

基于机器学习的挤压铸造 A356 合金 右悬置托臂全域力学性能预测

钟皓南¹, 马万里¹, 白文辉¹, 黄智², 杨鹏², 赵海东¹

(1. 华南理工大学 国家金属材料近净成形工程技术研究中心 机械与汽车工程学院, 广东广州 510640;

2. 山东宏和轻量化科技有限公司, 山东邹平 256200)

摘要: 提出了一种基于机器学习预测A356合金挤压铸件全域力学性能的方法, 建立了包括3个输入节点、2个输出节点和11×5的隐藏层的反向传播神经网络(Back Propagation Neural Network, BPNN)模型, 通过ProCast软件进行温度场模拟获取工艺数据, 并结合组织特征识别和局部力学性能预测模型构建BPNN数据集。采用小批量梯度下降(Mini-batch Gradient Descent, MBGD)法和外推策略训练并验证BPNN模型, 建立了“工艺-组织-性能”映射关系, 预测了右悬置托臂的全域抗拉强度和伸长率分布, 并通过拉伸试验验证了预测结果的可靠性。通过分析模型的权重和偏置项, 建立多项式回归模型解释参数优化过程, 提高了模型的可解释性和泛化能力。结果表明, 该方法能够高效且低成本预测A356合金挤压铸件的全域力学性能, 为结构优化设计提供了依据。

关键词: A356合金; 挤压铸造; 机器学习; 反向传播神经网络

作者简介:

钟皓南(2000-), 男, 硕士, 主要研究方向为AlSi合金挤压铸件的性能预测。E-mail: 528533314@qq.com

通信作者:

赵海东, 男, 教授, 博士, 博士生导师。电话: 020-87112948-302; E-mail: hdzhao@scut.edu.cn

中图分类号: TG146.21;
TG113.2

文献标识码: A

文章编号: 1001-4977(2025)
10-1336-08

基金项目:

北京市自然科学基金-小米创新联合基金(L223001); 广东省重点领域研发计划资助项目(2020B010186002)。

收稿日期:

2025-03-31 收到初稿,
2025-06-11 收到修订稿。

A356合金挤压铸件因其优良的力学性能广泛应用于汽车零部件制造^[1-2]。然而, 由于挤压铸造凝固过程的非平衡性和铸件结构的复杂性, 铸件各部位的微观组织和力学性能存在显著差异^[3-5]。传统汽车零部件设计时, 由于难以获知或预测各部位的力学性能, 主要基于有限元分析(Finite Element Analysis, FEA)所得的最低性能进行全局均一化设计。该设计方式难以充分利用材料的局部性能优势, 制约了轻量化设计的实现。Borns R等的研究表明, 基于局部力学性能对汽车转向节进行结构拓扑优化, 可以实现15.5%的减重^[6]。

微观组织特征是决定力学性能的关键。传统研究大多采用试验和有限元分析方法, 马万里等通过基于图像的有限元分析技术(Image-Based FEA, IB-FEA), 结合A356合金的微观组织特征, 成功预测了不同部位的抗拉强度和伸长率^[7]。然而, 在对复杂铸件全域性能预测时受到计算成本和试验数据的制约。

机器学习技术的快速发展, 为组织特征和性能预测提供了高效途径。Cecen A等利用三维卷积神经网络(3D-Convolutional Neural Networks, 3D-CNN)模型研究了铝基复合材料微观结构与力学性能的关系, 通过选取不同的滤波器并结合高阶统计量, 提取复杂微观组织的特征, 从而显著提高了性能预测的准确性^[8]。Murakami Y等通过使用多样化的微观组织图像训练深度学习模型, 成功预测了不同Si含量铝合金的抗拉强度、断后伸长率、杨氏模量和屈服强度, 模型的决定系数高达0.8^[9]。此外, Hao Y Z等结合元胞自动机(Cellular Automaton, CA)模拟和BPNN技术, 建立了铸件的凝固时刻数据与晶粒尺寸的映射关系, 实现了压铸Al-Si-Mg合金实际导轮的全域晶粒尺寸预测^[10]。

然而设计和评估实际铸件时, 全域力学性能的预测更为关键。挤压铸件的力学性能不仅受微观组织影响, 还与工艺条件(如冷却速率、凝固条件等)密切相关。因此, 在组织特征预测的基础上, 结合工艺条件对铸件全域力学性能的预测具有重

要意义。

本研究通过ProCast软件模拟A356合金右悬置托臂挤压铸造过程中的温度场，构建了凝固温度数据集。结合基于微观组织特征的有限元分析结果，通过反向传播神经网络（BPNN）建立了“工艺-组织-性能”的映射模型，实现了铸件全域抗拉强度和伸长率的预测。预测结果通过拉伸试验验证，证明该方法的有效性。

