

## 机器学习驱动三维螺旋晶格穿孔微通道的设计与优化

翁俊旗, 刘昊昕, 王菊, 储博钊

(中石化(上海)石油化工研究院有限公司, 上海 201208)

**摘要:** 提出了一种新型三维螺旋晶格穿孔微通道, 采用计算流体力学与深度神经网络相结合的方法对其结构参数进行了优化, 以在实现高混合性能的同时降低压降。首先, 通过CFD模拟对比了SMC、LMC和HLMC三种结构的混合性能与压降特性; 随后, 研究了HLMC的五个结构参数 ( $H_1$ 、 $W_0$ 、 $W_1$ 、 $L_0$ 和 $L_1$ ) 对压降和混合指数的影响; 最后, 利用CFD模拟数据训练了深度神经网络代理模型, 对混合指数与压降进行了多目标优化。结果表明, HLMC的混合指数达到0.985, 分别比SMC和LMC提高了121%和15.2%。 $H_1$ 、 $W_0$ 和 $W_1$ 存在最优取值, 而 $L_0$ 和 $L_1$ 越大, HLMC性能越高。获得压降和混合指数的Pareto前沿, 拐点压降为396 Pa/m、混合指数为0.985。研究结果可为微混合器的设计优化提供理论指导和可靠的数据驱动方法。

**关键词:** 微通道; 计算流体力学; 深度神经网络; 结构优化; 混合指数

中图分类号: TQ 021

文献标志码: A

文章编号: 0438-1157 (XXXX) XX-0001-13

## Engineering and optimization of a 3D helical lattice microchannel using machine learning

WENG Junqi, LIU Haoxin, WANG Ju, CHU Bozhao

(SINOPEC Shanghai Research Institute of Petrochemical Technology, Shanghai 201208, China)

**Abstract:** Micromixers are core devices for achieving highly efficient fluid mixing in micro-chemical processes, and their internal structures directly determine mixing performance and flow pressure drop. This paper proposes a novel three-dimensional helical lattice perforated microchannel and systematically optimizes its structural parameters using a combination of computational fluid dynamics (CFD) and deep neural networks (DNN) to achieve high mixing performance while minimizing pressure drop. First, the mixing performance and pressure drop characteristics of three configurations (straight microchannel, lattice microchannel, and helical lattice microchannel) were compared via CFD simulations. Subsequently, the effects of five structural parameters ( $H_1$ ,  $W_0$ ,  $W_1$ ,  $L_0$  and  $L_1$ ) on the pressure drop and mixing index were investigated. Finally, a DNN surrogate model was trained using CFD simulation data to perform multi-objective optimization of the mixing index and pressure drop. The results demonstrate that the mixing index of the HLMC reaches 0.985, representing increases of 121% and 15.2% compared to the SMC and LMC, respectively. Optimal values exist for  $H_1$ ,  $W_0$ , and  $W_1$ , whereas larger values of  $L_0$  and  $L_1$  correlate with higher HLMC performance. The Pareto front for pressure drop and mixing index was obtained, identifying a knee point with a pressure drop of 396 Pa/m and a mixing index of 0.985. These findings provide theoretical guidance and a robust data-driven methodology for the design and optimization of micromixers.

收稿日期: 2026-03-31 修回日期: 2026-04-27

通信作者: 储博钊(1987—),男,博士,研究员, Chubz.sshy@sinopec.com

第一作者: 翁俊旗(1998—),男,博士,助理研究员, Junqiweng@163.com

引用本文: 翁俊旗, 刘昊昕, 王菊, 储博钊. 机器学习驱动三维螺旋晶格穿孔微通道的设计与优化[J]. 化工学报, XXXX, XX(XX): 1-13

**Citation:** WENG Junqi, LIU Haoxin, WANG Ju, CHU Bozhao. Engineering and optimization of a 3D helical lattice microchannel using machine learning[J]. CIESC Journal, XXXX, XX(XX): 1-13

**Keywords:** microchannel; CFD; deep neural network; structural optimization; mixing index

**研究论文 DOI:** 10.11949/0438-1157.20260442

### 引 言

微通道/微流控器件作为微化工与微尺度传递过程中的重要平台,在药物输送、医疗诊断、化学合成、细胞分离、电子元件散热和环境监测等领域具有广泛的应用前景<sup>[1-6]</sup>。然而,在极小的特征尺度下,流体常呈现稳定的层流状态,系统内质量传递严重受限于缓慢的分子扩散,从而导致混合效率低下、所需的混合通道极长<sup>[7-8]</sup>。因此,如何通过微通道的内部拓扑结构设计来打破层流边界层,实现流体的高效混合,是当前微流控工程领域亟需解决的核心问题。

现有的微混合强化策略主要分为主动式与被动式两大类<sup>[9-11]</sup>。主动式技术虽能借助热<sup>[12]</sup>、声<sup>[13]</sup>、磁<sup>[14]</sup>、电<sup>[15]</sup>等外场扰动实现高效混合,但存在系统集成度低、制造成本高昂等工程局限性,极大限制了其工业化推广<sup>[16]</sup>。相比之下,被动式微混合器依靠复杂的内部几何构型诱导流体横向混合,凭借其易于微加工制造及高鲁棒性的优势,成为了该领域的主流发展方向。

传统的被动式微混合器的设计种类繁多,主要包括蛇形通道<sup>[17-18]</sup>、收敛发散通道<sup>[19-20]</sup>、分裂重组通

道<sup>[21-22]</sup>以及挡板结构<sup>[23-24]</sup>。这些传统的被动式结构主要通过二维平面内诱导横向流动来强化混合,但其对浓度边界层的破坏能力依然有限。相比之下,三维微结构能够利用复杂空间构型在多维上实现流体界面的拉伸与折叠,展现出更为优异的混合潜力<sup>[25-27]</sup>。因此,本文提出了一种新型三维螺旋晶格穿孔微通道(Helical Lattice Microchannel, HLMC),其结构如图1所示。该微混合器由若干周期性排列的基本结构单元串联而成。每个基本单元的高度为4 mm,包含3 mm的结构区域和1 mm的过渡区域。HLMC基本结构单元的三维几何构建过程可分为三个步骤。首先,构建由四个子流道模块组成的基础晶格,其中子流道模块的截面宽度分别为 $W_0$ 和 $L_0$ ,截面长度分别为 $W_1$ 和 $L_1$ ,高度为 $H_1$ ;随后,以3 mm结构区域的中心截面为镜像面,对基础晶格进行镜像复制,得到对称目标晶格,并将该镜像晶格绕通道轴线顺时针旋转 $90^\circ$ ;最后,采用螺旋扭转放样方法,将基础晶格与旋转后的镜像晶格在对应截面处连接,形成三维螺旋晶格穿孔结构。这种独特的拓扑结构不仅保留了传统晶格单元对流体界面的周期性拉伸与折叠,更通过空间流道的扭曲诱发了强烈的Dean涡与二次流,从而大幅度强化了通道内的横向混合传质性能。




图1 HLMC的结构示意图

Fig.1 Schematic diagram of the HLMC structure

在微混合器的结构设计与优化中,传统的参数化研究往往依赖于大量的CFD模拟或实验试错,计算成本高昂且优化效率低下。这类研究通常只能进行单一变量的局部优化,难以在多维参数空间中

