Computer Science and Application 计算机科学与应用, 2026, 16(11), 60-75
Published Online November 2026 in Hans. https://www.hanspub.org/journal/csa
https://doi.org/10.12677/csa.2026.1611326

Hans汉斯

基于改进麻雀搜索优化置信规则库的工业机器人故障诊断方法

黄建青，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：2026年10月1日；录用日期：2026年10月29日；发布日期：2026年11月9日

摘　要

针对工业机器人故障诊断问题，提出一种基于改进麻雀搜索优化置信规则库的工业机器人故障诊断方法(Refined Sparrow Search Algorithm Optimized Belief Rule Base, RSSA-BRB)。首先，结合先验知识建立了工业机器人故障诊断模型；其次，设计了改进麻雀搜索算法对模型参数进行优化，为提高优化精度，避免算法陷入局部最优，采用混沌映射初始化种群、自适应惯性权重位置更新、高斯变异最优个体策略对麻雀搜索算法进行了改进；最后，通过对工业机器人故障诊断案例进行研究，验证了本文方法在工业机器人故障诊断中的有效性。对比研究表明，本文方法在诊断精度和收敛速度方面具有一定的优势。

关键词

工业机器人，故障诊断，置信规则库，证据推理，麻雀搜索算法

Industrial Robot Fault Diagnosis Method Based on Refined Sparrow Search Algorithm Optimized Belief Rule Base

Jianqing Huang, Ning Ma*

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

Received: October 1, 2026; accepted: October 29, 2026; published: November 9, 2026

Abstract

Addressing the issue of industrial robot fault diagnosis, a method based on a refined Sparrow Search Algorithm optimized belief rule base (RSSA-BRB) is proposed. Firstly, an industrial robot fault

*通讯作者。

文章引用: 黄建青, 马宁. 基于改进麻雀搜索优化置信规则库的工业机器人故障诊断方法[J]. 计算机科学与应用, 2026, 16(11): 60-75. DOI: 10.12677/csa.2026.1611326

diagnosis model is established by combining prior knowledge. Secondly, an improved Sparrow Search Algorithm is designed to optimize the model parameters. To enhance optimization accuracy and prevent the algorithm from falling into local optima, the Sparrow Search Algorithm is improved by using chaos mapping to initialize the population, adaptive inertia weight position updating, and Gaussian mutation for the optimal individual strategy. Finally, through research on industrial robot fault diagnosis cases, the effectiveness of the proposed method in industrial robot fault diagnosis is verified. Comparative studies show that the proposed method has certain advantages in terms of diagnosis accuracy and convergence speed.

Keywords

Industrial Robot, Fault Diagnosis, Belief Rule Base, Evidential Reasoning, Sparrow Search Algorithm

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

工业机器人作为智能制造的核心装备，广泛应用于焊接、搬运、装配、喷涂等生产环节[1]。随着工业机器人保有量增长和服役环境复杂化，其关键部件会产生故障。故障不仅会导致生产线停机和产品质量下降，还可能引发安全事故并造成经济损失[2]。因此，准确、及时诊断工业机器人故障，对保障生产安全、降低维护成本和提高设备利用率具有重要意义[3]。

近年来，工业机器人故障诊断主要分为机理模型方法和数据驱动方法两类。机理模型方法通过建立机器人动力学或运动学模型，分析故障对系统参数的影响。Sabry 等人系统综述了多自由度工业机器人及多轴设备的故障检测与隔离技术，指出机械、电气和软件层面的耦合使其故障机理建模面临较大挑战[4]。数据驱动方法可从大量监测数据中自动学习故障特征，并在诊断精度上取得显著进展。Raouf 等人提出基于注意力引导特征聚合网络的伺服电机轴承故障诊断方法，通过分层信息聚合实现了工业机器人焊接场景下的鲁棒故障检测[5]。针对故障样本稀缺问题，有研究提出基于 Transformer 卷积集成特征度量网络的少样本故障诊断模型，在训练数据有限时仍取得较高的谐波减速器故障诊断准确率[6]。此外，多域神经过程模型[7]、轻量化卷积 Transformer 增强元学习[8]等方法也被相继用于工业机器人复合故障和异常检测。上述方法丰富了工业机器人故障诊断技术，但本质上仍属于数据驱动“黑箱”模型，决策过程难以解释，且性能依赖训练样本的数量与质量[9]。

BRB (Belief Rule Base)是 Yang 等人提出的一种融合专家知识与样本数据的灰箱模型[10]，以 IF-THEN 规则为载体，并通过置信度和证据推理处理不确定信息，具有较好的建模与解释能力。近年来，BRB 在故障诊断领域得到了广泛关注和应用[11]。Zhao 等人针对先验信息不足和监测数据可靠性不完全问题，提出自适应 BRB 方法，提高了制造系统诊断性能[12]。Wan 等人针对区间结构 BRB 因数据分散导致精度下降的问题，引入动态规则匹配和新的激活权重计算方法，并采用 P-CMA-ES 优化模型[13]。Gao 等人通过多维 BRB 分解模型输入，并结合 P-CMA-ES 进行参数优化，有效缓解规则组合爆炸并提升诊断精度[14]。Mai 等人将在线扩展 BRB 用于自主水下航行器故障诊断，通过基于马氏距离的聚类实现动态规则约减，在保证诊断精度的同时降低模型复杂度[15]。这些研究表明，BRB 能够有效融合专家知识与观测数据，在小样本和不确定性环境下展现出独特的优势，并已拓展至健康状态评估[16]、可靠性评估[17]、

预测和决策等多个领域[18] [19]。

BRB 模型的初始参数仅依靠专家给出，在故障诊断精度方面具有一定的局限性。群智能优化算法因其结构简单、全局搜索能力强、易于实现等特点，被广泛用于复杂模型的参数寻优。麻雀搜索算法(Sparrow Search Algorithm, SSA)是近年来提出的一种新型群智能算法，通过模拟麻雀觅食与反捕食行为，具有较快的收敛速度和较高的寻优精度[20]，但是迭代后期易出现种群多样性下降和局部最优问题。为此，已有研究通过相对距离与历史成功率机制，并结合柯西和高斯变异增强局部最优逃逸能力[21]。也有研究采用复合混沌映射、蜣螂舞蹈搜索和自适应 t 变异平衡全局探索与局部开发[22]。Wang 等人提出了一种多策略融合麻雀搜索算法(MISSA)，通过改进搜索、群体跟随和随机反向学习策略提升搜索能力与种群多样性[23]。这些改进工作为 SSA 在复杂优化问题中的应用提供了有效支撑，但用于 BRB 参数优化的研究仍较少。与此同时，BRB 在工业机器人故障诊断中还存在规则组合爆炸和参数优化困难两方面问题：前提属性及参考值增加会导致规则数指数增长，而规则权重、属性权重和置信度维度高、耦合强，使传统优化方法易陷入局部最优且收敛较慢。因此，在控制规则规模的同时实现高效全局寻优，是 BRB 应用于工业机器人故障诊断的关键问题。

