

基于多层置信规则库的钢疲劳预测方法

蒋毅行, 付伟*, 马宁

哈尔滨师范大学计算机科学与信息工程学院, 黑龙江 哈尔滨

收稿日期: 2024年10月22日; 录用日期: 2024年11月7日; 发布日期: 2024年11月20日

摘要

钢的疲劳断裂是工业中最常发生的灾难之一。为有效预测钢疲劳, 提出了一种基于多层置信规则库 (Multilayer Belief Rule Base, MBRB) 预测模型。首先, 采用主成分分析对关键特征进行筛选。其次, 利用具有可解释性约束的投影协方差矩阵自适应进化策略 (P-CMA-ES) 对模型参数进行优化, 以提高模型的精度。最后, 以美国国家材料科学研究所 (NIMS) MatNavi 的钢疲劳数据集为例进行了钢疲劳预测, 验证了该模型的有效性, 同时多层BRB解决了传统BRB组合规则爆炸的问题。与其他方法相比, 该模型具有更高的精度与透明的推理过程。

关键词

钢疲劳预测, 置信规则库, 参数优化, 证据推理

A Fatigue Prediction Method for Steel Based on the Multi-Layer Belief Rule Base

Yixing Jiang, Wei Fu*, Ning Ma

College of Computer Science and Information Engineering, Harbin Normal University, Harbin Heilongjiang

Received: Oct. 22nd, 2024; accepted: Nov. 7th, 2024; published: Nov. 20th, 2024

Abstract

Fatigue fracture of steel is one of the most common disasters in industry. In order to effectively predict steel fatigue, a prediction model based on Multilayer Belief Rule Base (MBRB) was proposed. Firstly, principal component analysis was used to screen the key features. Secondly, the projection covariance matrix adaptive evolution strategy with interpretability constraints (P-CMA-ES) was used to optimize the parameters of the model to improve the accuracy of the model. Finally, the steel fatigue dataset of MatNavi of the National Institute of Materials Science (NIMS) of United States

*通讯作者。

文章引用: 蒋毅行, 付伟, 马宁. 基于多层置信规则库的钢疲劳预测方法[J]. 人工智能与机器人研究, 2024, 13(4): 780-787. DOI: 10.12677/airr.2024.134080

is used as an example to predict the effectiveness of the model, and the multi-layer BRB solves the problem of the explosion of traditional BRB combination rules. Compared with other methods, the model has higher accuracy and transparent inference process.

Keywords

Steel Fatigue Prediction, Confidence Rule Base, Parameter Optimization, Evidentiary Reasoning

Copyright © 2024 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

金属的疲劳度是指材料在承受交变应力或循环应力时,能够承受的最大应力值、是机械部件设计和失效分析所需的最重要和最基本的数据,超过这个值,材料将发生疲劳破坏。随着人们对静力破坏规律的了解,材料结构因超过极限强度而出现的破坏已较为少见,而有 80%~90%的工程结构破坏是由金属疲劳引起[1]。而钢作为一种广泛应用于建筑业、工业、机械制造业以及日常生活中的金属,其疲劳强度受多种因素影响,包括材料成分、冶炼和加工工艺、表面状态以及应力幅值和频率。但由于疲劳测试的成本(和时间)极高,并且疲劳失效往往会造成衰弱的后果,因此准确预测钢的疲劳强度在材料科学中对一些先进技术应用具有特别重要的意义[2]。

多年来在工程应用中积累了大量关于工艺-性能关系的数据。虽然这些数据无助于理解疲劳的基本过程,但可用于在有限材料范围内对性能进行插值预测。随着计算机性能的快速提高和软件的发展,几十年来提出了许多机器学习算法。在传统方法中,我们必须从众多算法中选择合适的学习算法来求解一个问题,并从数据库中的许多特征中选择解释变量。这种传统方法在各个领域都取得了成功的预测。