实现真正的全局优化。近年来,机器学习技术在辅助化工过程建模与优化方面展现出显著优势<sup>[28-32]</sup>。通过构建数据驱动的深度神经网络代理模型,机器学习能够在有限的数据集基础上,以极低的计算成

本高效探索高维参数空间,并实现多目标复杂系统的全局优化。

本文提出了一种新型三维螺旋晶格穿孔微通道结构,并采用CFD与深度神经网络(Deep Neural Network, DNN)相结合的策略对其进行深度研究和结构优化。首先,对比了HLMC、直通基准微通道(Straight Microchannel, SMC)和三维晶格穿孔微通道(Lattice Microchannel, LMC)的混合性能和压降。随后,系统地研究了五个关键结构参数( $H_1$ 、 $W_0$ 、 $W_1$ 、 $L_0$ 、 $L_1$ )对HLMC性能的影响。这五个关键结构参数的选取基于其对HLMC内流动混合过程的物理调控作用。在此基础上,利用1350组CFD模拟数据训练获得了深度神经网络代理模型,并采用拉丁超立方采样与Pareto前沿分析,实现了混合指数与压降之间的全局多目标优化。

## 1 模型与方法

本文采用计算流体力学(CFD)模拟获取微混合器内的流场与浓度场信息,进而计算混合指数和压降。在此基础上,利用CFD模拟结果构建训练数据集,建立深度神经网络代理模型,以实现微混合器结构参数的高效优化。

### 1.1 动量和组分守恒方程

微混合器中的流体流动行为由连续性方程和

动量守恒方程描述。连续性方程为:

$$\nabla \cdot (\rho_t \mathbf{u}_t) = 0 \quad (1)$$

动量守恒方程为:

$$\nabla \cdot (\rho_t \mathbf{u}_t \mathbf{u}_t) = -\nabla p + \nabla \cdot \boldsymbol{\tau} \quad (2)$$

$$\boldsymbol{\tau} = \mu_t [\nabla \mathbf{u}_t + (\nabla \mathbf{u}_t)^T] - \frac{2}{3} \mu_t (\nabla \cdot \mathbf{u}_t) \mathbf{I} \quad (3)$$

微混合器中示踪剂的传质过程由组分守恒方程描述:

$$(\mathbf{u}_t \cdot \nabla) c = D \nabla^2 c \quad (4)$$

混合指数(Mixing Index, MI)定义为沿流动方向截面上浓度分布的均匀度,其计算公式为<sup>[33]</sup>:

$$MI = 1 - \frac{\sum_i |c_i - \bar{c}| A_i}{2\bar{c} \sum_i A_i} \quad (5)$$

### 1.2 神经网络代理模型

为实现微混合器结构参数的高效优化,本文构建了DNN作为代理模型,用于替代耗时的CFD模拟来预测微混合器的压降( $\Delta p/L$ )和混合指数(MI)。如图2所示,该神经网络包含一个输入层、四个隐藏层和一个输出层。输入层接收五个结构参数( $H_1$ 、 $W_0$ 、 $W_1$ 、 $L_0$ 、 $L_1$ ),输出层预测两个性能指标( $\Delta p/L$ 和MI)。四个隐藏层的神经元数量分别为64、128、128和64,均采用Sigmoid激活函数。

s




图2 深度神经网络模型示意图

Fig.2 Schematic diagram of the deep neural network

为消除量纲差异对模型训练的影响,在训练前对所有参数进行了归一化处理。输入参数与混合

指数MI均采用线性归一化:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (6)$$

由于压降在参数空间内跨越两个数量级,因此采用对数归一化以提高其数值分布的均匀性:

$$\Delta p^* = \frac{\ln \Delta p - \ln \Delta p_{\min}}{\ln \Delta p_{\max} - \ln \Delta p_{\min}} \quad (7)$$

隐藏层的前向传播通过下式描述:

$$\mathbf{h}^{(l)} = \sigma(\mathbf{W}^{(l)} \mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}), \quad l = 1, 2, 3, 4 \quad (8)$$

Sigmoid激活函数为:

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (9)$$

输出层采用线性激活,公式如下:

$$\hat{y} = \mathbf{W}^{(5)} \mathbf{h}^{(4)} + \mathbf{b}^{(5)} \quad (10)$$

模型采用均方误差 (Mean Squared Error, MSE) 作为损失函数:

$$L_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (11)$$

### 1.3 模型计算

本研究采用 ANSYS Fluent 进行 CFD 数值模拟。采用 SIMPLE 算法进行压力-速度耦合,对流项采用二阶迎风格式离散,扩散项采用中心差分格式离散。在本研究工况下,流体的雷诺数为 2.1,远低于层流-湍流转捩的临界阈值 ( $Re = 2300$ ),因此数值模拟中采用层流模型对流场进行求解。计算域采

用 ANSYS Meshing 进行网格划分。考虑到 HLMC 具有复杂的三维螺旋晶格结构,主体区域采用多面体网格以提高复杂几何区域的适应性;同时,为准确捕捉近壁面区域的速度梯度和浓度梯度,在所有壁面处设置 2 层棱柱层网格,网格示意图如图 3(a)所示,网格无关性分析结果如图 3(b)所示。当网格数量从 65 万加密至 179 万时,混合指数的相对偏差为 2.8%,压降的相对偏差为 0.8%。因此,继续加密网格对混合指数和压降的影响较小,计算结果趋于稳定。综合计算精度与计算效率,本文最终选取 65 万网格量作为基准计算方案。详细的模拟参数和边界条件如表 1 所示。为验证当前数值模型的可靠性,本文参照 Wang 等<sup>[34]</sup>报道的实验条件进行了对比验证。如图 4 所示,模拟获得的浓度分布与文献报道的结果吻合良好;根据该浓度分布计算得到的 MI 为 0.715,与文献报道值 0.723 基本一致。此外,在雷诺数为 100 条件下,本文计算得到的压降为 9550 Pa,与文献实验值 9586 Pa 的相对误差小于 0.4%。上述结果表明,本文所建立的 CFD 模型能够较准确地预测微通道内的混合指数和压降。

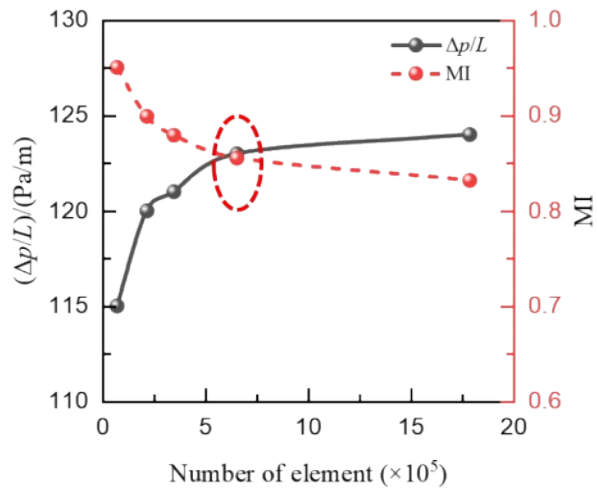



图3 网格示意图和网格无关性分析

Fig.3 Illustration of the mesh and mesh sensitivity analysis

注:(a)HLMC 网格示意图 (b)压降和混合指数与网格数的关系

神经网络模型训练采用 Adam 优化器,学习率设为 0.001,批次大小为 32,训练轮数为 1000。1350 组 CFD 模拟数据按照 8:2 的比例随机划分为训练集和测试集,并固定随机种子以保证结果可复现。模型的过拟合主要通过比较训练集与测试集上的  $R^2$  和 MAE 进行判断。此外,本文进一步考察了隐藏层数量、神经元规模和激活函数对模型预测性能的影响,结果如表 2 所示。增加隐藏层数量可提高模型精度,但进一步增加隐藏层后精度提升有限且模型复杂度增加;适当增加神经元数量有助于提高预测精度,但过大的网络规模会导致压降测试集  $R^2$  降低;在所比较的 ELU、RELU 和 sigmoid 激活函数中, sigmoid 激活函数表现出最佳预测精度。因此,本文最终选取 64-128-128-64 的隐藏层结构,并采用

