文章编号：1001-4888(2025)06-0747-12

# 基于神经网络的金属塑性参数球形压入学习及反演识别*

贾昊霖[1]，何艳骄[1]，刘二强[2]，树学峰[1]，肖革胜[1]
(1. 太原理工大学 航空航天学院应用力学研究所，山西太原 030024；2. 太原科技大学 应用科学学院，山西太原 030024)

**摘要：** 材料的本构参数能够有效反映其在相关服役环境中的力学性能，通常需要采用相应的力学测试方法来获取，现有的宏观力学测试手段需将试样加工成特定形状尺寸，而压入法则可实现原位测试且试样加工简单。为了通过压入测试有效获取金属的力学参数，本文采用 Instron 万能材料试验机开展了紫铜和低碳钢的准静态球形压入测试，结合压入载荷-深度曲线及训练后的神经网络反演出 2 种金属的塑性本构参数，并将其与拉伸测试所得的本构参数进行对比。结果表明，基于神经网络与球形压入测试所得紫铜的屈服强度为 307.6 MPa、应变硬化系数为 69.7 MPa、应变硬化指数为 0.338 1，低碳钢的屈服强度为 269.4 MPa、应变硬化系数为 541.4 MPa、应变硬化指数为 0.474 3，这些数值与拉伸测试表征所得相应结果的最大相对误差仅为 4.22%，证明了基于神经网络与球形压入测试反演金属塑性参数方法的有效性。本文的相关研究可为有效获取金属和合金的力学性能参数提供参考。

**关键词：** 球形压入；神经网络；金属；塑性参数；数值模拟
**中图分类号：** O344.3 **文献标志码：** A DOI：10.7520/1001-4888-24-123

## 0 引言

材料力学性能参数的反演是通过试验数据和理论模型逆向推导出相关力学参数，如弹性模量、泊松比、屈服强度、硬化模量与硬化指数等，这些力学参数对优化材料设计和提高工程结构的可靠性具有重要意义[1-3]。金属和合金类材料的力学参数常通过拉伸、压缩、扭转、压入等测试方法来获取，其中前三者为传统的力学测试手段，测试时需要提供一定形状尺寸的试样[4-6]；而压入法则允许在特定应用环境中对材料进行原位测试，仅需对其特定表面区域施加局部载荷并收集压入过程中的数据，结合理论和量纲分析及数值模拟即可获取材料的相关力学性能参数[7-10]。

在不同类型的压头中，尖锐压头在测试过程中会产生应力集中现象，从而影响测试结果[11-12]，球形压头的压入测试过程则更为平滑，此外，理论上通过单个球形压头的测试结果即可获得材料的力学性能参数。目前，大多数球形压头压入测试主要集中于定性分析材料的相关力学性能[13-15]，而基于球形压入测试反演获取金属材料力学参数的定量分析，则能更准确预测材料在不同环境及载荷条件下的响应[16-17]；定量获取金属材料力学参数的难点在于给出试验数据与材料力学行为之间的函数关系[18-20]，即建立一个与两者相关的非线性数据模型。

随着机器学习的不断发展和完善[21-22]，作为其重要分支的神经网络可有效学习更加复杂的非线性

* **收稿日期：** 2024-08-12；**修回日期：** 2024-12-03
**基金项目：** 国家自然科学基金项目(12272249，12272256)；山西省基础研究计划项目(202203021211180，202203021221159)
**通信作者：** 肖革胜(1989—)，男，博士，副教授。主要研究领域：塑性力学实验技术。Email：xiaogesheng@tyut.edu.cn

数据模型[23−25],但同时神经网络也存在一些缺点,如调参复杂、容易过拟合等[26−27]。已有的结合压入测试与机器学习获取材料力学参数的相关研究中,LONG 等[28−29]借助深度学习、卷积神经网络及压入数值模拟分析获取了涂层和薄膜材料的弹塑性力学参数;田静萱等[30]通过神经网络与数值模拟建立了压入载荷-深度曲线特征参数与材料力学参数之间的联系,并基于此给出了材料塑性力学参数的表征;此外,亦有基于残余划痕宽度及划痕深度等划痕特征参数,结合深度神经网络反演金属屈服强度与应变硬化指数的研究[31];上述相关研究[28−31]主要采用锥形压头开展,鲜见关于球形压入结合机器学习获取材料力学参数的研究。

本文针对紫铜和低碳钢 2 种典型金属开展球形压入测试,对所得压入载荷-深度曲线进行数据处理,借助神经网络算法反演出金属的塑性力学参数,具体过程为:开展不同塑性力学参数组合下的球形压入数值模拟,将模拟所得压入载荷-深度曲线的特征参数作为输入层数据,并进行归一化与标准化处理;再将处理后的数据转化为二进制编码,并对其高位进行补充以确保数据位数的一致性;之后通过对比不同激活函数、初始化参数方法及不同神经网络梯度更新方式下的训练效果,搭建了具有自适应学习率且结构合理的神经网络,在此基础上结合试验所得压入载荷-深度曲线得到金属的塑性力学参数,并将其与拉伸测试结果进行对比。

## 1 试验测试与数值模拟

### 1.1 拉伸测试与表征

拉伸测试所采用标准试样的形状尺寸如图 1 所示,选取紫铜、低碳钢这 2 种典型金属材料开展研究,通过 Instron 68TM-50TAO 试验机将试样夹持在夹具上,并在标距段安装引伸计以更加准确地测量拉伸应变,拉伸加载速率为 2 mm/min。

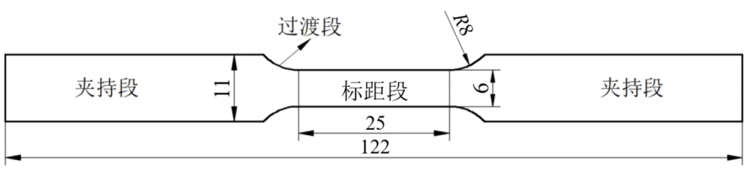


图 1 标准拉伸试样尺寸示意图(单位:mm)

Fig. 1 Diagram of relevant dimensions of tensile specimen(unit: mm)

紫铜与低碳钢的单轴拉伸测试均重复 3 次,所得载荷-位移曲线如图 2 所示(图中“测试 1、2、3”为针对紫铜与低碳钢所进行的 3 次重复性试验),拉伸载荷-位移曲线均表现出良好的重复性,文中将采用其中的 1 组数据用于结果分析。根据引伸计所记录的数据计算出紫铜的弹性模量 $E$ 为 106.8 GPa、低碳钢的弹性模量 $E$ 为 208.5 GPa,拉伸真应力 $\sigma$ 与真应变 $\varepsilon$ 可分别通过式(1)与式(2)获得,结果如图 3 所示。