国内外现已有如下结合了机器学习算法对钢疲劳进行预测的研究:张旭泽等人通过引入 GB、RF 和 SVM 算法,尝试提出一种基于机器学习的疲劳寿命预测方法[3]。申建国等人基于有限元模拟结果结合神经网络模型对试验钢的疲劳寿命进行预测[4]。Agrawal 等人使用 Weka 软件建立了一个机器学习模型来预测高强度钢的性能[5]。Yu 通过贝叶斯推理计算了高强度钢的材料参数[6]。Zhang 等人采用神经模糊网络预测了不锈钢的疲劳强度[7]。胡等人将贝叶斯方法与高斯过程回归结合,评估了钢的概率疲劳裂纹扩展情况[8]。Amiri 等人利用人工神经网络(ANN)预测了低碳钢点焊接头的抗拉强度和疲劳行为[9]。Yang 等人对合金钢材料进行了特征选择,并建立了包含 Mn、Ni、Cr 和 Si 等元素的模型,以优化疲劳强度,提供用于在线预测钢合金疲劳强度的数据驱动模型[10]。

尽管大量实验已经证明了机器学习在预测钢疲劳工作中的成功,但疲劳强度的预测精度低于抗拉强度和硬度等其他力学性能的预测精度。这可以通过以下事实来解释:疲劳涉及比静态机械性能更复杂的微观结构、应力和环境之间的相互作用。而且当样本数量不足或在使用大量热处理工艺参数、成分来预测疲劳强度等极值特性却缺乏记录时,这些方法很难建立准确的钢疲劳度预测模型。疲劳预测需要一种更复杂并且准确的方法。

BRB 是 Yang [11]等人提出的一种模型,它有效地利用了来自工程实践的小规模数据[12],并结合定性专家知识与定量数据,展示了强大的建模能力。BRB 是一种非线性建模方法,可以表达各种形式的不确定信息,包括随机性和无知性。BRB 是一种基于 IF-THEN [13]规则的建模方法,具有较强的因果推理

能力。这种方法融合数据驱动模型和白盒模型的优点，可以提供可靠且可解释的预测结果[14]。现已广泛应用于航空航天[15]、安全评估[16]、故障检测[17]等各个领域。

本文合理设计 BRB 的多层结构，提出一种基于多层 BRB (Multilayer Belief Rule Base, MBRB)的钢疲劳预测模型。

2. 问题描述

本文提出一种多层 BRB (Multilayer Belief Rule Base, MBRB)的钢疲劳预测模型的方法适用于钢的疲劳度预测。主要解决了以下问题：

数据稀缺是材料科学与工程的一个主要问题[18]。疲劳建模领域的可用数据通常特别稀缺、异质且不完整，因为时间和成本密集型表征工作使用不同的基础测试标准。此外，模型的泛化性被认为是在各种专业领域应用 ML 技术的另一个主要限制[18]。因此本文建立了结合专家知识的多层 MBRB 钢疲劳预测模型。对影响钢疲劳的要素数据集进行主成分分析，分别选取了钢材化学成分、上游加工细节、热处理条件中影响因素最大的数个特征，并建立了合适的 MBRB 模型进行钢疲劳的预测。推理过程如(1)所示。

$$s_v = \text{MBRB}(x'_1, \dots, x'_k, O') \quad (1)$$

其中 s_v 表示多层 BRB 性能分析的结果， x'_k 代表上一层子 BRB 的结果， O' 表示多层 BRB 系统中的参数集， $\text{MBRB}(\bullet)$ 为最后一层 BRB 的融合函数。

3. 基于 MBRB 的钢疲劳预测模型

随着工业发展和需求的提高，钢疲劳度对于建筑业、工业、制造业安全具有重大意义，具有可解释性的钢疲劳预测模型，能够有效预测钢疲劳度，以避免潜在危险的发生。

在本章中，3.1 节定义了多层 MBRB 的钢疲劳模型，3.2 节使用了 P-CMA-ES 对钢疲劳预测模型的参数进行了优化，3.3 节描述了钢疲劳预测模型的推理过程。

3.1. 定义多层 MBRB 的钢疲劳模型

BRB 的规则通常由领域专家基于经验知识和系统模型的历史数据确定，专家通过确定带有置信分布若干条规则重要参数的初始值，将专家知识镶嵌到规则中组成置信规则库。多层 BRB 系统是由若干个子规则库组成，每个子规则库由一定数量的规则组成，其中规则基本结构如[19]：

$$\begin{aligned} R_k^e : & \text{If } x_1 \text{ is } H_1^k \wedge x_2 \text{ is } H_2^k \cdots x_m \text{ is } H_m^k \\ & \text{Then } y \text{ is } \{(D_1, \beta_{1,k}), (D_2, \beta_{2,k}), \dots, (D_N, \beta_{N,k})\} \\ & \text{With rule } \theta_k, \text{ attribute weight } \vartheta_1, \vartheta_2, \dots, \vartheta_M \end{aligned} \quad (2)$$

