arXiv:2601.00335v1 [cs.LG] 1 Jan 2026

纳卫星电力系统智能故障检测

Alireza Rezaee德黑兰大学智能系统学院跨学科科学与技术学院机电工程系，伊朗德黑兰
arrezaee@ut.ac.ir

Niloofar Nobahari德黑兰大学智能系统学院跨学科科学与技术学院机电工程系，伊朗德黑兰
nobahari.niloofar@ut.ac.ir

Amin Asgarifar德黑兰大学新科学与技术学院，伊朗德黑兰

Farshid Hajati新英格兰大学科学、农业、商业与法律学院科学与技术学院，阿米代尔，新南威尔士州 2350，澳大利亚
fhajati@une.edu.au

2026年1月5日

摘要

本文提出了一种针对低地球轨道上未配备姿态确定与控制子系统（ADCS）的纳卫星电力故障的新型检测方法。由于耐压能力、运载火箭压力和环境条件等因素，该系统的各个部分都面临故障风险。常见故障包括光伏子系统的线间故障和开路、直流-直流变换器中绝缘栅双极型晶体管（IGBT）的短路和开路，以及地面电池的稳压器故障。本文利用太阳辐射和太阳能电池板表面温度作为输入数据、电流和负载作为输出，基于神经网络对无故障系统进行仿真。最后，利用神经网络分类器，根据故障模式和类型对不同故障进行诊断。故障分类还采用了其他机器学习方法，例如主成分分析分类、决策树和K近邻（KNN）。

关键词： 故障诊断、机器学习、纳卫星、电力系统

1 引言

纳卫星根据其任务配备多个子系统。电力子系统负责产生、管理和分配电力。电力子系统对所有卫星都至关重要。根据任务类型和要求，该子系统包含用于转换太阳能并产生电力的光伏太阳能阵列、用于功率优化和调节的直流-直流最大功率点跟踪器（最大功率点跟踪）变换器和稳压器。直流充电管理子系统、负载和开关机构则针对特定用途进行设计和配置 [1]。

光伏太阳能阵列产生的电力以及整个系统的性能会受到轨道条件和卫星环境的影响，例如轨道高度、倾角、辐射强度、热通量或轨道温度下的辐射，因此需要对这些因素进行分析 [2]。当整个系统及其组件正常工作时，卫星便能够执行任务。然而，运载火箭产生的冲击和压力可能导致多种故障。如果未能及时检测到这些故障，就可能造成整个系统或任务失败。

1.1 相关工作

除卫星电源系统外，电力、生物医学和电信领域中有关模式识别、控制和应用机器学习的研究，也为我们的方法提供了额外的方法论依据和研究动机 [22–59]。已有研究针对卫星电源分系统中的电气设备故障开展了检测、分类和诊断。Zhao 等人 [3] 提出了一种基于图的半监督学习（GBSL）的光伏太阳能阵列故障检测方法。通过 GBSL，他们检测出了过电流保护装置（OCPD）无法发现的故障。Zhao 等人 [4] 使用决策树检测并诊断光伏太阳能系统的故障。Mohamed 等人 [5] 还利用神经网络和遗传算法检测光伏太阳能系统的故障。在 [6], 提出的一种变换器中，有一种无需额外硬件即可检测故障（包括功率开关开路故障）的方法，并且使用了 PWM 变换器中正确的控制回路。

在航空航天项目中，锂离子电池因能量密度高而得到应用 [7]，并采用卡尔曼序贯自适应滤波器等方法进行故障诊断与识别，以监测电池的充放电状态、充放电速率，并估算荷电状态（SOC）和健康状态（RUH）；同时利用支持向量机并收集与之相连的负载信息 [8, 9]。

上述研究未考虑整个卫星电力系统的故障诊断。只有两项研究探讨了卫星电力子系统的故障诊断。第一项研究基于PCA方法，讨论了传感器发生电压、电流和温度故障时的故障诊断与容错。该论文仅关注电力系统传感器的累积故障 [10]。在 [11], 中，卫星电力系统中各类故障的概率由科学家的知识通过贝叶斯网络来确定；若要在不依赖科学家知识的情况下采用贝叶斯分类，则必须确定故障概率，或通过高斯方程进行估算 [12]。

本文对整个电力系统的故障进行诊断和排除，包括光伏部分、直流-直流变换器和电池。本文采用一种检测方法来区分故障。

2 材料与方法

卫星电力系统由模拟和数字电路组成，其中包括晶体管、晶闸管、二极管、放大器、逻辑元件、开关和连接件。这些部件按照特定的可靠性标准制造。组件的故障率（λ）定义为

$$\lambda = \frac{N_{\text{faulty}}}{N_{\text{total}} \times t}$$

其中， t 是运行时间小时单位（h）， N_{faulty} 是故障元件数量， N_{total} 是元件总数。该故障率取决于温度和运行模式。表1列出了各种组件的故障率。

表1：各种组件在温度 40 ℃ 下的故障率 [13, 14]。

设备	λ (10^{-9}/h)
晶体管	10–9
Trustor（功率开关系列）	10–9
数字集成电路	30
逻辑元件	30
模拟开关	2000
放大器	10–9
二极管	10–9
锂离子电池	10–9
太阳能阵列	10–9

利用故障率，我们可以诊断电力系统组件（如绝缘栅双极型晶体管、最大功率点跟踪变换器、调节器、太阳能阵列和电池）的故障。在纳米卫星电源系统中，太阳能阵列可能发生开路故障和线间故障，绝缘栅双极型晶体管、最大功率点跟踪变换器和调节器可能发生短路故障和开路故障，电池则可能发生接地故障。

图1展示了所提出的故障诊断模型的总体框图。首先，必须通过虚拟神经网络对系统进行辨识，以检测和分类不同系统中的故障。下一步，将可能的故障有意地以虚拟方式施加到系统中，然后像正常状态下一样对故障系统进行诊断。随后，针对每种故障创建一个如图1所示的模型，并将其与系统输出和模型输出进行比较。

