

物理与数据双驱动的材料力学AI教学实践

王 鹏, 张居敏

华中农业大学工学院, 湖北 武汉

收稿日期: 2026年8月3日; 录用日期: 2026年9月2日; 发布日期: 2026年9月9日

摘 要

目的: 针对材料力学课程性能参数获取方式单一、教学内容与工程前沿脱节、学生参与度不高的问题, 探索人工智能(AI)与力学理论教学深度融合的路径。方法: 提出物理规律与数据双驱动融合的改革方案, 确立物理优先、精选融合、反向强化三条原则, 在绪论、轴向拉压等5个章节嵌入AI应用, 并以轴向拉压为案例构建铁基与铝合金数据集, 开发可交互演示文件与操作指南。结果: 梯度提升树的预测精度最高($R^2 = 0.93$); 碳含量、晶粒尺寸和热处理温度依次主导屈服强度, 与固溶强化、Hall-Petch关系和回火软化规律一致; 铁基模型误用于铝合金时预测完全失效, 揭示了忽视材料体系物理差异的风险。结论: 方案不压缩理论课时、不要求编程基础, 可为工科基础课程智能化教学改革提供可复用范例。

关键词

材料力学, 人工智能赋能教学, 教学改革, 机器学习, 农业机械化

Teaching Practice of AI-Empowered Materials Mechanics Driven by Both Physical Laws and Data

Peng Wang, Jumin Zhang

College of Engineering, Huazhong Agricultural University, Wuhan Hubei

Received: August 3, 2026; accepted: September 2, 2026; published: September 9, 2026

Abstract

Objective: Aiming at the problems of the single means of obtaining material property parameters, the disconnection between teaching content and engineering frontiers, and the insufficient participation of students in the course of Materials Mechanics, this study explores a feasible path for the deep integration of artificial intelligence technology into the teaching of mechanics theory. **Methods:** A

teaching reform scheme integrating physics-driven and data-driven paradigms is proposed. Three design principles are established, namely physics first, selective integration and reverse reinforcement. Artificial intelligence applications are embedded into five chapters, including Introduction, Axial Tension and Compression, Stress State Analysis, Strength Theory, and Buckling Stability, without occupying additional class hours. Taking the chapter of axial tension and compression as a representative case, teaching datasets of iron-based alloys and aluminum alloys are constructed, and an interactive demonstration notebook together with a teacher's operation guide are developed. Linear regression, random forest and gradient boosting models are trained and compared on an independent test set, and the feature importance obtained from the model is systematically compared with classical strengthening theories. Results: Gradient boosting achieves the highest prediction accuracy ($R^2 = 0.93$), followed by linear regression and random forest. The feature importance analysis shows that carbon content, grain size and heat treatment temperature dominate the yield strength successively, which is highly consistent with the theory of solid solution strengthening, grain refinement strengthening and temper softening, and the parameter sensitivity analysis further verifies the above conclusions. When the iron-based model is deliberately misapplied to aluminum alloy data, the prediction fails completely, and the comparison between correct and incorrect modeling intuitively reveals the risk of ignoring the physical differences between material systems. Trials by peer teachers indicate that the resource package can be independently deployed within a short preparation time and is regarded as highly reusable. Conclusion: The proposed scheme neither compresses the class hours of mechanics theory nor requires students to have a programming background. It shifts the focus of AI-empowered teaching from what artificial intelligence can do to how to use artificial intelligence correctly, and provides a reusable example for the intelligent teaching reform of fundamental engineering courses.

Keywords

Materials Mechanics, AI-Empowered Teaching, Teaching Reform, Machine Learning, Agricultural Mechanization

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

农业机械化及其自动化专业承担着培养农业装备研发、智能农机系统设计与现代农业工程管理人才的核心任务。随着智能农机、精准农业和仿生农业装备的快速发展,新时代农业工程人才不仅需要扎实的力学理论基础,还需具备运用现代数字化工具分析复杂工程问题的能力。材料力学作为该专业的核心课程,其知识直接支撑农机零部件的强度校核、机架稳定性分析与材料选型决策,是连接基础理论与工程实践的重要桥梁[1] [2]。