式中： $H_K^e (e=1,2,\dots,S)$ 表示第 e 个子规则库的第 k 条规则； x_i 为属性输入； H_i^k 表示属性输入参考值 ($i=1,2,\dots,M$)； y 表示输出结果，作为下一层的输入信息； D_j 表示输出结果的参考等级； β_j 表示相对于参考等级的置信度 ($j=1,2,\dots,N$)； θ_k 表示规则权重； ϑ_j 表示属性权重。

多层 BRB 模型结构图如图 1 所示，将系统的所有输入属性划分为 n 个子规则库， $x_i^j (i=1,2,\dots,l; j=1,2,\dots,m,\dots,n)$ 表示为在第 j 个规则库 $BRB_j (j=1,2,\dots,m,\dots,n)$ 中第 i 个属性输入， $y_j (j=1,2,\dots,m,\dots,n)$ 表示为在第 j 个规则库的输出，子规则库的输出作为下一层规则库的输出，不断迭代直至到达状态 y_n [20]。

3.2. 参数优化

在 BRB 中参考值的最优情况下，参数(包括规则权重、置信度和属性权重)的优化至关重要。即使这

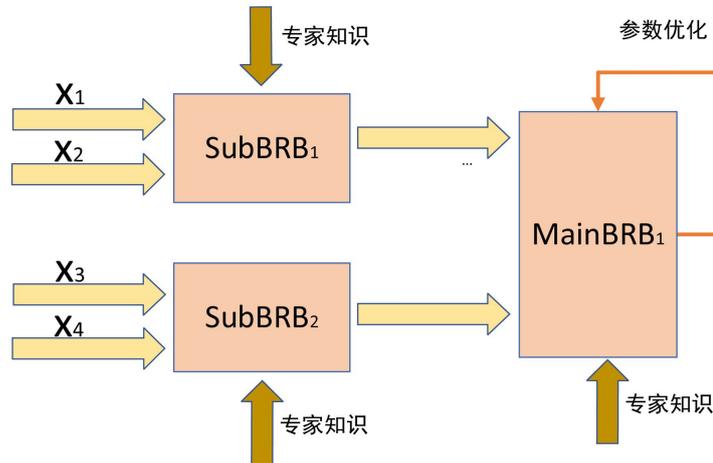


Figure 1. Structural diagram of the multi-layer BRB model
图 1. 多层 BRB 模型结构图

些参数稍有差异，也会显著影响 BRB 的预测精度。在目前的研究阶段，许多高性能算法被用模型的优化过程。本文采用带有可解释性的 P-CMA-ES 算法将 MBRB 参数进行优化[21]，进一步提高了模型的精度。本文中的优化算法为基于投影算子的协方差矩阵自适应优策略，P-CMA-ES 是在原始 CMA-ES 智能的优化算法的一种改进算法，通过生成初始种群，在约束条件下选择，生成子种群不断迭代寻找最优解，它 在高维非线性优化的方面表现良好，能够利用较少的样本快速收敛到全局最优点。

3.3. 基于 MBRB 的钢疲劳预测模型的推理过程

作为灰盒模型的 MBRB，它引入了在对钢疲劳度的影响因素的长期探索中获得的专家知识。MBRB 的主要构成有知识库、推理引擎和优化模型。在预测过程中存在固有的模糊性和不确定性，需要将指标数据转换为定量描述不确定性的统一形式。鉴于此，本文采用分析性证据推理(ER)算法进行推理，有效整合多指标信息对复杂系统进行评估，为不确定条件下信息的定量和定性表达提供支持。首先，需要计算激活权重，然后使用 ER。该算法集成了激活规则，具体步骤分为以下四个步骤。

步骤 1：需要计算输入样本信息与信念规则之间的匹配程度，即规则的适应程度。第 i 个输入下第 n 条规则的规则适应程度计算方式如下：

$$a_i^n = \begin{cases} \frac{A_i^{l+1} - x_i}{A_i^{l+1} - A_i^l} & n = l, A_i^l \leq x_i \leq A_i^{l+1} \\ 1 - a_i^k & n = l + 1 \\ 0 & n = 1, \dots, N; n \neq l, l + 1 \end{cases} \quad (3)$$