2. 问题描述

针对工业机器人故障诊断面临的挑战，RSSA-BRB 故障诊断模型主要面临了两个问题，具体问题如下。

问题 1：如何建立合理的故障诊断模型。确定输入属性后，需要构建融合专家知识与观测数据的 BRB 故障诊断模型，并通过推理机制输出诊断结果。该模型可表述为：

$$y = g(X^*, E_K, \Omega) \tag{1}$$

其中，X^* 表示筛选后的关键特征，E_K 表示专家知识，Ω 表示待优化的 BRB 参数集合，y 表示故障诊断结果，表示从特征到故障类型的非线性映射函数。

问题 2：如何优化模型参数。BRB 参数包括规则权重、属性权重和置信度，其取值直接影响诊断性能。初始参数依赖专家经验设定，主观性强且难以保证最优。该过程可表述为：

$$\Omega_{best} = \Theta(\Omega) \tag{2}$$

其中，Ω 表示待优化的 BRB 参数集合，Θ 表示参数优化过程，Ω_{best} 表示优化后的最优参数。

3. 基于 RSSA-BRB 的工业机器人故障诊断方法

针对问题描述中提出的题，本章构建基于改进麻雀搜索算法优化置信规则库的工业机器人故障诊断模型(RSSA-BRB)。该模型以 BRB 为诊断知识载体，以证据推理为推理引擎，以 RSSA 为参数优化工具，整体框架如图 1 所示。以下分别从模型的构建、推理和优化三个部分进行详细阐述。

3.1. RSSA-BRB 模型的构建

BRB 由若干条 IF-THEN 置信规则组成，能够以置信度的形式表达专家知识中的不确定性。对于工业机器人故障诊断问题，设经过特征筛选后得到的关键特征集为 $X^* = \{x_1, x_2, \cdots, x_T\}$，其中 T 为前提属性个数；故障类型集合为 $D = \{D_1, D_2, \cdots, D_N\}$，$N$ 为故障类别数。第 k 条的置信规则可表示为：

$$R_k : \begin{cases} \text{IF } x_1 \text{ is } A_1^k \wedge x_2 \text{ is } A_2^k \wedge \cdots \wedge x_T \text{ is } A_T^k, \\ \text{THEN } y \text{ is } \left\{\left(D_1, \beta_{1,k}\right), \left(D_2, \beta_{2,k}\right), \cdots, \left(D_N, \beta_{N,k}\right)\right\}, \\ \text{with rule weight } \theta_k \text{ and attribute weights } \delta_1, \delta_2, \cdots, \delta_T. \end{cases} \tag{3}$$

其中， A_i^k 表示第 i 个前提属性在第 k 条规则中的参考值，通常由专家根据故障特征的变化范围划分若干语义等级(如“低”“中”“高”等)；$0 \le \beta_{n,k} \le 1$ 表示在第 k 条规则下故障类型为 D_n 的置信度，且满足和为 1；$0 \le \theta_k \le 1$ 为规则权重，反映该规则在规则库中的重要程度；$0 \le \delta_i \le 1$ 为属性权重，反映第 i 个前提属性对诊断结果的影响程度。

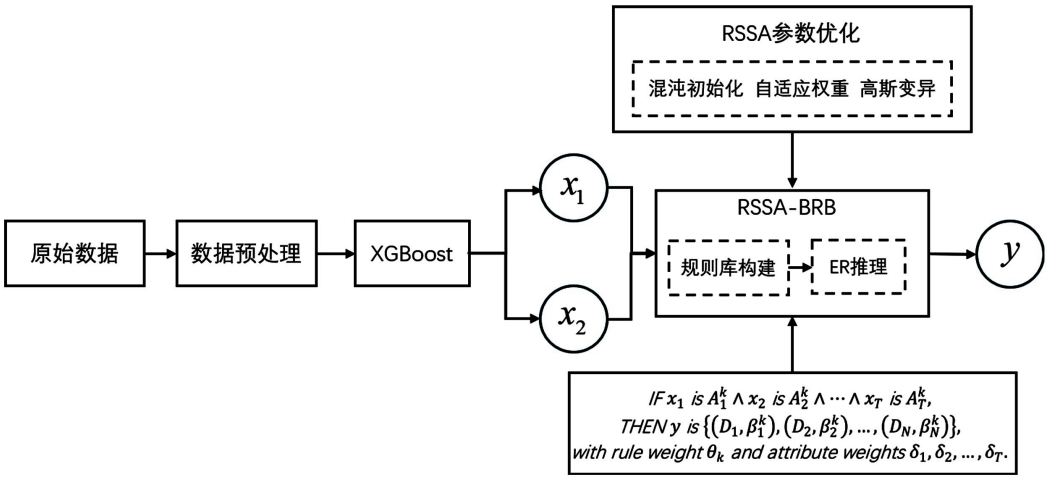


Figure 1. Structure diagram of RSSA-BRB model
图 1. RSSA-BRB 模型结构图

完成 BRB 结构设计后，还需确定规则权重、属性权重和初始置信度。这些参数直接影响模型的初始推理状态，因此需明确设定原则，以保证模型可解释性并减少人为设定的随意性。

首先，对于规则权重 θ_k，考虑到模型初始化阶段尚缺乏充分证据证明某一条规则相较于其他规则具有更高的重要程度，因此本文将所有规则的初始权重统一设置为 1，即：

$$\theta_k = 1, \ k = 1, 2, \cdots, L \tag{4}$$

其中， L 为规则总数。该设置避免参数优化前对部分规则赋予额外偏好，使各规则初始重要程度一致。随后，模型训练阶段，规则权重由 RSSA 基于样本数据自适应优化。

其次，属性权重反映不同输入属性对诊断结果的相对贡献。根据特征重要性评估结果，Current J2 和 Current J1 的重要性分别为 27.8%和 21.6%。为统一属性权重尺度，对两者的重要性进行归一化处理，计算得出 $\delta_1 = 0.563$， $\delta_2 = 0.437$。

该设置使 BRB 初始属性权重与数据驱动得到的特征判别能力相对应，同时保留后续 RSSA 对属性权重进一步优化的空间。最后，初始置信分布用于描述不同前提属性组合下各故障状态的初始倾向。本文未将初始置信度视为精确的经验概率，而是将其作为具有明确物理含义的启发式先验，用于为后续参数优化提供合理的初始搜索位置。结合工业机器人关节电流与运行负载、运动阻力及异常状态之间的关系，对不同输入参考等级下的故障状态进行初始判断。

3.2. RSSA-BRB 模型的推理

RSSA-BRB 模型采用证据推理(ER)算法作为推理引擎，将输入特征转化为置信分布，激活相应规则，并融合被激活规则输出诊断结果。推理过程分为以下四个步骤。

步骤 1：输入特征置信化。对于输入特征 x_i，根据其与参考值 $A_{i,j}$ 的匹配程度，将其转化为置信分布：

$$S(x_i) = \left\{ \left(A_{i,j}, \alpha_{i,j} \right) \mid j = 1, 2, \cdots, J_i \right\}, \quad i = 1, 2, \cdots, T \tag{5}$$

其中，J_i 为第 i 个属性的参考值个数，$a_{i,j}$ 为 x_i 匹配参考值 $A_{i,j}$ 的匹配度。若 x_i 位于相邻参考值 $A_{i,j}$ 与 $A_{i,j+1}$ 之间，则匹配度按线性插值计算：

$$\begin{aligned}&\alpha_{i,j}=\frac{A_{i,j+1}-x_i}{A_{i,j+1}-A_{i,j}}\ \text{and}\ \ \alpha_{i,j+1}=1-\alpha_{i,j},A_{i,j}\le x_i\le A_{i,j+1}\\&\alpha_{i,s}=0,\quad s\ne j,j+1\end{aligned}\tag{6}$$

步骤 2：计算规则激活权重。第 k 条规则的激活权重 w_k 由各前提属性的匹配度与属性权重共同决定：

$$\omega_k=\frac{\theta_k\prod_{i=1}^{T}\left(\alpha_i^k\right)^{\bar{\delta}_i}}{\sum_{l=1}^{L}\theta_l\prod_{i=1}^{T}\left(\alpha_i^l\right)^{\bar{\delta}_i}}\tag{7}$$

