



基于机器学习确定膜基材料弹性模量的仪器化压痕方法

孙廷威^{1*}, 张建伟¹, 秦瑾鸿², 赵思伟¹, 李元鑫¹

1. 郑州大学力学与安全工程学院, 郑州 450001;

2. 郑州大学机械与动力工程学院, 郑州 450001

*联系人, E-mail: zhangjianwei@zzu.edu.cn

收稿日期: 2022-10-06; 接受日期: 2022-11-14; 网络出版日期: 2022-12-15

国家自然科学基金(编号: 12072324)和河南省优秀青年科学基金(编号: 212300410087)资助项目

摘要 仪器化压痕测试方法在确定材料的力学性能方面有着广泛的应用。由于基底效应, 采用该方法确定膜基材料各层的力学性能变得更为复杂。本文采用有限元仿真结合经典多输出多层次感知器(MLP)神经网络的方法, 建立了膜基材料力学性能参数(薄膜弹性模量、基底弹性模量)与复合模量和无量纲化最大压入深度(最大压入深度/薄膜厚度)之间的关系, 并发展了基于机器学习确定膜基材料弹性模量的仪器化压痕方法。对比深度学习的预测和有限元的仿真结果, 发现经MLP神经网络训练的硬膜软基底材料和软膜硬基底材料的预测值与仿真结果的吻合度较好。开展硬膜软基底材料Ni/304不锈钢以及软膜硬基底材料Cu/304不锈钢的压痕试验对MLP神经网络进行验证, 结果表明, MLP神经网络预测的各层弹性模量与试验中获得的结果较为接近。本文结果可为评价膜基材料各层性能提供可供选择的测试方法。

关键词 神经网络, 膜基材料, 纳米压痕, 弹性模量

PACS: 62.20.-x, 62.20.Dc, 81.70.-q, 81.70.Bt

1 引言

薄膜材料因具备光、热和电等方面的特性在医疗^[1]、航空航天^[2]、机械部件^[3]等诸多领域都占据着重要地位, 其力学性能对服役行为有着显著影响。研究者在薄膜力学性能测试方面开展了大量的研究。孙晋美等人^[4]利用机械加载以及温度载荷的形式发现珍珠母中有机基质薄层可以增加其堆垛而成的微结构的强

度和韧性; 刘明等人^[5]通过划痕测试研究了TiN涂层的失效过程并评估了其断裂韧性; 方辉等人^[6]采用一种非接触式振动测试方法, 表征出人工合成的亚微米阵列薄膜材料的弹性参数。

压痕法作为一种微损的测试方法, 因为制样方便、操作简单等优点被广泛应用于材料力学性能的测试^[7-10]。目前应用最为广泛的是Oliver和Pharr^[11]提出的仪器化压痕测试方法, 该方法通过压痕测试得到的载

引用格式: 孙廷威, 张建伟, 秦瑾鸿, 等. 基于机器学习确定膜基材料弹性模量的仪器化压痕方法. 中国科学: 物理学 力学 天文学, 2023, 53: 214607
Sun T W, Zhang J W, Qin J H, et al. Determining the elastic modulus of film/substrate materials from instrumented indentation testing based on machine learning (in Chinese). Sci Sin-Phys Mech Astron, 2023, 53: 214607, doi: [10.1360/SSPMA-2022-0386](https://doi.org/10.1360/SSPMA-2022-0386)

荷-位移曲线可计算材料的弹性模量, 具体计算的公式如下:

$$E_r = \frac{\sqrt{\pi}S}{2\beta\sqrt{A}}, \quad (1)$$

$$\frac{1}{E_r} = \frac{1-v^2}{E} + \frac{1-v_i^2}{E_i}, \quad (2)$$

$$A(h_c) = 24.56h_c^2, \quad (3)$$

$$h_c = h_{\max} - \varepsilon \frac{P_{\max}}{S}, \quad (4)$$

其中, E_r 和 E_i 分别为折减模量和压头的弹性模量, S 为卸载刚度, β 是与压头几何形状相关的常数, v 和 v_i 分别为材料和压头的泊松比, h_c 为接触深度, A 为接触面积, P_{\max} 为最大法向载荷, h_{\max} 为最大压入深度.