其中， A_i^n 表示第 i 个输入的第 n 个参考值， a_i^n 是 A_i^n 对应的匹配度。

步骤 2：计算第 n 条规则的规则激活权重 ω_n 。激活权重可以按以下方式计算：

$$\omega_n = \frac{\theta_n \prod_{i=1}^M (a_i^n)^{\delta_i}}{\sum_{i=1}^N \theta_i \prod_{i=1}^M (a_i^i)^{\delta_i}} \quad (4)$$

其中， $\delta_i (i=1, \dots, M)$ 表示第 i 个评估指标的属性权重。

步骤 3：最终的置信度 $\beta_r (r=1, \dots, R)$ 是利用 ER 分析算法的规则推理得到的。计算方式如下所示：

$$\beta_r = \frac{\mu \times \left[\prod_{l=1}^L \left(\omega_l \beta_{r,l} + 1 - \omega_l \sum_{i=1}^R \beta_{i,l} \right) - \prod_{l=1}^L \left(1 - \omega_l \sum_{i=1}^R \beta_{i,l} \right) \right]}{1 - \mu \times \left[\prod_{l=1}^L (1 - \omega_l) \right]} \quad (5)$$

$$\mu = \frac{1}{\sum_{n=1}^R \prod_{l=1}^L \left(\omega_l \beta_{n,l} + 1 - \omega_l \sum_{i=1}^R \beta_{i,l} \right) - (R-1) \prod_{l=1}^L \left(1 - \omega_l \sum_{i=1}^R \beta_{i,l} \right)} \quad (6)$$

步骤 4: 计算预期的效用值并获得最终输出:

$$u(S(A')) = \sum_{r=1}^R u(H_r) \beta_r \quad (7)$$

其中, $S(\bullet)$ 表示由置信分布组成的集合, A' 表示实际的输入向量, $u(H_r)$ 表示 H_r 的效用, $u(S(A'))$ 是最终的期望效用, y 为最终的置信分布, 可以表示为:

$$y = \{(H_r, \beta_r), r = 1, \dots, R\} \quad (8)$$

4. 案例研究

4.1. 数据预处理

本文使用了美国国家材料科学研究所(NIMS) MatNavi 的钢疲劳数据集, 该数据包含炼钢过程中的各种实验条件, 其中涉及到的化学成分特征有 9 个, 上游加工细节有 3 个, 热处理条件有 5 个。但部分特征标准差为 0, 也就是说他们的数值是保持不变的, 这导致了他们无法被用来预测钢疲劳, 因此需要从中删除这些特征, 此外由于不同特征具有不同的重要程度, 因此进行了主成分分析, 计算每个属性的基于相关性的特征排名, 并选取了化学成分中相关性排名最高的碳(C)和铬(Cr), 热处理排名中相关性排名最高的回火温度(TT), 上游加工细节中相关性最高的减速比(Reduction Ratio)作为模型的输入属性, 并进行数据归一化处理。最终数据集包括 186 个数据点。在本文中, 每次实验随机抽取数据集的 2/3 作为训练集, 1/3 作为测试集。在机器学习领域, 这种训练集与测试集的比例划分是经过广泛研究和实践验证的。当数据集规模适中时, 2/3 和 1/3 的比例在平衡模型训练效果和泛化能力评估方面表现出色。它既能保证模型在训练过程中有足够的学习素材, 又能在测试阶段对模型的真实性能进行较为客观的衡量, 避免过拟合或欠拟合等问题对评估结果的影响。

4.2. 建模过程

多层模型共有 2 层, 下层为 2 个子规则库, 第一个子规则库 SubBrb₁ 的 2 个输入指标分别是的 x_1 (碳元素含量), x_2 (铬元素含量), 第二个子规则库 SubBrb₂ 的 2 个输入指标为 y (回火温度), z (减速比)。并将两个子规则库的输出 W_1 和 W_2 作为主规则库 MainBrb 的输入。在基于 MBRB 的钢疲劳预测中, 参考值由专家提供。这些专家知识是通过实际研究钢疲劳相关因素积累的。通过分析数据特征, 为每个指标设置了 7 个参考值, 共定义了 49 条置信规则。子规则库的参考值见表 1。