其中，$\bar{\delta}_i=\dfrac{\delta_i}{\max_{i=1,\cdots,T}\delta_i}$ 为归一化属性权重，a_i^k 表示第 k 条规则中第 i 个属性与输入匹配的置信度。

步骤 3：证据推理融合。被激活的规则通过 ER 算法进行融合，得到故障类型 D_n 的综合置信度 β_n：

$$\beta_n=\frac{\left[\prod_{k=1}^{L}\left(\omega_k\beta_{n,k}+1-\omega_k\sum_{j=1}^{N}\beta_{j,k}\right)-\prod_{k=1}^{L}\left(1-\omega_k\sum_{j=1}^{N}\beta_{j,k}\right)\right]}{\left[\sum_{n=1}^{N}\prod_{k=1}^{L}\left(\omega_k\beta_{n,k}+1-\omega_k\sum_{j=1}^{N}\beta_{j,k}\right)-(N-1)\prod_{k=1}^{L}\left(1-\omega_k\sum_{j=1}^{N}\beta_{j,k}\right)\right]-\prod_{k=1}^{L}(1-\omega_k)}\tag{8}$$

步骤 4：输出诊断结果。最终输出为故障类型的置信度分布：

$$S(y)=\left\{(D_n,\beta_n)\mid n=1,2,\cdots,N\right\}\tag{9}$$

取置信度最大的故障类型作为诊断结论：

$$y=\arg\max_n\beta_n\tag{10}$$

若需输出数值型结果，可通过效用函数计算期望效用：

$$u\left(S(y)\right)=\sum_{n=1}^{N}u(D_n)\beta_n\tag{11}$$

其中，$U(D_n)$ 为故障类型 D_n 的效用值。

3.3. RSSA-BRB 模型的优化

基础 BRB 的初始参数由专家设定，难以保证诊断精度。为此，本文采用改进麻雀搜索算法(RSSA)对 BRB 的参数进行全局寻优。待优化参数包括规则权重 θ_k、属性权重 δ_i 和置信度 β_n^k，构成参数向量 $\Omega=\left[\theta_1,\cdots,\theta_L,\delta_1,\cdots,\delta_L,\beta_1^1,\cdots,\beta_N^L\right]$。以诊断误差最小化为目标，采用均方误差(MSE)作为适应度函数：

$$\min_{\Omega}\mathrm{MSE}(\Omega)=\frac{1}{M}\sum_{m=1}^{M}\left(y_m-\hat{y}_m\right)^2\tag{12}$$

其中，M 为训练样本数，y_m 为第 m 个样本的真实故障标签(数值化表示)，$\hat{y}_m$ 为模型输出的诊断结果。规则权重、属性权重及置信度均约束在[0, 1]区间，且每条规则的置信度之和为 1。

SSA 算法原理。麻雀搜索算法(SSA)通过模拟麻雀种群的觅食与反捕食行为实现参数寻优，种群主要由发现者、跟随者和警戒者组成。发现者负责探索潜在优良区域，跟随者依据优良个体进行位置更新，警戒者根据风险信息调整搜索位置，三类个体协同完成全局探索与局部开发。其位置更新规则分别表示为：

$$X_{i,j}^{t+1}=\begin{cases}X_{i,j}^{t}\cdot\exp\left(-\dfrac{i}{\alpha T_{\max}}\right), & R_2<ST\\ X_{i,j}^{t}+Q\cdot L, & R_2\geq ST\end{cases} \tag{13}$$

$$X_{i,j}^{t+1}=\begin{cases}Q\cdot\exp\left(\dfrac{X_{worst}^{t}-X_{i,j}^{t}}{i^2}\right), & i>\dfrac{n}{2}\\ X_{best}^{t+1}+\left|X_{i,j}^{t}-X_{best}^{t+1}\right|\cdot A^{+}\cdot L, & i\leq\dfrac{n}{2}\end{cases} \tag{14}$$

$$X_{i,j}^{t+1}=\begin{cases}X_{best}^{t}+\gamma\cdot\left|X_{i,j}^{t}-X_{best}^{t}\right|, & f_i>f_{best}\\ X_{i,j}^{t}+K\cdot\dfrac{\left|X_{i,j}^{t}-X_{worst}^{t}\right|}{f_i-f_{worst}+\varepsilon}, & f_i=f_{best}\end{cases} \tag{15}$$

其中，t 为当前迭代次数，$T_{\max}$ 为最大迭代次数，$R^2\in[0,1]$ 为预警值，$ST\in[0.5,1]$ 为安全阈值，Q 为服从正态分布的随机数，L 为单位向量。其余参数用于控制个体搜索步长与随机扰动。

针对基础 SSA 迭代后期种群多样性下降、易陷入局部最优的不足，本文提出的 RSSA 引入以下改进策略：

(1) 混沌映射初始化种群。采用 Logistic 混沌映射生成初始种群，以提高初始解分布的均匀性和遍历性：

$$z_{k+1}=\mu z_k\left(1-z_k\right),\quad k=0,1,\cdots,n-1 \tag{16}$$

其中，$\mu=4$ 为控制参数，$z_0\in(0,1)$ 为随机初始值，且 $z_0\notin\{0,0.25,0.5,0.75,1\}$。将混沌变量映射到 BRB 参数的取值区间：

$$X_{i,j}^{0}=X_j^{\min}+z_{i,j}\left(X_j^{\max}-X_j^{\min}\right),\quad i=1,2,\cdots,n \tag{17}$$

其中，$X_{\min}$ 和 $X_{\max}$ 分别为参数向量的下界和上界，n 为种群规模。

(2) 自适应权重。在发现者位置更新中引入自适应惯性权重 w，使其随迭代次数非线性递减，从而在前期增强全局探索能力，后期增强局部开发能力：

$$w=w_{\max}-\left(w_{\max}-w_{\min}\right)\left(\frac{t}{T_{\max}}\right)^2 \tag{18}$$

其中，$w_{\max}$ 和 $w_{\min}$ 分别为权重的最大和最小值，通常取 $w_{\max}=0.9$，$w_{\min}=0.4$。则发现者位置更新式(13)修改为：

$$X_{i,j}^{t+1}=\begin{cases}w\cdot X_{i,j}^{t}\cdot\exp\left(-\dfrac{i}{\alpha T_{\max}}\right), & R_2<ST\\ X_{i,j}^{t}+Q\cdot L, & R_2\geq ST\end{cases} \tag{19}$$

(3) 高斯变异。对当前全局最优个体 X_{best}^{t} 施加高斯变异，以增强算法跳出局部最优的能力：

$$X_{best}^{'}=X_{best}^{t}+N\left(0,\sigma_t^2\right) \tag{20}$$

$$\sigma_t=\sigma_0\left(1-\frac{t}{T_{\max}}\right) \tag{21}$$

其中，$N\left(0,\sigma_t^2\right)$ 表示均值为 0、方差为 σ_t^2 的高斯随机数，σ_0 为初始标准差。若变异后的个体适应度优于

原最优个体，则替换原最优个体；否则保留原最优个体。

基于改进麻雀搜索优化置信规则库的机器人故障诊断方法流程如图 2 所示。具体步骤如下，将 BRB 参数向量 Ω 编码为麻雀个体位置，适应度函数取式(12)的 MSE。优化步骤如下。

步骤 1：初始化。设定种群规模 n 、最大迭代次数 $T_{\max}$ 、发现者比例 PD 、警戒者比例 SD 等参数。利用式(16)和式(17)的混沌映射生成 n 个初始个体，每个个体对应一组 BRB 参数。