此外, 压痕法也被用来测定薄膜/基底材料的力学性能. Suresh 等人^[12]研究了三种不同厚度但晶粒尺寸和结构相同的多晶铜薄膜在硅基底上的纳米压痕响应. Zhang 等人^[13]利用纳米压痕技术表征了 9Cr18 钢材料以及 DLC/9Cr18 钢膜基材料的机械性能. Graça 等人^[14]从微米以及纳米尺度上利用压痕分析了 Ni-Co 合金体系的复合硬度. Pelegri 等人^[15]利用压痕测试分析了最大接触深度对硬膜软基底以及软膜硬基底体系的力学响应. Zhao 等人^[16]结合有限元方法和量纲分析法提出新的模型, 可以通过圆锥压头压痕测试提取出沉积在弹性基底上薄膜的塑性力学性能. 考虑了基底效应和厚度, Chakroun 等人^[17]提出了一种表征弹性模量的模型, 并通过纳米压痕数值结果和 TiN/Zr 双层材料纳米压痕实验结果对提出的方法进行了验证. 马增胜等人^[18]采用纳米压痕的方法, 研究了拉伸变形后膜基试样的硬度、弹性模量等性能. Zhao 等人^[19]通过有限元结合权函数的方法, 提出了一种反演仪器化压痕测试中双层材料力学性能的求解方法.

通过压痕实验得到膜基材料各层的力学性能, 需要建立起压痕响应与测试材料力学参数之间的关系, 这是一个复杂的非线性问题^[20]. 神经网络(NNs)在该方面具有较大的优势^[21]. 最近, NNs 已被应用于确定材料的力学性能. 为了确定具有五边形截面的悬臂梁的小尺寸断裂韧性, Liu 等人^[22]发现, 与回归树方法相比, NNs 方法具有更简单的形式, 同时获得更准确的结果. Merayo 等人^[23]利用人工神经网络, 基于合金的化学成分、回火和布氏硬度, 预测出金属材料两种最常用的机械性能, 以表征塑性行为、屈服强度和极限抗

拉强度.

本文运用神经网络中的深度学习功能, 通过有限元仿真获得训练神经网络的数据集确定其网络框架, 并通过实验获得的复合模量以及归一化深度(压入深度/薄膜厚度)作为输入反向预测出软膜硬基底和硬膜软基底各层材料的弹性模量.

2 理论及计算

2.1 有限元仿真

图 1 是在有限元软件 ABAQUS 中建立的膜基材料的压痕有限元模型. 考虑到采用圆锥压头的压痕过程的轴对称特性, 所以建立一个尺寸为 30 mm × 15 mm 的轴对称模型, 其中薄膜厚度为 0.5 mm. 压头采用 70.3° 的圆锥压头, 假设为刚体. 模型的左边界为对称轴并固定了 x 方向的位移, 下边界约束了 y 方向的自由度, 通过控制压头的位移展开压痕模拟. 对压头与材料的接触区域进行了网格细化, 网格类型均为 CAX4R.

根据薄膜以及基底弹性模量的大小不同, 分为硬膜软基底和软膜硬基底两种方案, 这样更有利子神经网络的训练. 材料的本构模型假设为理想弹塑性, 材料的泊松比均采用 0.3、屈服强度均为 200 MPa, 界面摩擦系数均设为 0. 压入深度 0.1–0.5 mm, 间距为 0.1 mm, 表 1 和 2 分别为两种方案中所使用的基底弹性模量(E_s)、薄膜弹性模量(E_f)和压入深度的取值范围.