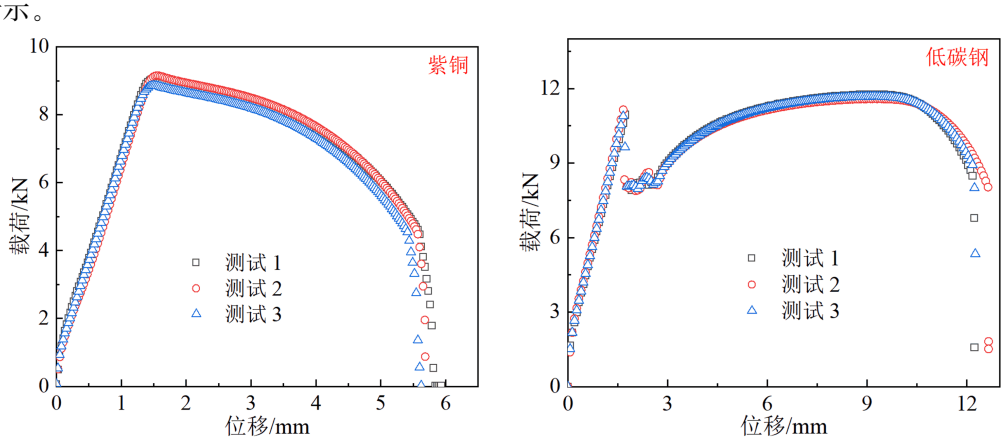


图 2 拉伸载荷-位移曲线

Fig. 2 Tensile load-displacement curves

$$\sigma = \sigma_N(1+\varepsilon_N) \tag{1}$$

$$\varepsilon = \ln(1+\varepsilon_N) \tag{2}$$

式中：$\sigma_N$ 与 $\varepsilon_N$ 分别为名义应力与名义应变，由拉伸试样的相关初始尺寸与拉伸载荷位移数据计算得到。针对图 3 中紫铜无显著屈服段的特征，取 0.2%塑性应变对应应力值之后、应力-应变曲线最大值之前的强化段数据，将其作为后续获取金属塑性力学参数的基础数据，如图 3(a)虚框与图 3(b)虚框所示；进而基于式(3)[32]拟合出紫铜的相关塑性参数：屈服应力 $\sigma_y$=313.3 MPa、应变硬化系数 $K$=72.5 MPa、应变硬化指数 $n$=0.339 5，如图 3(c)所示；低碳钢的相关塑性参数 $\sigma_y$=261.4 MPa、$K$=546.3 MPa、$n$=0.455 1，如图 3(d)所示；通过单轴拉伸试验获取紫铜、低碳钢的相关力学参数见表 1。

$$\sigma = \sigma_y + K\varepsilon_P^{\,n} \tag{3}$$

式中：$\varepsilon_P$ 为等效塑性应变；$\sigma_y$ 为屈服应力；$K$ 为应变硬化系数；$n$ 为应变硬化指数。

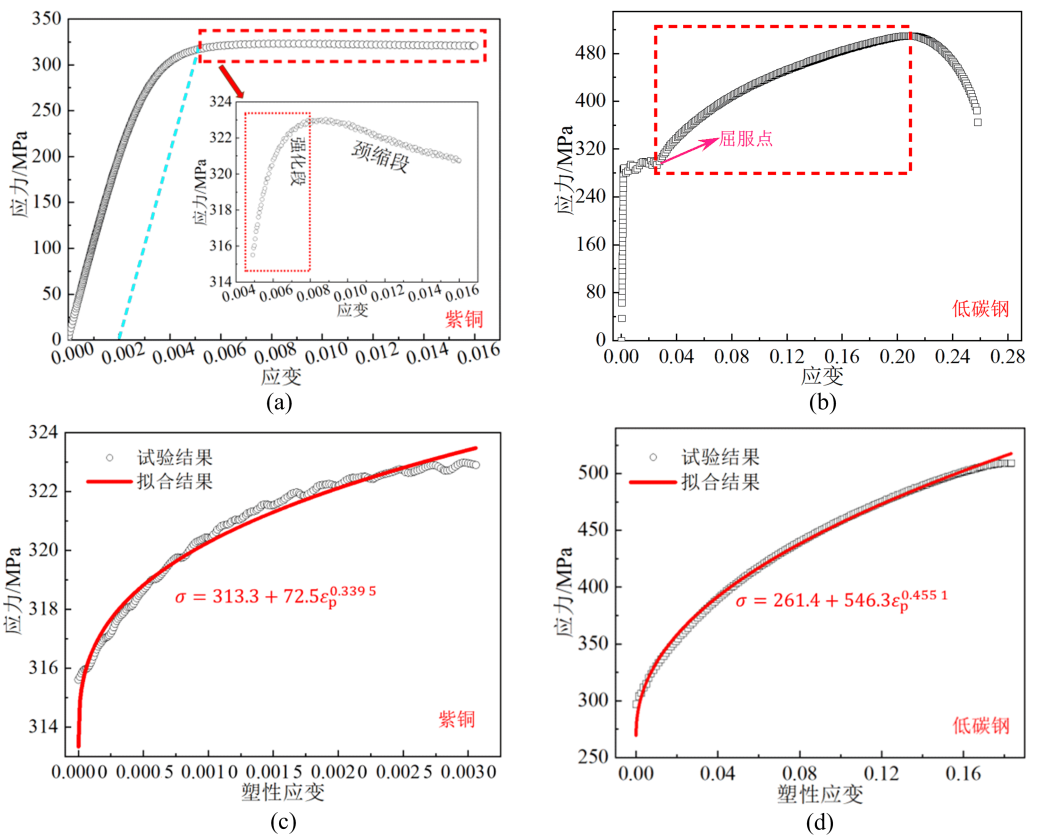


图 3　紫铜与低碳钢的拉伸应力-应变曲线及其相关塑性参数

Fig. 3　Tensile stress-strain curve and related plastic parameters of copper and low carbon steel

表 1　拉伸试验所得紫铜与低碳钢的塑性参数

Tab. 1　Plastic parameters based on tensile tests of copper and low carbon steel

| | $E$/GPa | $\sigma_y$/MPa | $K$/MPa | $n$ |
|---|---|---|---|---|
| 紫铜 | 106.8 | 313.3 | 72.5 | 0.339 5 |
| 低碳钢 | 208.5 | 261.4 | 546.3 | 0.455 1 |

## 1.2　球形压入测试与表征

锥形压头的自相似性使基于单个压头无法有效获取材料的力学性能参数[33−36]，相比而言，通过单个球形压头压入测试即可反映材料的弹-塑性变形特征，并能有效表征材料力学性能参数，进而提高测试效率；采用直径 5 mm 的碳化钨硬质合金(YG60)半球作为压头，并将其与试验机上压盘中间区域黏接固定，通过加载速率为 1 mm/min、卸载速率为 0.5 mm/min 的加载和卸载方式对直径与高度均为 20 mm 的紫铜与低碳钢柱状试样进行压入测试；鉴于被测金属可能出现的压入凸起现象对准确获取载荷-