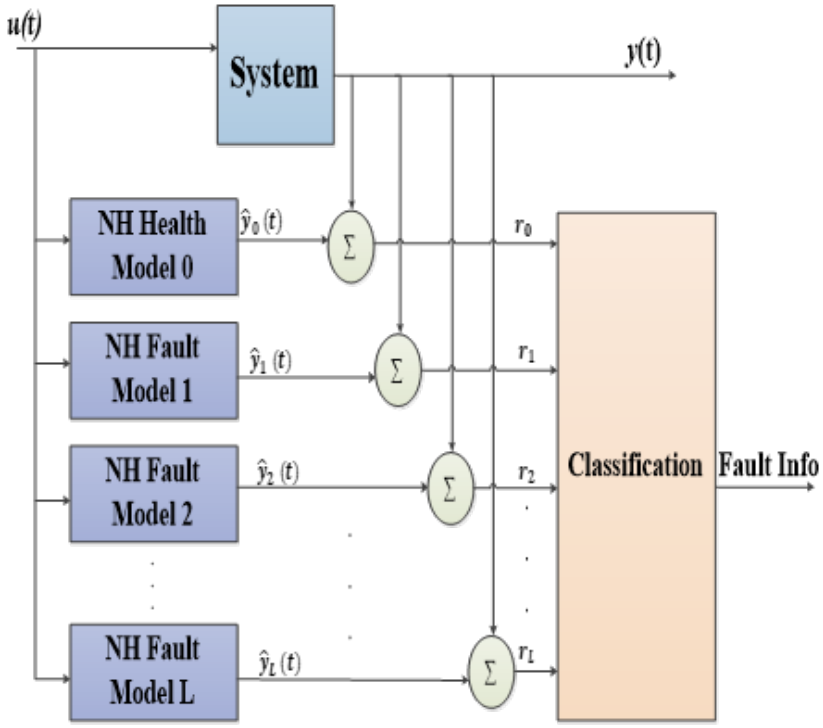


图1：所提出的故障诊断模型。

根据公式（1）创建残差，然后对故障进行分类：

$$r_i = y(t) - \hat{y}_i(t)\,, \tag{1}$$

其中，根据图1，将系统输出 $y(t)$ 与无故障系统的模型输出 $\hat{}y_0(t)$ 以及从 $\hat{}y_1(t)$ 到 $\hat{}y_n(t)$ 的故障模型输出进行对比；根据关系式（1）生成剩余量（r_0 至 r_n），并通过神经网络进行模式识别分类。

依次进行如下操作：首先，利用无故障神经网络对电力系统进行仿真，该网络是系统辨识中的一种强大工具 [15], ；然后将可能的故障注入系统，并对其进行仿真，得到相应图形。

2.1 电力系统建模

卫星的电力系统由太阳能阵列提供，该阵列将太阳辐射功率转换为电能。太阳能阵列的太阳辐射功率受环境条件影响。由于阵列功能和电力系统均受太阳辐射强度及太阳能电池表面温度的影响 [14]，太阳能阵列温度取决于太阳辐射强度、热通量等环境条件，其中热通量包括太阳热通量、反照率热通量和地球亚辐射通量。太阳能电池阵列输出电流直接取决于太阳辐射强度。因此，在 MATLAB 软件中对电力系统进行仿真后，将直接影响发电和卫星电力系统的两个参数——太阳辐射功率和太阳能阵列温度——作为系统输入。

纳卫星的空间、体积和质量有限，无法安装传感器；此外，为了降低项目和卫星发射的成本，在电力系统建模中，输出负载电流被视为输出，系统则根据

静态非线性特性基于方程（3）。

$$I_{\text{load}} = f(P_{\text{sun}}, T), \tag{2}$$

其中， I_{load} 为负载输出电流（A）， P_{sun} 为太阳辐射功率（例如 W/m²）， T 为太阳能阵列温度（摄氏度）。电力系统由各类元素和组件构成。对每个子系统建模并在这些模型之间建立连接十分复杂且耗时。因此，在对整个系统建模时，可以将这些部分视为一个整体，考察其输入和输出，并通过虚拟神经网络识别黑箱。

为了通过树层虚拟神经网络识别系统，基于公式（4），采用马夸特算法 [18], 对随机数据进行分类，并使用基本激活函数和双曲正切 sigmoid 函数计算故障方差的均方值。

$$E = \frac{1}{n}\sum_{k=1}^{n}(y_k - \hat{y}_k)^2, \tag{3}$$

在公式（4）中， y_k 为系统输出，$\hat{}y_k$ 为模型输出， n 为数据数量。此外，为了准确分析神经网络，使用网络输出相干尺度和系统输出，并根据故障图直方图研究其统计行为（平均值和故障方差）。