神经网络模型训练采用 Adam 优化器,学习率设为 0.001,批次大小为 32,训练轮数为 1000。1350 组 CFD 模拟数据按照 8:2 的比例随机划分为训练集和测试集,并固定随机种子以保证结果可复现。模型的过拟合主要通过比较训练集与测试集上的  $R^2$  和 MAE 进行判断。此外,本文进一步考察了隐藏层数量、神经元规模和激活函数对模型预测性能的影响,结果如表 2 所示。增加隐藏层数量可提高模型精度,但进一步增加隐藏层后精度提升有限且模型复杂度增加;适当增加神经元数量有助于提高预测精度,但过大的网络规模会导致压降测试集  $R^2$  降低;在所比较的 ELU、RELU 和 sigmoid 激活函数中, sigmoid 激活函数表现出最佳预测精度。因此,本文最终选取 64-128-128-64 的隐藏层结构,并采用

表1 模拟参数与边界条件

Table 1 Parameters and boundary conditions in this work

参数	数值	单位
进口速度	1.389	mm/s
进口浓度	0/1 <sup>a</sup>	mol/m <sup>3</sup>
流体密度	913	kg/m <sup>3</sup>
动力黏度	1.766×10 <sup>-3</sup>	Pa·s
扩散系数	1.396×10 <sup>-9</sup>	m <sup>2</sup> /s
出口压力	101325	Pa

注:<sup>a</sup> 0代表无示踪剂,1代表示踪剂浓度为1 mol/m<sup>3</sup>

sigmoid作为激活函数。

## 2 结果与讨论

### 2.1 典型结构对比

为验证本文提出的 HLMC 结构的混合性能,将其与 SMC 和 LMC 进行了对比分析。图5展示了三种微混合器的整体结构和单元结构示意图。SMC 在通道内不含任何内部结构;LMC 在通道内引入了周期性的晶格穿孔单元;而 HLMC 在晶格穿孔结构的基础上进一步引入了螺旋扭转,使流体流过晶格

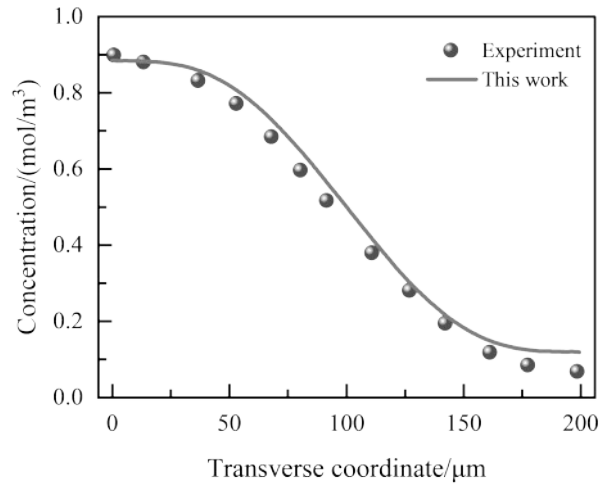


图4 在16 mm处的实验<sup>[34]</sup>与模拟的浓度分布比较

Fig.4 Comparison between experimental<sup>[34]</sup> and numerical concentration distribution at the distance of 16 mm

单元时产生旋转运动。三种微混合器具有相同的外部尺寸,仅内部结构不同,两侧进口通入纯流体(无示踪剂),中间进口导入浓度为1 mol/m<sup>3</sup>的示踪剂,三个进口速度均为1.389 mm/s。本节中,结构参数取值如下: $H_1 = 1.0 \text{ mm}$ ,  $L_0 = 0.9 \text{ mm}$ ,  $L_1 = 1.0 \text{ mm}$ ,  $W_0 = 0.9 \text{ mm}$ ,  $W_1 = 0.9 \text{ mm}$ 。

表2 深度神经网络模型的超参数敏感性分析

Table 2 Sensitivity analysis of hyperparameters for deep neural network models

隐藏层结构	训练次数	激活函数	测试集 $R_p^2$	测试集 $R_{MI}^2$	测试集 MAE/( $\Delta p$ )	测试集 MAE/(MI)
64-64	1000	sigmoid	0.99894	0.98352	0.43529	0.002711
64-128-64	1000	sigmoid	0.99946	0.99171	0.37509	0.001760
64-128-128-64	1000	sigmoid	0.99954	0.99504	0.32310	0.001376
64-128-128-128-64	1000	sigmoid	0.99967	0.99710	0.26417	0.001108
32-64-64-32	1000	sigmoid	0.99777	0.99277	0.65599	0.001653
128-256-256-128	1000	sigmoid	0.99656	0.99708	0.97043	0.001087
64-128-128-64	1000	ELU	0.99779	0.99394	0.33074	0.001489
64-128-128-64	1000	ReLU	0.99874	0.99390	0.62784	0.001503

图6展示了三种微混合器的浓度分布云图。从图中可以看出,SMC 中示踪剂仅在流体界面处发生缓慢的分子扩散,出口截面浓度分布极不均匀,混合效果较差;LMC 中晶格单元对流体的分割与合并强化了横向混合,出口截面的浓度差异明显减小;而 HLMC 中晶格单元对流体的分割、合并与螺旋扭转协同作用,使出口截面浓度分布最为均匀,表现出最佳的混合性能。

为定量地评价三种微混合器的性能,表3列出了三种微混合器的压降和混合指数。从表中可以看出,HLMC 的混合指数达到0.985,分别比 SMC

(MI = 0.446) 和 LMC (MI = 0.855) 提高了 121% 和 15.2%。HLMC 混合性能的显著提升可归因于以下两个方面:第一,螺旋扭转使流体在弯曲通道中产生离心力,从而在流道内部形成 Dean 涡和二次流,增强了横向方向的对流传质;第二,晶格单元的周期性分割与合并使流体经历反复的拉伸与折叠,形成混沌对流,进一步提高了混合性能。然而,上述混合增强结构也导致了压降的增加。HLMC 的压降为 719 Pa/m,分别比 SMC (13 Pa/m) 和 LMC (123 Pa/m) 提高了 5431% 和 485%,这是由于流体流过复杂的晶格穿孔和螺旋弯道时产生了较大的黏性耗散。