步骤 2：计算适应度。对每个个体，将其解码为 BRB 参数，利用式(5)~(11)计算诊断结果，并按式(12)计算 MSE，得到适应度值。

步骤 3：更新发现者、跟随者和警戒者位置。按式(19)、式(14)和式(15)更新个体位置，并按式(20)和式(21)对最优个体施加高斯变异。

步骤 4：边界处理与约束满足。对更新后的个体进行边界检查，使规则权重、属性权重和置信度均保持在[0, 1]区间；若某条规则的置信度之和不为 1，则进行归一化处理。

步骤 5：迭代终止判断。若达到最大迭代次数或适应度不再下降，则输出全局最优个体作为最优参数 Ω_{best} ；否则返回步骤 2。

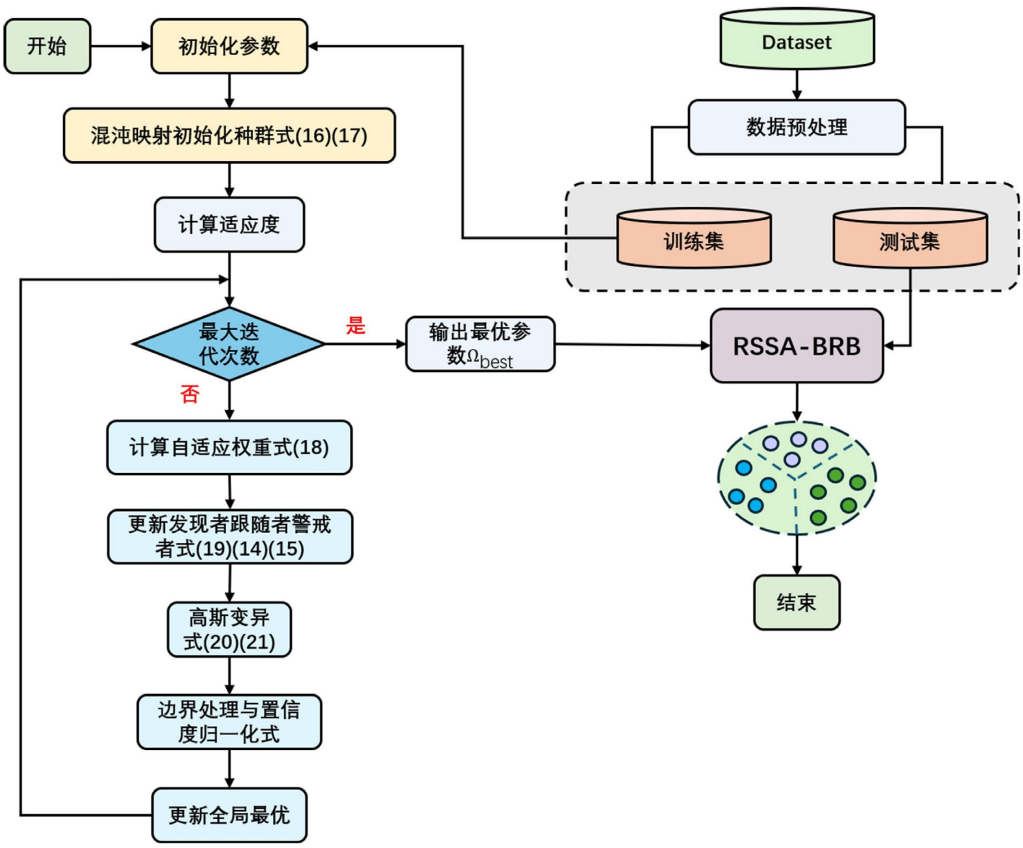


Figure 2. Flowchart of optimization algorithm
图 2. 优化算法流程图

4. 案例研究

4.1. 数据集与实验设置

本研究所使用的实验数据来源于 UCI 机器学习公共数据集——UR3 CobotOps。数据集共包含 7409

个时间步样本和 20 个特征变量，特征类型涵盖实数型、整数型和类别型。该数据集记录了 UR3 协作机器人的多项运行参数，以及系统运行中记录的保护性停止和抓取丢失两种故障事件。各项指标的具体描述如表 1 所示。因此，基于该数据集的工业机器人故障诊断可以描述为一个三分类任务，设故障类别集合为 $D=\{D_1,D_2,D_3\}$，其中 D_1 表示正常状态(Normal)，D_2 表示保护性停止(Protective Stop)，D_3 表示抓取丢失(Grip Loss)。诊断模型的目标是依据当前时刻的关节电流、温度、速度等特征向量，判断系统处于上述三种状态中的哪一种。

Table 1. Description of various indicators
表 1. 各项指标描述

变量名称	描述	单位	类型	值的范围
Current J0 -J5	Joint current	A	Float	[−6.24, 6.80]
Temperature J0 -J5	Joint temperature	℃	Float	[27.81, 45.37]
Speed J0 -J5	Joint speed	°/s	Float	[−1.62, 2.67]
Tool Current	Gripper current	A	Float	[0.02, 0.60]
Cycle	Operation cycles count	-	Integer	{1, 2, 3 … 264}
Protective Stop	Emergency halt status	-	Boolean	{“False”, “True”}
Grip Lost	Actual grip loss status	-	Boolean	{“False”, “True”}

将全部 20 个特征直接作为 BRB 前提属性面临两方面问题。其一，规则数量随属性维度呈指数增长。若每个特征划分 5 个语义参考等级，20 个属性将产生 5^{20} 条规则，引发严重的组合规则爆炸。其二，部分特征之间存在较强相关性，冗余特征不仅增加建模复杂度，还可能干扰诊断结果。因此，本文采用 XGBoost 筛选关键特征。以 20 个原始特征为输入、三分类故障标签为输出，采用 5 折交叉验证训练，并以多分类对数损失为优化目标。训练后根据分裂增益计算特征重要性并进行排序，筛选判别能力较强的属性作为 BRB 输入，排序结果如图 3 所示。

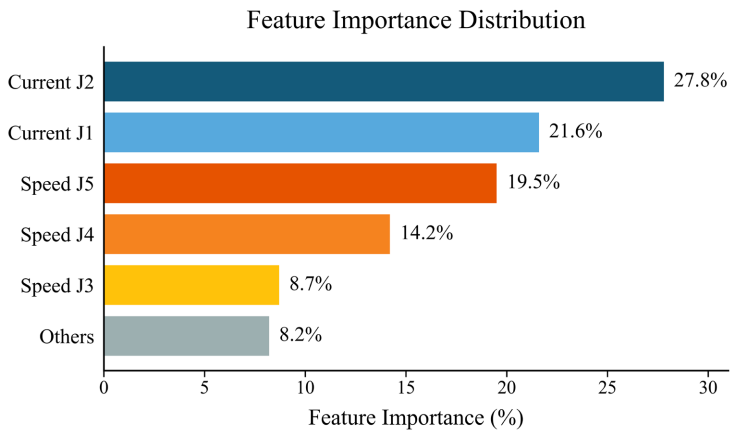


Figure 3. Feature importance ranking
图 3. 特征重要性排序

特征重要性评估后，选取得分最高的两个特征作为 BRB 模型的前提属性。设这两个特征分别为 x_1 和 x_2，后续 RSSA-BRB 诊断模型即以这两个特征作为输入前提属性，故障类别 D_1、D_2、D_3 作为输出标签，输出标签的参考值如表 2 所示。表 3 列出了输入属性的参考值。

