

基于最佳代理模型的液力变矩器多目标优化设计

陈洁*, 邱毅凡

华域动力总成部件系统(上海)有限公司, 上海

收稿日期: 2025年6月16日; 录用日期: 2025年7月9日; 发布日期: 2025年7月18日

摘要

为了缩短优化设计周期, 应用最佳代理模型结合基于非支配排序遗传算法II (NSGA-II) 的多目标优化方法进行液力变矩器优化设计。建立了液力变矩器参数化流道模型, 应用灵敏度分析方法筛选出对液力性能影响较大的关键设计参数用于优化设计变量。分别对比分析了多项式响应面法、径向基神经网络法、广义回归神经网络法、克里金法和支持向量回归法对液力性能的预测精度, 结果表明, 对于本文设计优化问题, 支持向量回归法具有最佳的预测精度。基于最佳预测代理模型对液力变矩器动力性、经济性和与发动机匹配性进行多目标优化, 选择一组合适的优化设计参数进行样件制造并进行试验验证。结果表明, 本文方法可以为液力变矩器的优化设计提供有效的解决方案。

关键词

液力变矩器, 参数化设计, 代理模型, 多目标优化设计

Multi-Objective Optimization Design of a Torque Converter Based on Optimal Surrogate Model

Jie Chen*, Yifan Qiu

Hasco Powertrain Components Systems (Shanghai) Co., Ltd., Shanghai

Received: Jun. 16th, 2025; accepted: Jul. 9th, 2025; published: Jul. 18th, 2025

Abstract

To reduce the total design and optimization time, the optimal surrogate model coupled with a multi-

*通讯作者。

objective optimization method based on non-dominated sorting genetic algorithm II (NSGA-II) is used to design optimum impellers for an automotive torque converter. A parameterized flow channel model for the torque converter is established, and sensitivity analysis is applied to select key design parameters which have a significant impact on hydraulic performance for optimizing design variables. We compared and analyzed the prediction accuracy of hydraulic performance using polynomial response surface method, radial basis function neural network method, generalized regression neural network method, kriging method, and support vector regression method. The results showed that for the optimization problem designed in this paper, support vector regression method has the best prediction accuracy. Based on the optimal surrogate model, multi-objective optimization is carried out on the power performance, economy, and matching performance with engine. A suitable group of optimization design parameters is selected for sample manufacturing and experimental verification. Results demonstrate that the presented method can provide an effective solution for the optimization design of torque converters.

Keywords

Torque Converter, Parametric Design, Surrogate Model, Multi-Objective Optimization

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

液力变矩器是传统自动变速系统最重要的部件之一, 因其具有良好的自适应能力、起步性能、低速稳定性和减振隔振性能, 被广泛应用于乘用车、铁道车辆、工程机械、发电机械、矿业冶金机械及化工机械等行业。为了满足液力性能需求, 液力变矩器的优化设计是整个研发过程中必不可少的阶段。文献[1]以叶片内外环偏转角为优化设计参数, 建立了设计、分析和优化集成平台, 结合 CFD 仿真计算与优化算法, 完成液力变矩器的优化设计。文献[2]编制了参数化儒科夫斯基型线导轮叶片设计程序, 并结合自动化液力变矩器三维流场设计分析平台, 利用遗传算法对儒式导轮进行了优化。以上方法是基于建立的液力变矩器设计、分析和优化集成平台进行优化设计, 预测精度上具有一定的优势, 但 CFD 仿真计算耗时较长, 导致整个优化设计的周期大大增加。

文献[3]以叶片进出口角为优化参数, 结合一维束流理论和多目标优化策略对液力变矩器的性能进行优化, 得到多目标优化非劣解集。文献[4]基于修正的一维束流理论, 应用遗传算法完成液力变矩器叶栅系统的优化。以上方法的主要思路是基于一维束流理论预测模型建立优化目标函数, 选择合适的优化算法完成液力变矩器的优化设计。但由于一维束流理论基于多种假设[5], 性能预测精度较低, 从而导致基于该模型的优化设计结果可靠性相对较低。

综上所述, 构建液力变矩器高精度预测模型并结合多目标优化设计方法进行优化设计能够解决预测精度和计算效率不能兼顾的问题, 具有较高的研究价值。本文以某款液力变矩器为研究对象, 建立以对液力性能影响较大的关键设计参数为优化变量, 以最佳动力性、经济性和与发动机匹配性为优化目标的优化设计模型, 并采用基于高精度代理模型的优化设计方法, 分别对液力变矩器关键设计参数进行优化设计。基于多目标优化设计结果, 根据性能要求选择一组优化设计参数并制造样件进行了试验验证, 进一步说明了本研究方法的可靠性。

2. 参数化设计模型

液力变矩器在优化设计过程中必然涉及大量的改型设计, 而液力变矩器叶栅系统结构复杂, 设计过程繁琐, 导致整个设计过程耗时较长, 若每次改型都进行重新设计, 必然大幅度地降低设计效率。本文提出了一种液力变矩器参数化设计方法, 能够快速实现液力变矩器的改型设计, 为代理模型构建过程中大量的三维流场仿真计算提供了模型基础。

2.1. 循环圆参数化设计

首先基于变速箱空间尺寸及锁止离合器部分的轴向尺寸确定液力变矩器循环圆的有效直径和轴向允许的极限尺寸, 基于三段圆弧方法可初步确定变矩器循环圆外环, 取比面积参数为常用值 23% 进一步确定循环圆内环, 根据经验和叶轮间间隙要求初步确定各叶轮叶片进出口半径。所研究液力变矩器有效直径为 220 mm, 最终确定的循环圆如图 1 所示。

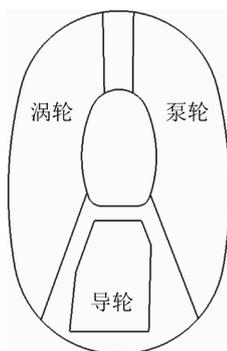


Figure 1. Torque converter torus design
图 1. 液力变矩器循环圆设计

2.2. 叶栅系统参数化设计

基于循环圆完成液力变矩器叶栅系统的参数化设计。对于泵轮, 首先确定叶片内外环二维设计曲线, 泵轮叶片内外环二维设计曲线由一段圆锥曲线构成, 示意图如图 2 所示。二维设计曲线设计完成后通过保角变换获取泵轮叶片内外环三维空间曲线, 又由叶片厚度、叶片内外环偏转角和泵轮叶片数最终完成泵轮叶栅系统的参数化设计。本次泵轮叶栅系统设计涉及的主要设计参数如表 1 所示。