图5 三种不同微混合器的整体结构和单元结构示意图

Fig.5 Schematic diagram of the overall and unit structures of three different micromixers




图6 三种不同微混合器的浓度分布云图

Fig.6 Contour of the concentration distribution for three different micromixers

图7(a)展示了三种不同微混合器在  $x = 14 \text{ mm}$  截面上的涡量分布。SMC 截面内涡量水平较低,表明其横向扰动较弱,混合过程主要受分子扩散控制;LMC 由于晶格单元引起流体分割与再合并,在近壁面区域形成一定涡量;相比之下,HLMC 在螺旋扭转作用下表现出更高的涡量水平,说明其能够诱导更强的 Dean 涡和二次流,从而增强横向对流传质。图7(b)进一步给出了三种微混合器沿  $x$  方向的混合指数演化。SMC 的 MI 沿程缓慢增加,LMC 的 MI 呈阶梯式提升,而 HLMC 的 MI 增长最快,尤其在  $1\text{--}2 \text{ mm}$  区域内提升最为明显,进一步证明螺旋晶格结构可通过 Dean 涡和二次流强化混合。

为进一步对比三种微混合器在不同操作条件下的性能,研究了进口流速和流体黏度对混合指数和压降的影响。图8展示了不同进口流速下三种微

表3 三种不同微混合器的压降和混合指数对比

Table 3 Comparison of the pressure drop and mixing index for three different micromixers

类型	$\Delta p/L/(\text{Pa}/\text{m})$	MI
SMC	13	0.446
LMC	123	0.855
HLMC	719	0.985

混合器的压降和混合指数。结果显示,随着进口流速的增大,三种微混合器的压降均单调增大,而混合指数逐渐降低。混合指数的降低是因为流速增大导致流体在微通道内的停留时间缩短,混合不够充分。尽管如此,HLMC 在所有流速条件下均保持了最高的混合指数,且其混合指数随流速增大的下降幅度较小,表明 HLMC 在所考察的流速范围内具有良好的鲁棒性。如图9所示,随着流体黏度的增

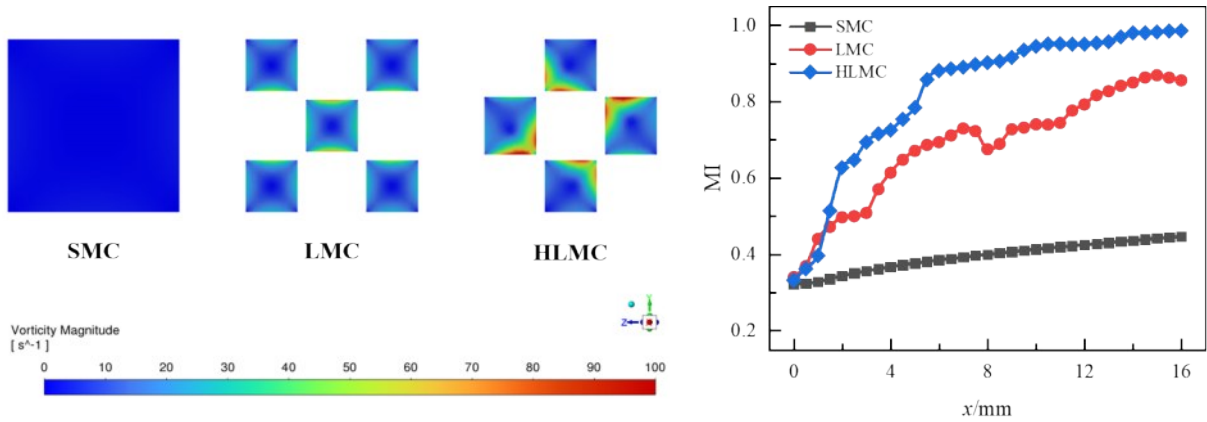


图7 三种不同微混合器在  $x = 14$  mm 截面上的涡量分布和沿  $x$  方向的混合指数变化

Fig.7 Vorticity magnitude distribution at  $x = 14$  mm and mixing index evolution along the  $x$ -direction for the three micromixers  
注:(a) $x = 14$  mm 截面上的涡量分布 (b)沿  $x$  方向的混合指数

大,压降显著增大,而混合指数持续降低。黏度增大导致流体惯性力与黏性力之比(即 Reynolds 数)降低,削弱了二次流和 Dean 涡的强度,使对流混合作用减弱,混合过程逐渐被低效的分子扩散所主导。此外,根据 Stokes-Einstein 方程<sup>[35]</sup>,分子扩散系数与黏度成反比关系,因此黏度的增大还会进一步降低

分子扩散速率。综上所述,黏度的增大从对流混合和分子扩散两个方面均不利于混合性能。然而,HLMC 随着黏度的升高,混合指数的下降幅度相对较小,表明其混合增强机制对黏度变化具有较好的鲁棒性。




图8 不同进口流速下三种微混合器的压降和混合指数( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm)

Fig.8 The pressure drop and mixing index for three different micromixers under different inlet velocities ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm)

注:(a)进口速度对压降的影响 (b)进口速度对混合指数的影响

### 2.2 结构参数影响

上述结果表明,HLMC在混合性能方面具有显著的优势,但其压降也相应增大。为进一步揭示结构参数对HLMC性能的调控规律,本节系统研究了五个关键结构参数( $H_1$ 、 $W_0$ 、 $W_1$ 、 $L_0$ 和 $L_1$ ,定义详见图5)对压降和混合指数的影响。单因素分析以 $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm作为基准参数组合。分析过程中每次仅改

变一个结构参数,其余参数均保持基准值不变,以便定量比较单一几何参数对压降和混合指数的影响。

图10展示了 $H_1$ 对HLMC压降和混合指数的影响。结果表明,随着 $H_1$ 从0.5 mm增大至0.8 mm,混合指数从0.969逐步升高至0.985。这是因为 $H_1$ 的增大缩短了螺旋晶格单元在流动方向上的延伸距离,从而增强了螺旋晶格的扭曲程度,使二次流和