2.2 神经网络解决方案

神经网络已被用于解决压痕问题. Huber 等人^[24]

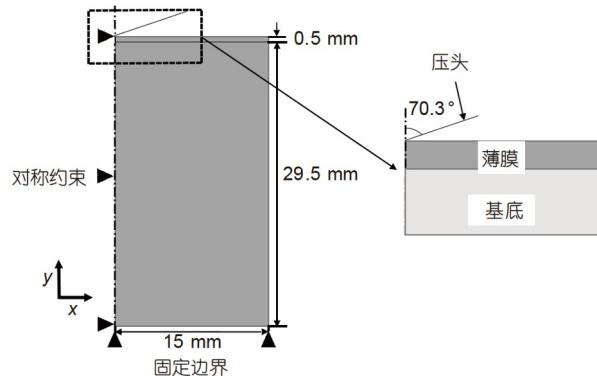


图 1 膜基材料压痕有限元模型

Figure 1 Finite element model of film-substrate material indentation.

表 1 硬薄膜软基底材料的有限元仿真输入参数**Table 1** Input parameters in finite element simulation for hard film on soft substrate materials

基底弹性模量 (GPa)	薄膜弹性模量 (GPa)	压入深度 (mm)
40	150, 170, 190, 210, 230, 250	
60	150, 170, 190, 210, 230, 250	
80	150, 170, 190, 210, 230, 250	
100	150, 170, 190, 210, 230, 250	
120	150, 170, 190, 210, 230, 250	
140	150, 170, 190, 210, 230, 250	0.1–0.5
160	170, 190, 210, 230, 250	
180	190, 210, 230, 250	
200	210, 230, 250	
220	230, 250	
240	250	

表 2 软薄膜硬基底材料的有限元仿真输入参数**Table 2** Input parameters of finite element simulation for soft film on hard substrate materials

基底弹性模量 (GPa)	薄膜弹性模量 (GPa)	压入深度 (mm)
140, 160, 180, 200, 220, 240	50	
140, 160, 180, 200, 220, 240	70	
140, 160, 180, 200, 220, 240	90	
140, 160, 180, 200, 220, 240	110	
140, 160, 180, 200, 220, 240	130	0.1–0.5
160, 180, 200, 220, 240	150	
180, 200, 220, 240	170	
200, 220, 240	190	
220, 240	210	
240	230	

在球形压头的特性以及材料性能未知的情况下, 训练两个神经网络以便在有限元数据范围内可以高精度地识别泊松比. Tyulyukovskiy等人^[25]基于有限元模拟得到压痕载荷-位移曲线的数据点, 通过训练神经网络得到材料的部分弹塑性参数. Haj-Ali等人^[26]利用人工神经网络(ANNs)表征了非弹性和非线性材料的压痕行为.

本文的目标是通过机器学习的方法建立薄膜和基底弹性模量与归一化深度以及复合模量之间的映射关系. 根据该映射关系, 通过输入复合模量与归一化深度

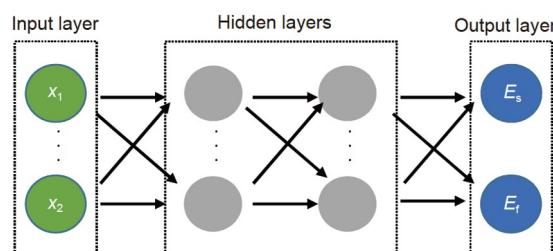
的值, 即可得到薄膜和基底的弹性模量值. 本文采用经典的多输出多层次感知器(MLP)神经网络用于从压痕测试中提取各层材料的弹性模量, 利用开源深度学习框架Pytorch编写MLP模型, 模型框如图2所示, 该模型由输入层、隐藏层和输出层所组成, 其中隐藏层的任务是寻找出预测值与输入值之间的关系.

把有限元中计算得到膜基材料的复合模量 E_r (可由式(1)计算得出)和归一化深度作为输入层, 经MLP隐藏层进行训练拟合, 从而分别输出薄膜以及基底的弹性模量. 需要注意的是, 在反算各层材料弹性模量时, 输入的复合模量以及归一化压入深度需要在有限元仿真的参数范围内.