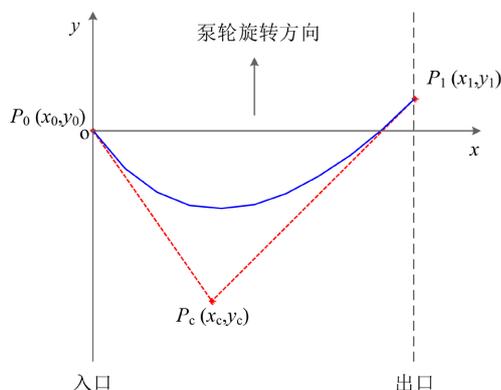
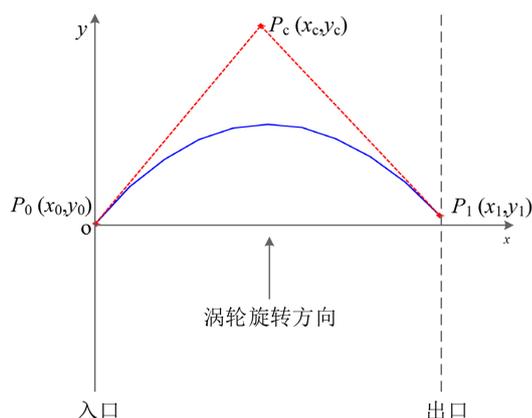


Figure 2. Two-dimensional design curve for pump blades inner and outer torus
图 2. 泵轮叶片内外环二维设计曲线示意图

Table 1. Pump main design parameters**表 1.** 泵轮主要设计参数

参数编号	参数符号/单位	参数名称
P1	$\alpha_p /(^{\circ})$	泵轮叶片偏转角
P2	z_p	泵轮叶片数
P3	l_{p_O} / mm	泵轮叶片外环周向偏移
P4	l_{p_I} / mm	泵轮叶片内环周向偏移
P5	$\beta_{pO_I} /(^{\circ})$	泵轮叶片内环出口角
P6	$\beta_{pI_I} /(^{\circ})$	泵轮叶片内环进口角
P7	$\beta_{pO_O} /(^{\circ})$	泵轮叶片外环出口角
P8	$\beta_{pI_O} /(^{\circ})$	泵轮叶片外环进口角
P9	f_{c,p_O}	泵轮叶片外环圆锥曲线参数
P10	f_{c,p_I}	泵轮叶片内环圆锥曲线参数

同样地, 对液力变矩器涡轮进行参数化设计, 涡轮叶片内外环二维设计曲线示意图如图 3 所示。涡轮叶片内外环二维设计曲线由一段圆锥曲线构成, 已知涡轮叶片内外环对应的循环圆曲线和二维设计曲线, 通过保角变换可以分别求得涡轮叶片内外环三维空间曲线, 又由涡轮叶片厚度、叶片内外环偏转角和涡轮叶片数最终完成涡轮叶栅系统的参数化设计。本次涡轮叶栅系统设计涉及的主要设计参数如表 2 所示。

**Figure 3.** Two-dimensional design curve for turbine blades inner and outer torus**图 3.** 涡轮叶片内外环二维设计曲线示意图**Table 2.** Turbine main design parameters**表 2.** 涡轮主要设计参数

参数编号	参数符号/单位	参数名称
T1	$\alpha_T /(^{\circ})$	涡轮叶片偏转角
T2	z_T	涡轮叶片数
T3	l_{T_O} / mm	涡轮叶片外环周向偏移
T4	l_{T_I} / mm	涡轮叶片内环周向偏移
T5	$\beta_{TO_I} /(^{\circ})$	涡轮叶片内环出口角
T6	$\beta_{TI_I} /(^{\circ})$	涡轮叶片内环进口角

续表

T7	$\beta_{TO_O}/(^{\circ})$	涡轮叶片外环出口角
T8	$\beta_{TI_O}/(^{\circ})$	涡轮叶片外环进口角
T9	f_{c,T_O}	涡轮叶片外环圆锥曲线参数
T10	f_{c,T_I}	涡轮叶片内环圆锥曲线参数

与泵轮和涡轮不同, 导轮的叶片为非等厚叶片, 叶片厚度尺寸轮廓涉及更多的设计参数。导轮叶片厚度轮廓的设计主要包括叶片厚度中弧线的设计和沿中弧线变化规律曲线的设计。本次设计导轮叶片内外环厚度轮廓中弧线均由一段圆锥曲线构成, 中弧线设计示意图如图 4 所示。导轮叶片厚度沿中弧线变化规律曲线是由四段相切的圆弧构成, 设计时压力面和吸力面仅叶片尾缘半径尺寸参数不同, 其余参数保持一致。导轮叶片内外环厚度沿中弧线变化规律示意图如图 5 所示, 其中, R_{SI} 为导轮叶片进口端圆弧半径, R_{SO} 为导轮叶片尾缘圆弧半径, $2t_{s_max}$ 为导轮叶片最大厚度, l_{St} 为导轮叶片最大厚度位置参数。导轮参数化设计涉及到的主要设计参数如表 3 所示, 需要注意的是厚度变化规律相关设计参数内环与外环单位是分别与各自的内外环循环圆长度成比例的, 以导轮叶片进口端圆弧半径为例, 导轮叶片内环进口端圆弧半径 R_{SI_I} 与对应的内环循环圆长度 L_{S_I} 成比例, 而导轮叶片外环进口端圆弧半径 R_{SI_O} 与对应的外环循环圆长度 L_{S_O} 成比例, 导轮叶片内外环循环圆长度往往是不同的。

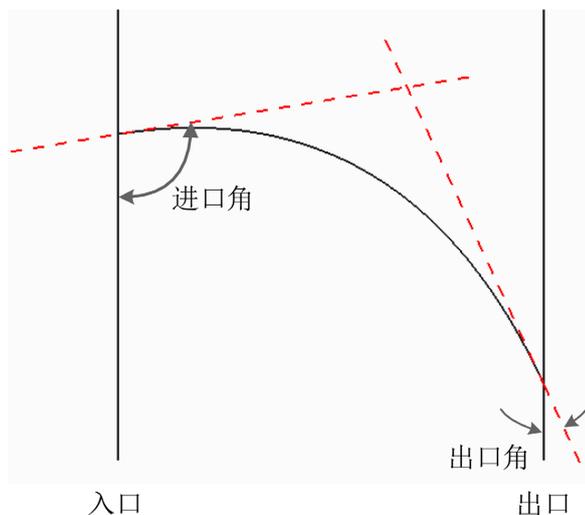


Figure 4. Thickness contour arc design for stator blades inner and outer torus
图 4. 导轮叶片内外环厚度轮廓中弧线设计示意图