深度曲线的影响,经预测试将紫铜、低碳钢的最大压入深度分别设置为 1.7 mm、1.6 mm。紫铜与低碳钢的球形压入测试均重复 3 次,所得载荷-深度曲线如图 4 所示,图中曲线均表现出良好的重复性,可采用其中任意一组数据用于结果分析。

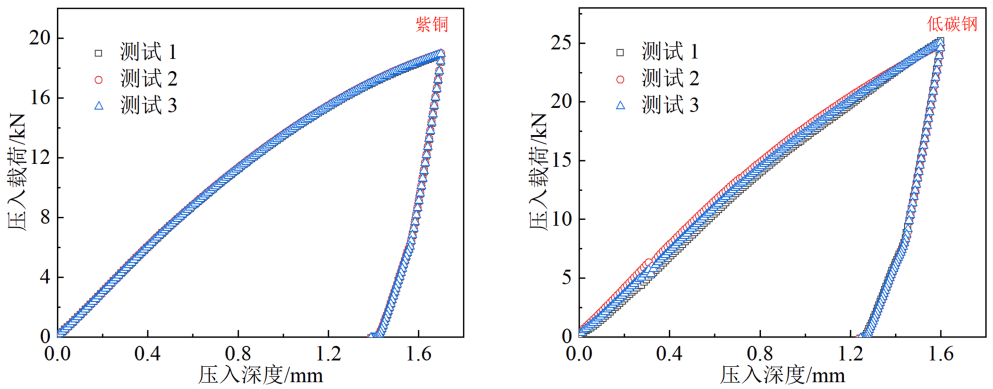


图 4 球形压入载荷-深度曲线

Fig. 4 Spherical indentation load-depth curves

针对 2 种金属材料球形压入载荷-深度曲线的特征,将加载段数据通过公式 $y=A\cdot x^2+B\cdot x$ 进行拟合,得到参数 $A$ 和 $B$,并对初始卸载段数据进行线性拟合得到初始卸载斜率值 $k$(图 5),这 3 个参数值作为对压入载荷-深度曲线的定量描述,将用于后续获取金属的塑性力学参数。

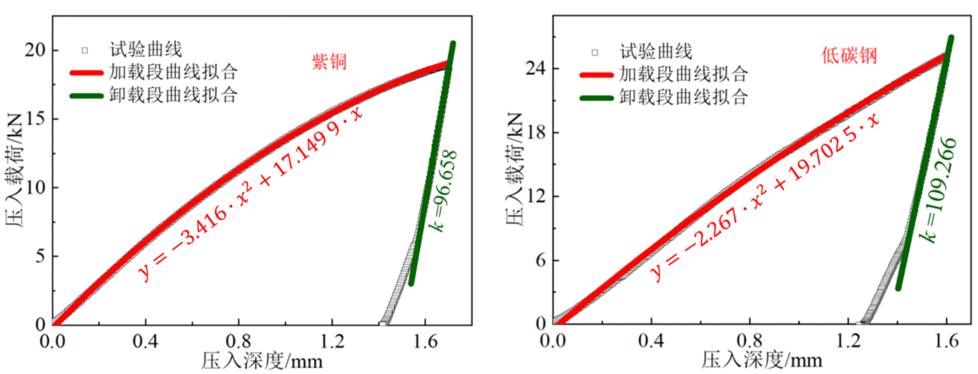


图 5 球形压入载荷-深度曲线及其特征参数

Fig. 5 Spherical indentation load-depth curves and the related characteristic parameters

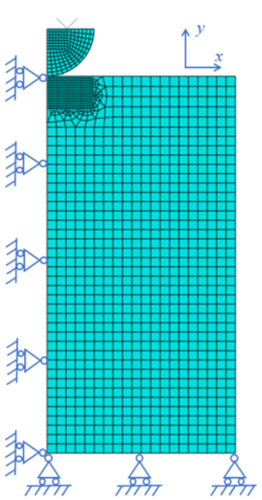


图 6 压入数值模拟模型

Fig. 6 Numerical simulation model for indentation

### 1.3 球形压入模拟与数据积累

在压入数值模拟过程中,由于压头、试样及球形压入试验的轴对称性,因此本文采用二维轴对称模型进行建模,球形压头为直径 5 mm 的 1/4 圆,压入试样水平与竖直方向的尺寸分别为 10 mm 与 20 mm;压头的弹性模量为 635 GPa(YG60 碳化钨合金),紫铜及低碳钢的弹性模量见表 1,压头与被测金属试样的泊松比分别为 0.21 与 0.30。试样的塑性变形规律遵循式(3),对压入模拟试样所设置的边界约束为对称轴上节点 $x=0$、下边界节点完全固定,对模型分区划分网格,细分压头与试样直接接触部分的网格(图 6),压头划分为数量为 147 的 CAX4R 轴对称单元,压入试样划分为总网格数为 1 121 的 CAX3(过渡区)及 CAX4R 轴对称单元。采用位移控制方式进行压入数值模拟,相应的加载和卸载速率及最大压深设置与试验测试时相同,压入数值模拟为接触变形,采用 0.15 的摩擦系数来量化压头与被压入试样之间的接触摩擦[34]。

本文通过编写控制脚本对 Abaqus 软件自动进行参数化建模、

模拟计算、数据提取，并对基于不同材料塑性力学参数模拟得到的载荷-深度数据进行存储，进一步将该数据以其对应的材料塑性参数值进行命名；基于表 2 与表 3 中不同塑性参数（$\sigma_y$、$K$、$n$）值之间的相互组合进行数值模拟，得到 1 331 组压入载荷-深度曲线，这 1 331 组数据可为后续工作提供丰富的数据基础。

表 2　用于紫铜模拟的相关塑性参数

Tab. 2　Plastic parameters used for numerical simulation of copper

| 塑性参数 | 数值 |
|---|---|
| $\sigma_y$/MPa | 250.0，260.0，270.0，280.0，290.0，300.0，310.0，320.0，330.0，340.0，350.0 |
| $K$/MPa | 20.0，30.0，40.0，50.0，60.0，70.0，80.0，90.0，100.0，110.0，120.0 |
| $n$ | 0.29，0.30，0.31，0.32，0.33，0.34，0.35，0.36，0.37，0.38，0.39 |

表 3　用于低碳钢模拟的相关塑性参数

Tab. 3　Plastic parameters used for numerical simulation of low carbon steel

| 塑性参数 | 数值 |
|---|---|
| $\sigma_y$/MPa | 210.0，220.0，230.0，240.0，250.0，260.0，270.0，280.0，290.0，300.0，310.0 |
| $K$/MPa | 500.0，510.0，520.0，530.0，540.0，550.0，560.0，570.0，580.0，590.0，600.0 |
| $n$ | 0.40，0.41，0.42，0.43，0.44，0.45，0.46，0.47，0.48，0.49，0.50 |