2.3 实验材料与方法

采用双电子束蒸发镀膜系统(ULVAC ei-5z)对表面处理过的304不锈钢(表面平均粗糙度为15 nm)进行镀镍和铜膜. 对于镀镍, 速度为8 Å/s, 功率为40%, 未对仪器腔室进行加热, 镍的薄膜厚度为1000 nm; 镀铜速度为1.5–2 Å/s, 功率为20%, 仪器腔室加热温度为80°C, 金属铜的薄膜厚度为300 nm.

利用纳米力学测试系统(Agilent Nano Indenter G200)对镍/304不锈钢体系以及铜/304不锈钢体系展开了纳米压痕实验, 该系统使用的是Berkovich压头(由参考文献可等效为70.3°的圆锥压头^[27]), 加载和卸载速度均为10 nm/s. 首先对未镀膜的304不锈钢基底展开压痕, 选取了300, 500和800 nm三种深度用于验证仪器的重复性, 每个深度均有大于6次的重复实验. 对于膜厚较大的镍/304不锈钢体系, 选取160, 265, 365, 470, 560, 650, 750和860 nm等多个深度进行压痕测试; 对于膜厚较小的铜/304不锈钢体系, 选取90, 130, 170, 210和250 nm等多个深度进行压痕, 两种体系在每个深

**图 2** (网络版彩图)经典的多输出多层次感知器(MLP)**Figure 2** (Color online) A classic multi-output multi-layer perceptron (MLP).

度都有6次的重复性实验. 实验均在室温下开展.

3 结果与讨论

3.1 MLP训练结果

针对两种不同的膜基体系, 共有480组有限元计算得到的数据集进行机器学习, 其中包括软膜硬基底225组, 硬膜软基底255组. 随机选取每组数据集的80%对神经网络进行训练, 并利用剩余的20%来进行验证. 考虑到校正线性单元(ReLU)可以有效地克服梯度消失问题并加快训练过程, 因此选择它作为MLP的激活函数. 双曲余弦被采用为两个目标输出(E_f 和 E_s)的损失函数. 平均绝对百分比误差(MAPE)用于评估模型的准确性, 计算公式为

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}(x)_i - y_i}{y_i} \right|, \quad (5)$$

其中 $\hat{y}(x)_i$ 和 y_i 分别是第*i*个数据点的预测值和真值. *N*是数据点的数量. 通过Optuna进行超参数调优, 表3所示为MLP超参数的搜索范围, 其中隐藏层为多输出多层次感知器(MLP)的组成之一; 每层单元数为隐藏层每层的节点数; 学习率为控制模型学习进度的参数, 即步长; 求解器是用来优化算法, 对损失函数(优化的目标函数)进行优化, 从而训练出最好的模型. 根据数据集的取值基于贝叶斯优化算法寻找出最优的超参数组合. 硬膜软基底模型和软膜硬基底模型的隐藏层分别为8层以及18层, 其中硬膜软基底模型单层最小的单元

表3 超参数的选取范围

Table 3 Range of hyperparameters for MLP

模型	MLP
隐藏层数	[1, 25]
每层单元数	[4, 256]
学习率	[1×10^{-6} , 1×10^{-2}]
优化器	Adam, RMSprop, SGD

数为16, 最大的单元个数为251, 学习步长为0.00287, 适应优化算法为Adam; 软膜硬基底模型单层最小的单元个数为62, 最大的单元个数为242, 学习步长为0.00019, 适应优化算法为Adam.

训练结果如表4所示, 两种材料体系最大误差值分别为11.13%和12.49%, 可以看出利用机器学习的方法可以较好地预测硬膜软基底材料和软膜硬基底材料的膜基弹性模量. 图3为机器学习预测两种体系各层模量的误差分布图. 从图3(a)和(b)中可以看出, 针对弹性模量的预测结果集中在较小的误差范围内.

3.2 实验结果与讨论

应用式(1)–(4)所示的O-P方法计算出不同压入深度下304不锈钢的弹性模量均在140 GPa左右. 结合魏莉芬^[28]和王红美等人^[29]的研究得知Cu和Ni的弹性模量约为110和190 GPa.