1 模型与方法

1.1 BPNN 模型建立

本文采用的神经网络结构模型如图1所示，输入层包含3个神经元，输出层包含2个神经元，隐藏层采用11×5结构，相邻层神经元之间采用全连接方式。BPNN模型依靠前向传播（Forward Propagation）和反向传播（Back Propagation）实现模型参数的动态调整以及结果的预测^[11]。

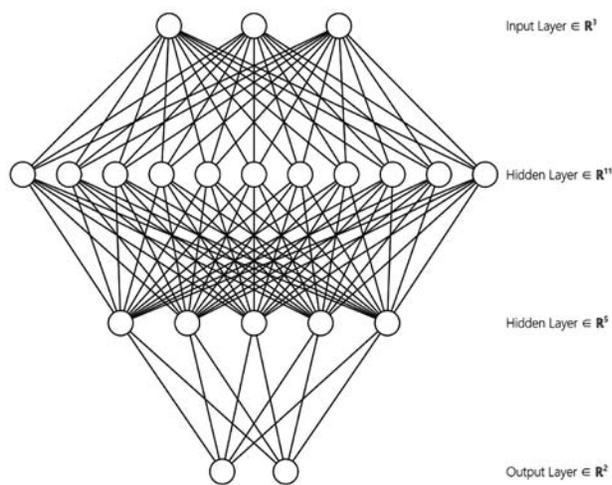


图1 挤压铸造“工艺-组织-性能”映射关系的BPNN模型
Fig. 1 The BPNN model of the “Process-Structure-Properties” relationship in squeeze casting

前向传播通过各层神经元的加权求和和激活函数的非线性变换，实现输入数据到输出结果的端到端映射。其数学表达式为：

$$y_j^k = f^k \left(\sum_{i=1}^{N_{k-1}} \omega_{ij}^k y_i^{k-1} + b_j^k \right) \quad (1)$$

式中： y_j^{k-1} 和 y_j^k 分别代表第 $k-1$ 层第 i 个神经元的值和第 k 层第 j 个神经元的值； ω_{ij}^k 表示第 $k-1$ 层第 i 个神经元与第 k 层第 j 个神经元连接的权重； b_j^k 表示第 k 层第 j 个神经元的偏置项； N_{k-1} 为第 $k-1$ 层的神经元总数； f^k 为激活函数。

本模型采用ReLU函数作为激活函数，其表达式如下：

$$f(s) = \max(0, x) \quad (2)$$

为提升模型表达能力，第一隐藏层在接收输入层结果的同时，通过融合机制引入额外特征数据进行校正，并经激活函数处理后传递至第二隐藏层进行降维和特征抽象，其表达式如下：

$$h^{(1)} = \alpha \cdot h_{\text{initial}}^{(1)} + (1-\alpha) \cdot F \quad (3)$$

式中：第一隐藏层输出 $h^{(1)}$ 为输入层结果 $h_{\text{initial}}^{(1)}$ 与组织特征 F 的加权和， α 为融合参数。

反向传播通过计算损失函数对模型参数（权重 ω_{ij} 和偏置项 b_i 统称为模型参数）的梯度，沿着梯度下降方向逐层更新参数以最小化总体误差。反向传播过程涉及两个关键因素：损失函数和梯度下降策略。

损失函数用于量化模型预测值和实际值之间的误差。本模型采用Huber损失优化迭代参数，其计算方法如下：

$$\text{HuberLoss} = \begin{cases} \frac{1}{2} (y - \hat{y})^2 & \text{if } |y - \hat{y}| \leq \delta \\ \delta (y - \hat{y})^2 - \frac{1}{2} \delta^2 & \text{otherwise} \end{cases} \quad (4)$$

式中： y 和 \hat{y} 分别为实际值与模型的预测值； δ 是Huber损失中定义的一个非负的超参数。

梯度下降策略通过沿着损失函数的负梯度方向更新模型参数，逐步接近最优解。本模型引入RMSprop自适应学习率方法以解决梯度下降策略中学习率的选择问题^[12]，同时引入动量项加速收敛并减少优化过程中的振荡，能在一定程度上避免陷入局部最优或鞍点“陷阱”^[13]，模型参数更新公式如下：

$$\theta^{(t+1)} = \theta^{(t)} - \frac{\eta_0}{r^{(t)} + \epsilon} v^{(t)} \quad (6)$$

$$v^{(t)} = \beta v^{(t-1)} + (1-\beta) \nabla L(\theta^{(t)}) \quad (7)$$

$$r^{(t)} = \lambda r^{(t-1)} + (1-\lambda) [\nabla L(\theta^{(t)})]^2 \quad (8)$$