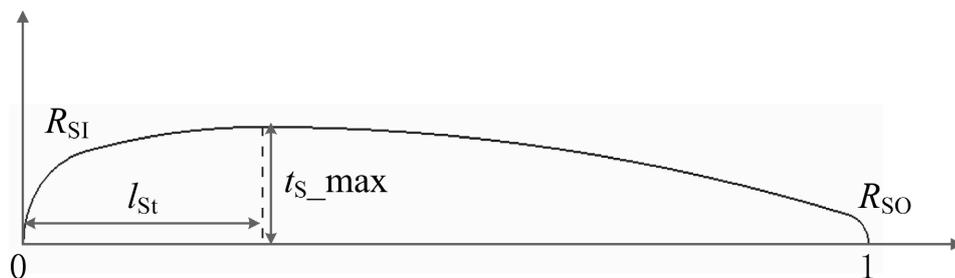
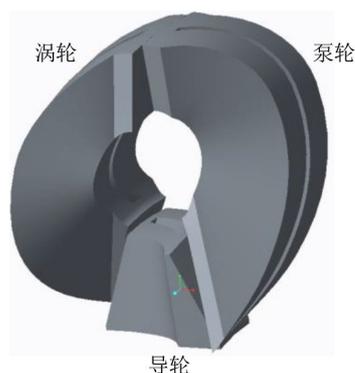


Figure 5. Thickness variation law of stator blades inner and outer torus along the central arc line
图 5. 导轮叶片内外环厚度沿中弧线变化规律示意图

Table 3. Stator main design parameters**表 3.** 导轮主要设计参数

参数编号	参数符号/单位	参数名称
S1	z_s	导轮叶片数
S2	$\alpha_s / (^\circ)$	导轮叶片偏转角
S3/S12	$\beta_{s1} / (^\circ)$	导轮叶片内/外环进口角
S4/S13	l_s / mm	导轮叶片内/外环周向偏移
S5/S14	$\beta_{s0} / (^\circ)$	导轮叶片内/外环出口角
S6/S15	$f_{c,s}$	导轮叶片内/外环圆锥曲线参数
S7/S16	$t_{s_max} / (*L_s)$	导轮叶片内/外环最大厚度(1/2)
S8/S17	$R_{sPO} / (*L_s)$	导轮叶片内/外环压力面尾缘圆弧半径
S9/S18	$R_{sI} / (*L_s)$	导轮叶片内/外环进口端圆弧半径
S10/S19	$R_{sSO} / (*L_s)$	导轮叶片内/外环吸力面尾缘圆弧半径
S11/S20	l_{st}	导轮叶片内/外环最大厚度位置参数

循环圆和叶栅系统参数化设计完成后即可得到目标液力变矩器初步参数化三维几何设计模型, 同样可以建立对应的参数化单流道设计模型, 为三维流场仿真计算提供模型基础, 液力变矩器参数化单流道模型如图 6 所示。

**Figure 6.** Single-channel parametric model of the torque converter**图 6.** 液力变矩器参数化单流道模型

3. 代理模型构建

3.1. 灵敏度分析

为了提高优化设计效率, 对液力变矩器主要设计参数进行灵敏度分析, 筛选出对液力性能影响较大的关键设计参数。首先根据统计数据和经验公式, 同时保证参数化设计模型不过度扭曲, 最终限定液力变矩器各主要设计参数变动范围, 结果如表 4 所示。考虑到在参数化设计时必须保证导轮叶片最大厚度(1/2)大于导轮叶片进口端圆弧半径, 表中将导轮叶片最大厚度限定范围转换为对两者差值的范围进行限定。应用正交设计方法建立 3 水平 40 因子的 81 个试验设计样本, 并根据每一组样本的设计参数组合更新液力变矩器参数化设计模型, 分别进行三维流场仿真计算, 计算结果如图 7 所示。应用基于正交设计的灵敏度分析方法对 81 个计算样本进行灵敏度分析, 求出各设计参数对不同性能评价指标的贡献度, 结果如图 8 所示。图 8 中, 1~10 分别代表泵轮相关设计参数 P1~P10, 11~30 分别代表导轮相关设计参数

S1~S20, 31~40 分别代表涡轮相关设计参数 T1~T10。基于以下原则选择对液力变矩器性能影响较大的关键设计参数: 该参数至少对两个性能响应的贡献度不低于 3%。最终确定的关键设计参数及其对液力变矩器液力性能的最大贡献度如表 5 所示。

Table 4. Main design parameters variation range
表 4. 主要设计参数变动范围

参数编号	参数范围	参数编号	参数范围
P1	[-2.5, 0.5]	S1	[21, 35]
P2	[27, 35]	S2	[-1, 1]
P3	[4, 12]	S3	[75, 95]
P4	[6, 10]	S4	[9, 13]
P5	[25, 45]	S5	[10, 30]
P6	[145, 165]	S6	[0.5, 0.7]
P7	[25, 45]	S7	S9+ [0.005, 0.035]
P8	[145, 165]	S8	[0.02, 0.07]
P9	[0.3, 0.5]	S9	[0.08, 0.14]
P10	[0.3, 0.5]	S10	[0.02, 0.07]
T1	[0, 3]	S11	[0.25, 0.40]
T2	[25, 33]	S12	[75, 95]
T3	[-5, 5]	S13	[6, 10]
T4	[-2.5, 2.5]	S14	[10, 30]
T5	[143, 163]	S15	[0.5, 0.7]
T6	[15, 35]	S16	S18+ [0.005, 0.035]
T7	[143, 163]	S17	[0.02, 0.07]
T8	[15, 35]	S18	[0.08, 0.14]
T9	[0.25, 0.45]	S19	[0.02, 0.07]
T10	[0.25, 0.45]	S20	[0.25, 0.40]

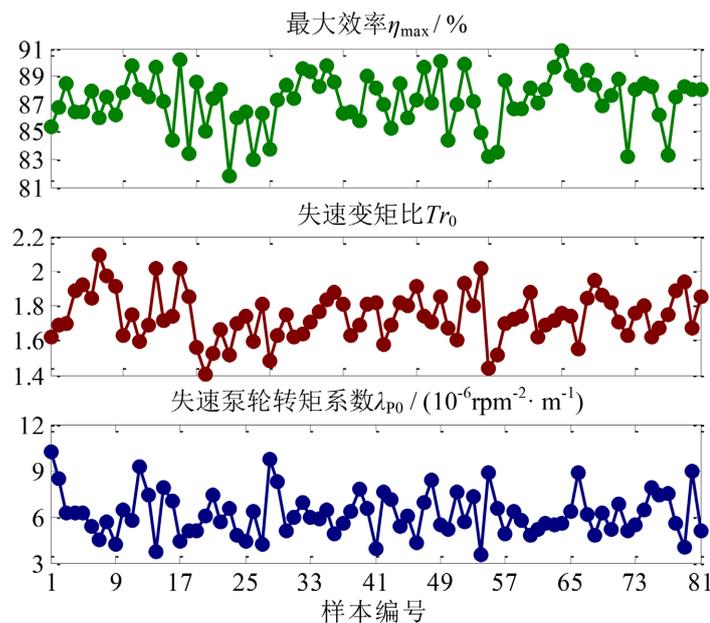


Figure 7. Performance calculation results of torque converter orthogonal design samples
图 7. 液力变矩器正交设计样本性能计算结果