对图 6 所采用的压入有限元模型，以塑性参数组合“$\sigma_y$=300 MPa、$K$=70 MPa、$n$=0.34”（表 2）与“$\sigma_y$=260 MPa、$K$=550 MPa、$n$=0.45”（表 3）为例开展了不同网格密度下的压入数值模拟。由图 7 可知，整体上基于图 6 所示网格密度（Optimal mesh density）与 2 倍网格密度（Double mesh density）所得的压入载荷-深度曲线高度吻合，而基于 1/2 倍网格密度（One-half mesh density）所得的压入载荷-深度曲线则显示出一定的差异与波动性，因此，在保证压入模拟结果准确性及计算效率的前提下，图 6 所采用的有限元模型是有效的。

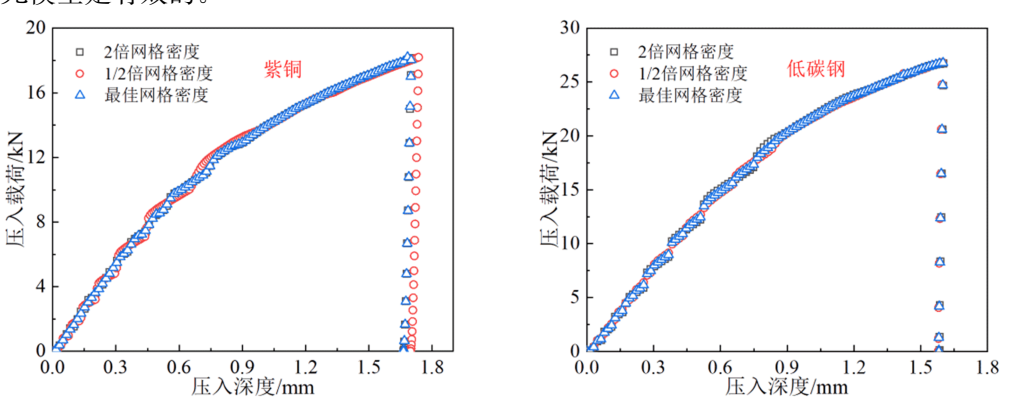


图 7　不同网格密度下的球形压入有限元模拟结果

Fig. 7　Finite element simulation results of spherical indentation under different mesh densities

## 2　神经网络

### 2.1　数据处理与积累

作为一种模仿生物神经系统结构和功能的计算模型[27]，神经网络可通过调整内部参数（权重和偏置），并基于大量数据进行训练，学习输入和输出之间的关系；而优化算法则被用来最小化预测结果和实际结果之间的误差，从而提高模型的泛化能力，使神经网络能够在新数据上表现良好。本文基于神经网络算法，将 1.3 节批量数值模拟所得载荷-深度曲线处理后作为输入层，对应的材料塑性参数为标签值作为输出层数据，并对这些数据进行训练，最终建立载荷-深度曲线与材料塑性本构参数的关系，如图 8

所示。

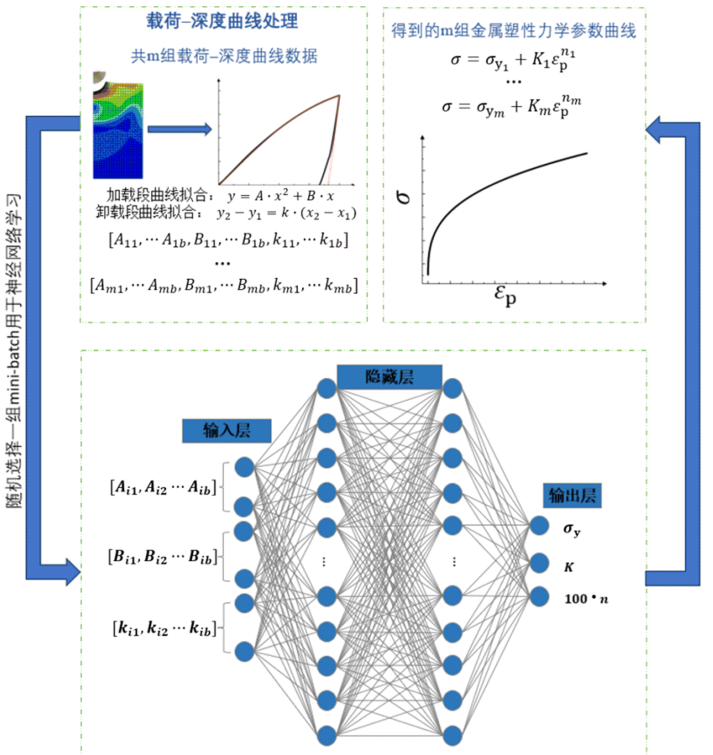


图 8 神经网络结构及相关参数

Fig. 8 Neural network structure and related parameters

将所有的 1 331 组数据按照 8∶2 的比例随机分配给训练集与测试集，鉴于 1.2 节中载荷-深度曲线特征参数($A$、$B$、$k$)的特点，对这 3 个特征参数进行如下处理：首先对参数进行取整并二进制化，将其高位补充成统一长度的二进制编码以适应第 1 层神经网络神经元的数量，经计算得出可能出现的最长数据位为 30 位，所以对小于 30 位的数据在高位补充数字 0，直到数据位数等于 30 位后停止补充，在此基础上高位补充 1 位数字用于标记曲线特征参数的正负，因此每个特征参数对应的二进制编码位数为 31。1 条载荷-深度曲线二进制化后的特征参数对应 1 个列表，在此基础上得到针对所有载荷-深度曲线的二维训练集数组，在对其进行读取的同时提取集合名(即材料的屈服应力 $\sigma_y$、应变硬化系数 $K$、应变硬化指数 $n$)作为标签集。本文采用的损失函数是均方误差损失函数 $L$，如式(4)所示[27]：

$$L=\frac{1}{2N}\sum_{i=1}^{N}\sum_{j=1}^{N'}(y_{ij}-t_{ij})^2 \tag{4}$$

式中：$N$ 为 1 组 mini-batch 数据的数量，1 组 mini-batch 是指每次进行神经网络训练前从训练集中随机选取的 1 小组数据；$N'$ 与 $y_{ij}$ 分别为输出层神经元数量及最末层输出值(即材料的屈服应力、应变硬化系数、应变硬化指数)；$t_{ij}$ 为监督数据。屈服应力的量级为 $10^2$，硬化系数的量级为 $10\sim10^2$，而硬化指数的量级则为 $10^{-1}$，由于塑性硬化指数 $n$ 的量级相对较小，为此将其均放大 100 倍。1 个二维列表对应 1 个载荷-深度曲线集合名，对其进行读取与处理以作为训练标签数组，为方便神经网络读取数据，将二维训练集与训练标签数组转化为 numpy 数组。