Table 2. Utility values of output fault types
表 2. 输出故障类型的效用值

输出	D_1	D_2	D_3
y	0	1	2

Table 3. Reference values for attribute
表 3. 属性参考值

属性	VL	L	M	H	VH
Current J1/Current J2	0	0.25	0.5	0.75	1.00

Table 4. Initial belief rule base parameters
表 4. 初始置信规则库参数

规则编号	属性 1	属性 2	规则权重	属性权重	初始置信分布
1	VL	VL	1.000	(0.563, 0.437)	(0.90, 0.05, 0.05)
2	VL	L	1.000	(0.563, 0.437)	(0.85, 0.08, 0.07)
3	VL	M	1.000	(0.563, 0.437)	(0.75, 0.15, 0.10)
4	VL	H	1.000	(0.563, 0.437)	(0.60, 0.25, 0.15)
5	VL	VH	1.000	(0.563, 0.437)	(0.45, 0.35, 0.20)
6	L	VL	1.000	(0.563, 0.437)	(0.85, 0.10, 0.05)
7	L	L	1.000	(0.563, 0.437)	(0.80, 0.12, 0.08)
8	L	M	1.000	(0.563, 0.437)	(0.65, 0.22, 0.13)
9	L	H	1.000	(0.563, 0.437)	(0.50, 0.32, 0.18)
10	L	VH	1.000	(0.563, 0.437)	(0.35, 0.45, 0.20)
11	M	VL	1.000	(0.563, 0.437)	(0.75, 0.15, 0.10)
12	M	L	1.000	(0.563, 0.437)	(0.65, 0.20, 0.15)
13	M	M	1.000	(0.563, 0.437)	(0.50, 0.30, 0.20)
14	M	H	1.000	(0.563, 0.437)	(0.35, 0.42, 0.23)
15	M	VH	1.000	(0.563, 0.437)	(0.25, 0.55, 0.20)
16	H	VL	1.000	(0.563, 0.437)	(0.60, 0.22, 0.18)
17	H	L	1.000	(0.563, 0.437)	(0.48, 0.30, 0.22)
18	H	M	1.000	(0.563, 0.437)	(0.35, 0.40, 0.25)
19	H	H	1.000	(0.563, 0.437)	(0.20, 0.55, 0.25)
20	H	VH	1.000	(0.563, 0.437)	(0.15, 0.65, 0.20)
21	VH	VL	1.000	(0.563, 0.437)	(0.45, 0.30, 0.25)
22	VH	L	1.000	(0.563, 0.437)	(0.35, 0.38, 0.27)
23	VH	M	1.000	(0.563, 0.437)	(0.25, 0.48, 0.27)
24	VH	H	1.000	(0.563, 0.437)	(0.15, 0.60, 0.25)
25	VH	VH	1.000	(0.563, 0.437)	(0.10, 0.70, 0.20)

经 XGBoost 特征重要性评估后，本文选取得分最高的两个特征 Current J2 和 Current J1 作为 BRB 模型的前提属性，分别记为属性 1 和属性 2。为消除量纲和取值范围差异，采用 Min-Max 归一化方法将两个属性映射至[0, 1]区间。在此基础上，结合 BRB 模型的参考值设定方式，划分为 5 个语言参考等级，见表 3。由此形成 25 条初始置信规则，见表 4，在保留关键故障判别信息的同时，有效控制了规则库规模。参考等级数量决定了 BRB 对输入空间的划分粒度。考虑到参考等级数量会影响输入空间划分粒度，本文进一步设置 3、5 和 7 个参考等级，对其诊断性能和模型复杂度进行比较，结果将在下一节分析。

4.2. 参考等级数量敏感性分析

为分析输入属性离散化粒度对 RSSA-BRB 诊断性能的影响，并验证本文采用 5 个语义参考等级的合理性，在保持所有一致的条件下，分别设置 3、5 和 7 个参考等级进行对比实验。由于本文 BRB 包含两个前提属性，当每个属性划分为 r 个参考等级时，完整规则库的规则数量为 r^2，因此 3、5 和 7 个参考等级分别对应 9、25 和 49 条规则。3 个参考等级的参数分别设置为{0, 0.5, 1}、{0, 0.25, 0.50, 0.75, 1}、{0, 0.167, 0.333, 0.500, 0.667, 0.833, 1}。在此基础上，对不同参考等级下模型的准确率、召回率、F1、MSE 以及计算时间进行比较。实验结果如表 5 所示。

Table 5. Comparison of RSSA-BRB performance under different numbers of reference levels
表 5. 不同参考等级数量下 RSSA-BRB 性能比较

参考等级数	规则数量	准确率/%	召回率/%	F1/%	均方误差	平均运行时间/s
3	9	89.4	89.2	89.5	0.083	124
5	25	92.2	91.6	92.9	0.065	155
7	49	92.1	91.3	91.9	0.071	163

由表 5 可知，参考等级数量显著影响 RSSA-BRB 的诊断性能与模型复杂度。当设置 3 个参考等级时，仅形成 9 条规则，模型结构较紧凑，但输入空间划分较粗，准确率、召回率和 F1 相对较低。增加至 5 个参考等级后，规则数增至 25 条，能够更细致地描述 Current J2、Current J1 与故障状态之间的非线性关系，诊断性能明显提升，同时规则规模仍较合理。当参考等级增至 7 个时，规则数增至 49 条，待优化参数和搜索维度同步增加，运行时间上升，而性能提升有限。综合诊断精度、规则规模与计算效率，5 个参考等级在模型表达能力和复杂度之间取得较好平衡，因此本文最终采用五个语义参考等级构建模型。

4.3. 初始模型与优化后模型的比较分析

为验证 RSSA 对 BRB 参数的优化效果，本节将初始专家 BRB、基础麻雀搜索算法优化 BRB (BRB-SSA)和本文改进麻雀搜索算法优化 BRB (BRB-RSSA)进行对比。优化后的 BRB 参数如表 6 所示，表中列出了规则权重、两个前提属性的权重以及各规则的置信分布。经过 RSSA 优化后，规则权重不再均匀分布，而是根据样本自适应调整。属性权重也由专家初始设定变为数据驱动优化，置信分布更加集中，且与故障类别的一致性更高。这说明优化过程有效融合了专家知识与样本信息，规则权重、属性权重和置信分布均被算法进行了优化。可以看出，不同规则对诊断结果的贡献存在差异。置信分布随前提属性参考值的变化呈现明显规律性，正常状态在低参考值区域置信度高，故障状态在高参考值区域置信度高，符合工业机器人运行机理。

为验证本文方法的有效性，将初始 BRB、BRB-SSA 和 BRB-RSSA 在相同训练集与测试集上进行比较，结果见表 7。初始 BRB 的准确率、召回率和 F1 分别为 86.5%、84.2%和 85.3%，MSE 为 0.094，表明仅依赖专家知识时诊断性能有限。经 SSA 优化后，BRB-SSA 的准确率、召回率和 F1 提升至 91.8%、

90.5%和 91.1%，MSE 降至 0.071 说明样本驱动优化能够改善模型性能。BRB-RSSA 进一步达到 92.2%、91.6%和 92.9%，MSE 降至 0.065，整体优于前两种模型，表明混沌初始化、自适应惯性权重和高斯变异能够提升 BRB 参数寻优效果。进一步进行 10 次独立运行，结果如图 4 所示。三种模型整体波动较小，其中 BRB-RSSA 始终保持最高准确率且稳定性较好。综上，RSSA 能够有效改善基础 SSA 的参数优化能力，提升 BRB 的诊断精度与稳定性，验证了 RSSA-BRB 在工业机器人故障诊断中的有效性。