主规则库 MainBrb 的参考值如表 2。

4.3. 结果分析

精度分析

在精度分析中, 本节使用了 RMSE 作为评价指标。MBRB 结合 KStar、SVM、ANN、REPTree、LinearRegression。结果如表 3 所示, 预测值的真实值的拟合程度如图 2 所示。

Table 1. Sub rule library reference values
表 1. 子规则库参考值

	参考点	L1	L2	L3	L4	L5	L6	L7
SubBrb ₁	x_1	0	0.009	0.081	0.099	0.22	0.77	1
	x_2	0	0.14	0.4	0.62	0.68	0.92	1
SubBrb ₂	y	0	0.63	0.66	0.69	0.72	0.91	1
	z	0	0.27	0.53	0.66	0.8	0.9	1

Table 2. Main rule library reference values
表 2. 主规则库参考值

	参考点	L1	L2	L3	L4	L5	L6	L7
MainBrb	a_1	0	0.41	0.63	0.67	0.69	0.75	1
	a_2	0	0.27	0.53	0.66	0.71	0.73	1

Table 3. Comparison between MBRB and other models
表 3. MBRB 与其他模型比较

No.	Method	RMSE
1	MBRB-e	0.0435
2	KStar	0.0857
3	SVM	0.0580
4	ANN	0.0470
5	REPTree	0.0542
6	LinearRegression	0.0581

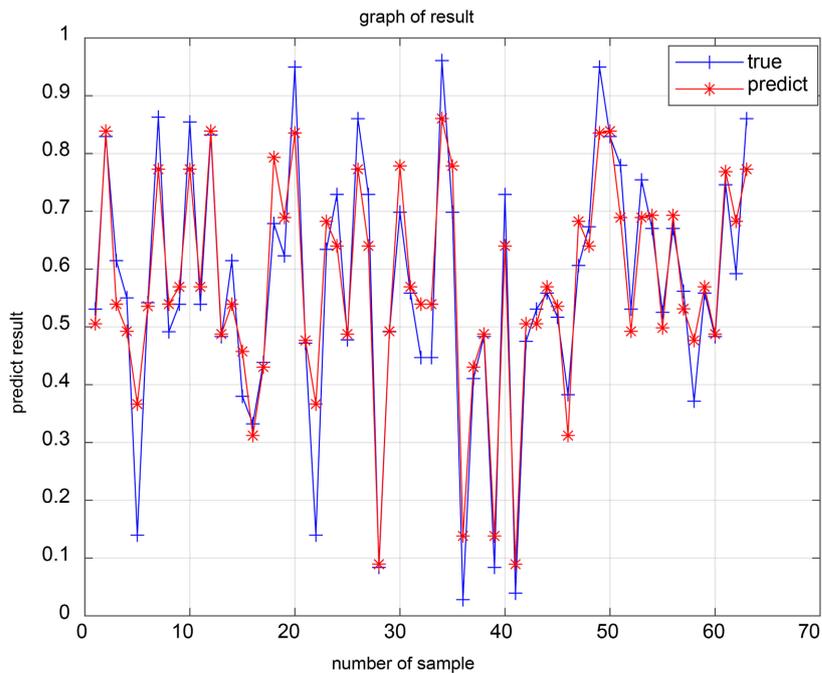


Figure 2. The fitting degree of the predicted values of MBRB to the true values
图 2. MBRB 预测值的真实值的拟合程度

由表 3 可以看出 MBRB 的预测精度优于其他机械学习的模型。

在相同数量的数据集下, MBRB 模型相比于基于数据驱动的 ANN 和 Kstar 模型具有以下特点: 首先, MBRB 模型具有透明的推理过程, 而 ANN 和 Kstar 等数据驱动模型的内部结构是不可见的。其次, MBRB 模型基于规则建模, 能够合理解释输出结果, 而数据驱动模型无法解释输入与输出之间的关系。此外, MBRB 模型能够有效利用专家知识构建模型, 这有助于人们充分理解模型, 而数据驱动模型则不具备这种能力。最后, MBRB 模型对样本依赖性较低, 即使在小样本情况下也能保证精度, 而数据驱动模型对样本依赖性较高, 在小样本情况下精度较低。