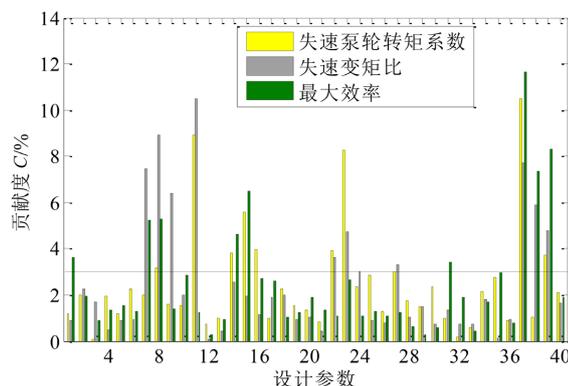


Figure 8. Different performance evaluation indicators contribution of torque converter design parameters
图 8. 液力变矩器各设计参数不同性能评价指标贡献度

Table 5. Key design parameters and maximum contribution

表 5. 关键设计参数及最大贡献度

参数编号	关键设计参数	最大贡献度 $C/\%$
P7	泵轮叶片外环出口角	7.438312
P8	泵轮叶片外环进口角	8.899141
S1	导轮叶片数	10.48208
S4	导轮叶片内环周向偏移	4.624351
S5	导轮叶片内环出口角	6.504602
S12	导轮叶片外环进口角	3.939253
S13	导轮叶片外环周向偏移	8.279419
T7	涡轮叶片外环出口角	11.66140
T8	涡轮叶片外环进口角	7.335631
T9	涡轮叶片外环圆锥曲线参数	8.299191

3.2. 建立代理模型

3.2.1. 基于多项式响应面法性能预测

多项式响应面法(RSM)是一种采用多项式回归技术,对试验或仿真数据进行最小二乘拟合,求出待定系数,从而确定代理模型的一种方法。多项式响应面的数学表达形式为:

$$y(\mathbf{x}) = \sum_{i=1}^p \phi_i f_i(\mathbf{x}) \quad (1)$$

式中, $\mathbf{x} = (\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(m)})$ 为样本输入设计变量, m 为样本数; $f_i(\mathbf{x})$ 为设计变量的第 i 个基函数; p 为基函数的个数; ϕ 为回归参数向量。

回归参数 ϕ 的最小二乘估计为:

$$\hat{\phi} = (F^T(\mathbf{x})F(\mathbf{x}))^{-1} F^T(\mathbf{x})Y \quad (2)$$

式中, $Y = [y^{(1)}, y^{(2)}, \dots, y^{(m)}]^T$, $(i=1, 2, \dots, m)$ 为第 i 个输出变量响应值;

$$F(\mathbf{x}) = \begin{bmatrix} f_1(\mathbf{x}^{(1)}) & f_2(\mathbf{x}^{(1)}) & \dots & f_p(\mathbf{x}^{(1)}) \\ f_1(\mathbf{x}^{(2)}) & f_2(\mathbf{x}^{(2)}) & \dots & f_p(\mathbf{x}^{(2)}) \\ \dots & \dots & \dots & \dots \\ f_1(\mathbf{x}^{(m)}) & f_2(\mathbf{x}^{(m)}) & \dots & f_p(\mathbf{x}^{(m)}) \end{bmatrix} \quad (3)$$

随着响应面法中多项式次数的增加, 性能预测所要求的最低样本数急剧增大, 从而增加了仿真计算量, 降低了性能预测效率, 因此, 在实际应用中多项式次数通常不超过 3 次。不同阶次多项式响应面法要求的最低样本数如表所示, 表 6 中, n 为输入设计变量的维度, 即设计参数的个数。

Table 6. Minimum sample size requirement for response surface methodology with different polynomials orders
表 6. 不同阶次多项式响应面法最低样本数要求

阶次	样本数
1 次	$n + 1$
2 次	$(n + 1)(n + 2)/2$
3 次	$(n + 1)(n + 2)/2 + n$

对代理模型进行性能预测精度评估, 常用的精度评估指标有决定系数 R^2 、均方根误差(RMSE, Root Mean Squared Error)和平均相对误差 e_{avg} , 表达式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^{m_{\text{test}}} (y^{(i)} - \hat{y}^{(i)})^2}{\sum_{i=1}^{m_{\text{test}}} (y^{(i)} - \bar{y})^2} \quad (4)$$

$$RMSE = \sqrt{\frac{1}{m_{\text{test}}} \sum_{i=1}^{m_{\text{test}}} (y^{(i)} - \hat{y}^{(i)})^2} \quad (5)$$

$$e_{\text{avg}} = \frac{1}{m_{\text{test}}} \sum_{i=1}^{m_{\text{test}}} \left(\frac{\hat{y}^{(i)} - y^{(i)}}{y^{(i)}} \right) \quad (6)$$

式中, $y^{(i)}$ 为第 i 个测试样本的仿真计算值; \hat{y} 为第 i 个测试样本的性能预测值; \bar{y} 为所有测试样本仿真计算值的平均值; m_{test} 为测试样本数量。在进行预测精度评估时, R^2 值越大(≤ 1)说明模型精度越高; 而 $RMSE$ 和 e_{avg} 值越小, 模型预测精度越高。由于 R^2 值代表的整体精度更能反映模型的预测能力, 因此, 本文主要选用 R^2 值作为对比分析不同代理模型预测精度的评估指标。

3.2.2. 径向基神经网络法性能预测

径向基神经网络[6] (RBFNN, Radical Basis Function Neural Network)类属于前向神经网络, 包括输入层、隐含层和输出层。输入层由信号源节点组成, 而输出层是对输入模型做出响应。隐含层中的变换函数为径向基函数, 该函数是局部响应函数而非全局响应函数, 为对中心点径向对称且衰减的非负非线性函数。液力变矩器性能预测径向基神经网络一般结构如图 9 所示。