Table 6. Optimized parameters of the belief rule base
表 6. 优化后的置信规则库参数

规则编号	属性 1	属性 2	优化后规则权重	优化后属性权重	优化后置信分布
1	VL	VL	0.942	(0.614, 0.386)	(0.963, 0.021, 0.016)
2	VL	L	0.918	(0.614, 0.386)	(0.927, 0.046, 0.027)
3	VL	M	0.873	(0.614, 0.386)	(0.806, 0.132, 0.062)
4	VL	H	0.814	(0.614, 0.386)	(0.612, 0.294, 0.094)
5	VL	VH	0.768	(0.614, 0.386)	(0.438, 0.454, 0.108)
6	L	VL	0.931	(0.614, 0.386)	(0.921, 0.049, 0.030)
7	L	L	0.904	(0.614, 0.386)	(0.878, 0.078, 0.044)
8	L	M	0.866	(0.614, 0.386)	(0.701, 0.214, 0.085)
9	L	H	0.841	(0.614, 0.386)	(0.482, 0.397, 0.121)
10	L	VH	0.807	(0.614, 0.386)	(0.286, 0.581, 0.133)
11	M	VL	0.887	(0.614, 0.386)	(0.793, 0.083, 0.124)
12	M	L	0.872	(0.614, 0.386)	(0.651, 0.171, 0.178)
13	M	M	0.858	(0.614, 0.386)	(0.442, 0.316, 0.242)
14	M	H	0.895	(0.614, 0.386)	(0.247, 0.536, 0.217)
15	M	VH	0.926	(0.614, 0.386)	(0.142, 0.709, 0.149)
16	H	VL	0.904	(0.614, 0.386)	(0.522, 0.126, 0.352)
17	H	L	0.917	(0.614, 0.386)	(0.397, 0.188, 0.415)
18	H	M	0.936	(0.614, 0.386)	(0.236, 0.316, 0.448)
19	H	H	0.953	(0.614, 0.386)	(0.128, 0.594, 0.278)
20	H	VH	0.969	(0.614, 0.386)	(0.064, 0.797, 0.139)
21	VH	VL	0.934	(0.614, 0.386)	(0.318, 0.101, 0.581)
22	VH	L	0.947	(0.614, 0.386)	(0.221, 0.167, 0.612)
23	VH	M	0.961	(0.614, 0.386)	(0.134, 0.283, 0.583)
24	VH	H	0.978	(0.614, 0.386)	(0.071, 0.651, 0.278)
25	VH	VH	0.991	(0.614, 0.386)	(0.038, 0.846, 0.116)

Table 7. Comparison of diagnostic results between the initial model and the optimized model
表 7. 初始模型与优化后的模型的诊断结果对比

模型	准确率/%	召回率/%	F1/%	均方误差
初始 BRB	86.5	84.2	85.3	0.094
BRB-SSA	91.8	90.5	91.1	0.071
BRB-RSSA	92.2	91.6	92.9	0.065

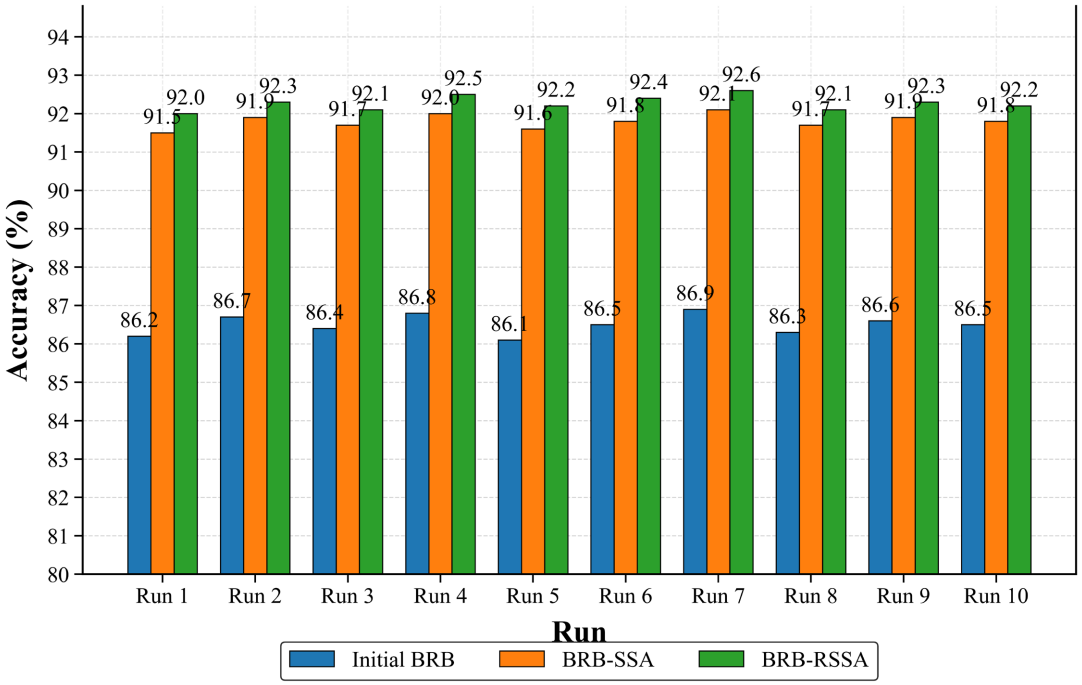


Figure 4. Comparison of accuracy rates of 10 independent runs of three BRB models
图 4. 3 种 BRB 模型 10 次独立运行准确率对比

4.4. 与优秀的优化算法比较分析

为验证 RSSA 在 BRB 参数寻优中的性能，选取麻雀搜索算法(SSA)、投影协方差矩阵自适应进化策略(P-CMA-ES)、粒子群优化(PSO)、鲸鱼优化(WOA)等代表性算法，并进一步引入 2025 年提出的多策略融合麻雀搜索算法(MISSA)作为 RSSA 的对比基准。MISSA 针对基础 SSA 搜索精度不足和易陷入局部最优等问题，引入改进搜索策略、群体跟随策略以及随机反向学习策略，以增强搜索能力、局部最优逃逸能力和种群多样性。在相同 BRB 结构、相同训练集与测试集、相同适应度函数下进行对比，种群规模设定为 60，迭代次数为 500。独立运行 10 次取平均值。结果如表 8 所示。各优化算法的精度收敛性比较如图 5 所示。

Table 8. Comparison of diagnostic performance of BRB optimized by different optimization algorithms
表 8. 不同优化算法优化 BRB 的诊断性能对比

优化算法	准确率/%	召回率/%	F1/%	均方误差	迭代次数
SSA-BRB	91.8	90.5	91.1	0.071	312
P-CMA-ES-BRB	90.1	89.4	90.7	0.072	246
PSO-BRB	90.4	89.3	89.8	0.086	358
WOA-BRB	89.7	88.6	89.1	0.091	402
MISSA-BRB	90.6	91.2	90.6	0.077	239
RSSA-BRB	92.2	91.6	92.9	0.065	148

由表 8 可知，RSSA-BRB 的准确率、召回率和 F1 分别达到 92.2%、91.6%和 92.9%，MSE 降至 0.065，整体优于 SSA-BRB、P-CMA-ES-BRB、PSO-BRB、WOA-BRB 和 MISSA-BRB。MISSA-BRB 较基础 SSA-

BRB 性能有所提升，说明多策略融合能够改善 SSA 搜索能力；RSSA-BRB 在准确率、F1 和 MSE 上进一步取得更优结果，表明混沌初始化、自适应惯性权重和高斯变异能够提高 BRB 参数寻优精度。由图 5 可知，RSSA 约在 148 代收敛，快于 MISSA 的 239 代、P-CMA-ES 的 246 代、SSA 的 312 代、PSO 的 358 代和 WOA 的 402 代。综上，RSSA-BRB 在诊断精度和收敛效率方面表现最佳，说明三种改进策略能够增强全局探索与局部开发能力，并提高跳出局部最优的能力，从而提升 BRB 参数优化效果。