## 2.2 寻找最优参数策略及激活函数的选取

SGD(随机梯度下降法)、Momentum(动量优化法)、AdaGrad(自适应梯度法)和 Adam(自适应矩估计方法)是神经网络算法中常用的优化策略，在使用过程中需要根据具体情况选择合适的策略。SGD 是最基本的优化策略之一，简单易实现且适用于大数据集，其数学表达式如下[27]：

$$\theta_t=\theta_{t-1}-\alpha\cdot g_t \tag{5}$$

式中：$\theta_t$ 为迭代 $t$ 次后的模型参数；$g_t$ 为目标函数迭代 $t$ 次后的梯度；$\alpha$ 为学习率。SGD 中每一次参数

更新仅依赖于当前的梯度，容易受到梯度噪声的干扰；对损失函数表面比较崎岖的情况，可能导致参数更新方向的不断变动，影响收敛的稳定性。对此，Momentum 通过动量项（$m$）在 SGD 的基础上引入了之前梯度的影响，减少震荡并加快了收敛速率，其数学式如下[37]：

$$\begin{cases} m_t=\beta_1 m_{t-1}+(1-\beta_1)\,g_t \\ \hat{m_t}=\dfrac{m_t}{1-\beta_1^t} \\ \theta_t=\theta_{t-1}-\alpha\cdot\hat{m_t} \end{cases} \tag{6}$$

式中：$m_t$ 为迭代 $t$ 次后的动量值；$\beta_1$ 为动量因子；$\hat{m_t}$ 为 $m_t$ 的矩估计。

由于动量初始值 $m_0=0$，$m_1$（迭代 1 次的动量值）则非常小，因此对 $m_t$ 进行修正，引入的动量因子 $\beta_1$ 通常取 0.9[27]。Momentum 采用固定的学习率，无法完全适应参数尺度各异的复杂模型；AdaGrad 通过计算梯度平方的加权平均，能有效应对梯度消失或爆炸问题，适用于参数更新方向和速度频繁变化的情况，能为每个参数定制合适的学习率并提升模型训练的效率和稳定性，数学表达式如下[37]：

$$\begin{cases} v_t=\beta_2 v_{t-1}+(1-\beta_2)\,g_t^2 \\ \hat{v_t}=\dfrac{v_t}{1-\beta_2{}^t} \\ \theta_t=\theta_{t-1}-\dfrac{\alpha}{\sqrt{\hat{v_t}}+\varepsilon}\cdot g_t \end{cases} \tag{7}$$

式中：$v_t$ 是迭代 $t$ 次后梯度平方的加权平均，同样初始化 $v_0=0$；$\beta_2$ 为二阶矩因子；$\hat{v_t}$ 为 $v_t$ 的矩估计；$\alpha$ 为全局学习率，用来控制所有参数更新的步长；$\varepsilon$ 通常取 $10^{-8}$，以防止计算自适应学习率时除数为 0 的情况。AdaGrad 在训练后期收敛速度缓慢；Adam 策略结合了 Momentum 和 AdaGrad 的优点，不仅引入了历史梯度的影响，也能够自适应地调整每个参数的学习率，收敛速度快且对超参数不敏感[27]，其数学式如下[37]：

$$\begin{cases} g_t=\nabla_\theta f_t(\theta_{t-1}) \\ m_t=\beta_1 m_{t-1}+(1-\beta_1)\,g_t \\ v_t=\beta_2 v_{t-1}+(1-\beta_2)\,g_t^2 \\ \hat{m_t}=\dfrac{m_t}{1-\beta_1^t} \\ \hat{v_t}=\dfrac{v_t}{1-\beta_2^t} \\ \theta_t=\theta_{t-1}-\dfrac{\alpha\cdot\hat{m_t}}{\sqrt{\hat{v_t}}+\varepsilon} \end{cases} \tag{8}$$

式中：$\nabla_\theta$ 为参数 $\theta$ 的梯度；$f_t$ 为迭代 $t$ 次后的目标函数。

本文分析比较了采用 4 种寻优策略对训练集数据进行学习时的响应，给出了如图 9 所示损失函数值随训练次数的变化趋势（以紫铜为例），由图可见，相比于 Momentum 与 AdaGrad 策略，Adam 与 SGD 策略下的损失函数值在训练后期均很低，同时 Adam 策略下的后期损失函数值低于 SGD 策略，且收敛所需要的训练次数更少，因此最终选择 Adam 策略作为本文中的优化策略。

激活函数将非线性特性引入到神经网络中，这对处理复杂和线性不可分的数据至关重要，通过引入非线性因素，使神经网络能够逼近任意非线性函数，可帮助模型学习复杂函数[27]。在常用的激活函数中，ReLu 函数不会出现梯度消失的问题，有助于在深层神经网络中传播梯度，从而可加速训练过程；同时 ReLu 函数的计算简单，只需要比较输入值是否大于 0 即可，因此在实际应用中具有较高的计算效率，ReLu 函数的表达式为

$$h(x)=\begin{cases} x & (x>0) \\ 0 & (x\leqslant 0) \end{cases} \tag{9}$$

式中:$h(x)$为 ReLu 函数。为了加速神经网络的收敛速度并提升训练效果,结合本文采用的 ReLu 激活函数,初始化神经网络权重的方法采用“He 初始化”。“He 初始化”的特点是根据上一层神经元的数量改变权重初始化时正态分布标准差的值,即对全连接层从均值为 0、方差为 $2/n$ 的正态分布中随机抽取权重,其中 $n$ 为上一层神经元的数量。通过测试得到是否使用“He 初始值”对神经网络训练效果的影响(图 10),不采用“He 初始值”时,训练后期的损失函数值相对较大、效果较差,因此本文在训练神经网络时采用“He 初始值”。

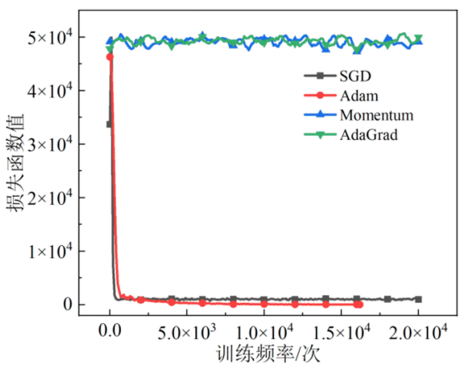


图 9 不同寻找最优参数策略对神经网络训练效果的影响

Fig. 9 Influence of different optimal parameter search strategies on neural network training effect