建模结果如图2所示。

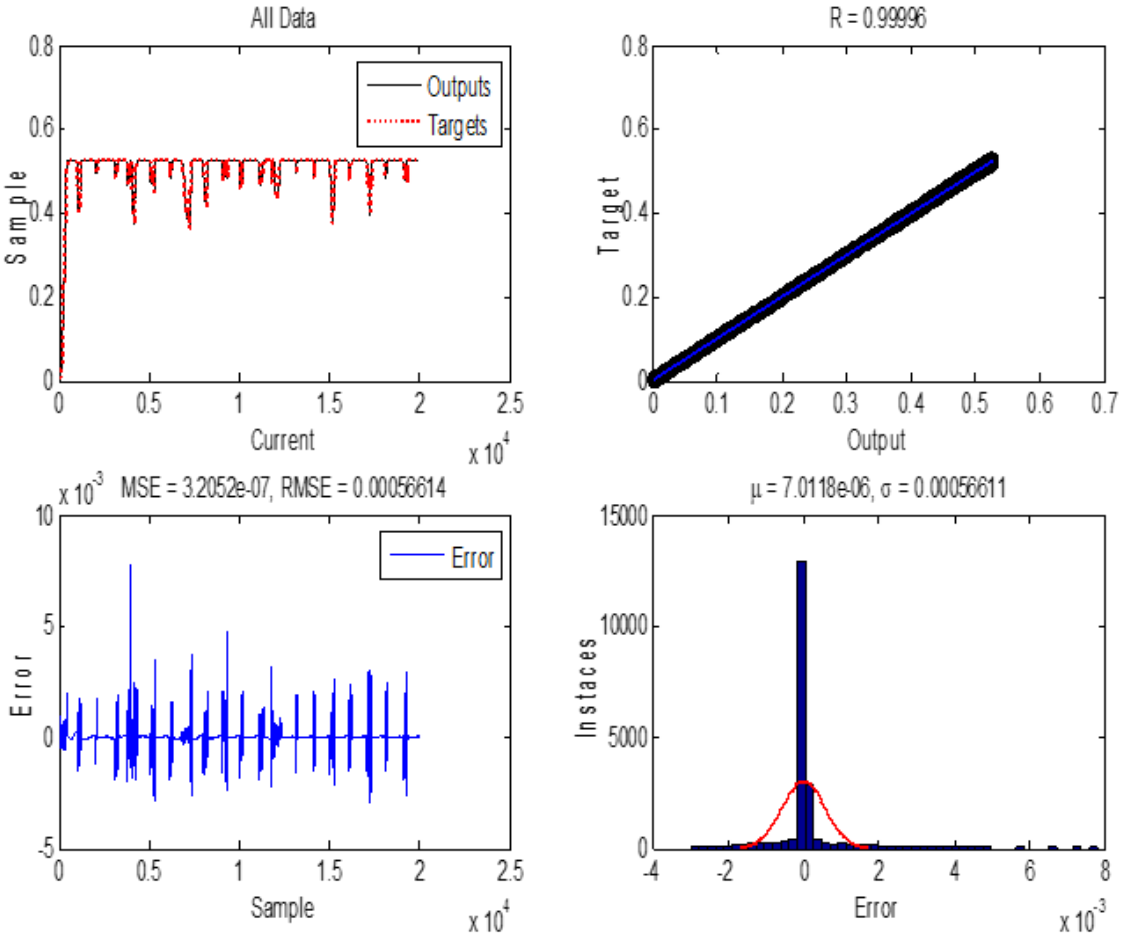


图2：系统输出相干性及其估计值、无故障电力系统的输出及其估计值图、故障估计直方图和故障平方平均值，以及基于样本的故障平方平均值。

在最大功率点跟踪变换器中，为了计算光伏子系统的功率优化，会使用电流和电压传感器对这些参数进行实时采样，并将采样值与优化值 [19] 进行比较。因此，

诊断并识别光伏子系统中可能出现的故障时，可以使用这些传感器，从而更快速地诊断电力系统中太阳能阵列的故障并防止故障蔓延。因此，在对光伏子系统进行建模时，与之前一样，将太阳辐射功率和太阳能阵列表面温度作为输入，将阵列的电流和电压作为输出，并使用神经网络、非线性假设和静态模型来识别系统。结果如图3和图4所示。