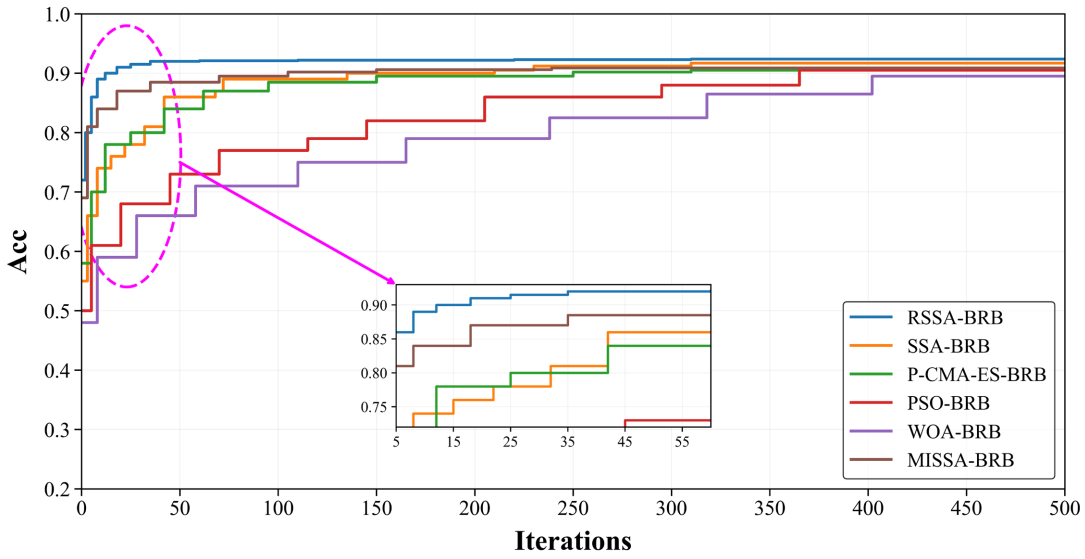


Figure 5. Comparison of accuracy convergence of optimization algorithms
图 5. 优化算法的精度收敛性比较

4.5. 消融实验

为验证三种改进策略对 SSA 性能的贡献，本文设计消融实验进行对比。三种策略分别为 Logistic 混沌初始化(CI)、自适应惯性权重(AW)和高斯变异(GM)。将三种策略分别加入基础 SSA，并与三者联合的 RSSA 进行比较。实验采用相同的 BRB 结构、相同训练集与测试集、相同适应度函数，种群规模 60，最大迭代次数 500，独立运行 10 次取平均值，实验结果如表 9 所示。图 6 为各策略的精度收敛性的比较。

由表 9 可知，单独引入任一改进策略并不能提升基础 SSA 的优化性能。其中策略 2 的影响最小，策略 3 次之，策略 1 相对较低。但是，三策略共同作用时，RSSA 在准确率、召回率、F1 和 MSE 上均取得最优值，与表现最好的单策略 SSA + 策略 2 相比，RSSA 准确率有提高，收敛明显加快。这说明混沌初始化、自适应权重和高斯变异并非简单叠加，而是相互协同。三者结合显著提升了寻优精度和收敛速度。

Table 9. Comparison results of ablation experiments
表 9. 消融实验对比结果

模型	改进策略	准确率/%	召回率/%	F1/%	均方误差	迭代次数
SSA-BRB	无	91.8	90.5	91.1	0.071	312
SSA + CI-BRB	Logistic 混沌初始化	87.2	88.8	89.5	0.080	276
SSA + AW-BRB	自适应惯性权重	90.4	91.3	92.0	0.075	208
SSA + GM-BRB	高斯变异	90.3	91.2	91.9	0.079	226
RSSA-BRB	CI + AW + GM	92.2	91.6	92.9	0.065	148

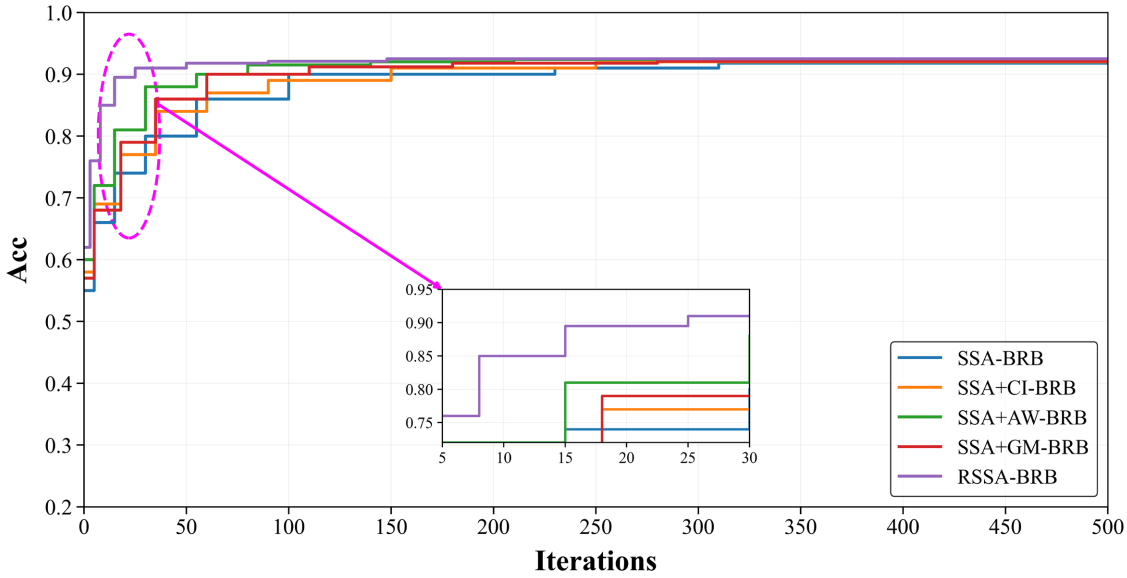


Figure 6. Comparison of accuracy convergence of various strategies
图 6. 各策略的精度收敛性比较

4.6. 与其他故障诊断方法的比较分析

为了验证所提 RSSA-BRB 模型的有效性，将其与多种主流分类方法进行对比，分别是 BPNN、KNN、SVM、ELM。为了从多个角度来评估模型的性能，采用了准确率、精确率、召回率以及 F1 分数来衡量模型的性能。为进一步比较不同模型的运行稳定性，对 RSSA-BRB、SVM、BPNN、KNN 和 ELM 进行 10 次独立运行取平均值，实验结果如表 10 所示。

Table 10. Experimental results of other models
表 10. 其他模型的实验结果

模型名称	准确率/%	精确率/%	召回率/%	F1/%
RSSA-BRB	92.23	92.95	92.91	92.93
BPNN	91.94	91.56	90.42	90.99
KNN	90.06	90.07	90.93	90.50
SVM	92.03	93.02	92.66	92.64
ELM	89.90	89.03	89.89	89.46

表 10 给出了 RSSA-BRB 与 BPNN、KNN、SVM 和 ELM 的对比结果。整体来看，ELM 各项指标最低，表明其在该故障诊断任务中的分类能力较弱；KNN 各指标相对均衡，但整体性能偏低。BPNN 整体性能优于 KNN 和 ELM，但各项指标仍低于 RSSA-BRB 和 SVM。SVM 是除 RSSA-BRB 外综合性能较好的方法，其精确率略高于 RSSA-BRB，表明其在降低误报方面具有一定优势。相比之下，RSSA-BRB 在准确率、召回率和 F1 上均高于 SVM，能够在保持较低误报水平的同时提高故障样本识别能力，综合诊断性能更优。其原因在于 RSSA-BRB 利用置信规则库融合专家知识与样本数据，并通过改进麻雀搜索算法对规则权重、属性权重和置信度进行全局优化，提高了模型的参数寻优能力。综上，RSSA-BRB 在多种对比方法中表现出较好的综合诊断性能，验证了所提方法在工业机器人故障诊断中的有效性。