然而,当前材料力学课程教学面临三方面困境:材料性能参数的获取长期依赖手册查询和有限的标准实验,面对新型材料或复杂工况时缺乏有效的分析工具;课堂教学以低碳钢、铸铁等少数典型材料为例,与工程设计中涉及的多样化材料选型和复杂服役工况差距明显;抽象的公式推导难以激发学生的主动探索欲望,课堂参与度普遍偏低[3] [4]。上述问题与农业装备智能化发展对人才培养提出的新要求形成明显落差。

人工智能(Artificial Intelligence, AI)技术的快速发展为工程力学课程改革提供了新的契机[5]-[8]。近年来,机器学习方法在材料力学性能预测领域取得重要进展[9] [10],随机森林、梯度提升树等集成学习算

法预测金属材料屈服强度的精度 R^2 可达 0.9 以上[11] [12]; 物理信息神经网络(Physics-Informed Neural Network, PINN)将力学控制方程约束嵌入神经网络训练过程, 在材料本构关系建模和复杂应力场预测中展现出广阔应用前景[13]。这些技术既代表着材料力学研究的前沿方向[10] [14], 也为课程教学提供了直观可操作的演示工具。但已有探索多停留于概念介绍层面, 面向工科基础力学课程的系统性实施方案与配套教学资源仍较为匮乏。

为此, 本研究提出物理规律驱动与数据驱动融合的课程改革理念, 在材料力学精选章节中系统融入 AI 技术应用, 以轴向拉压章节为典型案例开发完整教学资源包, 并结合专业特色引入农机零件设计的工程情景。本研究并非以 AI 取代力学基础教育, 而是以力学理论为根基, 引导学生在 AI 工具的操作体验中加深对物理规律的理解, 并在物理原理的审视下建立对 AI 结果的批判性认知。

2. 研究方法

2.1. 两种范式的融合理念

材料力学问题的求解长期遵循物理规律驱动范式: 从基本假设出发, 通过理论推导建立力学模型并以公式预测材料与结构的行为。该范式结果可解释、适用范围明确, 是工程设计安全性的理论基础, 但在新材料与极端服役环境下局限日益凸显: 传统本构模型仅在有限温度和应变率范围内适用, 含缺陷或各向异性材料的解析解难以获得, 大量性能参数仍依赖实验测定与手册查询。数据驱动范式无需预设公式, 直接从实验或仿真数据中学习成分、工艺与力学性能之间的映射关系, 能够处理强非线性、多因素耦合问题, 为上述困境提供了新的解决路径。

两种范式并非对立, 而是相辅相成。物理规律为数据驱动模型提供不可或缺的先验约束: 缺乏物理知识指导的机器学习模型, 在训练数据边界之外极易产生违反力学基本原理的非物理解。反之, 数据驱动方法也为物理理论提供了验证手段, 通过分析特征重要性可定量揭示各参数对力学性能的相对贡献, 与固溶强化、细晶强化等经典理论形成互证。因此, 融合的实质是以力学理论为骨架、以数据驱动方法为延伸, 帮助学生建立面向复杂工程问题的现代分析思维。

2.2. 课程改革的设计原则

基于上述理念, 本研究确立三条设计原则。第一, 物理优先: 传统力学理论是课程主干, AI 内容以嵌入方式融入各章节, 不压缩核心理论课时, 每个 AI 结论都须与对应的力学理论对照验证, 而非作为无需验证的权威数字直接采用。第二, 精选融合: 只在物理概念与数据特征最自然契合的章节切入, 每章聚焦一个清晰的 AI 应用问题, 以深度优先。第三, 反向强化: 将 AI 预测失效的场景作为教学设计的重要环节, 通过正误对比深化学生对材料体系物理本质差异的认识, 强调力学基础对于正确使用 AI 工具的不可替代性。

2.3. 章节遴选与实施安排

材料力学课程涵盖十余个章节, 并非都适合融入 AI 内容。本研究依据三条标准精选改造章节: 一是关键物理量可结构化, 即成分、尺寸、载荷、应力等能够转化为模型的输入特征; 二是切入点自然, AI 方法针对传统教学中真实存在的痛点; 三是与工程实践关联紧密, 便于结合农机设计情景呈现。据此选取 5 个章节, 具体方案见表 1。