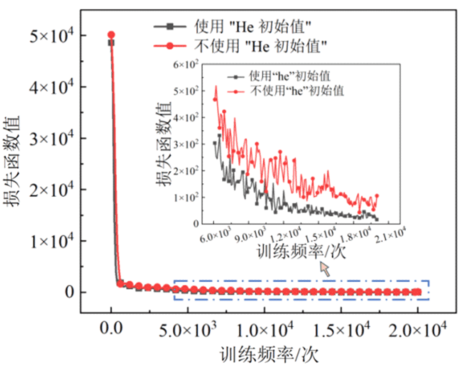


图 10 是否使用“He 初始值”对损失函数值的影响

Fig. 10 Effect of whether to use the “He initial value” on loss function value

## 2.3 神经网络的神经元结构及反演结果

本文所用神经网络的输入层为 93 个神经元,这 93 个神经元具体为:对图 5 所得压入载荷-深度曲线的 3 个特征参数 $A$、$B$、$k$ 分别予以二进制化及高位补充等处理后,每个特征参数对应的二进制编码位数为 31;输出层为 3 个神经元(对应于 3 个塑性参数),学习过程中收敛条件设置为紫铜的训练次数大于 20 000、低碳钢的训练次数大于 50 000,通过改变隐藏层神经元数量来使神经网络达到较好的训练效果,比较不同隐藏层神经元数量下的训练集损失函数随训练次数的变化(图 11),图中曲线以隐藏层神经元数量命名。由图 11 可知,在一定范围内,神经网络结构越复杂,训练前期损失函数值下降越快,但同时训练 1 次的时间也相对越长(图 12),神经网络结构较简单时容易出现欠拟合,如图 11(a)和图 11(b)中的“5”与“5-5”(5-5 代表隐藏层为 2 层,每层均有 5 个神经元)所示,综合考虑损失函数最终值与每遍历 1 次训练集的时间(图 12),最终选择“93-300-3”为由压入载荷-深度曲线反演紫铜塑性参数的神经网络结构,“93-50-50-3(93 代表输入层有 93 个神经元,中间的 50-50 代表隐藏层为 2 层,每层均有 50 个神经元,最后的 3 代表输出层有 3 个神经元)”为由压入载荷-深度曲线反演低碳钢塑性参数的神经网络结构。

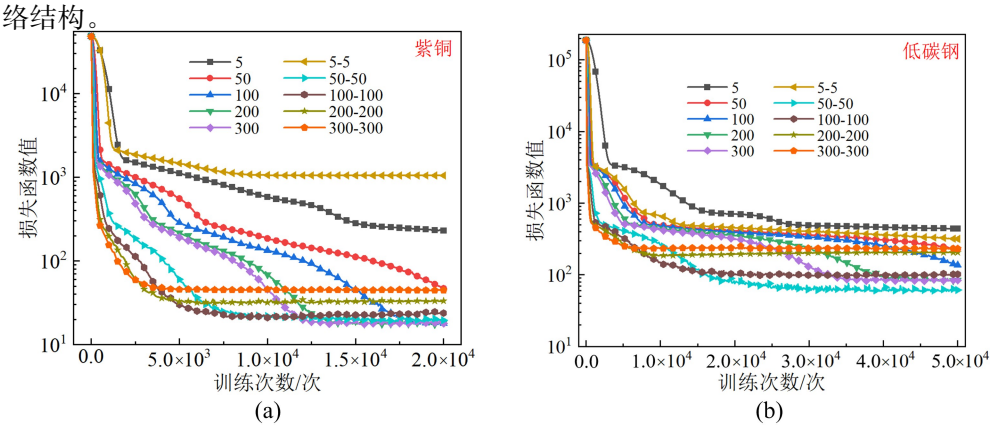


图 11 隐藏层神经元结构对训练集训练效果的影响

Fig. 11 Influence of neuron structures with different hidden layers on the training effect of training set

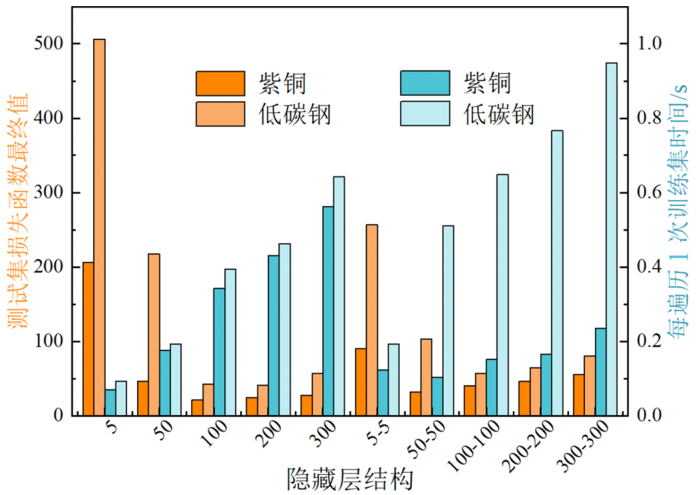


图 12　隐藏层神经元结构对损失函数最终值与训练时间的影响

Fig. 12　Influence of neuron structures with different hidden layers on the final value of training loss function and training time

选用最优的神经网络结构进行学习后，得到紫铜的训练集与测试集损失函数值均为 17.9，低碳钢训练集与测试集损失函数值分别为 43.2、61.4；结合试验所得 2 种金属的压入载荷-深度曲线数据(图 5)与训练好的神经网络，得到紫铜与低碳钢的相关塑性参数见表 4，与拉伸测试所得 2 种金属的塑性参数进行对比可知，2 种方法所得结果的相对误差最大仅为 4.22%，相对误差由[(神经网络反演结果－拉伸测试结果)/拉伸测试结果]×100%计算得到，从而验证了本文结合神经网络与球形压入载荷-深度曲线反演金属塑性力学参数的可行性。

表 4　2 种金属塑性参数的神经网络反演结果与拉伸测试结果

Tab. 4　Neural network inversion results and tensile test results of plastic parameters for the two metals

| | | 紫铜 | 低碳钢 |
|---|---|---|---|
| $\sigma_y$/MPa | 神经网络反演结果 | 307.6 | 269.4 |
| | 拉伸测试结果 | 313.3 | 261.4 |
| | 相对误差 | －1.82% | 3.06% |
| $K$/MPa | 神经网络反演结果 | 69.7 | 541.4 |
| | 拉伸测试结果 | 72.5 | 546.3 |
| | 相对误差 | －3.86% | －0.90% |
| $n$ | 神经网络反演结果 | 0.338 1 | 0.474 3 |
| | 拉伸测试结果 | 0.339 5 | 0.455 1 |
| | 相对误差 | －0.41% | 4.22% |

## 3　结论

本文利用球形压入载荷-深度曲线与神经网络算法进行了紫铜、低碳钢的塑性参数反演研究，相关研究过程与结论如下：

1)对球形压入测试所得紫铜、低碳钢的压入载荷-深度曲线进行特征提取，将不同塑性参数组合下压入数值模拟所得载荷-深度曲线特征参数作为神经网络算法的数据集，针对模拟所得数据集特征参数的特点，对其进行归一化标准化处理，再将处理后的数据转化为二进制编码并对其高位进行补充以确保数据位数的一致性。将金属的塑性力学参数作为输出层数据，在此基础上根据损失函数结果建立了通过压入载荷-深度曲线反演金属塑性力学参数的有效神经网络结构；学习后紫铜的训练集与测试集损失