5. 结语

准确预测钢疲劳是一项艰巨的任务。本文在 BRB 的基础上构建了 MBRB 模型, 提出了一种基于多层置信规则库预测模型, 采用主成分分析对关键特征进行筛选, 利用具有可解释性约束的投影协方差矩阵自适应进化策略对模型参数进行优化, 为钢疲劳预测提供了一种高度准确和可信的方法。这一成就不仅强调了置信规则库和专家知识在预测钢疲劳方面的有效性, 而且强调了通过创新方法解决一些材料科学问题的潜力。

MBRB 模型已经被证明能够有效地处理钢疲劳预测问题, 但这有一定的局限性。我们计划在未来继续进行以下方面的研究:

我们将搜集更多的钢疲劳相关的数据集, 以增强预测结果并提高准确率。本研究证明了利用四个特征预测钢疲劳强度的有效性, 证明他们确实是预测钢疲劳的可靠变量。然而, 未知的数据质量对于疲劳预测的人工智能模型也起到一定的影响, 重要的是继续研究和审查其他潜在的变量和特征, 对相关数据进行更深层次的探索, 以获得更准确和可靠的钢疲劳预测结果。

现有的关于金属疲劳的建模分为五个应用场景: 疲劳寿命预测、疲劳裂纹、疲劳损伤诊断、疲劳强度和疲劳负荷。本文仅将 MBRB 模型应用于钢疲劳强度预测, 后续将继续疲劳建模研究, 将 MBRB 模型应用于更多场景。

我们研究出 MBRB 模型在钢疲劳预测方面的意义, 并证明了它优于传统的深度学习算法。通过置信规则库和专家系统的协同作用, 为克服材料科学应用, 尤其是疲劳预测领域的稀缺、异构和不完整的数据构成的重大挑战提供了新方法, 为人工智能与材料科学相结合的未来开创了新思路。

基金项目

黑龙江省自然科学基金项目(LH2021F037)资助; 黑龙江省高等教育教学改革项目(SJGY20180259, SJGY20200368)资助; 哈尔滨市科技局科技创新人才研究专项项目(2017RAQXJ050)资助; 哈尔滨师范大学博士科研启动基金项目(XKB201901)资助; 哈尔滨师范大学研究生培养质量提升工程项目(HSDYJSJG2019006)资助; 哈尔滨师范大学教学改革项目(XJGRYK2022017, XJGYFW2022038); 哈尔滨师范大学计算机学院教学改革项目(JKYJGY202209); 装备智能运用教育部重点实验室开放基金课题资助(AAIE-2023-0102)。

参考文献

- [1] Fajri, A., Prabowo, A.R., Muhayat, N., Smaradhana, D.F. and Bahatmaka, A. (2021) Fatigue Analysis of Engineering Structures: State of Development and Achievement. *Procedia Structural Integrity*, **33**, 19-26. <https://doi.org/10.1016/j.prostr.2021.10.004>
- [2] Agrawal, A., Deshpande, P.D., Cecen, A., Basavarsu, G.P., Choudhary, A.N. and Kalidindi, S.R. (2014) Exploration of Data Science Techniques to Predict Fatigue Strength of Steel from Composition and Processing Parameters. *Integrating Materials and Manufacturing Innovation*, **3**, 90-108. <https://doi.org/10.1186/2193-9772-3-8>