AI 赋能内容采用嵌入式讲授方式, 不单独开设课程、不额外占用课时。多数章节以 20~30 min 的课堂演示和讨论为主, 作为重点实施章节的轴向拉压安排 40~45 min, 并辅以课外自主实践, 具体安排见表 2。全部 AI 内容合计 130~135 min, 占课程总学时的 4.51%~4.69%; 这部分时间主要通过精简重复性例题

讲解与手工绘图演示获得,核心理论推导的课时保持不变,力学理论教学的完整性不受影响。

Table 1. Overview of the AI-empowered chapters in the materials mechanics course
表 1. 材料力学课程 AI 赋能改造章节一览

章节	传统教学痛点	AI 赋能内容	工程应用情景
绪论	内容抽象, 缺乏前沿视野	机器学习本构建模原理; PINN 概念介绍	智能农机功能材料认知
轴向拉压	性能获取依赖手册查询; 成分-性能关系认知浅	铁基合金强度智能预测; 特征重要性 与强化机制对照; 正误建模对比	农机零件材料选型; 犁铧、机架用钢强度分析
应力状态分析	应力圆手工绘制繁琐; 主应力求解易出错	AI 自动绘制应力圆; 主应力与主方向智能求解	农机受力部位应力状态快速分析
强度理论	强度理论选择缺乏系统性指导	基于材料类型与应力状态的强度理论智能推荐	农机零件失效模式分析与强度校核
压杆稳定	欧拉公式适用范围判断模糊	AI 辅助临界载荷计算与适用范围判断	温室骨架立柱、农机机架稳定性分析

Table 2. Class time allocation of the AI-empowered content in each chapter
表 2. 各章节 AI 赋能内容课时安排

章节	课堂演示时间/min	备注
绪论	20	概念引入为主, 不要求动手操作
轴向拉压	40~45	重点实施章节
应力状态分析	25	工具演示为主
强度理论	25	结合失效案例讨论
压杆稳定	20	与温室骨架案例结合
合计	130~135	约占课程总学时的 4.51%~4.69%

2.4. 教学资源包开发与评价方法

为每个改造章节开发配套教学资源包,均包含数据集、可交互演示文件和教师操作指南三类材料。以轴向拉压章节为例,构建包含 140 个样本的碳钢/合金钢教学数据集,涵盖碳含量 0.08~0.60 wt%的低碳钢至中碳钢、5~90 μm 的晶粒尺寸和未热处理至 700℃回火的热处理制度,选取碳含量、锰含量、硅含量、铬含量、热处理温度和晶粒尺寸共 6 个物理意义明确的特征作为输入,以屈服强度为预测目标;同时构建特征体系独立的铝合金数据集,用于正误对比演示。分别训练线性回归、随机森林和梯度提升树 3 种模型,在独立测试集(占 20%,共 28 个样本)上以决定系数 R^2 、平均绝对误差(MAE)和均方根误差(RMSE)评价预测性能。教学效果评价采用两条路径:一是对演示文件进行全流程执行测试与数据集物理一致性核查;二是邀请 3 位从事材料力学教学的同行教师试用资源包,就课前配置耗时、可复用性和各教学环节的价值进行评议。

3. 结果

3.1. 建模前提的正误对比

钢和铸铁同属铁基合金,决定其强度的核心合金元素为碳、锰、硅、铬,强化机制以固溶强化、细晶强化和热处理相变为主;铝合金的核心合金元素为镁、硅、铜、锌,强化机制以时效析出强化为主,两者物理本质截然不同。若将铝合金数据强行代入以碳、锰、硅、铬为特征建立的铁基预测模型,模型虽能输出数值,但该数值毫无物理意义。演示结果显示,这种错误混用使模型预测精度 R^2 降至-21.82, MAE

达 618.2 MPa, 远超铝合金屈服强度本身的量级; 而使用铝合金专用特征体系建立的独立模型, R^2 达 0.99, MAE 仅 9.5 MPa, 对比结果如图 1 所示。此处两个模型均在全部铝合金样本上评价, 仅用于凸显特征体系错配的后果, 其数值不宜与表 3 中基于独立测试集的模型精度直接比较。




Figure 1. Comparison of the yield strength predictions for aluminum alloys
图 1. 铝合金屈服强度的预测结果对比