式中： $\theta^{(t+1)}$ 和 $\theta^{(t)}$ 分别为第 $t+1$ 次和第 t 次迭代的模型参数； η_0 为初始学习率，本模型设定 $\eta_0=0.001$ ； $\nabla L(\theta^{(t)}) = \partial L(\theta^{(t)}) / \partial \theta^{(t)}$ 为第 t 次迭代时损失函数对参数 θ 的梯度； $r^{(t)}$ 为参数 θ 历史梯度平方和； ϵ 为一个避免分母为0的常数； λ 为自适应学习率衰减系数，本模型设定 $\lambda=0.999$ ； $v^{(t)}$ 为动量相，为当前梯度与前 $t-1$ 次梯度的加权； β 为动量系数，用于控制第 $t-1$ 次动量相的保留程度，本模型设定 $\beta=0.9$ 。

1.2 BPNN 数据集

BPNN数据集由三部分构成，包括挤压铸件的工艺数据、组织特征数据和力学性能数据。其中工艺数据包括初生相凝固时间 $t_{\alpha\text{-Al}}$ 、共晶相凝固时间 $t_{\alpha\text{-Al+Si}}$ 和形核过冷度 ΔT ，力学性能数据包括抗拉强度（UTS）和伸长率（EL），分别作为模型的输入和输出。组织特征数据包括包含粒子长度、面积分数和粒子间距等11个

微观组织特征参数，作为隐藏层用于模型校正。

通过ProCast软件计算右悬置托臂挤压铸造温度场。铸件的尺寸为193 mm × 135 mm × 80 mm，如图2 (a)所示，模具尺寸为308 mm × 282 mm × 166.14 mm，其中定模和动模分别如图2 (b)和 (c)所示。为简化计算，在保留原有模具基本结构的基础上，对模具结构进行简化。图2 (d)、(e)和 (f)分别为铸件、

定模、动模的网格划分结果，其中铸件网格尺寸约为1~3 mm，模具网格尺寸约为5 mm，铸件网格数量为181 460。铸件浇注温度为700 °C，预热温度为200 °C，模具采用H13钢材料。