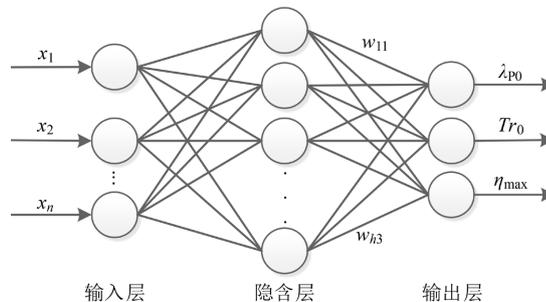


Figure 9. Structure diagram of radial basis function neural network
图 9. 径向基神经网络结构图

径向神经网络中一般常使用高斯函数作为径向基函数, 表示方式如下

$$R(\mathbf{x}^{(k)}, c_i) = \exp\left(-\frac{1}{2\sigma^2} \|\mathbf{x}^{(k)} - c_i\|^2\right), \quad i=1, 2, \dots, h \quad (7)$$

式中, $\mathbf{x}^{(k)}$ 为第 k 个输入样本, $k=1, 2, \dots, m$, m 为样本数; h 为隐含层节点数; c_i 为高斯函数的中心; σ 为高斯函数的方差(即扩散系数)。由径向神经网络的结构可得到网络的输出为:

$$y_j = \sum_{i=1}^h w_{ji} R(\mathbf{x}^{(k)}, c_i), \quad i=1, 2, \dots, h \quad (8)$$

式中, w_{ji} 为隐含层到输出层的连接权重; y_j 为第 j 个输出节点的实际输出。

3.2.3. 广义回归神经网络法性能预测

广义回归神经网络[7] (GRNN, Generalized Regression Neural Network)与径向神经网络较为相似, 它由输入层、模式层、求和层和输出层四层构成。液力变矩器性能预测广义回归神经网络一般结构如图 10 所示。

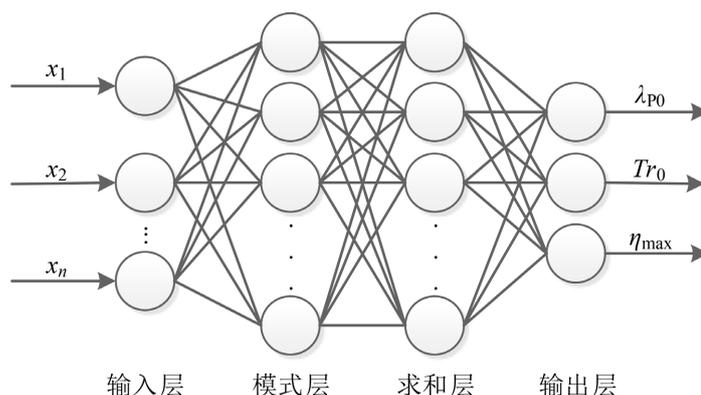


Figure 10. Generalized regression neural network structure diagram
图 10. 广义回归神经网络结构图

广义回归神经网络输入层神经元的数目与学习样本中输入设计向量的维度相等, 而模式层神经元数目与学习样本的数目相等。输出层的计算公式为:

$$\hat{y}(\mathbf{x}) = \frac{\sum_{k=1}^m [y^{(k)} \exp(-D_k^2/2\sigma^2)]}{\sum_{k=1}^m [\exp(-D_k^2/2\sigma^2)]} \quad (9)$$

式中, $y^{(k)}$ 为第 k 个样本的输出响应; m 为样本数; σ 为光滑因子(扩散系数); D_k 为输入 \mathbf{x} 与第 k 个样本输入 $\mathbf{x}^{(k)}$ 的欧式距离: $D_k^2 = (\mathbf{x} - \mathbf{x}^{(k)})^T (\mathbf{x} - \mathbf{x}^{(k)})$ 。

3.2.4. 基于克里金法性能预测

克里金(Kriging, KRG)是一种插值贝叶斯代理模型技术, 包括回归部分和非参数部分, 表达形式如下:

$$y(\mathbf{x}) = \Gamma(\mathbf{x}) + Z(\mathbf{x}) = \mathbf{f}^T(\mathbf{x})\boldsymbol{\phi} + Z(\mathbf{x}) \quad (10)$$

式中, $\mathbf{x} \in \mathbb{R}^n$ 为设计变量; $y(\mathbf{x})$ 为未知目标响应; $\Gamma(\mathbf{x})$ 为回归模型; $Z(\mathbf{x})$ 为均值为零、方差非零的随机分布函数; $\mathbf{f}(\mathbf{x}) = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_p(\mathbf{x})]^T$, p 为回归函数的个数, $f_i(\mathbf{x})$ ($i=1, 2, \dots, p$) 为多项式项,

可以是常数、一次或二次; $\phi = [\phi_1, \phi_2, \dots, \phi_p]^T$, ϕ_i ($i=1, 2, \dots, p$)为第 i 个回归参数。

随机分布函数 $Z(\mathbf{x})$ 两个样本点的协方差为:

$$\text{Cov}[Z(\mathbf{x}^{(j)}), Z(\mathbf{x}^{(k)})] = \sigma^2 \mathbf{R}([R(\boldsymbol{\theta}, \mathbf{x}^{(j)}, \mathbf{x}^{(k)})]) \quad (11)$$

式中, σ^2 是随机函数的方差; $\boldsymbol{\theta}$ 是参数向量; \mathbf{R} 是一个对角线元素为 1 的 $m \times m$ 对称矩阵; $R(\boldsymbol{\theta}, \mathbf{x}^{(j)}, \mathbf{x}^{(k)})$ 是任意两个样本点 $\mathbf{x}^{(j)}$ 和 $\mathbf{x}^{(k)}$ 的相关函数, 其中 $j, k=1, 2, \dots, m$, m 为样本数。

任一样本点输入 \mathbf{x} 的克里金预测函数值表示如下:

$$\hat{y}(\mathbf{x}) = \mathbf{f}^T(\mathbf{x})\hat{\boldsymbol{\phi}} + \mathbf{r}^T(\mathbf{x})\mathbf{R}^{-1}(\mathbf{y} - \mathbf{F}\hat{\boldsymbol{\phi}}) \quad (12)$$

式中, $\hat{\boldsymbol{\phi}}$ 为 $\boldsymbol{\phi}$ 的估计值; $\mathbf{r}^T(\mathbf{x}) = [R(\mathbf{x}, \mathbf{x}^{(1)}), R(\mathbf{x}, \mathbf{x}^{(2)}), \dots, R(\mathbf{x}, \mathbf{x}^{(m)})]$ 为相关函数向量; \mathbf{y} 为 $[\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(m)}]^T$ 对应的目标响应值; $\mathbf{F} = [\mathbf{f}(\mathbf{x}^{(1)}), \mathbf{f}(\mathbf{x}^{(2)}), \dots, \mathbf{f}(\mathbf{x}^{(m)})]^T$ 。