3.2. 三种模型的预测性能

碳钢/合金钢教学数据集的整体分布特征如图 2 所示, 三种模型在独立测试集上的预测性能见表 3, 预测精度的可视化比较如图 3 所示。梯度提升树的预测精度最高, 这与该方法能够捕捉碳含量、热处理温度和晶粒尺寸之间的非线性耦合效应密切相关; 线性回归同样取得了较高精度($R^2=0.90$), 反映出钢铁材料强度与成分参数之间的强线性相关性, 这一现象本身也是值得课堂讨论的物理规律。




Figure 2. Feature distribution of the carbon steel/alloy steel teaching dataset
图 2. 碳钢/合金钢教学数据集特征分布

Table 3. Performance comparison of three models for yield strength prediction
表 3. 三种模型的屈服强度预测性能对比

模型	R^2	MAE/MPa	RMSE/MPa
线性回归	0.90	38.5	50.0
随机森林	0.88	44.5	55.2
梯度提升树	0.93	31.5	40.7




Figure 3. Prediction accuracy of the three models on the test set

图 3. 三种模型在测试集上的预测精度对比

3.3. 特征重要性与力学理论的对照

特征重要性分析选用随机森林模型, 其基于不纯度下降的重要程度量便于课堂解释, 且精度与梯度提升树接近。各特征重要性得分如图 4 所示。碳含量重要性最高(0.554), 与冶金理论高度吻合, 碳通过间隙固溶和促进碳化物析出显著阻碍位错运动, 其对强度的贡献居各元素之首; 晶粒尺寸重要性居第二位(0.190), 符合 Hall-Petch 关系[15], 即晶粒越细小, 晶界密度越大, 位错运动阻力越强; 热处理温度位列第三(0.144), 对应回火过程中碳化物聚集粗化与位错回复导致的强度下降规律; 铬、锰、硅三者的重要性均很低(0.056、0.031、0.024), 合计不足 0.12, 相对前三者难以对强度变化形成主导影响。对于此类低重要性特征, 其得分易受样本成分分布与特征相关性的影响, 不宜据此推断各元素强化作用的强弱。




Figure 4. Feature importance scores of the random forest model

图 4. 随机森林模型的特征重要性得分

3.4. 参数敏感性分析

以碳含量 0.35 wt%、锰含量 1.0 wt%、硅含量 0.40 wt%、铬含量 0.20 wt%、晶粒尺寸 30 μm 、未经回火处理(热处理温度取 0)为基准状态开展参数敏感性分析, 结果如图 5 所示。单独增大碳含量, 屈服强度持续上升; 单独减小晶粒尺寸, 屈服强度上升, 且曲线形态与 Hall-Petch 关系的趋势吻合; 随热处理温度升高, 强度在高温阶段呈下降趋势, 与钢的回火软化规律相符。三组单因素分析结果均与相应的材料力学和冶金学理论预期一致。




Figure 5. Parameter sensitivity analysis

图 5. 参数敏感性分析

3.5. 资源包的技术验证与试用评价

演示文件经完整执行测试, 全部 9 个教学步骤均正常运行, 代码执行时间约 15 s, 具备课堂演示所需的流畅性。数据集生成逻辑经物理一致性核查: 铁基数据集中碳含量与屈服强度的正相关趋势、晶粒尺寸对强度的负相关效应、热处理温度升高导致强度下降的规律均与冶金理论吻合; 铝合金数据集中时效温度对强度的影响呈现典型的峰值时效特征, 符合析出强化的物理机制。3 位同行教师均表示, 在阅读操作指南后能够在 30 min 内独立完成课前配置, 认可资源包的可复用性, 并一致将铁基模型误用于铝合金的失效演示评为教学价值最高的环节, 认为正误对比能有效促使学生反思 AI 结果的可靠边界。

4. 讨论

4.1. 数据驱动结果与经典强化理论的互证

上述结果表明, 数据驱动方法从教学数据中自动捕捉的规律, 与冶金工程师基于物理直觉得出的认知能够相互印证。居前三位的特征其排序与固溶强化、细晶强化和回火软化等经典理论高度一致, 使抽象的强化机制获得了可量化、可视化的表达, 较之单纯的理论讲授更具说服力, 这为力学基础课程中引入数据驱动方法提供了直接依据。