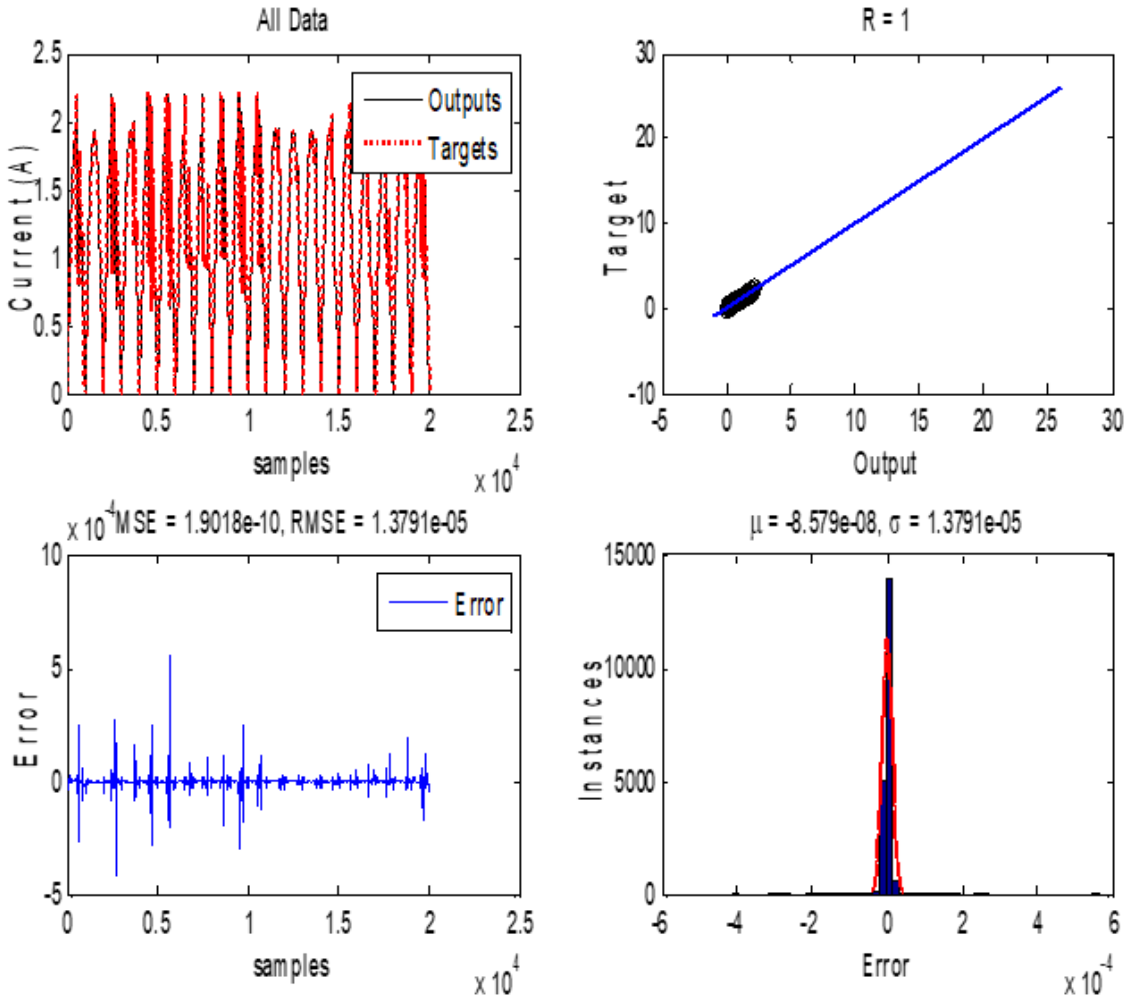


图3：光伏系统的电流、系统输出相干性及其估计值、输出图及其估计值、故障估计直方图，以及基于样本的故障均方和故障平方平均值。

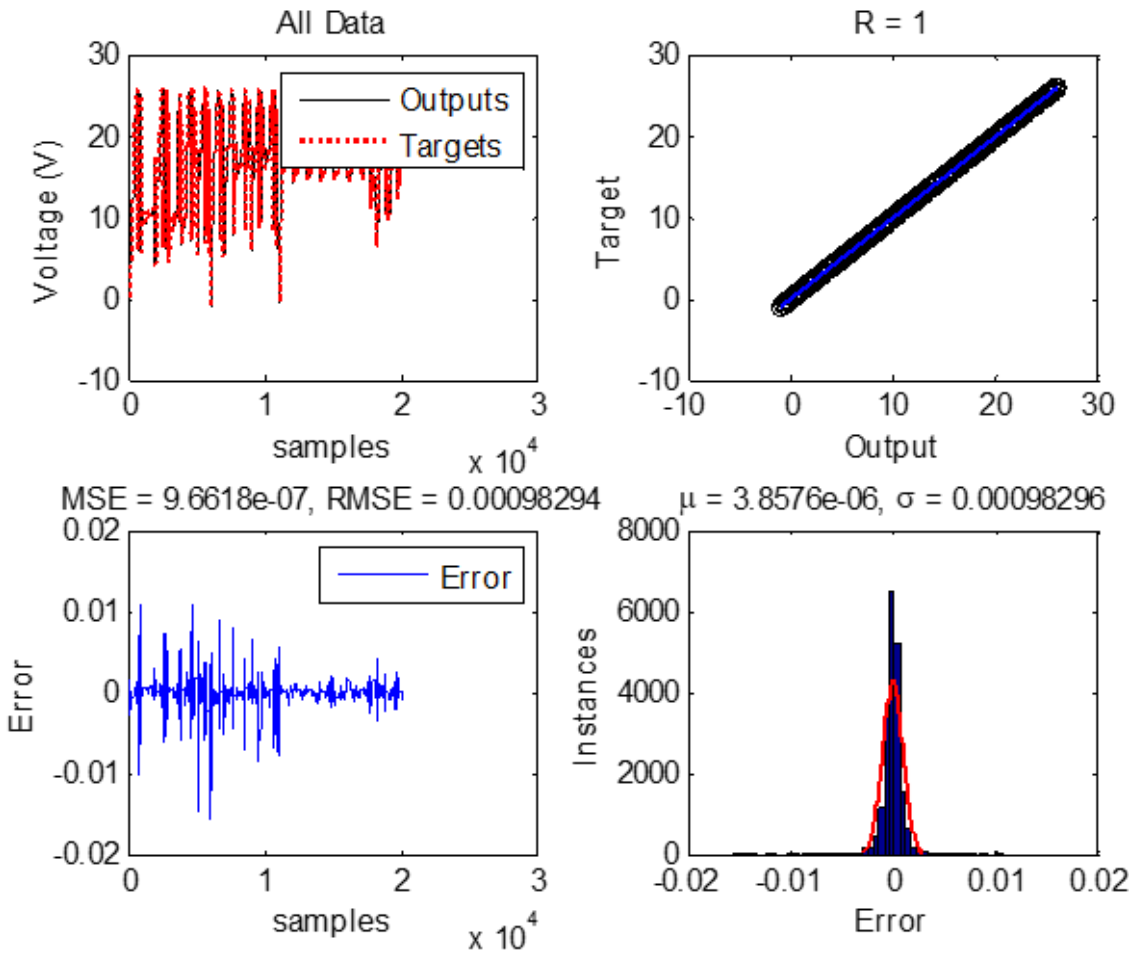


图4：光伏系统输出电压的系统输出相干性及其估计值、输出图及其估计值、故障估计直方图，以及故障平方平均值和基于样本计算的故障平方平均值。

通过研究图2至图4可知，神经网络对输出模型具有较高的准确率。基于系统输出，估计结果呈现振荡；在含电流负载的系统建模中，实际输出与估计输出的相似度为96%，而在光伏系统模型中为100%。建模中的故障通过故障平方平均值、平均值和故障方差等参数进行评估。在先前的仿真中，含负载电流的系统建模中的故障平方平均值小于 10^{-6}；光伏系统输出中，电压故障平方平均值小于 10^{-6}，电流故障平方平均值小于 10^{-9}。通过研究图2至图4中的故障直方图可知，系统建模中的故障平均值小于 10^{-5}；光伏系统输出中，电压故障平均值小于 10^{-6}，电流故障平均值小于 10^{-9}。先前建模中的故障方差依次为0.00056、0.00013和0.00098。从故障直方图可以看出，图2至图4中建模故障的高斯估计峰值理想，这表明故障与平均值之间没有明显分离。因此，上述神经网络对无故障电力系统模型具有较高的准确率。

2.2 故障电力系统建模

电气和电子系统中的故障是随机发生的 [13]。基于这一假设，必须将每种可能的故障注入系统，并使用神经网络识别系统模型。随后，根据第2节，对太阳能阵列中的开路故障和线间故障、最大功率点跟踪变换器绝缘栅双极型晶体管开路故障、开路故障、绝缘栅双极型晶体管稳压变换器短路以及电池接地故障进行识别，并汇总于表2。

表2：电力系统故障建模结果汇总。

子系统	故障模型	系统输出相干性	RMSE	故障均值 μ	故障方差 δ
光伏	开路电流	1	10^{-11}	3.6×10^{-7}	6.7×10^{-6}
	开路电压	1	10^{-5}	0.00225	0.00921
	线间电流	0.99838	0.00056	0.00032	0.02375
	线间电压	1	10^{-8}	10^{-6}	0.00103
绝缘栅双极型晶体管 最大功率点跟踪	开路负载电流	0.99999	10^{-8}	5.3×10^{-7}	0.00023
绝缘栅双极型晶体管稳压变换器	开路负载电流	0.99963	10^{-10}	10^{-8}	9.5×10^{-5}
	短路负载电流	0.99986	10^{-6}	10^{-6}	0.0122
电池	接地负载电流	1	10^{-8}	10^{-8}	0.00012

2.3 基于多层感知机神经网络的光伏子系统故障分类

在光伏子系统中，可能发生的故障包括线间故障和开路故障。也可以使用多层感知机神经网络进行故障判定和分类。上一节已计算出正常光伏系统、线间故障和开路故障的模型。现在，将模型输出向量与系统输出向量进行比较，根据方程（5）构建残差，并将其作为输入送入分类器。

$$r = \left[V_{\text{pv}} - \hat{V}_{\text{pv}},\ I_{\text{pv}} - \hat{I}_{\text{pv}}\right], \tag{4}$$