回归参数向量估计值为:

$$\hat{\boldsymbol{\phi}} = (\mathbf{F}^T \mathbf{R}^{-1} \mathbf{F})^{-1} \mathbf{F}^T \mathbf{R}^{-1} \mathbf{y} \quad (13)$$

方差估计值为:

$$\hat{\sigma}^2 = \frac{(\mathbf{y} - \mathbf{F}\hat{\boldsymbol{\phi}})^T \mathbf{R}^{-1} (\mathbf{y} - \mathbf{F}\hat{\boldsymbol{\phi}})}{n} \quad (14)$$

设置参数 $\boldsymbol{\theta}$ 通过求解非线性无约束最优化问题确定:

$$\max \left(-\frac{n \ln(\hat{\sigma}^2) + \ln|\mathbf{R}|}{2} \right) \quad (15)$$

3.2.5. 基于支持向量回归法性能预测

支持向量回归(SVR, Support Vector Regression)是支持向量机(SVM, Support Vector Machine)重要的应用分支。与传统回归方法不同, 支持向量回归能够容忍真实值与预测值之间最多有 ε 的偏差, 当且仅当两者差别绝对值大于不敏感系数 ε 时计算损失。如图 11 所示, 以 $f(\mathbf{x}) = \boldsymbol{\omega}^T \mathbf{x} + b$ 为中心构建一个宽度为 2ε 的间隔带, 训练样本若位于此间隔带则认为预测是正确的。

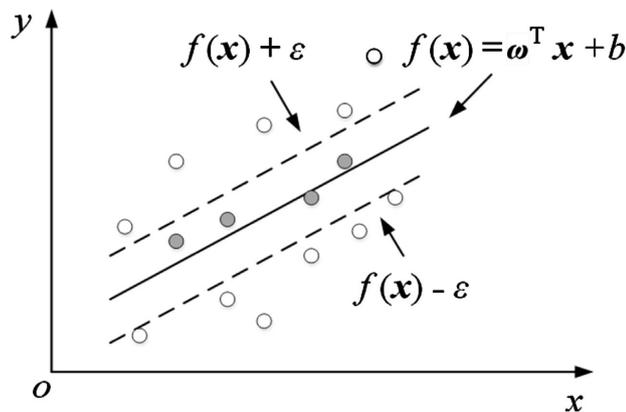


Figure 11. Support vector regression schematic diagram
图 11. 支持向量回归示意图

SVR 可应用于线性回归和非线性回归, 对于线性回归问题, $f(\mathbf{x}) = \boldsymbol{\omega}^T \mathbf{x} + b$, 求解可转化为如下优化过程:

$$\begin{aligned} \min_{\boldsymbol{\omega}, \xi_i, \xi_i^*} \quad & \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \delta \sum_{i=1}^m (\xi_i + \xi_i^*) \\ \text{s.t.} \quad & f(\mathbf{x}^{(i)}) - y_i \leq \varepsilon + \xi_i \\ & y_i - f(\mathbf{x}^{(i)}) \leq \varepsilon + \xi_i^* \\ & \xi_i \geq 0, \xi_i^* \geq 0 \end{aligned} \quad (16)$$

式中, $\|\boldsymbol{\omega}\|$ 为向量 $\boldsymbol{\omega}$ 的范数; $i = 1, 2, \dots, m$; m 为训练样本数; δ 为惩罚因子; ξ_i 和 ξ_i^* 为松弛变量; $\mathbf{x}^{(i)}$ 为第 i 个训练样本。

引入拉格朗日乘子 α' , α^* , μ , μ^* , 可得拉格朗日函数

$$\begin{aligned} L(\boldsymbol{\omega}, b, \alpha', \alpha^*, \xi, \xi^*, \mu, \mu^*) \\ = \frac{1}{2} \|\boldsymbol{\omega}\|^2 + \delta \sum_{i=1}^m (\xi_i + \xi_i^*) - \sum_{i=1}^m \mu_i \xi_i - \sum_{i=1}^m \mu_i^* \xi_i^* \\ + \sum_{i=1}^m \alpha'_i (f(\mathbf{x}^{(i)}) - y_i - \varepsilon - \xi_i) + \sum_{i=1}^m \alpha_i^* (y_i - f(\mathbf{x}^{(i)}) - \varepsilon - \xi_i^*) \end{aligned} \quad (17)$$

分别对 $\boldsymbol{\omega}$, b , ξ 和 ξ_i^* 求偏导, 令偏导数为零, 可得

$$\begin{cases} \boldsymbol{\omega} = \sum_{i=1}^m (\alpha_i^* - \alpha'_i) \mathbf{x}^{(i)} \\ 0 = \sum_{i=1}^m (\alpha_i^* - \alpha'_i) \\ \delta = \alpha'_i + \mu_i \\ \delta = \alpha_i^* + \mu_i^* \end{cases} \quad (18)$$

将式(18)代入式(17)即可求得 SVR 对偶问题:

$$\begin{aligned} \max_{\alpha', \alpha^*} \quad & \sum_{i=1}^m y_i (\alpha_i^* - \alpha'_i) - \varepsilon \sum_{i=1}^m (\alpha_i^* + \alpha'_i) \\ & - \frac{1}{2} \sum_{i,j=1}^m (\alpha_i^* - \alpha'_i) (\alpha_j^* - \alpha'_j) \mathbf{x}^{(i)T} \mathbf{x}^{(j)} \\ \text{s.t.} \quad & \sum_{i=1}^m (\alpha_i^* - \alpha'_i) = 0, \\ & 0 \leq \alpha'_i, \alpha_i^* \leq \delta \end{aligned} \quad (19)$$

需要满足的 Kuhn-Tucker (KKT) 条件为

$$\begin{cases} \alpha'_i (f(\mathbf{x}^{(i)}) - y_i - \varepsilon - \xi_i) = 0 \\ \alpha_i^* (y_i - f(\mathbf{x}^{(i)}) - \varepsilon - \xi_i^*) = 0 \\ \alpha'_i \alpha_i^* = 0, \xi_i \xi_i^* = 0 \\ (\delta - \alpha'_i) \xi_i = 0, (\delta - \alpha_i^*) \xi_i^* = 0 \end{cases} \quad (20)$$

最后, 可得 SVR 的解为:

$$f(\mathbf{x}) = \sum_{i=1}^m (\alpha_i^* - \alpha_i') \mathbf{x}^{(i)\top} \mathbf{x} + b \tag{21}$$

其中, b 为

$$b = y_i + \varepsilon - \sum_{i=1}^m (\alpha_i^* - \alpha_i') \mathbf{x}^{(i)\top} \mathbf{x} \tag{22}$$