- [3] 张旭泽. 基于机器学习的金属材料超高周疲劳寿命预测[D]: [硕士学位论文]. 武汉: 武汉纺织大学, 2023.
- [4] 申建国, 汪舟, 卢伟, 等. 有限元模拟和神经网络相结合的喷丸处理 SAE9254 钢疲劳寿命预测[J]. 机械工程材料, 2024, 48(7): 77-84.
- [5] Agrawal, A., Deshpande, P.D., Cecen, A., Basavarsu, G.P., Choudhary, A.N. and Kalidindi, S.R. (2014) Exploration of Data Science Techniques to Predict Fatigue Strength of Steel from Composition and Processing Parameters. *Integrating Materials and Manufacturing Innovation*, **3**, 90-108. <https://doi.org/10.1186/2193-9772-3-8>
- [6] Yu, X. (2016) Material Parameter Identification of the Stamping Forming Plate of Advanced High Strength Steel Based on Bayesian Inference. M.Sc. Thesis, Hunan University.
- [7] Zhang, M., Sun, C., Zhang, X., Goh, P.C., Wei, J., Hardacre, D., *et al.* (2019) High Cycle Fatigue Life Prediction of Laser Additive Manufactured Stainless Steel: A Machine Learning Approach. *International Journal of Fatigue*, **128**, Article ID: 105194. <https://doi.org/10.1016/j.ijfatigue.2019.105194>
- [8] Hu, D., Su, X., Liu, X., Mao, J., Shan, X. and Wang, R. (2020) Bayesian-Based Probabilistic Fatigue Crack Growth Evaluation Combined with Machine-Learning-Assisted GPR. *Engineering Fracture Mechanics*, **229**, Article ID: 106933. <https://doi.org/10.1016/j.engfracmech.2020.106933>
- [9] Amiri, N., Farrahi, G.H., Kashyzadeh, K.R. and Chizari, M. (2020) Applications of Ultrasonic Testing and Machine Learning Methods to Predict the Static & Fatigue Behavior of Spot-Welded Joints. *Journal of Manufacturing Processes*, **52**, 26-34. <https://doi.org/10.1016/j.jmapro.2020.01.047>
- [10] Yang, Y.L., Wang, L. and Ma, C.H. (2020) Quantitative Analysis of Liquid Steel Element in LIBS Using SVR Improved by Particle Swarm Optimization. *Laser & Optoelectronics Progress*, **57**, Article ID: 053002. <https://doi.org/10.3788/lop57.053002>
- [11] Yang, J.-B., Liu, J., Wang, J., Sii, H.-S. and Wang, H.-W. (2006) Belief Rule-Base Inference Methodology Using the Evidential Reasoning Approach-Rimer. *IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans*, **36**, 266-285. <https://doi.org/10.1109/tsmca.2005.851270>
- [12] Cao, Y., Zhou, Z., Tang, S., Ning, P. and Chen, M. (2023) On the Robustness of Belief-Rule-Based Expert Systems. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, **53**, 6043-6055. <https://doi.org/10.1109/tsmc.2023.3279286>
- [13] Cao, Y., Zhou, Z., Hu, C., He, W. and Tang, S. (2021) On the Interpretability of Belief Rule-Based Expert Systems. *IEEE Transactions on Fuzzy Systems*, **29**, 3489-3503. <https://doi.org/10.1109/TFUZZ.2020.3024024>
- [14] 周志杰, 曹友, 胡昌华, 等. 基于规则的建模方法的可解释性及其发展[J]. 自动化学报, 2021, 47(6): 1201-1216.
- [15] 程晓玉, 韩鹏, 贺维, 等. 一种新的基于可解释性置信规则库的飞轮健康状态评估模型[J]. 航空学报, 2023, 44(S1): 177-189.
- [16] 董昕昊, 周志杰, 胡昌华, 等. 基于分层置信规则库的惯导系统性能评估方法[J]. 航空学报, 2021, 42(7): 441-451.
- [17] 朱海龙, 耿文强, 韩劲松, 等. 利用置信规则库构建 WSN 节点故障检测模型[J]. 智能系统学报, 2021, 16(3): 511-517.
- [18] Frie, C., Riza Durmaz, A. and Eberl, C. (2024) Exploration of Materials Fatigue Influence Factors Using Interpretable Machine Learning. *Fatigue & Fracture of Engineering Materials & Structures*, **47**, 2752-2773. <https://doi.org/10.1111/ffe.14315>
- [19] Chen, Y., Yang, J., Xu, D., Zhou, Z. and Tang, D. (2011) Inference Analysis and Adaptive Training for Belief Rule Based Systems. *Expert Systems with Applications*, **38**, 12845-12860. <https://doi.org/10.1016/j.eswa.2011.04.077>
- [20] Yang, J. and Xu, D. (2013) Evidential Reasoning Rule for Evidence Combination. *Artificial Intelligence*, **205**, 1-29. <https://doi.org/10.1016/j.artint.2013.09.003>
- [21] Hu, G., Zhou, Z., Zhang, B., Yin, X., Gao, Z. and Zhou, Z. (2016) A Method for Predicting the Network Security Situation Based on Hidden BRB Model and Revised CMA-ES Algorithm. *Applied Soft Computing*, **48**, 404-418. <https://doi.org/10.1016/j.asoc.2016.05.046>