在公式（5）中，r 为剩余量，V_{pv} 和 I_{pv} 为光伏系统的电压和电流量，V_{pv} 和 I_{pv} 为光伏系统的输出电压和电流量。分类器的仿真数据数量为2001，每个类别均提供相应数据。输出为3位，用于标识故障类别。分类结果如图5所示的混淆矩阵所示。

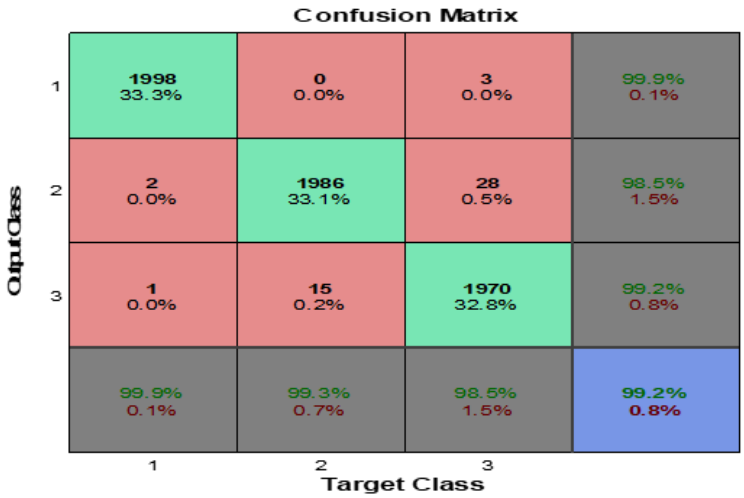


图5：用于识别光伏系统故障的多层感知机神经网络分类器混淆矩阵。

对图5的研究表明，神经网络对光伏系统中可能发生的故障进行分类时，准确率超过99.9%，这说明其准确率很高；而模型对无故障系统、线间故障和开路故障类别的分类准确率也很高。此外，显然，在2001个无故障系统类别的数据中，1998个数据被正确分类，3个数据被判定为存在故障，这意味着该类别的检测准确率约为99.9%。在光伏系统的故障类别中，准确率为99.3%；在2001个数据中，1968个数据分类正确，15个数据分类错误。此外，在开路故障类别中，准确率为98.5%；在2001个数据中，1970个数据分类正确，31个数据分类错误。对图5的研究还可以看出，在无故障系统类别中被错误诊断的3个数据里，2个被错误分类为线间故障，1个被错误分类为开路故障。线间故障类别中错误分类的15个数据均被归入开路故障类别；而在31个数据中，必须归入开路故障类别的有28个数值数据，另有3个数值数据被归入无故障系统类别。

2.4 基于多层感知机神经网络的电力系统故障分类

在分类过程中，神经网络多层感知机神经网络的树层将5位分配给5个输出类别，以识别电力系统中另一种可能的故障。这5个类别包括无故障系统、电池接地故障、IGBT变换器最大功率点跟踪开路故障、开路故障，以及IGBT稳压变换器短路故障。神经网络分类器的输入基于图1，包括神经网络模型的输出以及根据公式（6）得出的系统输出量。

$$x = [r_0, r_1, \ldots, r_4] \tag{5}$$

在公式（6）中， r_i 为剩余量， x 为图1所示神经网络分类器的输入向量。将公式（6）的输入输入混淆矩阵分类器后，可得到图6。

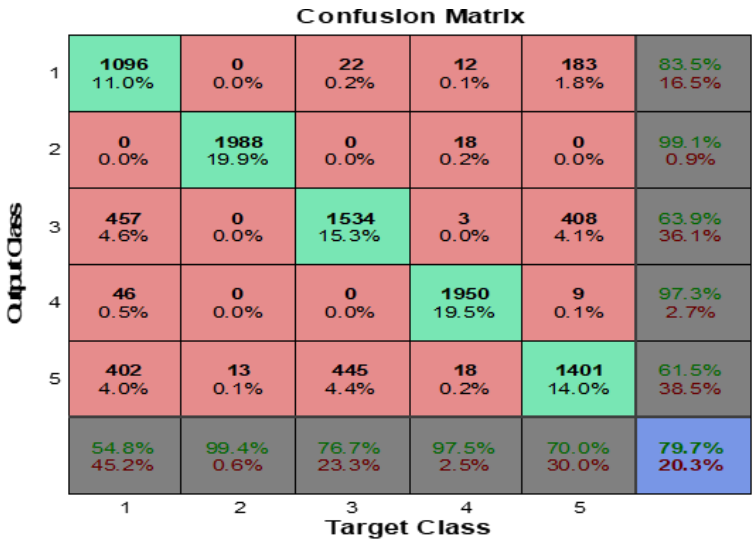


图6：第一状态下多层感知机神经网络分类器的混淆矩阵。

图6显示，在第一类中，多层感知机神经网络能够从2001个数据中正确诊断出1096个数据，准确率为54.8%，故障率为45%。其中，457、46和402个数据分别属于IGBT变换器最大功率点跟踪开路故障、开路故障和IGBT稳压变换器短路故障。地面电池故障类别的分类器准确率高于其他类别，超过99%；IGBT短路故障类别中有13个数据被错误分类。在所设计神经网络对各类别进行区分时，最大功率点跟踪变换器开路故障、开路故障和IGBT稳压变换器短路故障的准确率依次为76.7%、97.5%和70%。这意味着，对IGBT开路故障和稳压变换器进行区分时，准确率较高，但仍有12个无故障类别的数据、18个地面电池故障数据、3个IGBT最大功率点跟踪变换器开路故障数据以及18个IGBT稳压变换器短路故障类别的数据被错误诊断。最后，图6显示了混淆矩阵；该多层感知机神经网络在纳卫星电力系统的多个状态下准确率为79.7%，故障率为20.3%。因此，根据这些结果和准确率，不能使用该网络及其输出进行系统故障分类。

为克服神经网络准确率不足的问题并提高准确率，可以利用输出信号（负载电流）的另一项特征。根据公式（7）和（8），将输出电流的一阶矩向量（每个时刻的电流平均值）作为生成的属性之一进行识别。

$$m_1 = \frac{1}{N} \sum_{k=1}^{N} I_{\text{load}}(k) \tag{6}$$

在公式 (7) 和 (8) 中， m_1 是第一个输出电流时刻， r_i 是神经网络模型的剩余数量。将先前的输出输入树层多层感知机神经网络，并对混淆矩阵中每个类别的 2001 个数据进行研究后，便可依据图7计算分类结果。图7中的混淆矩阵呈对角分布，表明五个类别中的数据均有 100% 被正确分类。所设计的多层感知机神经网络能够以较高准确率检测故障系统的所有状态，因为每个类别中有 20% 的数据，也就是说每个类别有 2001 个数据，而依据图7，各类别中的故障分类数为零。

