

A 3D architectural rendering of a large circular tunnel structure, likely for a particle collider. The structure is shown in a cross-section, revealing a dark interior with a blue track or pipe running along the perimeter. The structure is supported by numerous vertical pillars. The background shows a landscape with green hills and a blue sky with clouds.

基于深度学习代理模型的桶轭结构优化 响应快速预测

夏商



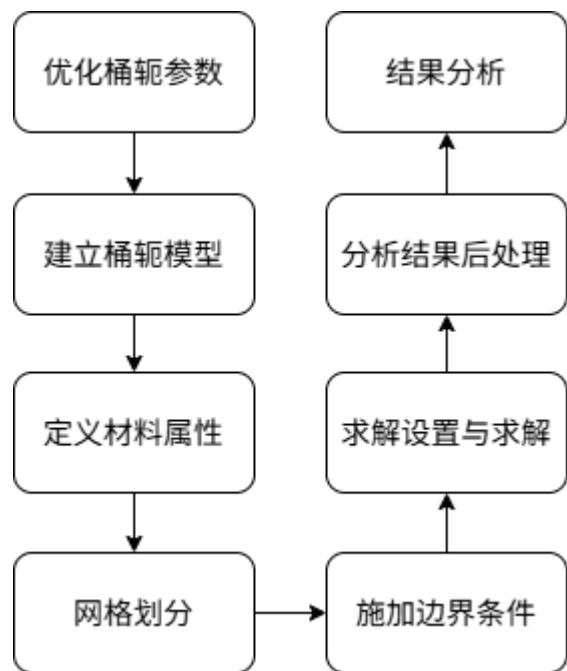
中国科学院高能物理研究所
Institute of High Energy Physics
Chinese Academy of Sciences

目录

- 研究背景与意义
- 深度学习代理模型
- 数据采集
- 模型设计
- 模型训练
- 模型验证
- 对比传统机器学习算法预测模型
- 实验条件与后续计划

研究背景与意义

桶辘FEA流程



优点:

1.分析精度高

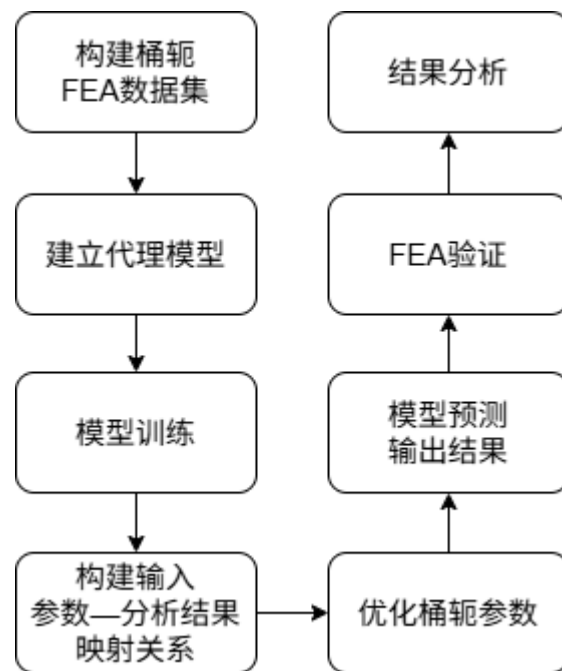
缺点:

1.优化流程耗时, 不断重复性分析流程, 效率低

2.已有分析结果无法有效利用

3.多参数优化难度大

基于代理模型的桶辘优化流程



优点:

1.代理模型替代FEA分析, 计算效率高

2.充分利用已有的分析数据

3.便于多参数优化

缺点:

1.预测精度会略低于有限元分析

2.依赖数据集的质量

意义: 基于代理模型的优化通过构建高效近似模型替代有限元分析, 在保证一定精度的前提下, 降低计算耗时、提升优化效率, 是复杂工程结构优化设计的主流与高效方法。

深度学习代理模型

代理模型：


为降低复杂系统分析与优化的计算成本，基于有限样本数据构建的、能够近似逼近原模型输入-输出映射关系的高效近似模型。在保证一定近似精度的前提下，提升桶轭结构的优化效率。

分类：

1. 多项式类(响应面优化)
2. 径向基与插值类(克里金Kriging)
3. 机器学习/神经网络类(SVR, MLP, CNN)

典型应用：


1. 结构优化/形状优化
2. 多目标优化设计
3. 仿真加速(复杂结构/多物理场耦合)