从图4可以看出膜基弹性模量的大小对曲线趋势的影响十分明显, 对于软膜硬基底材料, 复合模量会随着归一化深度的增加而不断增大, 而对于硬膜软基底则

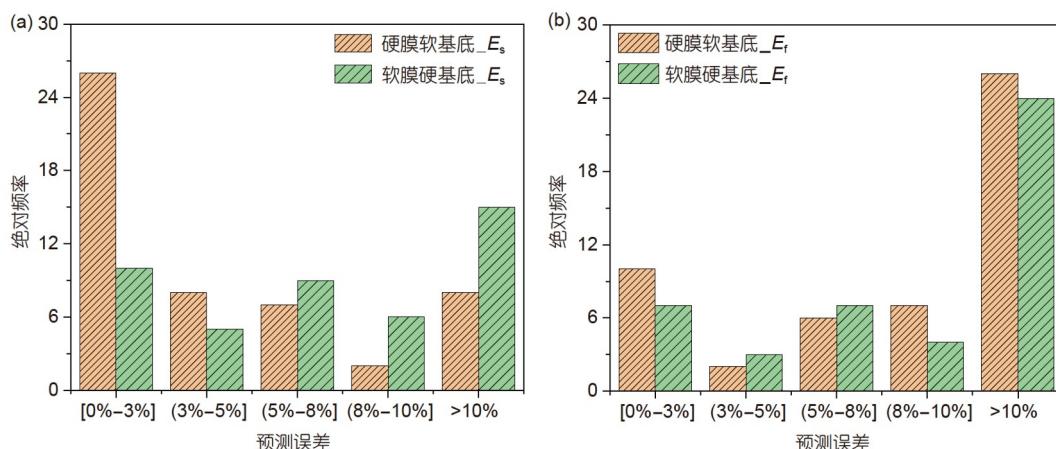


图3 (网络版彩图)机器学习预测硬膜软基底以及软膜硬基底的误差分布. (a) 基底模量; (b) 薄膜模量

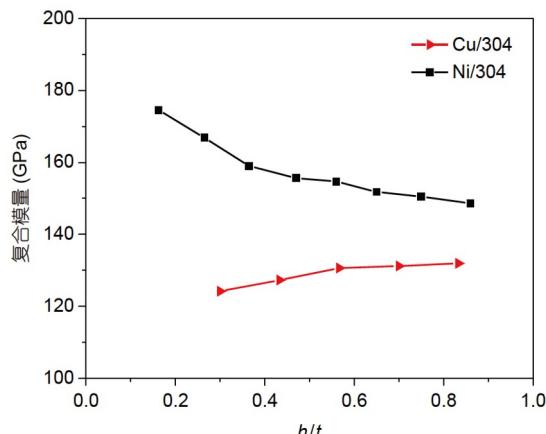
Figure 3 (Color online) Machine learning predicts (a) substrate modulus and (b) film modulus for hard film soft substrate and soft film hard substrate.

表 4 MLP 在训练和测试数据集上的性能**Table 4** Performance of MLP on train and test datasets

	硬膜软基底 (%)	软膜硬基底 (%)
训练误差	8.72	12.19
测试误差(E_s)	5.61	8.26
测试误差(E_f)	11.13	12.49

表 5 不同本构模型的计算结果**Table 5** The calculation results of different constitutive models

本构模型	复合模量 (GPa)	基底弹性模量 (GPa)	薄膜弹性模量 (GPa)
理想弹塑性	146.90	127.97	196.62
幂律硬化	144.03	124.07	193.02