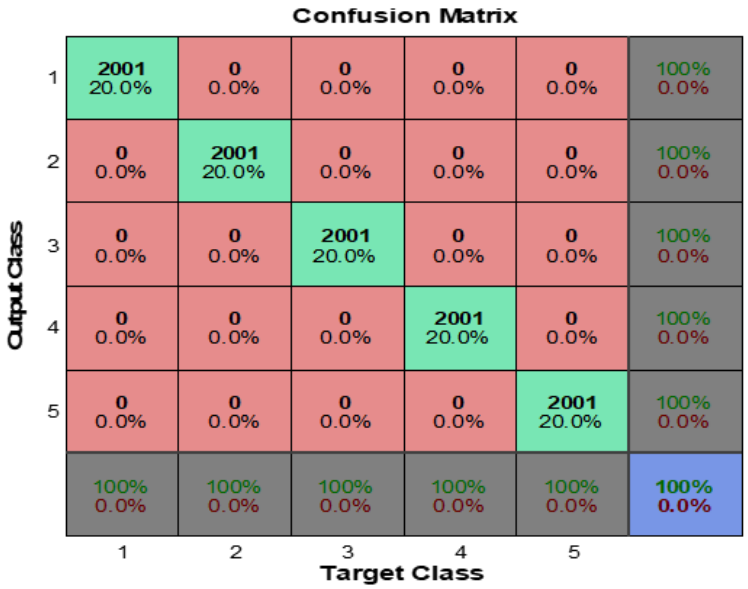


图7：具有5位输出的神经网络MLP分类混淆矩阵。

2.5 使用另一种智能方法进行故障分类

计算每个时刻输出负载电流的平均值可能会给系统处理器带来较大的计算负担，因此可以采用另一种智能方法来区分系统故障。

在用于控制和管理电池充电与放电的卫星电子电源系统中，使用SOC参数和电池荷电状态。精确估计电池荷电状态可以保护电池健康，避免不必要的电池充电和放电，延长电池寿命，降低故障发生的概率，并提高系统可靠性 [9]。SOC参数通过卡尔曼方法计算。使用方法 [20] 计算得到SOC。现在，利用主成分分析、K近邻和决策树等智能分类方法，可根据电流负载输入和电池SOC对电力系统进行可能的故障分类。

2.5.1 K近邻方法

故障分类也可以使用K近邻方法。K近邻是一种惰性分类器，无需构建模型和学习样本即可对数据进行分类。使用K近邻分类器方法，并利用输出电流输入、电池荷电状态构建有序对（I_{load}，SOC），即可确定卫星电力中的可能故障； K 是基于公式（9）计算的几何欧氏距离，在每个有序对（I_{load}，SOC）周围用于数据分类 [21]。

$$d = \sqrt{(I_{\text{load}} - I_k)^2 + (\text{SOC} - \text{SOC}_k)^2} \tag{7}$$

在上述方程中， d 是几何距离， I_{load} 是负载电流，而(I_k，SOC_k)是图（7）平面中点 k 的荷电状态。为了评估该算法的函数，可进一步研究交叉验证和替代损失参数。在交叉验证中，数据被分成 K 组，然后对每组进行学习和交叉测试，并据此定义K折损失参数。

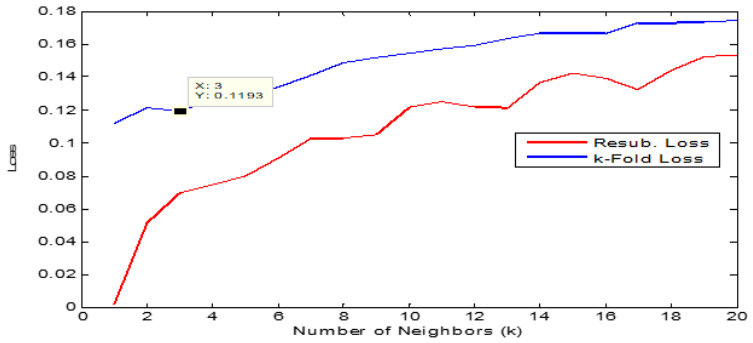


图8：K近邻方法中的K折故障与替换。

通过研究图8可知，K近邻方法中的邻居数应设为3，这与替代损失和K折损失相当，因为替代损失会使一个或两个近邻发生故障；但若选择 K参数为1或2，则会导致分类器对数据学习过度拟合。为确定邻居数，进行了故障分类，结果见表3。

$$\text{Resubstitution Loss} \approx 0.0698 \sim 7\%, \quad \text{K_Fold Loss} \approx 0.1193 \sim 12\%$$

表3：K近邻分类方法的结果。

类别	准确率（%）	注释
无故障系统	86	
电池接地故障	100	
IGBT最大功率点跟踪开路	86	
稳压器开路	99.99	
IGBT稳压器短路	92	

从表（3）可以看出，KNN算法无法完整地对故障进行分类。

2.5.2 决策树

对于独立且彼此分离的类别，可以使用学习树或决策树。决策树是一种用于估计离散目标值的方法。这种方法是最著名的后验学习算法之一，已成功应用于各种领域，并且具有抵抗输入数据噪声的能力。决策树学习采用ID3算法。基于决策树的分类会选择最有可能的策略 [21]。

决策树方法通过使用输出负载电流和电池荷电状态，将有故障系统与无故障系统分离；与PCA方法和K近邻方法类似，表（4）展示了故障分类结果、替代故障率和kreplicate。

$$\text{Resubstituting Loss} \approx 0.0137 \sim 1.3\%, \quad \text{K_Fold Loss} \approx 0.0435 \sim 4.3\%$$

表4：决策树分类结果。

类别	准确率（%）	备注
无故障系统	97	
电池接地故障	99.99	
IGBT最大功率点跟踪开路	98	
稳压器开路	99.6	
IGBT稳压器短路	98.35	

2.5.3 PCA方法

PCA方法是一种输入与输出之间的线性映射，离散系统基于其特征值和特征向量建立该映射。图9展示了系统故障类别下输出负载电流和电池荷电状态输入的二维平面，以及在应用PCA方法之前系统中可能存在的故障类型。