代理模型构建流程

深度学习：



机器学习的一个分支，通过构建多层神经网络，从数据中自动学习多层次的特征与映射关系，从而实现对复杂非线性系统的高精度拟合与预测。



数据采集

桶轭结构影响参数(输入参数)

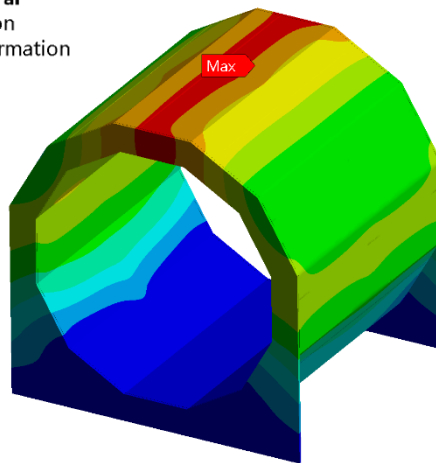

- 1.端部法兰的厚度 t , $t \in [100\text{mm}, 300\text{mm}]$
- 2.底部支撑宽度 w , $w \in [10370\text{mm}, 15000\text{mm}]$





桶轭结构响应值(输出参数)

- 1.最大变形量 δ_{max}
- 2.最大等效应力值 σ_{max}


A: Static Structural
Total Deformation
Type: Total Deformation
Unit: mm
Time: 1



A: Static Structural
Equivalent Stress
Type: Equivalent (von-Mises) Stress
Unit: MPa
Time: 1



数据采集

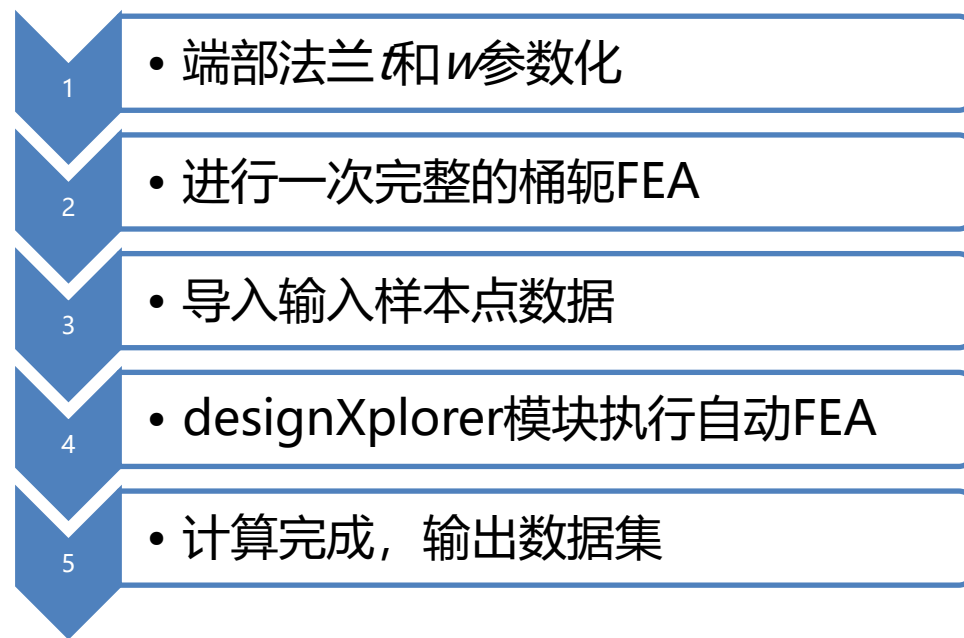


输入参数: 1500组样本点

t	w	δ_{max}	σ_{max}
100	10370
101	10500
...
300	15000

采样方法:
拉丁超立方采样方法(LHS)

优点:
能够在多维输入参数空间中实现均匀分层采样, 具有良好的空间填充性和均衡性, 是构建高精度代理模型的理想采样方式。




模型设计

代理模型核心架构:

多层感知机 (Multilayer Perceptron, MLP)

由三层或更多层全连接的神经元组成



双输入双输出MLP神经网络模型

优点:

- 1.非线性拟合能力强
- 2.数据量越大效果越好
- 3.灵活适配不同复杂度的问题

缺点:

- 1.样本过小容易过拟合
- 2.训练成本高

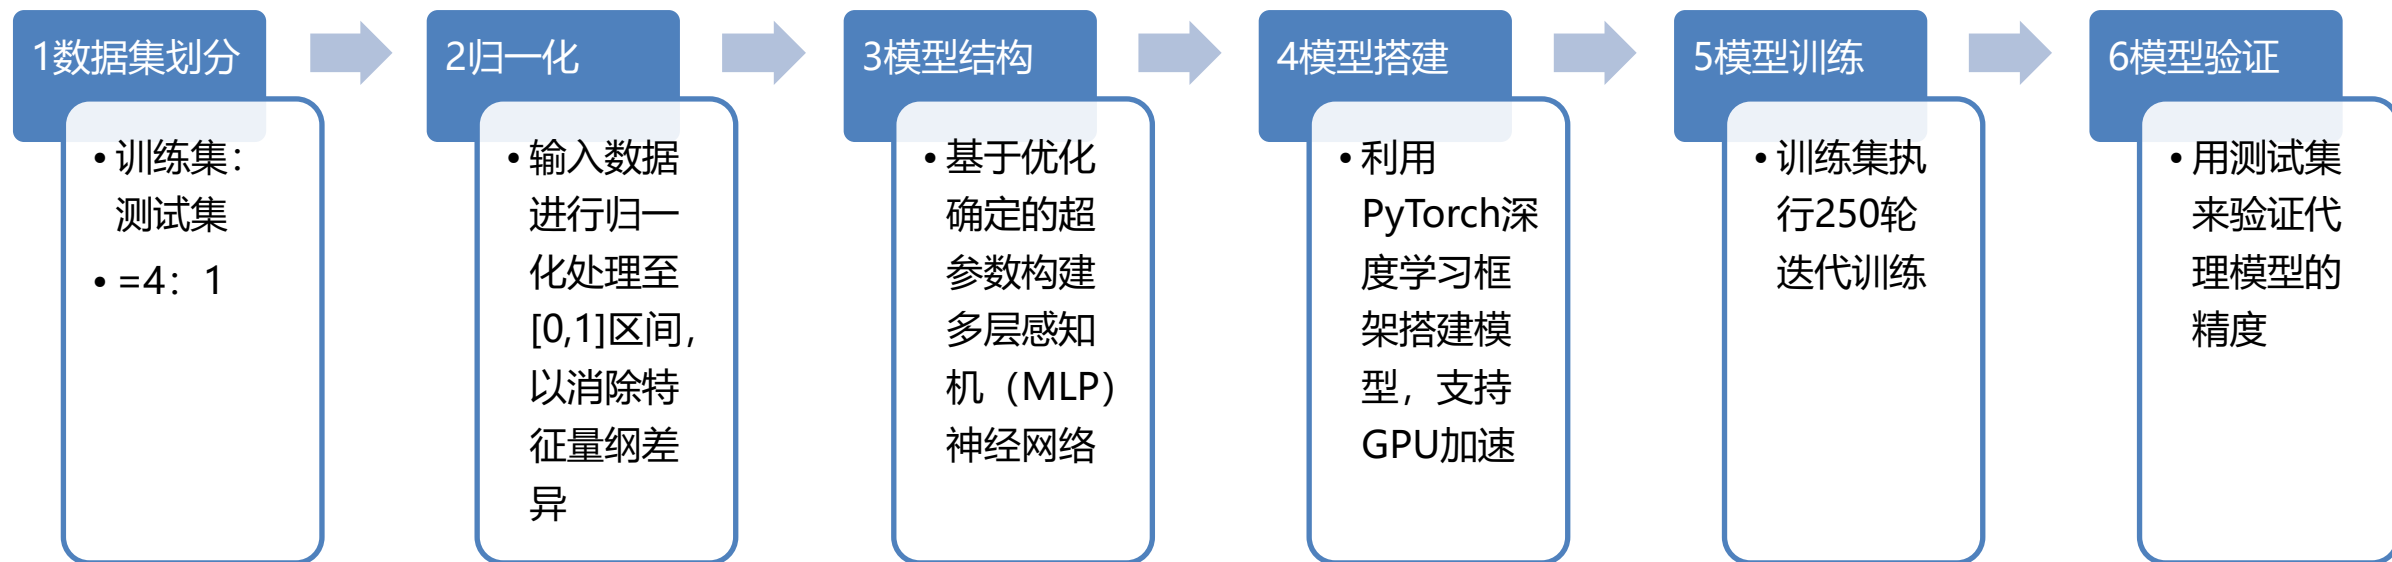
超参数:

决定神经网络的大小和形状, 选择不同的超参数值, 会极大地影响模型的性能、训练速度和泛化能力。

暂定的模型超参数

超参数	取值	意义
(fc1,fc2,fc3)	(128,64,32)	隐藏层及其神经元个数
dropout	0.08	训练时随机丢弃8%的神经元, 防止模型过拟合
激活函数	ReLU	非线性激活函数, 避免梯度消失, 提升模型表达能力
batch size	64	每次迭代训练的样本数
学习率(lr)	0.001	初始学习率, 控制参数更新步长
权重衰减	3e-6	L2正则化强度, 防止过拟合
训练轮数	250	模型训练的迭代次数
学习率调度	(50, 0.75)	缓慢降低学习率, 避免骤降导致模型停止学习
StepLR(step_size,gamma)		

模型训练



训练过程:

多层神经网络通过“加权求和做线性组合 + 激活函数引入非线性”，一层一层叠加，最终可以逼近任意复杂的非线性函数。

PyTorch:

由Facebook AI研究院开发的开源深度学习框架，基于Python语言构建，支持张量计算、自动微分、动态计算图，可高效实现神经网络的构建、训练与部署，是当前科研与工程领域构建深度学习模型的主流工具之一。

模型验证

验证方法:

通过训练集训练好的模型，用测试集的输入值来预测桶轭的最大响应值，然后将预测的最大响应值和实际值进行比较。

用时对比:


统计模型训练用时、预测桶轭的最大响应值的用时，然后与FEA用时进行比较。

常用验证指标

指标	公式	含义	取值范围	评价标准
决定系数 (R^2)	$R^2 = 1 - \frac{\sum_{k=1}^m (P_k - Q_k)^2}{\sum_{k=1}^m (\bar{Q}_k - Q_k)^2}$	衡量模型对数据变异的解释程度，反映预测值与真实值的拟合优度	(0,1)	越接近 1，模型拟合效果越好；越接近 0，拟合效果越差
平均绝对误差 (MAE)	$MAE = \frac{1}{m} \sum_{k=1}^m P_k - Q_k $	预测值与真实值绝对误差的平均值，反映平均预测偏差	$[0, +\infty)$	值越小，预测精度越高
均方根误差 (RMSE)	$RMSE = \sqrt{\frac{1}{m} \sum_{k=1}^m (P_k - Q_k)^2}$	均方误差的算术平方根，衡量预测值与真实值的离散程度	$[0, +\infty)$	值越小，模型拟合精度越高
均方误差 (MSE)	$MSE_k = \frac{1}{m} \sum_{k=1}^m (P_k - Q_k)^2$	预测值与真实值偏差平方的平均值，反映模型拟合精度	$[0, +\infty)$	值越小，模型对数据描述越精确

对比传统机器学习算法预测模型

支持向量机回归 (SVR) 算法



在线性函数的两侧构建宽度为 2ϵ 的“间隔带”，间隔带内的样本点视为预测正确（损失为零），间隔带外的样本点通过支持向量计算损失，最终通过最小化总损失与最大化间隔的平衡实现模型优化。针对非线性问题，SVR采用核函数将输入空间映射到特征空间进行线性回归。

优点：

- 1.鲁棒性强，异常值影响小
- 2.泛化能力强，不易过拟合
- 3.解释性强

缺点：

- 1.预测速度慢
- 2.需要精细调参优化

基于SVR算法的预测模型：

与上文代理模型相同的1500组训练数据
(1200组训练集+300组测试集)

核函数：

径向基函数RBF

验证指标：

同样采用决定系数 (R^2)、平均绝对误差 (MAE)、均方根误差 (RMSE)、均方误差 (MSE)、模型训练用时、预测桶轭的最大响应值的用时

超参数	意义
C	惩罚系数
gamma	控制核函数的范围
epsilon	误差容忍带

实验条件与下一步计划

- 实验条件：工作站，24核 CPU + NVIDIA RTX A2000 GPU，能够满足测试要求
- 目前已经完成了70%的桶轭FEA数据搜集
- MLP模型和SVR模型代码已搭建，等数据搜集完成，就可以开始测试
- 下一步计划：代理模型效果若达到要求，应该可以整合为一篇小论文

谢谢!