将单元节点的温度和坐标以及固相分数数据以二进制文件形式保存，并进行数据处理和特征值筛选，具体过程如图3所示。

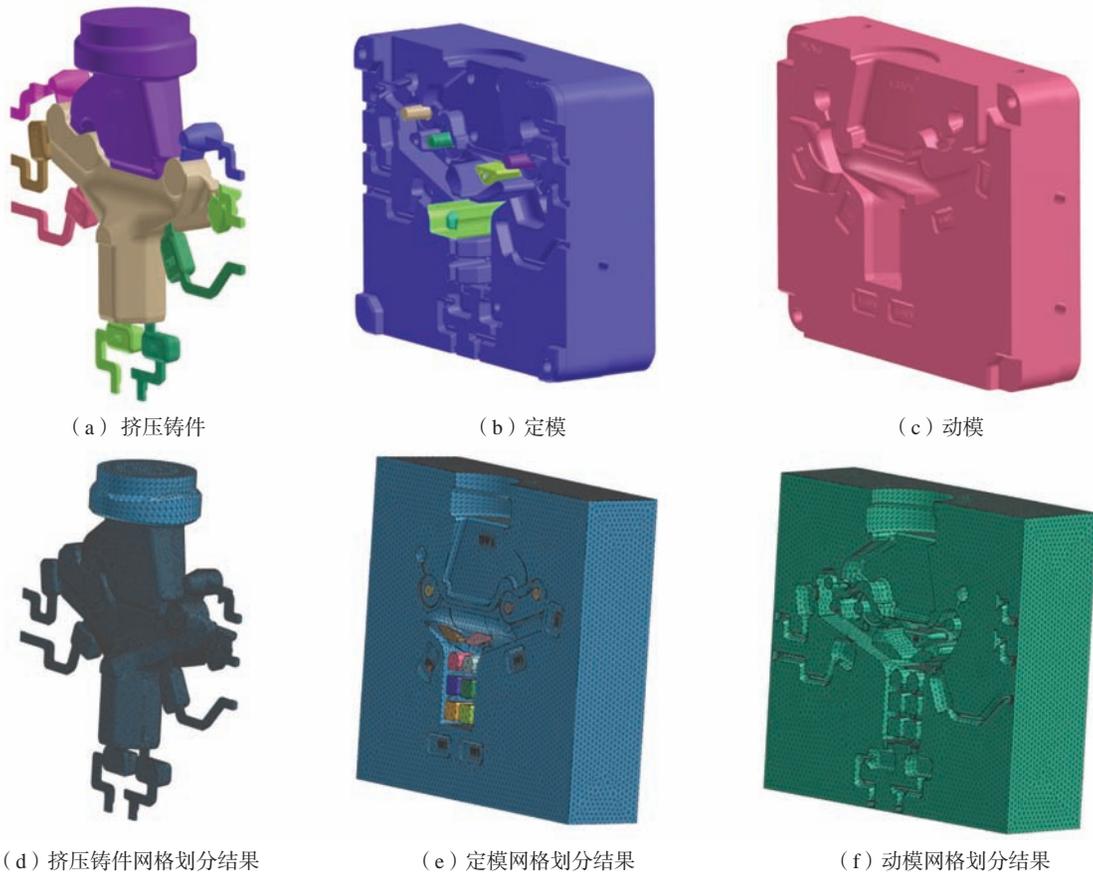


图2 铸件和模具的几何模型

Fig. 2 Models of casting and mold

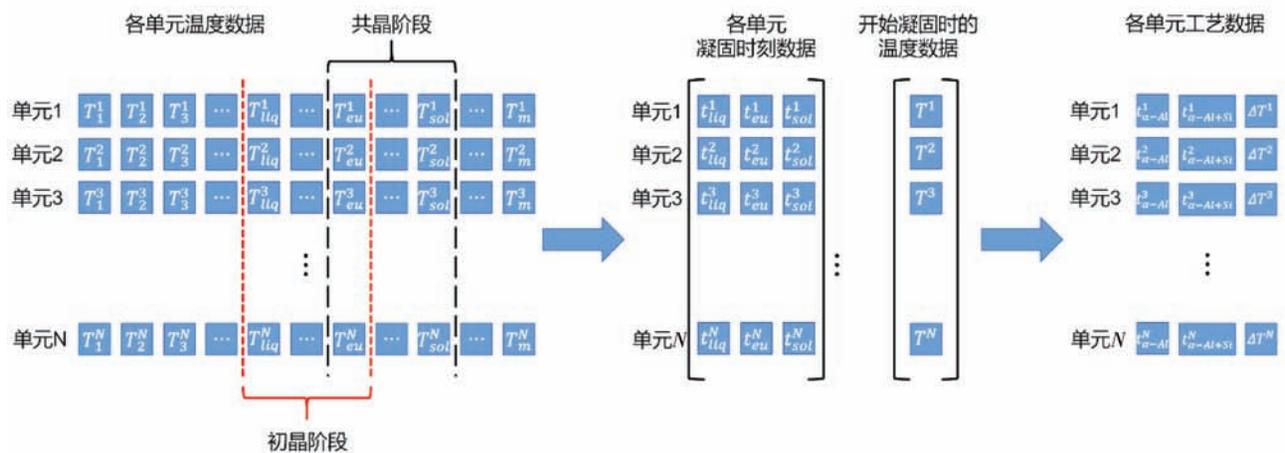


图3 温度数据处理和特征值筛选

Fig. 3 Temperature data processing and feature selecting

在挤压铸造Al-Si合金的凝固过程中，当单元温度降至液相线温度 T_{liq} 以下时，初生 α -Al相开始形成；随着温度继续降低至共晶区形成温度 T_{eu} 时， α -Al相结束生长，并开始形成共晶相；最终，当温度降至固相线温度 T_{sol} 时凝固过程完成。为准确描述铸件各单元初生 α -Al相和共晶相的生长规律，将不同铸件单元的温度数据集划分为 $[T_{sol}, T_{eu}]$ 和 $[T_{eu}, T_{liq}]$ 两个子集。对于铸件单元 i ，采用 T_{liq} 遍历不同时刻的模拟温度，得到 t_{liq}^i 。若 $T_{t+1}^i < T_{liq} < T_t^i$ ，则依据温度对时间进行线性插值。类似地，遍历 T_{sol} 和 T_{eu} 获得 t_{sol}^i 和 t_{eu}^i 。计算铸件各单元的初生 α -Al相和共晶相凝固时间 $t_{\alpha-Al}$ 和 $t_{\alpha-Al+Si}$ ：

$$t_{\alpha-Al}^i = t_{eu}^i - t_{liq}^i \quad (8)$$

$$t_{\alpha-Al+Si}^i = t_{sol}^i - t_{eu}^i \quad (9)$$

此外，初生相的形核与铸件单元的形核过冷度密切相关。通过遍历铸件单元的温度数据，找到该单元固相分数发生变化的时刻 t^i ，采用 t^i 遍历得到该单元开始凝固时的模拟温度 T^i 。同理若 $t_T^i < t^i < t_{T+1}^i$ ，则依据时间对温度进行线性插值。计算铸件单元的形核过冷度 ΔT^i ：

$$\Delta T^i = T_{liq}^i - T^i \quad (10)$$

根据Thermo-Calc软件计算的A356.2合金非平衡凝固过程，获得液相线温度为 $T_{liq}=614$ °C、固相线温度为 $T_{sol}=479$ °C、共晶区形成温度为 $T_{eu}=574$ °C，铸件单元数量为 $N=181\ 460$ 。

通过Python程序读取单元节点的温度和坐标以及固相分数数据，采用 T_{liq} 、 T_{eu} 、 T_{sol} 和固相分数变化时刻 t^i 遍历数据，计算得到铸件第 i 个单元的工艺数据 $(t_{\alpha-Al}^i, t_{\alpha-Al+Si}^i, \Delta T^i)$ ，如表1所示。