函数值均为17.9,低碳钢训练集损失函数值为43.2,测试集损失函数值为61.4,均没有出现过拟合现象。

2)传统拉伸测试分析所得紫铜的塑性参数为$\sigma_y$=313.3 MPa、$K$=72.5 MPa、$n$=0.339 5,低碳钢的塑性参数为$\sigma_y$=261.4 MPa、$K$=546.3 MPa、$n$=0.455 1;结合试验所得2种金属的压入载荷-深度曲线数据与训练好的神经网络得到紫铜的塑性参数为$\sigma_y$=307.6 MPa、$K$=69.7 MPa、$n$=0.338 1,低碳钢的塑性参数为$\sigma_y$=269.4 MPa、$K$=541.4 MPa、$n$=0.474 3;2种金属塑性参数的神经网络反演结果与相应拉伸测试表征结果的相对误差最大值仅为4.22%,验证了本研究结合球形压入载荷-深度曲线与神经网络算法反演金属塑性力学参数方法的有效性。

**参考文献:**


[1] 张茜,王娟,亢一澜. 实验数据反演识别分析方法与力学表征[J]. 实验力学,2013,28(2):141-150 (ZHANG Qian, WANG Juan, KANG Yilan. Inversion identification method and mechanical characterization based on experimental data[J]. Journal of Experimental Mechanics, 2013, 28(2):141-150 (in Chinese))

[2] 陶伟明,吕景贵,徐博侯,等. 肺组织、肿瘤材料参数的反演[J]. 力学季刊,2006,27(3):463-468 (TAO Weiming, LÜ Jinggui, XU Bohou, et al. Inverse analysis of material parameters for lung tissure and tumor[J]. Chinese Quarterly of Mechanics, 2006, 27(3):463-468 (in Chinese))

[3] 李云鹏,王芝银,丁秀丽. 岩体原位流变荷载试验的力学参数与模型反演[J]. 实验力学,2005,20(2):297-303 (LI Yunpeng, WANG Zhiyin, DING Xiuli. Back analysis of mechanical parameters and model of rheological in situ loading test for rock mass[J]. Journal of Experimental Mechanics, 2005, 20(2):297-303 (in Chinese))

[4] YANG J S, DENG M K, WANG Y T, et al. Uniaxial tensile test of high-strength high-ductility concrete (HSHDC): mechanical response and toughness evaluation[J]. Journal of Building Engineering, 2024, 89: 109332.

[5] 刘星辰,黄锋,李修磊,等. 高温处理灰岩单轴压缩力学性质及能量演化规律[J]. 力学季刊,2023,44(4):854-866 (LIU Xingchen, HUANG Feng, LI Xiulei, et al. Uniaxial compression mechanical properties and energy evolution law of high temperature treated limestone[J]. Chinese Quarterly of Mechanics, 2023, 44(4):854-866 (in Chinese))

[6] 王洁,郭昱,张小虎,等. 基于单目位姿估计的拉力扭转形变测量方法研究[J]. 实验力学,2017,32(6):725-732 (WANG Jie, GUO Yu, ZHANG Xiaohu, et al. On the measurement method of tensile torsion deformation based on monocular pose estimation[J]. Journal of Experimental Mechanics, 2017, 32(6):725-732 (in Chinese))

[7] 张泰华. 微/纳米力学测试技术:仪器化压入的测量、分析、应用及其标准化[M]. 北京:科学出版社,2013 (ZHANG Taihua. Micro/nano mechanics testing technology: instrumental indentation measurement, analysis, application and standardization[M]. Beijing: Science Press, 2013 (in Chinese))

[8] GOULDSTONE A, CHOLLACOOP N, DAO M, et al. Indentation across size scales and disciplines: recent developments in experimentation and modeling[J]. Acta Materialia, 2007, 55(12):4015-4039.

[9] SONG Z, KOMVOPOULOS K. An elastic-plastic analysis of spherical indentation: constitutive equations for single-indentation unloading and development of plasticity due to repeated indentation[J]. Mechanics of Materials, 2014, 76:93-101.

[10] CLAYTON J D, CASEM D T, LLOYD J T, et al. Toward material property extraction from dynamic spherical indentation experiments on hardening polycrystalline metals[J]. Metals, 2023, 13(2):276.

[11] KIM S, LEE H C. Error estimate of a finite element method for an optimal control problem with corner singularity using the stress intensity factor[J]. Numerical Methods for Partial Differential Equations, 2022, 38(6):1578-1594.

[12] 刘明,侯冬杨,高诚辉,等. 利用维氏和玻氏压头表征半导体材料断裂韧性[J]. 力学学报,2021,53(2):413-423 (LIU Ming, HOU Dongyang, GAO Chenghui, et al. Study on fracture toughness of semiconductor material using vickers and berkovich indenters[J]. Chinese Journal of Theoretical and Applied Mechanics, 2021, 53(2):413-423 (in Chinese))

[13] GAO C H, PROUDHON H, LIU M. Three-dimensional finite element analysis of shallow indentation of rough

strain-hardening surface[J]. Friction, 2019, 7(6):587-602.

[14] SONG Z, KOMVOPOULOS K. Elastic-plastic spherical indentation: deformation regimes, evolution of plasticity, and hardening effect[J]. Mechanics of Materials, 2013, 61:91-100.

[15] LEE A, KOMVOPOULOS K. Dynamic spherical indentation of elastic-plastic solids[J]. International Journal of Solids and Structures, 2018, 146:180-191.

[16] 姜鹏，张泰华，杨荣，等. 基于球形压入法提取材料的塑性力学参数[J]. 力学学报，2009，41(5):730-738 (JIANG Peng, ZHANG Taihua, YANG Rong, et al. A new spherical indentation-based method to extract plastic material parameters[J]. Chinese Journal of Theoretical and Applied Mechanics, 2009, 41(5):730-738 (in Chinese))

[17] LEE H, LEE J H, PHARR G M. A numerical approach to spherical indentation techniques for material property evaluation[J]. Journal of the Mechanics and Physics of Solids, 2005, 53(9):2037-2069.

[18] XIE W Q, LIU X L, ZHANG X P, et al. A review of rock macro-indentation: theories, experiments, simulations, and applications[J]. Journal of Rock Mechanics and Geotechnical Engineering, 2024, 16(6):2351-2374.

[19] FIELD J S, SWAIN M V. A simple predictive model for spherical indentation[J]. Journal of Materials Research, 1993, 8(2):297-306.

[20] PATHAK S, KALIDINDI S R, KLEMENZ C, et al. Analyzing indentation stress-strain response of $LaGaO_3$ single crystals using spherical indenters[J]. Journal of the European Ceramic Society, 2008, 28(11):2213-2220.