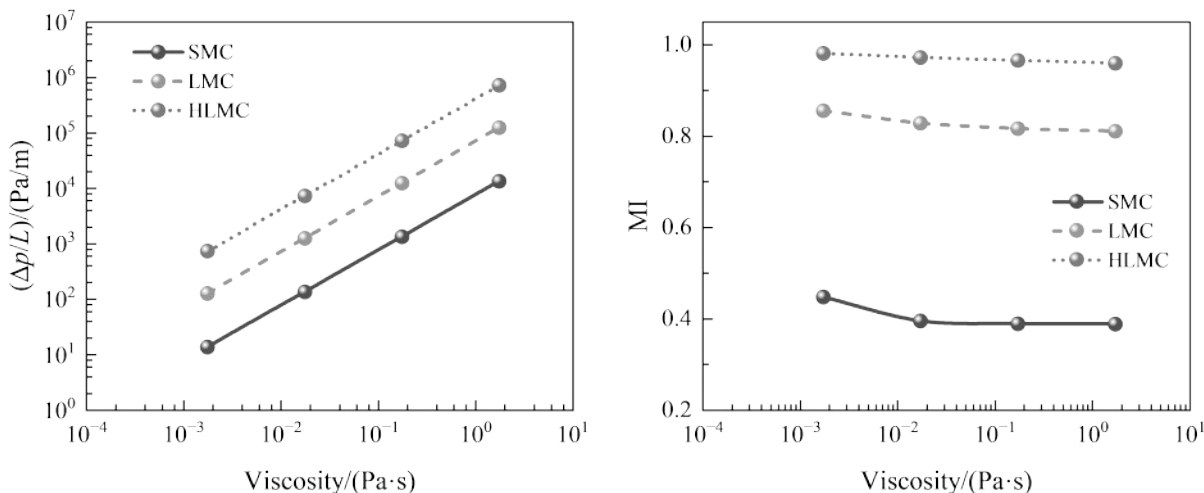


图9 不同流体黏度下三种微混合器的压降和混合指数( $H_1 = 1.0 \text{ mm}$ ,  $L_0 = 0.9 \text{ mm}$ ,  $L_1 = 1.0 \text{ mm}$ ,  $W_0 = 0.9 \text{ mm}$ ,  $W_1 = 0.9 \text{ mm}$ )  
 Fig.9 The pressure drop and mixing index for three different micromixers under different viscosities ( $H_1 = 1.0 \text{ mm}$ ,  $L_0 = 0.9 \text{ mm}$ ,  $L_1 = 1.0 \text{ mm}$ ,  $W_0 = 0.9 \text{ mm}$ ,  $W_1 = 0.9 \text{ mm}$ )

注:(a)流体黏度对压降的影响 (b)流体黏度对混合指数的影响

Dean 涡的强度增大,有效强化了流体的横向混合。然而,当 $H_1$ 进一步增大至 1.00 mm 时,混合指数的提升趋于平缓,而压降则从 395 Pa/m 显著增加至 719 Pa/m。这一现象可归因于: $H_1$ 的过度增大虽然进一步提高了螺旋晶格单元的扭曲程度,但同时导致晶格单元在轴向方向上的延伸量减小,削弱了流体在晶格内的分割与再混合效果,两种效应对混合性能的贡献趋于相互抵消;与此同时,流道扭曲程度的持续增大显著增加了流动阻力,导致压降大幅上升。因此, $H_1$ 的选取需在混合增强与压降控制之间进行权衡。

图 11 展示了  $L_0$  和  $L_1$  对 HLMC 压降和混合指数




图 10  $H_1$  对 HLMC 压降和混合指数的影响( $L_0 = 0.9 \text{ mm}$ ,  $L_1 = 1.0 \text{ mm}$ ,  $W_0 = 0.9 \text{ mm}$ ,  $W_1 = 0.9 \text{ mm}$ )

Fig.10 The effect of  $H_1$  on HLMC pressure drop and mixing index ( $L_0 = 0.9 \text{ mm}$ ,  $L_1 = 1.0 \text{ mm}$ ,  $W_0 = 0.9 \text{ mm}$ ,  $W_1 = 0.9 \text{ mm}$ )

的影响。结果表明, $L_0$ 和 $L_1$ 的增大同时有利于提高混合指数和降低压降。这是因为: $L_0$ 或 $L_1$ 的增大扩展了其对应流道的轴向尺寸,使流道的扭曲程度相应降低,流动阻力随之减小(图 11 中压降随 $L_0$ 或 $L_1$ 的增大而降低即为佐证),从而使四个流道之间的流量分配更加均匀,进而提升了整体混合性能。值得注意的是,尽管较小的 $L_0$ 或 $L_1$ 使对应流道更加扭曲,但过度的扭曲会导致局部流动阻力过大,迫使大部分流体绕行至其余流道,反而削弱了流体在晶格单元内的均匀分配,导致混合性能下降。这与 $H_1$ 的影响机制有所不同: $H_1$ 的增大使所有流道的扭曲程度同步增强,流量分配的均匀性不受影响,因此能够持续提升混合性能。

图 12 展示了  $W_0$  和  $W_1$  对 HLMC 压降和混合指数的影响。结果显示,随着  $W_0$  或  $W_1$  的增大,混合指数呈现先升高后降低的非单调变化趋势,而压降则持续降低。当  $W_0$  或  $W_1$  较小时,其所对应的流道过度扭曲,局部流动阻力较大,流体倾向于绕行至其余流道,导致流量分配不均,混合效果受限。适当增大  $W_0$  或  $W_1$  可缓解流道的过度扭曲,使各流道间的流量分配更加均匀,从而改善混合性能。然而,当  $W_0$  或  $W_1$  超过最优值后,流道的扭曲程度过度降低,二次流和 Dean 涡的强度减弱;同时,流道截面积的增大降低了局部流速,进一步削弱了对流混合的驱动力。上述非单调的影响规律表明, $W_0$  和  $W_1$  存在最优取值区间,需在流量均匀分配与对流混合强化之间寻求平衡。




图 11 (a) $L_0$ ( $H_1 = 1.0$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm)和(b) $L_1$ ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm)对 HLMC 压降和混合指数的影响

Fig.11 Effect of  $L_0$ ( $H_1 = 1.0$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm) and (b)  $L_1$ ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $W_0 = 0.9$  mm,  $W_1 = 0.9$  mm) on HLMC pressure drop and mixing index

注:(a) $L_0$ 对混合指数和压降的影响 (b) $L_1$ 对混合指数和压降的影响




图 12 (a) $W_0$ ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_1 = 0.9$  mm)和(b) $W_1$ ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm)对 HLMC 压降和混合指数的影响

Fig.12 Effect of  $W_0$ ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_1 = 0.9$  mm) and (b)  $W_1$ ( $H_1 = 1.0$  mm,  $L_0 = 0.9$  mm,  $L_1 = 1.0$  mm,  $W_0 = 0.9$  mm) on HLMC pressure drop and mixing index

注:(a) $W_0$ 对混合指数和压降的影响 (b) $W_1$ 对混合指数和压降的影响

### 2.3 基于神经网络的多目标优化

上一节的单因素分析揭示了各结构参数对 HLMC 性能的影响规律,但每次仅变化一个参数而固定其余参数的研究方式无法充分反映多个参数之间的交互效应。此外,在五维参数空间中通过逐一遍历 CFD 模拟寻找全局最优解面临着极高的计算成本。因此,本节构建深度神经网络代理模型以替代 CFD 模拟,并结合多目标优化方法在全参数空间中寻找 Pareto 最优解。表 4 列出了五个关键结构参数的取值范围与参数水平。这些取值范围主要依据 HLMC 几何结构的拓扑约束确定,即在保证四个子流道之间不发生干涉或重叠的前提下,使各子

流道截面积保持在合理范围内,从而避免局部堵塞或过高流动阻力。数据集采用全因子设计方法生成, $H_1$ 取 6 个水平、 $L_0$ 取 5 个水平、 $L_1$ 取 3 个水平、 $W_0$ 取 3 个水平、 $W_1$ 取 5 个水平,总计  $6 \times 5 \times 3 \times 3 \times 5 = 1350$  组参数组合。值得注意的是,本文采用离线全因子设计的目的在于构建覆盖五维结构参数的高精度全局代理模型,从而确保模型在整个参数空间内的预测可靠性。然而,当研究目标聚焦于多目标优化,而不需要对全参数空间进行映射时,可采用在线代理优化方法。该方法通常以少量 CFD 预模拟结果作为初始样本,并通过贝叶斯优化等自适应采样策略迭代更新代理模型,从而以更低的计算成