对右悬置托臂实际铸件随机选取150个部位，采用

表1 铸件单元的工艺数据集
Tab. 1 The process data of squeeze casting elements

序号	$t_{\alpha-Al}/s$	$t_{\alpha-Al+Si}/s$	$\Delta T/^\circ C$
1	0.83	23.35	3.72
2	0.79	23.44	4.35
3	0.67	24.02	3.38
...			
181 459	8.92	18.17	7.92
181 460	2.47	3.59	4.87

图像识别程序提取共晶Si粒子和 α -Al基体轮廓，定量计算微观组织特征参数，如表2所示。采用基于微观组织特征的有限元分析，计算每个部位的力学性能。以工艺数据作为自变量 $X_{process}$ ，对应的力学性能数据作为因变量 $Y_{property}$ ，将微观组织特征 $H_{structure}$ 用于模型矫正。构建BPNN数据集如表3^[7]所示，表中每一行数据表示BPNN训练的一个样本。

1.3 全域力学性能预测方法

对整个数据集进行归一化处理，并以综合目标值(50%UTS+50%EL)对其进行升序排列。将排序后的数据集分为训练集和验证集，其中训练集占80%，验证集占20%。训练集包含综合目标值较低的前80%样本，测试集包含目标值较高的后20%样本，以确保测试集的目标值超出训练集范围。

模型训练时采用MBGD^[14]法，将训练集划分为10个子集。第次训练时采用前个子集，累积式训练，渐

表2 挤压铸件不同试样的组织特征
Tab. 2 Microstructure characteristics of different samples

	颗粒长度/ μm		长径比		颗粒面积分数	颗粒间距/ μm		颗粒数密度/ μm^{-2}	颗粒形状因子		最大颗粒面积/ μm^2
	最大值	平均值	最大值	平均值		最大值	平均值		最大值	平均值	
1 [#]	6.73	5.21	4.32	1.51	0.099	1.61	4.14	0.019	3.28	1.79	322.02
2 [#]	11.89	6.25	4.95	1.68	0.117	1.40	4.12	0.020	3.75	1.86	1 118.73
3 [#]	7.47	4.82	4.13	1.62	0.116	1.72	3.74	0.021	3.07	1.80	891.70
4 [#]	5.80	3.72	4.25	1.62	0.090	1.53	3.53	0.025	2.87	1.76	773.14
5 [#]	6.44	4.80	3.93	1.87	0.097	1.80	4.21	0.021	2.89	1.76	291.54
...											
34 [#]	6.88	4.58	3.86	2.07	0.057	1.58	4.11	0.015	2.71	1.76	513.36
35 [#]	7.22	4.26	4.57	2.58	0.059	1.43	4.10	0.015	2.92	1.77	498.00
36 [#]	6.58	3.97	5.91	1.87	0.064	2.09	4.21	0.017	3.67	1.81	940.71
...											
148 [#]	7.86	4.08	5.10	1.72	0.083	1.19	3.93	0.019	4.91	1.84	683.82
149 [#]	6.93	4.03	5.05	1.58	0.048	1.55	4.33	0.010	2.94	1.82	894.98
150 [#]	7.03	4.05	6.17	1.61	0.057	1.48	4.15	0.016	3.00	1.83	669.81

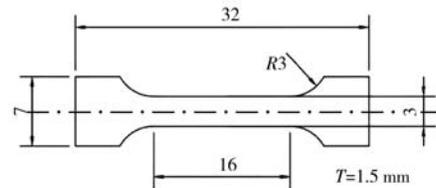
表3 BPNN输入-输出数据集
Tab. 3 BPNN input-output dataset

	工艺参数			力学性能	
	$t_{\alpha-Al}/s$	$t_{\alpha-Al-Si}/s$	$\Delta T/^\circ C$	抗拉强度/MPa	伸长率/%
1 [#]	6.37	17.09	9.75	325	7.4
2 [#]	9.91	27.35	7.86	320	5.6
3 [#]	6.22	18.39	8.77	316	4.4
4 [#]	4.80	18.91	6.13	327	8.3
5 [#]	2.68	21.34	3.77	324	7.1
			...		
34 [#]	5.00	31.44	12.85	325	8.3
35 [#]	6.46	29.90	7.96	323	7.8
36 [#]	6.21	30.14	9.20	325	8.6
			...		
148 [#]	1.46	35.50	12.58	325	7.3
149 [#]	9.46	15.37	7.83	323	7.8
150 [#]	8.57	12.79	8.07	325	8.6



图4 拉伸试验取样位置及试样尺寸

Fig. 4 Sampling position and specimen size for tensile tests



进式学习低性能到高性能样本，并动态更新BPNN模型参数。采用外推策略^[15]在验证集上进行验证。基于所得映射关系，输入表3中各单元的工艺数据，对挤压铸造A356合金右悬置托臂全域力学性能预测。

BPNN模型训练、开发和运行环境为AMD Ryzen Threadripper PRO 3995WX 64-Cores 2.70 GHz处理器，内存128 G；NVIDIA RTX A6000 10752-Cores显卡，内存48 G。