4.2. 失效演示的教学价值

已有教改探索多以展示 AI 的预测能力为主, 容易使学生形成 AI 万能的片面印象。本研究将模型用错的场景纳入核心教学设计, 铁基模型误用于铝合金时 R^2 稳定为大幅负值, 远低于以均值预测为基准的零值, 这一结果直观说明: 对材料体系强化机制的理解是正确使用 AI 工具的前提, 忽视学科基础知识而盲目套用模型, 不仅得不到有意义的预测, 还会产生误导性结果。由此, AI 赋能教学的重心得以从 AI 能做什么转向如何正确使用 AI, 与工科基础课程的育人要求保持一致。

4.3. 数据驱动方法的局限与批判性审视

数据驱动方法的可靠性首先取决于数据质量。本研究的教学数据集为保证课堂演示的可控性而采用合成样本, 其成分-工艺-性能关系虽经物理一致性核查, 但在噪声水平、样本代表性和分布均衡性上与真实实验数据仍有差距。真实材料数据中, 成分覆盖不均、工艺记录缺失、测试标准不统一等问题普遍存在, 若不加甄别地直接建模, 模型将忠实地学习数据中的偏差而非材料的物理规律。因此有必要向学生明确: 模型精度的上限由数据决定, 预测结果的可信度不能脱离训练数据的来源与边界来讨论, 后

续也需引入公开材料数据库以增强真实性。

模型可解释性是另一重需要审慎对待的问题。特征重要性反映的是模型拟合过程中对各输入变量的依赖程度,属于相关性度量而非因果判据,不同算法给出的排序也并不唯一。随机森林以各特征在全部决策树中累计的不纯度下降计分,当碳含量与热处理温度等变量相关时,重要性会在相关特征之间被分摊;梯度提升树按序拟合残差,先被选入的特征往往吸收了与之共线特征的大部分贡献,次要特征的排序因而可能发生变动。这提示教学中不应把某一模型输出的重要性排序视作强化机制的定论,而应将其作为与固溶强化、细晶强化等理论相互印证的线索——本研究中居前三位的碳含量、晶粒尺寸与热处理温度与经典理论高度吻合,而重要性很低的几个成分特征则难以据此判断其强化作用,这说明只有当特征的物理意义明确、贡献足够显著时,重要性排序才具备与机理对话的价值。

在安全攸关的工程设计中依赖 AI 预测还涉及责任伦理问题。农机机架、收获机械传动件等构件一旦失效将直接威胁人身安全,其强度校核必须以现行设计规范、材料标准和安全系数为依据, AI 预测只能用于方案初筛、材料预选与趋势判断,不能替代实验验证与规范校核。教学中应明确模型的适用边界与责任归属,引导学生对黑箱结论保持必要警惕:当模型结果与力学常识冲突时,首先应当质疑的是模型而非常识。此外,本研究改造章节目前集中于强度与稳定性相关内容,扭转、弯曲等章节的融合路径尚待进一步探索。

4.4. 教学评估方案设计与实施计划

本研究当前的评价以技术验证和同行教师试用为主,尚缺少覆盖完整学期的学生学习成效数据。为此已设计一项覆盖完整学期的准实验研究,拟于下一教学周期实施:选取同年级同专业的两个平行班(每班约 30 人),随机指定为实验班与对照班,由同一教师任课并保持教学进度与考核标准一致,实验班在 5 个改造章节嵌入 AI 内容。

评估沿三条路径展开。一是概念理解的前测-后测:学期初与学期末各实施一次同源异卷的物理概念测验,覆盖应力-应变关系、强化机制与稳定性判据等核心概念;班内以配对样本 t 检验比较前后测差异,班间以前测成绩为协变量作协方差分析,并报告效应量。二是 AI 辨析能力的专项考察:在期末考试中单独设置两类题目,一类要求学生判断给定条件下模型预测结果是否合理并给出力学依据,另一类给出跨材料体系误用模型的情景要求辨析错误来源,两类题目单独统计得分率作班间比较。三是学习体验的匿名问卷:学期末发放 5 点 Likert 量表问卷,测量课堂参与度、学习兴趣与认知负荷,并设开放题收集意见,内部一致性以 Cronbach's α 系数检验。

实施中将向学生说明数据仅用于教学研究并匿名处理,学期结束后向对照班开放全部资源以保证公平。评估结果将另文报告。

5. 结论

(1) 提出了物理优先、精选融合、反向强化三条设计原则,明确了以力学理论为主干、AI 工具为延伸的改革定位,尤其将 AI 失效案例作为深化物理认知的教学手段,为同类工科基础课的智能化改造提供了方法论参考。