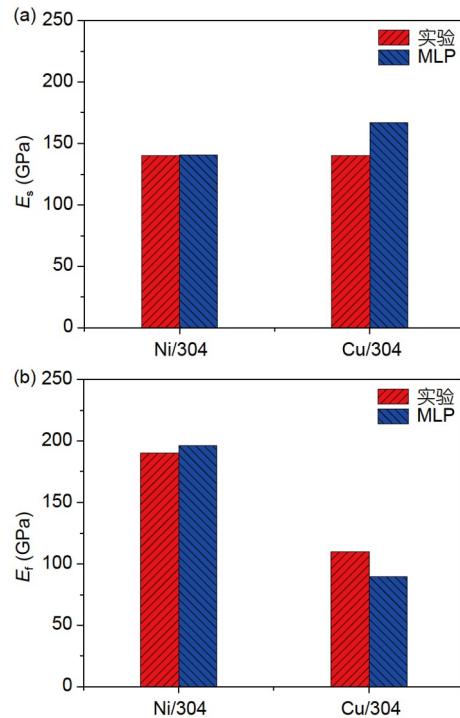
**图 4** (网络版彩图) 复合模量随归一化深度(h/t)的变化
Figure 4 (Color online) Change of composite modulus with normalized depth (h/t).

相反, 即复合模量会随着归一化深度的增加而不断减小.

将利用压痕实验得到的复合模量以及压入深度值归一化处理后输入到训练过的MLP模型中可以得到各层材料的弹性模量, 并与实验得到的结果进行对比.

从图5(a)和(b)中可以看出, 训练过的模型预测Ni/304不锈钢和Cu/304不锈钢膜基材料的各层弹性模量与纳米压痕实验和文献结果得到^[28,29]的数值吻合较好.

为了考虑非理想弹塑性材料的适用性, 计算了一组幂律硬化模型的算例, 其中基底模量为120 GPa, 薄膜模量为210 GPa, 压入深度为0.3 mm, 屈服强度为200 MPa硬化指数为0.193, 将得到的复合模量以及归

**图 5** (网络版彩图) 实验以及MLP训练得到的基底弹性模量(a)和薄膜弹性模量(b)**Figure 5** (Color online) The elastic moduli of (a) substrate and (b) thin film were obtained by experiment and MLP training.

一化深度作为输入得到各层材料的弹性模量, 相应结果如表5所示, 可以看出幂律硬化模型对于该方法也是适用的. 需要指出的是, 反算各层材料弹性模量时, 输入的复合模量以及归一化深度需要在有限元仿真的参数范围内. 且本文分为硬膜软基底与软膜硬基底体系进行训练, 后续需进一步优化机器学习训练, 以期得到更优的训练效果. 本文结果可以为确定膜基材料力学性能和更多层材料力学性能提供良好的研究基础.

4 总结

本文基于有限元仿真与深度学习的方法, 提出了一种通过压痕实验得到膜基材料各层弹性模量的方法. 测试误差表明训练过的MLP模型能较好地确定膜基材料的弹性模量. 经过训练过的MLP模型获得的Ni/304不锈钢和Cu/304不锈钢膜基材料的各层弹性模量与实验结果较为接近. 本文研究验证了机器学习在膜基体系的应用潜力, 为确定膜基材料力学性能提供了一种可供选择的测试方法.