1.4 试验验证

试验采用宇部挤压铸造机HVSC350制备的A356合金右悬置托臂，热处理工艺为：随炉升温至535 °C，固溶7.5 h，出炉水淬至室温；在170 °C时效6 h，随后出炉空冷至室温。采用线切割加工方法加工片状拉伸试样，加工位置和几何尺寸如图4所示。拉伸试验在室温下进行，使用的设备为MTS E44 304电子万能材料试验机，配备视频延伸计，应变速率为 $1.0 \times 10^{-3} s^{-1}$ 。

2 结果与讨论

2.1 模型训练与验证

图5展示了BPNN模型在验证集上的预测结果与FEA计算结果的拟合程度。结果表明，建立的BPNN模型能够很好地实现挤压铸件工艺数据到力学性能的映射，可以通过该模型预测挤压铸件的全域力学性能。

2.2 全域力学性能预测

图6 (a) 和 (b) 为挤压铸件抗拉强度和伸长率的预测结果，(c) 和 (d) 为铸件部分的局部放大示意图。预测结果表明，抗拉强度和伸长率的分布呈现明显的趋势，其中料饼处抗拉强度高于铸件，但伸长率低于铸件。这是由于料饼的凝固速度较慢，共晶凝固时间长，微观组织主要以共晶形式存在，因此抗拉强度较高，但伸长率较低。

2.3 预测结果与试验结果对比分析

如图7所示为拉伸试验结果与对应区域预测的最低性能值的对比。三个区域的抗拉强度预测误差在16 MPa以内，伸长率预测误差在1.1%以内，在误差允许的范围内验证了挤压铸造A356合金铸件全域力学性能预测模型的可靠性。

实际拉伸所得的力学性能值普遍高于模型预测的最低性能值，这是因为实际拉伸试验中，Si粒子的断裂或与基体发生应力集中，诱发微裂纹形成，导致局部区域发生应力重分布。在力学性能最低区域处，微裂纹合并形成主裂纹，并向其他区域扩展。由于Si粒子分布不均匀，周围的微观结构通过裂纹偏转、裂纹桥联和裂纹钝化等微观增韧机制分散了应力集中，同时延缓了主裂纹的扩展速度，最终导致实际拉伸性能略高于局部最低性能预测值^[16]。