本获得 Pareto 最优解<sup>[36]</sup>。

表 4 结构参数的取值范围与参数水平

Table 4 Value range and parameter level of structural parameters

参数	范围	参数水平	单位
$H_1$	0.50~1.00	0.50, 0.60, 0.70, 0.80, 0.90, 1.00	mm
$L_0$	0.50~0.90	0.50, 0.60, 0.70, 0.80, 0.90	mm
$L_1$	0.60~1.00	0.60, 0.80, 1.00	mm
$W_0$	0.50~0.90	0.50, 0.70, 0.90	mm
$W_1$	0.50~0.90	0.50, 0.60, 0.70, 0.80, 0.90	mm





图 13 神经网络模型在测试集上对压降和混合指数的预测性能

Fig.13 The predictive performance of the neural network model on the test set for pressure drop and mixing index

注:(a)测试集压降预测性能 (b)测试集混合指数预测性能

上一节的单因素分析能够揭示单一结构参数对 HLMC 性能的影响规律,但在多参数耦合问题中仍可能导致趋势解释过度简化。因此,本文基于训练后的深度神经网络代理模型,进一步采用 Sobol 方法对五个结构参数进行全局敏感性分析。结果如图 14 所示,对于压降而言, $H_1$ 的敏感性最高,其次是 $L_0$ 、 $W_1$ 、 $L_1$ 、 $W_0$ 。对于混合指数而言, $W_1$ 的敏感性最高,其次是 $L_0$ 、 $W_0$ 、 $L_1$ 、 $H_1$ 。压降相关参数的一阶敏感性指数整体接近总阶敏感性指数,说明各参数对压降的独立贡献较为显著;而混合指数相关参数的一阶敏感性指数与总阶敏感性指数差异更明显,表明结构参数间的交互作用对混合性能具有重要影响。

为获得高混合指数的同时保持较低的压降,本研究采用拉丁超立方采样在参数空间内生成了 10 万组参数组合,并利用训练好的深度神经网络模型快速预测每组参数所对应的压降和混合指数。随

图 13 展示了训练后的深度神经网络模型在测试集上对压降和混合指数的预测性能。可以看出,模型预测值与 CFD 模拟值高度一致。对于压降预测, RMSE 和 MAE 分别为 41.25 Pa/m 和 20.19 Pa/m;对于混合指数预测, RMSE 和 MAE 分别为 0.0020 和 0.0014;两项输出的决定系数均达到  $R^2 > 0.995$ 。上述结果表明,所构建的深度神经网络代理模型能够准确预测不同结构参数组合下 HLMC 的压降和混合指数,可有效替代计算成本较高的 CFD 模拟,为后续多参数全局优化提供高效预测工具。

后,通过非支配排序筛选获得了 Pareto 最优前沿,结果如图 15 所示。从图中可以看出,在低压降区间(压降低于 396 Pa/m),混合指数随压降的增加而迅速提升。当压降超过 396 Pa/m 后,混合指数的增长趋于平缓。

表 5 列出了 Pareto 前沿上九个典型最优解的结构参数与对应的压降和混合指数。从表中可以看出,当压降从 319 Pa/m 增加至 396 Pa/m (增幅 24%) 时,混合指数从 0.973 提升至 0.985 (提升 1.2%);而当压降从 396 Pa/m 进一步增加至 1492 Pa/m (增幅 277%) 时,混合指数仅从 0.985 升至 0.992 (提升 0.7%)。上述定量对比进一步印证了 Pareto 前沿在压降为 396 Pa/m 附近存在显著的性能拐点:拐点之前,单位压降增加可换取较大的混合增益;拐点之后,边际收益急剧下降。因此,在实际工程应用中,当优先追求高混合效率时,可参考 Case 4 的结构参数 ( $MI = 0.985, \Delta p/L = 396 \text{ Pa/m}$ ),以较低的压降代

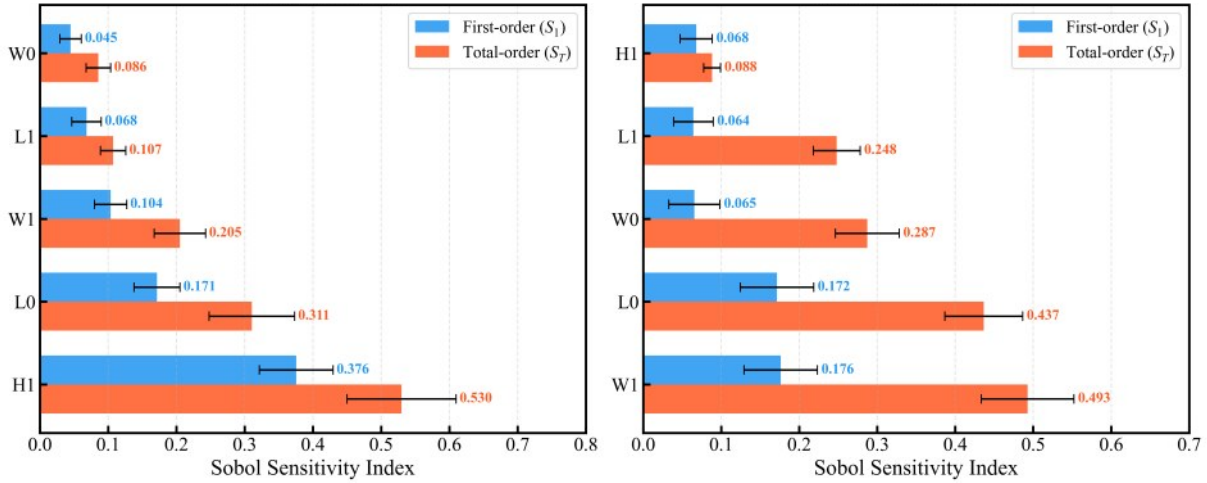


图14 Sobol全局敏感性分析图

Fig.14 Sobol global sensitivity analysis

注:(a)压降的全局敏感性分析 (b)混合指数的全局敏感性分析

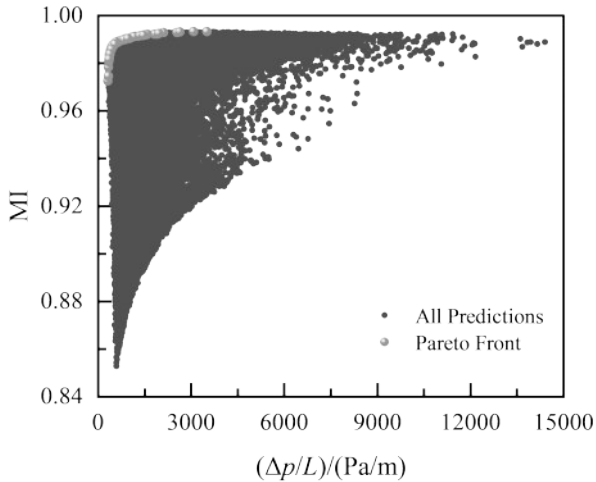


图15 HLMC混合指数与压降的Pareto最优前沿

Fig.15 Pareto optimal front of HLMC mixing index and pressure drop

价获得接近极限的混合性能;当需严格控制能耗时,可参考 Case 1 的结构参数 ( $MI = 0.973$ ,  $\Delta p/L = 319 \text{ Pa/m}$ ),在混合指数仅降低 1.2% 的前提下将压降降低 19%。虽然优化后的 HLMC ( $396 \text{ Pa/m}$ ) 压降仍高于 SMC 和 LMC,但其压降量级显著低于文献中报道的高效微混合结构(通常为  $1 \times 10^5 \text{ Pa/m}$  至  $1 \times 10^6 \text{ Pa/m}$ )<sup>[37-38]</sup>。这主要与本文微通道反应器具有较大的特征尺寸 ( $3 \text{ mm} \times 3 \text{ mm}$ ) 有关。综合考虑  $MI = 0.985$  的高混合性能和  $396 \text{ Pa/m}$  的较低压降,优化后的 HLMC 在工程应用中具有较好的可接受性,可作为后续放大设计和实验验证的候选结构。