参考文献

- 1 Long D P, Xue J R, Yan Z X. Nanoindentation and nanoscratch measurements to determine the mechanical properties of TiO₂ nano films (in Chinese). *Surf Technol*, 2015, 44: 115–119 [龙东平, 薛建荣, 晏智鑫. 纳米压痕和划痕法测定TiO₂纳米薄膜的力学性能. 表面技术, 2015, 44: 115–119]
- 2 Ji M M, Zhu S Z, Ma Z. Advances in the research of thermal protective coatings on aerospace metal surface (in Chinese). *Surf Technol*, 2021, 50: 253–266 [姬梅梅, 朱时珍, 马壮. 航空航天用金属表面热防护涂层的研究进展. 表面技术, 2021, 50: 253–266]
- 3 Shankar A R, George R P, Philip J. Evaluation of thermal cycling performance of plasma sprayed alumina coating on Inconel 600 with different bond coats. *J Mater Eng Perform*, 2022, 31: 4406–4418
- 4 Sun J M, Guo W L. Mechanical properties and thermal stability of stacked microstructure of nacre (in Chinese). *Sci Sin-Phys Mech Astron*, 2010, 40: 1044–1053 [孙晋美, 郭万林. 珍珠母堆垛微结构的力学性能和热稳定性. 中国科学: 物理学 力学 天文学, 2010, 40: 1044–1053]
- 5 Liu M, Li S, Gao C H. Study of failure mechanism of TiN coatings by micro-scratch testing (in Chinese). *Acta Metrologica Sin*, 2020, 41: 696–703 [刘明, 李砾, 高诚辉. 利用微米划痕研究TiN涂层的失效机理. 计量学报, 2020, 41: 696–703]
- 6 Fang H, Takashi S, Takayuki K. Elastic properties of array films at submicron-scale evaluated by resonance frequency spectra (in Chinese). *Sci Sin-Phys Mech Astron*, 2014, 44: 1196–1202 [方辉, 澄川贵志, 北村隆行. 基于振动的亚微米阵列薄膜弹性参数辨识. 中国科学: 物理学 力学 天文学, 2014, 44: 1196–1202]
- 7 Peng G, Xu F, Chen J, et al. Evaluation of non-equibiaxial residual stresses in metallic materials via instrumented spherical indentation. *Metals*, 2020, 10: 440
- 8 Yao B, Cai L X, Bao C. Research on acquisition of mechanical properties of materials based on conical indentation (in Chinese). *Acta Aeronaut Astronaut Sin*, 2013, 34: 1874–1883 [姚博, 蔡力勋, 包陈. 基于锥形压入的材料力学性能测试方法研究. 航空学报, 2013, 34: 1874–1883]
- 9 Chen H, Cai L, Bao C. Equivalent-energy indentation method to predict the tensile properties of light alloys. *Mater Des*, 2019, 162: 322–330
- 10 Long X, Jia Q, Li Z, et al. Reverse analysis of constitutive properties of sintered silver particles from nanoindentations. *Int J Solids Struct*, 2020, 191–192: 351–362
- 11 Oliver W C, Pharr G M. An improved technique for determining hardness and elastic modulus using load and displacement sensing indentation experiments. *J Mater Res*, 1992, 7: 1564–1583
- 12 Suresh S, Nieh T G, Choi B W. Nano-indentation of copper thin films on silicon substrates. *Scripta Mater*, 1999, 41: 951–957
- 13 Zhang T, Liu D, Huan Y, et al. Micro/nanomechanical and tribological properties of thin diamond-like carbon coatings. *Chin J Aeronautics*, 2003, 16: 47–51
- 14 Graça S, Colaço R, Vilar R. Micro-to-nano indentation and scratch hardness in the Ni-Co system: Depth dependence and implications for tribological behavior. *Tribol Lett*, 2008, 31: 177–185
- 15 Pelegri A A, Huang X. Nanoindentation on soft film/hard substrate and hard film/soft substrate material systems with finite element analysis. *Compos Sci Tech*, 2008, 68: 147–155
- 16 Zhao M, Chen X, Xiang Y, et al. Measuring elastoplastic properties of thin films on an elastic substrate using sharp indentation. *Acta Mater*, 2009, 55: 6260–6274
- 17 Chakroun N, Tekaya A, Belhadjsalah H, et al. A new inverse analysis method for identifying the elastic properties of thin films considering thickness and substrate effects simultaneously. *Int J Appl Mech*, 2017, 09: 1750096
- 18 Ma Z S, Long S G, Han H S, et al. Effects of tensile deformation on mechanical properties of electrodeposited nickel coating (in Chinese). *Mater Sci Eng C*, 2008, 32: 18–20, 51 [马增胜, 龙士国, 韩海生, 等. 用纳米压痕法研究拉伸变形对电沉积镍镀层力学性能的影响. 机械工程材料, 2008, 32: 18–20, 51]
- 19 Zhao S, Zhang J, Li Y, et al. An indentation method for determining the film thickness, Young's modulus, and hardness of bilayer materials. *J Phys D*, 2022, 55: 274002
- 20 Bellemare S C, Dao M, Suresh S. Effects of mechanical properties and surface friction on elasto-plastic sliding contact. *Mech Mater*, 2008, 40: 206–219
- 21 Jia B C, Han B. Determination of properties of materials by the spherical indentor: A neural network approach (in Chinese). *J Beijing Inst Technol*, 2003, 23: 154–157 [贾勃晨, 韩斌. 球形压痕法测材料力学性能: 神经网络模拟. 北京理工大学学报, 2003, 23: 154–157]
- 22 Liu X, Athanasiou C E, Padture N P, et al. A machine learning approach to fracture mechanics problems. *Acta Mater*, 2020, 190: 105–112