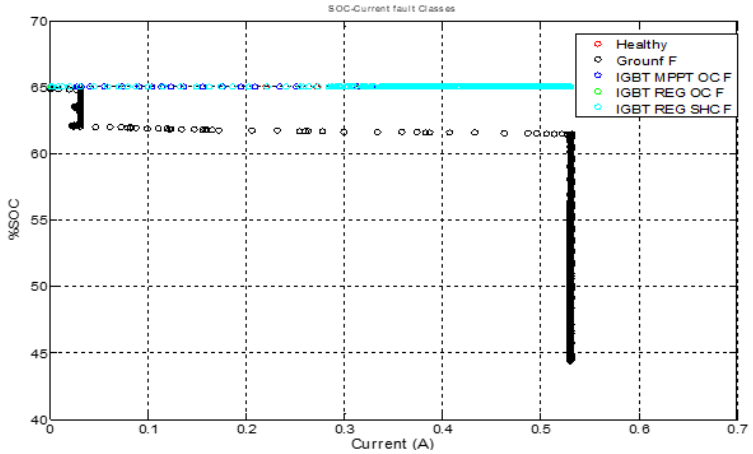


图9：电池荷电状态与负载电流平面上的故障类别。

图8展示了在电池荷电状态和输出负载电流二维平面上，无故障状态以及电力系统中可能的故障类别，这些状态无法离散表示。

使用PCA方法时，首先考虑输入分类器为有序对（I_{load}，SOC），并考虑公式（9）中的矩阵 X 。

$$X = \begin{bmatrix} I_{\text{load},1} & \cdots & I_{\text{load},N} \\ \text{SOC}_1 & \cdots & \text{SOC}_N \end{bmatrix}$$

此外，在公式（9）中， y 是映射输出向量， Q是公式（10）中协方差矩阵 C 的特征向量矩阵。在该公式中，平均数据（偏置）等于零，定义如下：

$$C = \frac{1}{N} X X^{\top}$$

为计算 PCA 方法的方程，矩阵 Q 中最大特征值对应的特征向量矩阵 C 按升序在矩阵 Q 的列中确定，然后选择特征值较大的特征向量，从而使 y 输出产生更大的方差分散。使用 PCA 方法进行分离和分类后，结果将故障状态与无故障状态区分开来，并在图10中展示了故障类别。

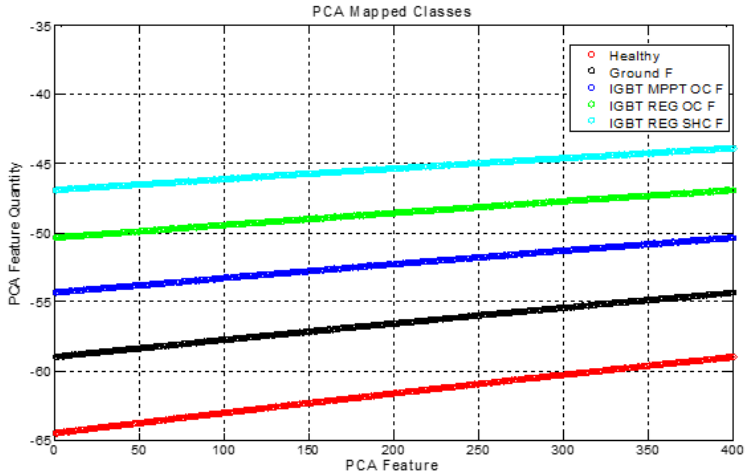


图10：使用PCA方法分离电力系统中可能的故障。

图10显示，无故障状态和可能的故障类别被降至一维，并通过 PCA 方法在适当的空间中加以分离。

结论中介绍的电力系统故障分离方法（光伏子系统除外）的结果见表5。

表5：电力系统故障分类方法比较。

方法	系统	准确率（%）
神经网络（多层感知机）	电力	100
	光伏	99.2
PCA	电力	100
KNN	电力	93
DT	电力	98.6

表（5）显示，用于区分和分类纳卫星电力系统中可能故障的两种算法——多层感知机神经网络和PCA方法——其准确率高于其他方法。决策树方法的准确率也很高，但根据其准确率，K近邻方法无法用于此目的。关于各类别中电力系统可能故障的分类质量分析，可参见表7（为简洁起见，此处省略）。

3 结论

本文提出了纳卫星卫星电力系统的仿真方案。由于质量和体积受限，选取影响电力系统功能的有效参数作为输入，电负载电流作为输出；结合这些参数，并利用神经网络对系统设备进行可靠性分析，以适当的准确率确定了无故障状态和存在可能故障时的电力系统模型。随后采用多层感知机神经网络、PCA、K近邻和决策树方法进行类别区分，并指出多层感知机神经网络和PCA方法能够区分和分类无故障系统与可能故障类别，且比K近邻和决策树方法更有效。

参考文献

[1] M. Patel. 航天器电力系统。CRC出版社，2004年。[2] J. Gonzalez-Llorente 和 E. Ortiz-Rivera. 立方星电力系统中最大功率点跟踪技术的比较。小卫星会议，2013年。[3] Y. Zhao 等. 基于图的半监督学习在太阳能光伏阵列故障检测与分类中的应用。*IEEE*电力电子学汇刊，30(5):2848–2858，2015年。[4] Y. Zhao 等. 基于决策树的太阳能光伏阵列故障检测与分类。载于第二十七届*IEEE*应用电力电子会议暨展览会（*APEC*），2012年。[5] A. H. Mohamed 和 A. M. Nassar. 光伏能源系统故障诊断新算法。国际计算机应用杂志，114(9)，2015年。[6] N. M. A. Freire、J. O. Estima 和 A. J. M. Cardoso. 一种无需额外硬件、基于电压的闭环PWM交流再生驱动器开路故障诊断方法。*IEEE*工业电子学汇刊，61(9):4960–4970，2014年。[7] Y. He 等. 一种用于高功率锂离子电池荷电状态（SOC）估计的新模型。《应用能源》，101:808–814，2013年。[8] S. Sepasi、R. Ghorbani 和 B. Y. Liaw. 一种基于模型自适应扩展卡尔曼滤波器的老化锂离子电池车载荷电状态估计新方法。《电源杂志》，245:337–344，2014年。[9] A. Nuhic 等. 使用数据驱动方法进行锂离子电池健康诊断与剩余使用寿命预测。《电源杂志》，239:680–688，2013年。[10] B. Lee 和 X. Wang. 基于主成分分析的微卫星电源子系统故障检测与重构。载于航空航天系统与控制（*ISSCAA*），2010年第三届国际研讨会。IEEE，2010年。