表5 Pareto 前沿上典型最优解的结构参数与性能指标

Table 5 Structural parameters and performance indicators of typical optimal solutions on the Pareto front

Case	$H_1/\text{mm}$	$L_0/\text{mm}$	$L_1/\text{mm}$	$W_0/\text{mm}$	$W_1/\text{mm}$	$\Delta p/L/(\text{Pa/m})$	MI
1	0.526	0.889	0.996	0.884	0.871	319	0.973
2	0.650	0.874	0.998	0.899	0.854	354	0.981
3	0.701	0.899	0.987	0.845	0.868	374	0.984
4	0.704	0.893	0.988	0.891	0.803	396	0.985
5	0.763	0.892	0.999	0.863	0.759	464	0.987
6	0.850	0.900	0.984	0.892	0.746	557	0.989
7	0.919	0.886	0.899	0.891	0.712	846	0.990
8	0.978	0.792	0.888	0.897	0.690	1492	0.992
9	0.993	0.699	0.767	0.829	0.596	3519	0.993

### 3 结论

本文提出了一种新型三维螺旋晶格穿孔微通道结构以提升微混合器的混合性能,采用计算流体力学结合深度神经网络的方法对其结构进行了优化。首先,对比了 HLMC、SMC 和 LMC 的混合性能和压降。随后,研究了五个结构参数 ( $H_1$ 、 $W_0$ 、 $W_1$ 、 $L_0$ 、 $L_1$ ) 对 HLMC 性能的影响。最后,利用 1350 组 CFD 模拟数据训练深度神经网络代理模型,以实现压降和混合指数的多目标优化。得出以下主要结论:

(1) HLMC 具有优异的混合性能,其混合指数达到 0.985, 分别比 SMC 和 LMC 提高了 121% 和 15.2%。混合性能的显著提升可归因于螺旋扭转引入的 Dean 涡与二次流强化了横向对流传质,以及晶格单元的周期性分割与再合并所产生的混沌对流

效应。

(2)五个关键结构参数对 HLMC 性能的影响规律各异： $H_1$ 的增大有利于提高混合指数，但伴随压降的显著增加； $L_0$ 和 $L_1$ 的增大同时有利于提升混合指数和降低压降； $W_0$ 和 $W_1$ 对混合指数的影响均呈现先增后降的非单调趋势，存在最优取值区间。

(3)基于 1350 组 CFD 模拟数据训练的神经网络代理模型对压降和混合指数的预测精度均达到  $R^2 > 0.995$ ，能够有效替代计算成本高昂的 CFD 模拟。结合拉丁超立方采样与 Pareto 前沿分析，实现了混合性能与压降之间的多目标优化。Pareto 前沿分析表明，在压降为 396 Pa/m 处存在显著的性能拐点：在该拐点处可获得  $MI = 0.985$  的混合指数，兼顾了高混合效率与低能耗需求。

### 符号说明

- $A_i$ ——出口截面第  $i$  个网格单元面积,  $m^2$   
 $b^{(l)}$ ——神经网络第  $l$  层偏置向量  
 $c$ ——示踪剂摩尔浓度,  $mol/m^3$   
 $c_i$ ——出口截面第  $i$  个网格单元处的摩尔浓度,  $mol/m^3$   
 $\bar{c}$ ——出口截面平均摩尔浓度,  $mol/m^3$   
 $D$ ——示踪剂分子扩散系数,  $m^2/s$   
 $H_1$ ——螺旋晶格单元高度, mm  
 $h^{(l)}$ ——神经网络第  $l$  层输出向量  
 $I$ ——单位张量  
 $L_{MSE}$ ——均方误差损失函数值  
 $MI$ ——混合指数  
 $MAE$ ——平均绝对误差  
 $n$ ——训练样本数  
 $p$ ——压力, Pa  
 $\Delta p/L$ ——单位长度压降, Pa/m  
 $\Delta p^*$ ——对数归一化压降  
 $R^2$ ——决定系数  
 $Re$ ——雷诺数  
 $RMSE$ ——均方根误差  
 $u_i$ ——流体速度, m/s  
 $W^{(l)}$ ——神经网络第  $l$  层权重矩阵  
 $x$ ——待归一化的参数值  
 $x^*$ ——线性归一化后的参数值  
 $y_i$ ——第  $i$  个样本的真实值  
 $\hat{y}_i$ ——第  $i$  个样本的神经网络预测值  
 $\mu_t$ ——流体动力黏度,  $Pa \cdot s$   
 $\rho_t$ ——流体密度,  $kg/m^3$   
 $\sigma$ ——Sigmoid 激活函数  
 $\tau$ ——应力张量, Pa