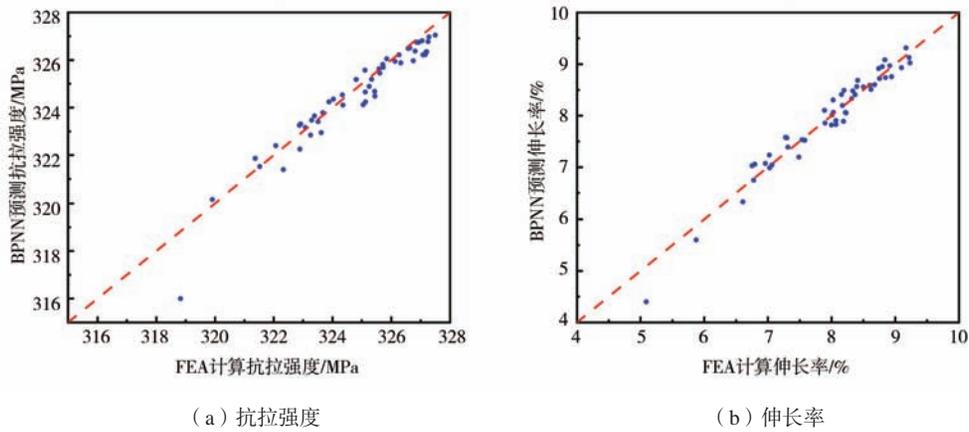


图5 BPNN与FEA结果对比
Fig. 5 Comparison between BPNN and FEA results

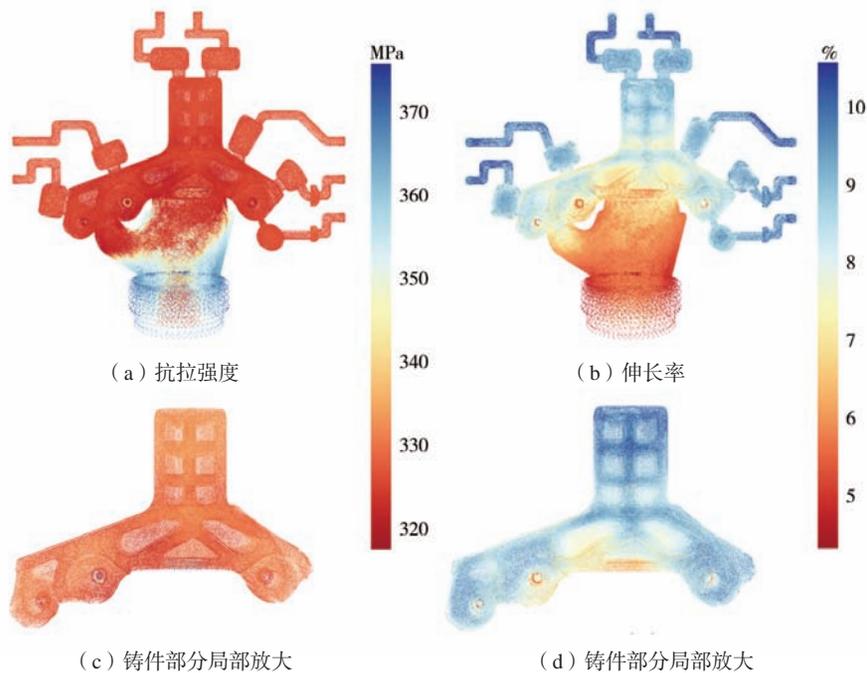


图6 挤压铸件全域力学性能预测结果

Fig. 6 Prediction results of global mechanical properties of squeeze casting

2.4 模型参数分析与优化

通过分析BPNN模型的权重和偏置参数，可以更有效地解释BPNN模型预测机制。基于铸件工艺数据对力学性能数据的影响，同时考虑到该模型涉及组织特征数据作为隐藏层的修正，构建了一个等效的三层多项式回归模型，旨在将BPNN复杂的非线性映射简化。其数学表达式如下：

$$\alpha_i^{(2)} = \sum_{j=1}^n W_{ij}^{(3)} \cdot x_j + b_i^{(3)} \quad (11)$$

$$W_{ij}^{(3)} = \sum_{k=1}^m W_{kj}^{(1)} \cdot W_{ik}^{(2)} \quad (12)$$

$$b_i^{(3)} = \sum_{k=1}^m W_{ik}^{(2)} \cdot b_k^{(1)} + b_i^{(2)} \quad (13)$$

该回归模型输入层为工艺数据，第一层（隐藏层）为组织特征数据，第二层（输出层）为力学性能数据。

式中： $\alpha_i^{(2)}$ 为第*i*个输出层神经元的激活输出； $W_{ij}^{(3)}$ 为输入特征 x_j 到输出的 $\alpha_i^{(2)}$ 总权重； $b_i^{(3)}$ 表示输出的 $\alpha_i^{(2)}$ 偏置； $W_{kj}^{(1)}$ 为输入层到第*k*个隐藏层神经元的权重； $W_{ik}^{(2)}$ 为隐藏层到第*i*个输出层神经元的权重； $b_k^{(1)}$ 为第*k*个隐藏层神经元的偏置； $b_i^{(2)}$ 为第*i*个输出层神经元的

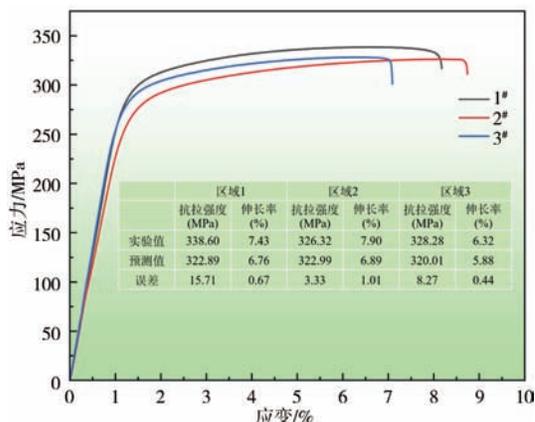


图7 拉伸试验结果与对应区域预测的最低性能值对比图

Fig. 7 Comparison of tensile test results and predicted minimum performance values for the corresponding regions

偏置。

模型参数经过多次迭代更新后结果如表4所示。

3 结论

(1) 结合温度场模拟和IB-FEA计算,建立了挤压铸件全域力学性能预测的BPNN数据集。基于BPNN

表4 挤压铸造“工艺-组织-性能”关系BPNN模型参数
Tab. 4 BPNN model parameters of squeeze casting
“Process-Structure-Properties” relationships

项目	$b_i^{(3)}$	$W_{ij}^{(3)}$
抗拉强度	330.45	$\begin{bmatrix} 0.28 & -0.13 & -0.45 \end{bmatrix}$
伸长率	11.36	$\begin{bmatrix} 0.06 & -0.06 & -0.26 \end{bmatrix}$

模型及其训练和验证方法,建立了挤压铸件工艺数据与力学性能数据之间的内在映射关系模型。通过对比BPNN预测结果与FEA计算结果的吻合度,验证了模型的准确性。

(2) 基于所建立的内在映射关系模型,预测了挤压铸造A356合金右悬置托臂的全域力学性能。结果表明所建立的全域力学性能预测方法具有高效和低成本的优势,可为铸件的优化设计提供依据。