- 23 Merayo D, Rodríguez-Prieto A, Camacho A M. Prediction of mechanical properties by artificial neural networks to characterize the plastic behavior of aluminum alloys. *Materials*, 2020, 13: 5227
- 24 Huber N, Tsakmakis C. Determination of Poisson's ratio by spherical indentation using neural networks—Part II: Identification method. *J Appl Mech*, 2001, 68: 224–229
- 25 Tyulyukovskiy E, Huber N. Identification of viscoplastic material parameters from spherical indentation data: Part I. Neural networks. *J Mater Res*, 2006, 21: 664–676
- 26 Haj-Ali R, Kim H K, Koh S W, et al. Nonlinear constitutive models from nanoindentation tests using artificial neural networks. *Int J Plast*, 2008, 24: 371–396
- 27 Jiang W G, Yan C, Qu S X. Friction effect on micro-indentation measurement with different indenters (in Chinese). *Chin Quarter Mech*, 2010, 31: 236–242 [江五贵, 袁 C, 曲绍兴. 摩擦因素对不同形状压头微压痕测试的影响. 力学季刊, 2010, 31: 236–242]
- 28 Wei L F. The Effect of Grain Size and Orientation on the Mechanical Property of Copper (in Chinese). Dissertation for Master's Degree. Wuhan: Huazhong University of Science and Technology, 2012 [魏莉芬. 晶粒尺寸及取向对铜的力学性能的影响. 硕士学位论文. 武汉: 华中科技大学, 2012]
- 29 Wang H M, Xu B S, Ma S N, et al. Hardness and modulus of elasticity of brush plated nickel coating by nanoindentation testing (in Chinese). *Chin J Mech Eng*, 2005, 4: 128–131 [王红美, 徐滨士, 马世宁, 等. 纳米压痕法测试电刷镀镍镀层的硬度和弹性模量. 机械工程学报, 2005, 4: 128–131]

Determining the elastic modulus of film/substrate materials from instrumented indentation testing based on machine learning

SUN TingWei¹, ZHANG JianWei^{1*}, QIN JinHong², ZHAO SiWei¹ & LI YuanXin¹

¹ School of Mechanics and Safety Engineering, Zhengzhou University, Zhengzhou 450001, China;

² School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou 450001, China

Instrumented indentation testing has been widely used to determine the mechanical properties of materials. However, due to the substrate effect, the mechanical properties of each layer of film/substrate material becomes complicated to determine using this method. Through the finite element simulation, combined with a classic neural network method of multi-output multilayer perceptron (MLP), the relationship between the film/substrate material parameters (elastic modulus of film and substrate), normalized indentation depth (indentation depth/film thickness), and composite modulus is established. This established relationship is used to develop an indentation method to determine the elastic modulus of film/substrate. Prediction results through deep learning and the finite element simulation results are compared. The comparison results indicate that the predicted values of hard film/soft and soft film/hard substrate materials obtained from MLP are in good agreement with the simulation results. Indentation tests of Ni/304 and Cu/304 stainless steel were conducted to verify the trained neural network. The results indicate that elastic modulus of each layer predicted using the MLP is close to those obtained in the test. The results of this study can provide alternative research methods for evaluating the properties of film/substrate materials.

neural network, film/substrate material, nanoindentation, elastic modulus

PACS: 62.20.-x, 62.20.Dc, 81.70.-q, 81.70.Bt

doi: [10.1360/SSPMA-2022-0386](https://doi.org/10.1360/SSPMA-2022-0386)