### 参考文献

- [1] Usefian A, Bayareh M. Numerical and experimental investigation of an efficient convergent - divergent micromixer[J]. Meccanica, 2020, **55**(5): 1025-1035.[LinkOut]
- [2] Razavi Bazaz S, Mihandoust A, Salomon R, et al. Zigzag microchannel for rigid inertial separation and enrichment (Z-RISE) of cells and particles[J]. Lab on a Chip, 2022, **22**(21): 4093-4109.[LinkOut]
- [3] Liu C, Li Y, Liu B F. Micromixers and their applications in kinetic analysis of biochemical reactions[J]. Talanta, 2019, **205**: 120136.[LinkOut]
- [4] Fan W T, Zhao F, Chen M, et al. An efficient microreactor with continuous serially connected micromixers for the synthesis of superparamagnetic magnetite nanoparticles[J]. Chinese Journal of Chemical Engineering, 2023, **59**: 85-91.[LinkOut]
- [5] Bie H Y, Liu J H, Xue L C, et al. Flow mechanism and mixing enhancement in a micromixer based on trigonometric baffles[J]. Chemical Engineering Science, 2025, **316**: 121970.[LinkOut]
- [6] Yu Z Q, Li M T, Cao B Y. A comprehensive review on microchannel heat sinks for electronics cooling[J]. International Journal of Extreme Manufacturing, 2024, **6**(2): 022005.[LinkOut]
- [7] Gande V V, Podupu P K R, Berry B, et al. Engineering advancements in microfluidic systems for enhanced mixing at low Reynolds numbers[J]. Biomicrofluidics, 2024, **18**: 011502.[LinkOut]
- [8] Han W B, Li W, Zhang H P. A comprehensive review on the fundamental principles, innovative designs, and multidisciplinary applications of micromixers[J]. Physics of Fluids, 2024, **36**(10): 101306.[LinkOut]
- [9] Razavi Bazaz S, Sayyah A, Hazeri A H, et al. Micromixer research trend of active and passive designs[J]. Chemical Engineering Science, 2024, **293**: 120028.[LinkOut]
- [10] Wang X, Liu Z Q, Wang B, et al. An overview on state-of-art of micromixer designs, characteristics and applications[J]. Analytica Chimica Acta, 2023, **1279**: 341685.[LinkOut]
- [11] Bayareh M, Ashani M N, Usefian A. Active and passive micromixers: a comprehensive review[J]. Chemical Engineering and Processing - Process Intensification, 2020, **147**: 107771.[LinkOut]
- [12] Zhang F, Chen H, Chen B, et al. Alternating current electrothermal micromixer with thin film resistive heaters[J]. Advances in Mechanical Engineering, 2016, **8**(5): 1687814016646264.[LinkOut]
- [13] Ghorbani Kharaji Z, Bayareh M, Kalantar V. A review on acoustic field-driven micromixers[J]. International Journal of Chemical Reactor Engineering, 2021, **19**(6): 553-569.[LinkOut]
- [14] Shanko E S, van de Burgt Y, Anderson P D, et al. Microfluidic magnetic mixing at low Reynolds numbers and in stagnant fluids [J]. Micromachines, 2019, **10**(11): 731.[LinkOut]
- [15] Eric Ortiz-Castillo J, Vazquez-Pinon M, Martinez-Chapa S O, et al. A reactor-on-a-chip for cost-effective synthesis of gold nanoparticles[J]. Materials Today: Proceedings, 2022, **48**: 10-15.[LinkOut]
- [16] Ward K, Fan Z H. Mixing in microfluidic devices and enhancement methods[J]. Journal of Micromechanics and

- Microengineering, 2015, **25**(9): 094001.[LinkOut]
- [17] Chen X Y, Li T C, Hu Z L. A novel research on serpentine microchannels of passive micromixers[J]. *Microsystem Technologies*, 2017, **23**(7): 2649–2656.[LinkOut]
- [18] Javaid M U, Ahmad Cheema T, Park C W. Analysis of passive mixing in a serpentine microchannel with sinusoidal side walls[J]. *Micromachines*, 2018, **9**(1): 8.[LinkOut]
- [19] Razavi Bazaz S, Hazeri A H, Rouhi O, et al. Volume-preserving strategies to improve the mixing efficiency of serpentine micromixers[J]. *Journal of Micromechanics and Microengineering*, 2020, **30**(11): 115022.[LinkOut]
- [20] Khosravi Parsa M, Hormozi F, Jafari D. Mixing enhancement in a passive micromixer with convergent - divergent sinusoidal microchannels and different ratio of amplitude to wave length[J]. *Computers & Fluids*, 2014, **105**: 82–90.[LinkOut]
- [21] Raza W, Kim K Y. Unbalanced split and recombine micromixer with three-dimensional steps[J]. *Industrial & Engineering Chemistry Research*, 2020, **59**(9): 3744–3756.[LinkOut]
- [22] Amar K, Embarek D, Sofiane K. Parametric study of the Crossing elongation effect on the mixing performances using short Two-Layer Crossing Channels Micromixer (TLCCM) geometry[J]. *Chemical Engineering Research and Design*, 2020, **158**: 33–43. [LinkOut]
- [23] de Oliveira Maionchi D, Ainstein L, dos Santos F P, et al. Computational fluid dynamics and machine learning as tools for optimization of micromixers geometry[J]. *International Journal of Heat and Mass Transfer*, 2022, **194**: 123110.[LinkOut]
- [24] Cunegatto E H T, Zinani F S F, Biserni C, et al. Constructal design of passive micromixers with multiple obstacles *via* computational fluid dynamics[J]. *International Journal of Heat and Mass Transfer*, 2023, **215**: 124519.[LinkOut]
- [25] Raza W, Hossain S, Kim K Y. A review of passive micromixers with a comparative analysis[J]. *Micromachines*, 2020, **11**(5): 455. [LinkOut]
- [26] Hong H, Doh I, Jeong J, et al. Mixing enhancement with generation of effective secondary flow parallel to fluid interface in three-dimensional serpentine channel[J]. *Results in Engineering*, 2024, **24**: 103362.[LinkOut]
- [27] Hong H, Yeom E. Numerical and experimental analysis of effective passive mixing *via* a 3D serpentine channel[J]. *Chemical Engineering Science*, 2022, **261**: 117972.[LinkOut]
- [28] Huang X, Li X G, Xiao W D, et al. Machine learning-assisted multiscale modeling of an autothermal fixed-bed reactor for methanol to propylene process[J]. *AIChE Journal*, 2023, **69**(4): e17945.[LinkOut]
- [29] Wei H L, Ouyang B, Zhu L T, et al. Identification of the reaction network for the synthesis of adipic acid using machine learning coupling with target factor analysis[J]. *AIChE Journal*, 2023, **69** (1): e17939.[LinkOut]
- [30] Zhu L T, Chen X Z, Ouyang B, et al. Review of machine learning for hydrodynamics, transport, and reactions in multiphase flows and reactors[J]. *Industrial & Engineering Chemistry Research*, 2022, **61**(28): 9901–9949.[LinkOut]
- [31] Dobbelaere M R, Plehiers P P, Van de Vijver R, et al. Machine learning in chemical engineering: strengths, weaknesses, opportunities, and threats[J]. *Engineering*, 2021, **7**(9): 1201–1211. [LinkOut]
- [32] Yang G, Xu R, Tian Y S, et al. Data-driven methods for flow and transport in porous media: a review[J]. *International Journal of Heat and Mass Transfer*, 2024, **235**: 126149.[LinkOut]
- [33] ANSYS Inc. ANSYS Fluent Theory Guide[J]. 2011.
- [34] Wang L, Liu D Q, Wang X J, et al. Mixing enhancement of novel passive microfluidic mixers with cylindrical grooves[J]. *Chemical Engineering Science*, 2012, **81**: 157–163.[LinkOut]
- [35] Poling B E, Prausnitz J M, O'Connell J P. *The Properties of Gases and Liquids*[M]. 5th ed. New York: McGraw-Hill, 2001.[LinkOut]
- [36] Hu T, Qin L, Zhou L Y, et al. Analysis and optimization of methanol production and temperature gradient in CO<sub>2</sub> hydrogenation fixed bed reactors using CFD and Bayesian optimization[J]. *Chemical Engineering Science*, 2026, **321**: 123030.[LinkOut]
- [37] Akar S, Taheri A, Bazaz R, et al. Twisted architecture for enhancement of passive micromixing in a wide range of Reynolds numbers[J]. *Chemical Engineering and Processing - Process Intensification*, 2021, **160**: 108251.[LinkOut]
- [38] Agarwal T, Wang L Q. Mixing in a misaligned serpentine micromixer with flow splitting and recombination[J]. *ASME Journal of Heat and Mass Transfer*, 2023, **145**(3): 032502. [LinkOut]