对于非线性回归, 利用核函数 $\kappa(\mathbf{x}^{(i)}, \mathbf{x}^{(j)})$ 将非线性回归转化为线性回归, 优化函数为:

$$\begin{aligned} & \max_{\alpha', \alpha^*} \sum_{i=1}^m y_i (\alpha_i^* - \alpha_i') - \varepsilon \sum_{i=1}^m (\alpha_i^* + \alpha_i') \\ & \quad - \frac{1}{2} \sum_{i,j=1}^m (\alpha_i^* - \alpha_i') (\alpha_j^* - \alpha_j') \kappa(\mathbf{x}^{(i)}, \mathbf{x}^{(j)}) \\ & \text{s.t.} \quad \sum_{i=1}^m (\alpha_i^* - \alpha_i') = 0, \\ & \quad 0 \leq \alpha_i', \alpha_i^* \leq \delta \end{aligned} \tag{23}$$

SVR 的解为:

$$f(\mathbf{x}) = \sum_{i=1}^m (\alpha_i^* - \alpha_i') \kappa(\mathbf{x}^{(i)}, \mathbf{x}) + b \tag{24}$$

常用的核函数有多项式核函数 $K(\mathbf{x}^{(i)}, \mathbf{x}) = (\gamma \mathbf{x}^{(i)\top} \mathbf{x} + r)^d, \gamma > 0$, 和径向基核函数 $K(\mathbf{x}^{(i)}, \mathbf{x}) = \exp(-\gamma \|\mathbf{x}^{(i)} - \mathbf{x}\|^2), \gamma > 0$, 式中, r 为多项式核函数的内部设置参数, 默认值为 0; d 为多项式核函数的次数, 一般选用 1 次, 2 次或 3 次。

除核函数类型外, 支持向量回归法需要确定的参数有惩罚因子 δ 和内部设置参数 γ 。限定参数搜索范围: $-8 \leq \log_2 \delta \leq 8, -8 \leq \log_2 \gamma \leq 8$, 对惩罚因子和内部设置参数 γ 同时寻优, 为了提高搜索效率, 首先进行初步搜索, 缩小搜缩范围后再进行精细搜索。

3.2.6. 最佳代理模型

基于 10 个关键设计参数, 应用优化拉丁超立方方法建立 100 个试验样本, 根据样本参数组合更新液力变矩器参数化流道模型, 仿真计算获取所有样本的液力变矩器性能数据。分别应用多项式响应面法 (RSM)、径向基神经网络法 (RBFNN)、广义回归神经网络法 (GRNN)、克里金法 (KRG) 和支持向量回归法 (SVR) 对试验样本进行 20 次 5 折交叉验证运算, 对预测精度评估结果进行平均计算, 所有计算结果汇总如表 7 所示。由表中可以看出, SVR 代理模型对各项性能评价指标均具有最高的预测精度为最佳代理模型, 可以作为优化设计的模型基础。

Table 7. Optimal prediction accuracy evaluation for different surrogate models

表 7. 不同代理模型最优预测精度评估

性能评价指标	代理模型	最佳设置参数	平均 R^2 值	
			训练样本	测试样本
失速泵轮转矩系数	RSM	1 次多项式	0.8877	0.8302
	RBFNN	$\sigma = 1.5$	1	0.9126
	GRNN	$\sigma = 0.3$	1	0.4398
	KRG	高斯函数, 0 次回归, $t_0 = 1$	1	0.8612
	SVR	径向基核函数, $[\delta, \gamma] = [194.0117, 0.027205]$	0.9933	0.9592

续表

失速变矩比	RSM	2 次多项式	0.998	0.9371
	RBFNN	$\sigma = 1.6$	1	0.9600
	GRNN	$\sigma = 0.2$	1	0.5163
	KRG	指数函数, 1 次回归, $t_0 = 2$	1	0.9375
	SVR	径向基核函数, $[\delta, \gamma] = [22.6274, 0.071794]$	0.998	0.9762
最大效率	RSM	1 次多项式	0.9578	0.9371
	RBFNN	$\sigma = 1.2$	1	0.9450
	GRNN	$\sigma = 0.2$	1	0.5053
	KRG	样条函数, 1 次回归, $t_0 = 1$	1	0.9371
	SVR	径向基核函数, $[\delta, \gamma] = [2, 0.15389]$	0.9879	0.9538

4. 多目标优化设计

本文选用的液力变矩器性能评价指标有失速泵轮转矩系数、失速变矩比和最大效率, 失速变矩比和最大效率越大, 说明变矩性能和经济性能越好, 而失速泵轮转矩系数的大小不能直接反映液力性能的优劣, 需要与发动机进行匹配分析, 对于本项目增大失速泵轮转矩系数具有更好的匹配效果, 因此, 建立液力变矩器多目标优化问题的数学表达式如下:

$$\begin{aligned}
 \max. \quad & \begin{cases} \lambda_{p0} = f_1(x_{p1}, x_{p2}, x_{s1}, x_{s2}, x_{s3}, x_{s4}, x_{s5}, x_{T1}, x_{T2}, x_{T3}) \\ Tr_0 = f_2(x_{p1}, x_{p2}, x_{s1}, x_{s2}, x_{s3}, x_{s4}, x_{s5}, x_{T1}, x_{T2}, x_{T3}) \\ \eta_{max} = f_3(x_{p1}, x_{p2}, x_{s1}, x_{s2}, x_{s3}, x_{s4}, x_{s5}, x_{T1}, x_{T2}, x_{T3}) \end{cases} \\
 \text{s.t.} \quad & 25^\circ \leq x_{p1} \leq 45^\circ; 145^\circ \leq x_{p2} \leq 165^\circ; 21 \leq x_{s1} \leq 35; \\
 & 9 \text{ mm} \leq x_{s2} \leq 13 \text{ mm}; 10^\circ \leq x_{s3} \leq 30^\circ; 75^\circ \leq x_{s4} \leq 95^\circ; \\
 & 6 \text{ mm} \leq x_{s5} \leq 10 \text{ mm}; 143^\circ \leq x_{T1} \leq 163^\circ; 15^\circ \leq x_{T2} \leq 35^\circ; \\
 & 0.25 \leq x_{T3} \leq 0.45; x_{s1} \in N^*
 \end{aligned} \tag{25}$$

式中, x_{p1} 、 x_{p2} 、 x_{s1} 、 x_{s2} 、 x_{s3} 、 x_{s4} 、 x_{s5} 、 x_{T1} 、 x_{T2} 和 x_{T3} 别为关键设计参数 P7、P8、S1、S4、S5、S12、S13、T7、T8 和 T9 的变量输入, f_1 、 f_2 和 f_3 分别为失速泵轮转矩系数、失速变矩比和最大效率的性能预测代理模型。基于最佳代理模型, 应用 NSGA-II 算法进行多目标优化, 进行 200 次迭代, 计算结果如图 12 所示。

