 1-020906. 13.

[15] 杨淋麟, 张丽, 朱惠人. 篦齿结构对封严性能的影响[J]. 科学技术与工程, 2013, 13(33): 10069-10073.

ZHANG Linlin, ZHANG Li, ZHU Hui ren. Effect of labyrinth structure on seal performance[J]. Science Technology and Engineering, 2013, 13(33): 10069-10073. (in Chinese)

[16] 张留祥, 陈俊东, 耿旭辉, 等. 直通式篦齿密封性能的数字模拟与试验研究[J]. 润滑与密封, 2013, 38(10): 51-54.

ZHANG Liuxiang, CHEN Jundong, GENG Xuhui, et al. Numerical simulation and experimental investigation on straight-through labyrinth seal performance[J]. Lubrication and seal, 2013, 38(10): 51-54. (in Chinese)

[17] 魏海坤. 神经网络结构设计的理论与方法[M]. 北京: 国防工业出版社, 2005.

[18] BASSAM A, CONDE-GUTIERREZ R A, CASTILLO J, et al. Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement[J]. Fuel, 2014, 124: 158-167.

(编辑: 陈 越)