(2) 以轴向拉压章节为典型案例,开发了含铁基合金与铝合金双数据集、可交互演示文件及教师操作指南的完整资源包。梯度提升树预测精度最高($R^2=0.93$),特征重要性排序与固溶强化、细晶强化和回火软化等经典理论高度吻合,实现了 AI 工具体验与力学理论深化的协同。

(3) 方案不压缩理论课时、不要求学生具备编程基础,经同行教师试用验证具备可复用性,可为农业工程类高校及同类工科专业开展基础课程智能化改革提供实施范例。

基金项目

华中农业大学本科教育教学综合改革课程创新项目(AI2025034)。

参考文献

- [1] 徐锋, 范剑, 许晨光. 新工科背景下地方高校材料力学金课建设路径与探索[J]. 力学与实践, 2020, 42(2): 226-231.
- [2] 乔玲, 糜长稳, 白鹏翔, 等. 聚焦解决复杂工程问题能力培养的材料力学课程教学研究[J]. 高教学刊, 2026, 12(8): 21-26.
- [3] 何巍, 高鸿隽, 孙星, 等. 新工科视域下“产-教-研-学”四位一体的实验教学改革与育人模式探索[J]. 力学与实践, 2026, 48(3): 543-550.
- [4] 殷跃, 徐媛媛, 房玉强, 等. 产学研背景下材料力学课程探索型课程设计方案研究——以大口径高内压管道设计为例[J]. 农业工程, 2025, 15(12): 132-137.
- [5] 郭丽峰, 刘宏新, 谢秋菊, 等. AI 技术在农业教育中的应用[J]. 农业工程, 2026, 16(2): 162-166.
- [6] 都琳, 徐爽, 徐宗本. 师-生-AI 协同课堂: 人工智能赋能大学数学教育的载体及实践[J]. 中国大学教学, 2025(4): 59-65+81.
- [7] 徐晓飞, 张策. 生成式人工智能赋能工程教育及学生能力的培养、测评与认证体系[J]. 高等工程教育研究, 2025(4): 1-9.
- [8] 唐超, 张泽治, 张雅楠, 等. “山海 AI”: DeepSeek 赋能多场景联动的区域智能教育系统[J]. 现代教育技术, 2026(2): 128-136.
- [9] Ramprasad, R., Batra, R., Pilania, G., Mannodi-Kanakkithodi, A. and Kim, C. (2017) Machine Learning in Materials Informatics: Recent Applications and Prospects. *npj Computational Materials*, **3**, Article No. 54. <https://doi.org/10.1038/s41524-017-0056-5>.
- [10] 曹志增, 王桂吉, 罗斌强. 基于机器学习的金属材料力学性能智能预测研究现状与展望[J]. 力学进展, 2026, 56(1): 123-168.
- [11] Schmidt, J., Marques, M.R.G., Botti, S. and Marques, M.A.L. (2019) Recent Advances and Applications of Machine Learning in Solid-State Materials Science. *npj Computational Materials*, **5**, Article No. 83. <https://doi.org/10.1038/s41524-019-0221-0>
- [12] Bhadeshia, H.K.D.H., Dimitriu, R.C., Forsik, S., Pak, J.H. and Ryu, J.H. (2009) Performance of Neural Networks in Materials Science. *Materials Science and Technology*, **25**, 504-510. <https://doi.org/10.1179/174328408x311053>
- [13] Raissi, M., Perdikaris, P. and Karniadakis, G.E. (2019) Physics-Informed Neural Networks: A Deep Learning Framework for Solving Forward and Inverse Problems Involving Nonlinear Partial Differential Equations. *Journal of Computational Physics*, **378**, 686-707. <https://doi.org/10.1016/j.jcp.2018.10.045>
- [14] 翁焕博, 罗诚, 袁荒. 基于晶体塑性力学框架的材料本构行为智能预测研究[J]. 力学学报, 2024, 56(12): 3468-3483.
- [15] Hall, E.O. (1951) The Deformation and Ageing of Mild Steel: III Discussion of Results. *Proceedings of the Physical Society, Section B*, **64**, 747-753. <https://doi.org/10.1088/0370-1301/64/9/303>