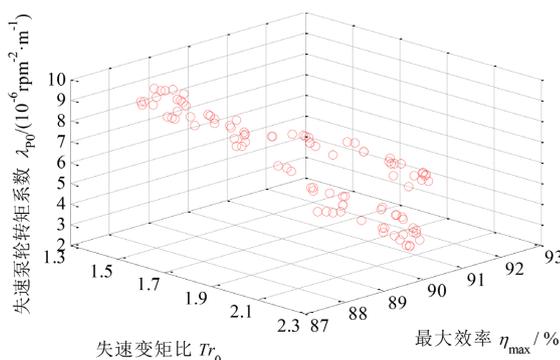


Figure 12. Optimization design Pareto frontier based on the optimal surrogate model
 图 12. 基于最佳代理模型优化设计 Pareto 前沿

根据客户对液力变矩器的性能需求, 直接基于仿真数据从 100 组最优点集中选取一组参数组合作为最终优化点, 并进行样件生产和试验验证, 最终选取的液力变矩器优化设计点各工作轮叶片叶型如图 13 所示, 所选液力变矩器泵轮、涡轮和导轮叶片数分别为 31、29 和 27。

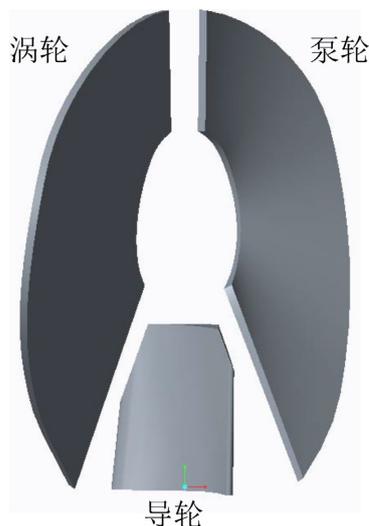


Figure 13. Impellers blades profile of the torque converter final optimal design
图 13. 液力变矩器最终优化设计各工作轮叶片叶型

5. 试验验证

基于最终确定的液力变矩器进行工艺出图和样件生产, 图 14 为液力变矩器泵轮、涡轮和导轮生产完成的样件产品。



Figure 14. Sample part of each impeller of the torque converter
图 14. 液力变矩器各工作轮样件

组装液力变矩器总成, 之后在综合传动试验台上进行液力变矩器性能试验测试。进行牵引性能试验时, 保持输入转速为 2000 rpm 不变, 分别测量不同速比工况下液力变矩器性能。将客户最低性能要求的液力变矩器液力曲线与试验数据进行对比, 结果如图 15 所示。

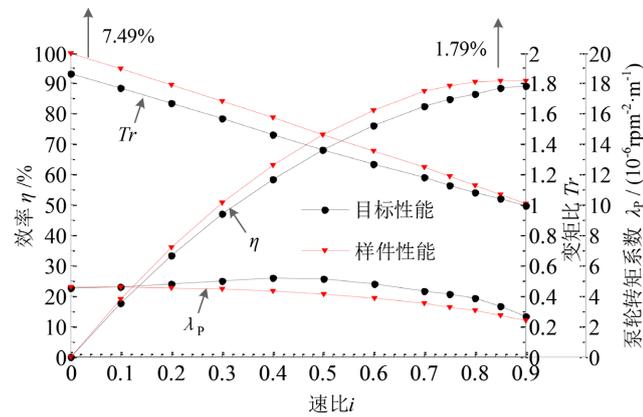


Figure 15. Comparison between sample performance and target performance of the torque converter

图 15. 液力变矩器样件性能与目标性能对比

由图可知, 所有速比工况液力变矩器的动力性能和经济性能均提升明显, 失速变矩比提高了 7.49%, 最大效率提高了 1.79%, 通过与发动机匹配共同输入特性和共同输出特性分析, 液力变矩器与发动机匹配性能同样得以改善, 验证了本文提出的液力变矩器优化设计方法的可靠性。

6. 结论

(1) 进行初步设计并建立了液力变矩器参数化设计模型; 进一步基于正交设计方法对主要设计参数进行灵敏度分析, 最终筛选出 10 个关键的设计参数, 分别为泵轮叶片外环进出口角、导轮叶片数、导轮叶片内外环周向偏移、导轮叶片内环出口角和外环进口角、涡轮叶片外环进出口角和涡轮叶片外环圆锥曲线参数。

(2) 基于关键设计参数, 应用优化拉丁超立方方法建立试验样本, 并分别对液力变矩器各性能评价指标包括失速泵轮转矩系数、失速变矩比和最大效率建立了多项式响应面、径向基神经网络、广义回归神经网络、克里金和支持向量回归单一代理模型, 结果表明, 支持向量回归代理模型预测精度最高, 为最佳代理模型。

(3) 基于最佳代理模型应用 NSGA-II 方法完成液力变矩器的多目标优化设计, 并选取一组满足性能需求的优化设计参数进行样件生产和试验验证, 对比分析结果说明了本文液力变矩器优化设计方法的可靠性。

参考文献

- [1] Liu, C., Untaroiu, A., Wood, H.G., Yan, Q. and Wei, W. (2014) Parametric Analysis and Optimization of Inlet Deflection Angle in Torque Converters. *Journal of Fluids Engineering*, **137**, Article 031101. <https://doi.org/10.1115/1.4028596>
- [2] 刘城, 闫清东, 魏巍. 液力变矩器导轮叶片造型及优化设计[J]. 哈尔滨工业大学学报, 2016, 48(1): 114-199.
- [3] 闫清东, 李新毅, 魏巍. 基于多目标优化的液力变矩器叶形角度设计[J]. 华中科技大学学报(自然科学版), 2017, 45(9): 69-75.
- [4] Wu, G.Q. and Wang, L.J. (2015) Multi-Objective Optimization Employing Genetic Algorithm for the Torque Converter with Dual-Blade Stator. SAE Technical Paper.
- [5] 马文星. 液力传动理论与设计[M]. 北京: 化学工业出版社, 2004.
- [6] Adeli, H. and Karim, A. (2000) Fuzzy-Wavelet RBFNN Model for Freeway Incident Detection. *Journal of Transportation Engineering*, **126**, 464-471. [https://doi.org/10.1061/\(asce\)0733-947x\(2000\)126:6\(464\)](https://doi.org/10.1061/(asce)0733-947x(2000)126:6(464))
- [7] Chasset, P.O. (2013) GRNN: General Regression Neural Network. *Revue de Physique Appliquée*, **6**, 1321-1325.