[21] WU Y C, FENG J W. Development and application of artificial neural network[J]. Wireless Personal Communications, 2018, 102(2):1645-1656.

[22] ABIODUN O I, JANTAN A, OMOLARA A E, et al. State-of-the-art in artificial neural network applications: a survey[J]. Heliyon, 2018, 4(11):e00938.

[23] 黄钟民，陈思亚，陈卫，等. 薄板弯曲问题的神经网络方法[J]. 固体力学学报，2021，42(6):697-706 (HUANG Zhongmin, CHEN Siya, CHEN Wei, et al. Neural network method for thin plate bending problem[J]. Chinese Journal of Solid Mechanics, 2021, 42(6):697-706 (in Chinese))

[24] 高恩来. 知识与数据交互驱动的力学性能极限研究进展[J]. 固体力学学报，2024，45(2):170-187 (GAO Enlai. Knowledge and data-driven exploration of bounds on mechanical properties: a review[J]. Chinese Journal of Solid Mechanics, 2024, 45(2):170-187 (in Chinese))

[25] 张猛，刘秀成，王建国，等. 列车车轮钢表面硬度的微磁定量检测方法[J]. 实验力学，2023，38(4):425-434 (ZHANG Meng, LIU Xiucheng, WANG Jianguo, et al. Micromagnetic and quantitative evaluation method for surface hardness of train wheel steel[J]. Journal of Experimental Mechanics, 2023, 38(4):425-434 (in Chinese))

[26] 闫盼盼，牛青林，高文强，等. 基于卷积神经网络的地面尾喷焰流场预测[J]. 力学学报，2024，56(4):980-990 (YAN Panpan, NIU Qinglin, GAO Wenqiang, et al. Prediction of ground rocket exhaust plume flow field based on convolutional neural network[J]. Chinese Journal of Theoretical and Applied Mechanics, 2024, 56(4):980-990 (in Chinese))

[27] 斋藤康毅. 深度学习入门：基于 Python 的理论与实现[M]. 陆宇杰，译. 北京：人民邮电出版社，2018 (YASUHIRO SAITO. Deep learning from scratch: theory and implementation based on Python[M]. LU Yujie, translation. Beijing: The People's Posts and Telecommunications Press, 2018 (in Chinese))

[28] LONG X, DING X Y, LI J, et al. Indentation reverse algorithm of mechanical response for elastoplastic coatings based on LSTM deep learning[J]. Materials, 2023, 16(7):2617.

[29] LONG X, LU C H, SHEN Z Y, et al. Identification of mechanical properties of thin-film elastoplastic materials by machine learning[J]. Acta Mechanica Solida Sinica, 2023, 36(1):13-21.

[30] 田静萱，夏僮，杨振宇，等. 基于纳米压痕试验的塑性本构参数反演方法研究[J]. 固体力学学报，2023，44(5):606-621 (TIAN Jingxuan, XIA Tong, YANG Zhenyu, et al. Reverse analysis for plastic constitutive parameters based on nanoindentation test[J]. Chinese Journal of Solid Mechanics, 2023, 44(5):606-621 (in Chinese))

[31] ZHANG J W, QIN J H, LI Y X, et al. Extraction of the plastic properties of metallic materials from scratch tests using deep learning[J]. Mechanics of Materials, 2022, 175:104502.

[32] 南策文. 关于复合材料弹塑性的一个理论描述[J]. 力学学报，1994，26(5):636-640 (NAN Cewen. On a theory

for elastoplasticity of composites[J]. Chinese Journal of Theoretical and Applied Mechanics, 1994, 26(5):636-640 (in Chinese))

[33] JI X K, XIAO G S, LU P, et al. Characterization of power-law constitutive relationship of nickel-based single crystal superalloys under different loading rates by nanoindentation with different types of indenters[J]. International Journal of Solids and Structures, 2022, 259:112025.

[34] XIAO G S, MA Y H, JI X K, et al. Effective acquisition of elastoplastic and creep parameters of lead-free solder alloy from high-temperature micro-indentation eliminating the size effect[J]. Mechanics of Materials, 2021, 160: 103985.

[35] XIAO G S, YANG X X, QIU J, et al. Determination of power hardening elastoplastic constitutive relation of metals through indentation tests with plural indenters[J]. Mechanics of Materials, 2019, 138:103173.

[36] 刘勇勇, 肖革胜, 李志刚, 等. 基于微纳米压入法提取无铅焊料合金弹塑性力学参数的研究[J]. 力学季刊, 2019, 40(1): 55-63 (LIU Yongyong, XIAO Gesheng, LI Zhigang, et al. Research on the elastic-plastic mechanical parameters of lead-free solder alloys using micro-/nano-indentation[J]. Chinese Quarterly of Mechanics, 2019, 40(1):55-63 (in Chinese))

[37] ZHANG A, LIPTON Z C, LI M, et al. Dive into deep learning[M]. Cambridge: Cambridge University Press, 2023.

# Spherical indentation learning and inversion recognition of metal plastic parameters based on a neural network

JIA Haolin[1], HE Yanjiao[1], LIU Erqiang[2], SHU Xuefeng[1], XIAO Gesheng[1]

(1. Institute of Applied Mechanics, College of Aeronautics and Astronautics, Taiyuan University of Technology, Taiyuan 030024, Shanxi, China; 2. College of Applied Science, Taiyuan University of Science and Technology, Taiyuan 030024, Shanxi, China)

**Abstract**: The constitutive parameters of materials can effectively reflect their mechanical properties in relevant service environments, which usually require corresponding mechanical testing methods to obtain. Existing macroscopic mechanical testing techniques necessitate that samples be processed into specific shapes and sizes, whereas the indentation method allows for in-situ testing with simple sample preparation. To effectively obtain the mechanical parameters of metals through indentation testing, this study employed an Instron universal testing machine to conduct quasi-static spherical indentation tests on copper and low-carbon steel. By analyzing the indentation load-depth curves and utilizing a trained neural network, the plastic constitutive parameters of the two metals were inverted and compared with those obtained from tensile tests. The results show that the yield strength of copper based on the neural network and spherical indentation testing is 307.6 MPa, the strain hardening coefficient is 69.7 MPa, and the strain hardening exponent is 0.338 1. For low-carbon steel, the yield strength is 269.4 MPa, the strain hardening coefficient is 541.4 MPa, and the strain hardening exponent is 0.474 3. The maximum relative error between these values and the corresponding results obtained from tensile tests is only 4.22%, indicating the effectiveness of the inversion method of metal plastic parameters based on neural networks and spherical indentation testing. The relevant research of this article can provide a reference method for effectively obtaining the mechanical performance parameters of metals or alloys.

**Keywords**: spherical indentation; neural network; metals; plastic parameters; numerical simulation