5. 结论

本文提出了一种基于改进麻雀搜索算法优化置信规则库的工业机器人故障诊断方法(RSSA-BRB)。该方法以置信规则库为诊断知识载体，利用证据推理实现不确定性信息融合，并采用改进麻雀搜索算法对BRB 的规则权重、属性权重及置信度进行全局寻优。为降低规则库规模，本文采用 XGBoost 对 UR3 协作机器人数据集的 20 个原始特征进行重要性评估，筛选出得分最高的两个特征作为前提属性，将规则数量降至 25 条，有效缓解了组合规则爆炸问题。在优化过程中，针对基础麻雀搜索算法易陷入局部最优的不足，引入 Logistic 混沌映射初始化种群、自适应惯性权重和高斯变异策略，提升了算法的全局搜索能力与收敛速度。实验结果表明，RSSA-BRB 模型能够有效融合专家知识与观测数据，在保证诊断准确率的同时，保留了 BRB 模型推理过程透明的优势。与基础 BRB 及典型优化方法相比，RSSA-BRB 在诊断精度和收敛性能上均表现出一定优势，验证了所提方法在工业机器人故障诊断中的可行性与有效性。

基金项目

哈尔滨师范大学博士科研启动基金项目(XKB201901)资助。

参考文献

[1] 赵杰. 我国工业机器人发展现状与面临的挑战[J]. 航空制造技术, 2012, 55(12): 26-29.

[2] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.

[3] 刘亚军, 訾斌, 王正雨, 等. 智能喷涂机器人关键技术研究现状及进展[J]. 机械工程学报, 2022, 58(7): 53-74.

[4] Sabry, A.H. and Ungku Amirulddin, U.A.B. (2024) A Review on Fault Detection and Diagnosis of Industrial Robots and Multi-Axis Machines. *Results in Engineering*, **23**, Article 102397. https://doi.org/10.1016/j.rineng.2024.102397

[5] Raouf, I., Kumar, P. and Soo Kim, H. (2024) Deep Learning-Based Fault Diagnosis of Servo Motor Bearing Using the Attention-Guided Feature Aggregation Network. *Expert Systems with Applications*, **258**, Article 125137. https://doi.org/10.1016/j.eswa.2024.125137

[6] Vu, M., Nguyen, V., Tran, T., Pham, V. and Lo, M. (2024) Few-Shot Bearing Fault Diagnosis via Ensembling Transformer-Based Model with Mahalanobis Distance Metric Learning from Multiscale Features. *IEEE Transactions on Instrumentation and Measurement*, **73**, 1-18. https://doi.org/10.1109/tim.2024.3381270

[7] Yang, B., Huang, Y., Jiao, J., Xu, W., Liu, L., Xie, K., *et al*. (2024) Multidomain Neural Process Model Based on Source Attention for Industrial Robot Anomaly Detection. *Advanced Engineering Informatics*, **62**, Article 102910. https://doi.org/10.1016/j.aei.2024.102910

[8] Chen, C., Wang, T., Liu, C., Liu, Y. and Cheng, L. (2023) Lightweight Convolutional Transformers Enhanced Meta-Learning for Compound Fault Diagnosis of Industrial Robot. *IEEE Transactions on Instrumentation and Measurement*, **72**, 1-12. https://doi.org/10.1109/tim.2023.3277956

[9] Chen, Y., Yang, J., Xu, D. and Yang, S. (2013) On the Inference and Approximation Properties of Belief Rule Based Systems. *Information Sciences*, **234**, 121-135. https://doi.org/10.1016/j.ins.2013.01.022

[10] Yang, J.B., Liu, J., Wang, J., *et al*. (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

[11] Li, J., Yang, F., He, W., *et al*. (2025) An Online Ultrasonic Flowmeter Fault Diagnosis Method Based on an Extended Belief Rule Base. *KSII Transactions on Internet & Information Systems*, **19**, 123-148.

[12] Zhao, B., Kong, L., He, W., Zhou, G. and Zhu, H. (2025) A Fault Diagnosis Method for Manufacturing System Based on Adaptive BRB Considering Environmental Disturbance. *International Journal of Fuzzy Systems*, **27**, 1038-1051. https://doi.org/10.1007/s40815-024-01799-9

[13] Wan, H., Liu, M., Zhu, H., Ma, N. and He, W. (2024) An Interpretable Bearing Fault Diagnosis Method Based on Belief Rule Base with Interval Structured. *IEEE Access*, **12**, 116939-116955. https://doi.org/10.1109/access.2024.3435057

[14] Gao, Z., He, M., Zhang, X., Hu, G., He, W. and Chen, S. (2024) Fault Diagnosis of High-Speed Train Motors Based on a Multidimensional Belief Rule Base. *IEEE Access*, **12**, 122544-122556. https://doi.org/10.1109/access.2024.3452641

[15] Mai, J., Luo, Z., Ge, G., Zhang, G. and He, W. (2024) A Fault Diagnosis Method for Autonomous Underwater Vehicles

Based on Online Extended Belief Rule Base with Dynamic Rule Reduction. *IEEE Access*, **12**, 165407-165424. https://doi.org/10.1109/access.2024.3487841

[16] Zhou, Z., Cao, Y., Hu, G., Zhang, Y., Tang, S. and Chen, Y. (2021) New Health-State Assessment Model Based on Belief Rule Base with Interpretability. *Science China Information Sciences*, **64**, Article 172214. https://doi.org/10.1007/s11432-020-3001-7

[17] Feng, Z., Zhou, Z., Hu, C., Chang, L., Hu, G. and Zhao, F. (2018) A New Belief Rule Base Model with Attribute Reliability. *IEEE Transactions on Fuzzy Systems*, **27**, 903-916. https://doi.org/10.1109/tfuzz.2018.2878196

[18] Si, X.S., Hu, C.H., Yang, J.B., *et al*. (2011) A New Prediction Model Based on Belief Rule Base for System's Behavior Prediction. *IEEE Transactions on Fuzzy Systems*, **19**, 636-651. https://doi.org/10.1109/tfuzz.2011.2130527

[19] Jiao, L., Zhang, H., Geng, X. and Pan, Q. (2024) Belief Rule Learning and Reasoning for Classification Based on Fuzzy Belief Decision Tree. *International Journal of Approximate Reasoning*, **175**, Article 109300. https://doi.org/10.1016/j.ijar.2024.109300

[20] Xue, J. and Shen, B. (2020) A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm. *Systems Science & Control Engineering*, **8**, 22-34. https://doi.org/10.1080/21642583.2019.1708830

[21] Ren, J., Wei, H., Yuan, Y., Li, X., Luo, F. and Wu, Z. (2022) Boosting Sparrow Search Algorithm for Multi-Strategy-Assist Engineering Optimization Problems. *AIP Advances*, **12**, Article 095201. https://doi.org/10.1063/5.0108340

[22] Xu, K., Chen, Y., Zhang, X., Ge, Y., Zhang, X., Li, L., *et al*. (2024) Improved Sparrow Search Algorithm Based on Multistrategy Collaborative Optimization Performance and Path Planning Applications. *Processes*, **12**, Article 2775. https://doi.org/10.3390/pr12122775

[23] Wang, Z., Peng, Q., Rao, W. and Li, D. (2025) An Improved Sparrow Search Algorithm with Multi-Strategy Integration. *Scientific Reports*, **15**, Article No. 3314. https://doi.org/10.1038/s41598-025-86298-z