(3) 实际拉伸试验结果与对应区域预测的最低性能对比结果表明,在误差允许的范围内,挤压铸造A356合金铸件全域力学性能预测模型具有可靠性。

(4) 对BPNN模型的权重和偏置参数进行分析,建立了多项式回归模型,描述了模型参数优化的过程,获得了最终的模型参数,提高了模型的泛化能力。

参考文献:

- [1] 齐丕骧. 挤压铸造 [M]. 北京: 国防工业出版社, 1984.
- [2] EL-KHAIR M T A. Microstructure characterization and tensile properties of squeeze-cast AlSiMg alloys [J]. Materials Letters, 2005, 59 (8/9): 894-900.
- [3] 雷月琴, 赵海东, 王雪灵, 等. 高真空压铸AlSi10MgMn合金淬火敏感性 [J]. 中国有色金属学报, 2023, 33 (9): 2839-2849.
- [4] 李俊文, 赵海东, 吴朝忠, 等. 铝合金挤压铸造过程界面的传热行为 [J]. 中国有色金属学报, 2014 (11): 2727-2734.
- [5] LI J W, ZHAO H D, WU C Z, et al. Interfacial heat transfer behavior of aluminum alloy during squeeze casting [J]. Chinese Journal of Nonferrous Metals, 2014, 24 (11): 2727-2734.
- [6] BORNS R, WHITACRE D. Optimizing designs of aluminum suspension components using an integrated approach [M]. Warrendale, PA, USA: SAE International, 2005.
- [7] 马万里, 赵海东, 王雪灵, 等. 基于组织特征的挤压铸造A356合金局部力学性能研究 [J]. 铸造, 2024, 73 (3): 303-312.
- [8] CECEAN A, DAI H, YABANSU Y C, et al. Material structure-property linkages using three-dimensional convolutional neural networks [J]. Acta Materialia, 2018, 146: 76-84.
- [9] MURAKAMI Y, FURUSHIMA R, SHIGA K, et al. Mechanical property prediction of aluminium alloys with varied silicon content using deep learning [J]. Acta Materialia, 2025, 286: 120683.
- [10] HAO Y, ZHAO H, SHEN X, et al. Simulation of α -Al grain formation in high vacuum die-casting Al-Si-Mg alloys with multi-component quantitative cellular automaton method [J]. China Foundry, 2022, 19 (2): 99-108.
- [11] ZHANG J R, ZHANG J, LOK T M, et al. A hybrid particle swarm optimization-back-propagation algorithm for feedforward neural network training [J]. Applied Mathematics & Computation, 2007, 185 (2): 1026-1037.
- [12] KINGMA D, BA J. Adam: a method for stochastic optimization [J]. Computer Science, 2014, 1412 (6): 1048550.

- [13] MOREIRA M, FIESLER E. Neural networks with adaptive learning rate and momentum terms [J]. *Technique Report*, 1995, 95 (4) : 1–29.
- [14] WILSON D R, MARTINEZ T R. The general inefficiency of batch training for gradient descent learning [J]. *Neural Networks*, 2003, 16 (10) : 1429–1451.
- [15] YONG W, ZHANG H, FU H, et al. Improving prediction accuracy of high-performance materials via modified machine learning strategy [J]. *Computational Materials Science*, 2022, 204: 111181.
- [16] 李祥. A319合金Al₂Cu相的三维特征及其对力学行为的影响 [D]. 广州: 华南理工大学, 2022.

Prediction of Global Mechanical Properties of Squeeze-Cast A356 Alloy Right Suspension Bracket Using Machine Learning

ZHONG Hao-nan¹, MA Wan-li¹, BAI Wen-hui¹, HUANG Zhi², YANG Peng², ZHAO Hai-dong¹

(1. School of Mechanical and Automotive Engineering, National Engineering Research Center of Near-Net-Shape Forming for Metallic Materials, South China University of Technology, Guangzhou 510640, Guangdong, China; 2. Shandong Honghe Lightweight Technology Co., Ltd., Zouping 256200, Shandong, China)

Abstract:

This paper proposes a machine learning-based method to predict the global mechanical properties of squeeze-cast A356 alloy components. A Back Propagation Neural Network (BPNN) model was developed with 3 input nodes, 2 output nodes, and an 11×5 hidden layer architecture. Process data were derived from temperature field simulations in ProCast software, and combined with microstructure feature identification and local mechanical property predictions to construct the BPNN dataset. The model was trained and validated using Mini-batch Gradient Descent (MBGD) and an extrapolation strategy, establishing a mapping between processing parameters, microstructure, and properties. This enabled prediction of the tensile strength and elongation distribution across a right suspension bracket, with results validated through tensile testing. Analysis of the model's weights and biases led to a polynomial regression model that elucidated the parameter optimization process, improving interpretability and generalization ability. The findings showed that this method offers an efficient, cost-effective approach to predict global mechanical properties of squeeze-cast A356 alloy components, supporting the structural optimization design.

Key words:

A356 alloy; squeeze casting; machine learning; back propagation neural network