[11] S. Xie 等. 基于贝叶斯网络的卫星电力系统故障诊断。载于计算机科学与教育（*ICCSE*），2013年第八届国际会议。IEEE，2013年。[12] T. T. Wong. 一种用于朴素贝叶斯分类器的混合离散化方法。模式识别，45(6):2321–2325，2012年。[13] R. Isermann. 故障诊断系统：从故障检测到容错的介绍。施普林格，2006年。[14] M. Vázquez 和 I. Rey-Stolle. 基于现场退化研究的光伏组件可靠性模型。光伏进展：研究与应用，16(5):419–433，2008年。[15] R. J. Patton 和 J. Chen. 奇偶空间故障诊断方法综述。载于*IFAC*安全过程会议，1991年。[16] S. Chen、S. A. Billings 和 P. M. Grant. 使用神经网络进行非线性系统辨识。国际控制杂志，51(6):1191–1214，1990年。[17] L. Jacques. oufti-1纳米卫星的热设计。博士论文，列日大学，2009年。[18] M. T. Hagan 和 M. B. Menhaj. 使用马夸特算法训练前馈网络。*IEEE*神经网络汇刊，5(6):989–993，1994年。[19] B. Subudhi 和 R. Pradhan. 光伏电力系统最大功率点跟踪技术比较研究。*IEEE*可持续能源汇刊，4(1):89–98，2013年。[20] W. He 等. 使用神经网络建模和基于无迹卡尔曼滤波器的误差抵消估计锂离子电池荷电状态。国际电力与能源系统杂志，62:783–791，2014年。[21] S. R. Gaddam、V. V. Phoha 和 K. S. Balagani. K-Means+ID3：一种通过级联K-Means聚类与ID3决策树学习方法进行监督式异常检测的新方法。*IEEE*知识与数据工程汇刊，19(3):345–354，2007年。[22] S. Abdoli 和 F. Hajati. 使用测地线导数模式进行离线签名验证，载于2014年第22届伊朗电气工程会议（ICEE），2014年：IEEE，第1018–1023页。[23] F. Ayatollahi、A. A. Raie 和 F. Hajati. 使用深度与强度双树复小波变换特征进行表情不变的人脸识别，《电子成像杂志》，第24卷，第2期，第023031-023031页，2015年。[24] L. Barolli.《高级信息网络与应用：第38届国际高级信息网络与应用会议（AINA-2024）论文集》，第2卷，编者：施普林格·自然，2024年。[25] L. Barolli、P. Hellinckx 和 T. Enokido.《宽带无线计算、通信与应用进展：第14届宽带无线计算、通信与应用国际会议（BWCCA-2019）论文集》。施普林格·自然，2019年。[26] L. Barolli、M. Takizawa、F. Xhafa 和 T. Enokido.《网络、人工智能与网络应用：第33届国际高级信息网络与应用会议（WAINA-2019）研讨会论文集》。施普林格，2019年。[27] R. Barzamini、F. Hajati、S. Gheisari 和 M. Motamadinejad. 使用多层感知器和模糊推理系统进行短期负荷预测，《应用科学杂志》，第12卷，第1期，第40-47页，2012年。[28] D. Cremers、I. Reid、H. Saito 和 M.-H. Yang.《计算机视觉—ACCV 2014：第12届亚洲计算机视觉会议，澳大利亚新加坡，2014年11月1日至5日，修订精选论文，第V部分》。施普林格，2015年。[29] S. Fiorini、F. Hajati、A. Barla 和 F. Girosi. 通过时间跨度引导的神经注意力网络预测澳大利亚人口开始糖尿病二线治疗，PLOS ONE，第10卷，第14期，文章编号e0211844，2019年。[30] F. Hajati、A. Cheraghian、S. Gheisari、Y. Gao 和 A. S. Mian. 用于三维可变形纹理匹配的表面测地线模式，《模式识别》，第62卷，第21-32页，2017年。[31] F. Hajati、K. Faez 和 S. K. Pakazad. 一种在人脸定位与彩色图像识别中的高效方法，载于《系统、人类与控制论》，2006年。SMC'06，IEEE国际会议，2006年，第5卷：IEEE，第4214-4219页。[32] F. Hajati、A. A. Raie 和 Y. Gao. 使用测地线纹理变形进行姿态不变的2.5D人脸识别，载于2010年第11届国际控制、自动化、机器人与视觉会议，2010年：IEEE，第1837-1841页。[33] F. Hajati、M. Tavakolian、S. Gheisari、Y. Gao 和 A. S. Mian. 使用导数稀疏表示进行动态纹理比较：在基于视频的人脸识别中的应用，《IEEE人机系统汇刊》，第47卷，第6期，第970-982页，2017年。

[34] P. Mahajan、S. Uddin、F. Hajati、M. A. Moni 和 E. Gide，《使用多个数据集进行疾病预测的机器学习集成方法比较评估》，Health and Technology，第14卷，第3期，第597-613页，2024年。[35] S. K. Pakazad、K. Faez 和 F. Hajati，《基于人脸各组成部分中心几何矩的人脸检测》，载于《系统、人类与控制论》，2006年，SMC'06 IEEE国际会议，2006年，第4225-4230页。[36] A. Sadeghi、M. Sadeghi、A. Sharifpour、M. Fakhar、Z. Zakariaei 和 F. Hajati，《一种新型深度学习方法在COVID-19诊断中的潜在应用》，Nature Scientific Reports，第14卷，第1期，第280页，2024年。[37] F. Shojaiee 和 F. Hajati，《用于掌纹识别的局部组合导数模式》，载于2014年第22届伊朗电气工程会议（ICEE），2014年：IEEE，第965-970页。[38] C. J. P. Sopo、F. Hajati 和 S. Gheisari，《DeFungi：显微真菌图像的直接真菌学检查》，arXiv预印本 arXiv:2109.07322，2021年。[39] A. Tavakolian、F. Hajati、A. Rezaee、A. O. Fasakhodi 和 S. Uddin，《利用优化并行 Inception快速筛查COVID-19与H1N1》，Expert Systems with Applications，第204卷，第117551页，2022年。[40] A. Tavakolian、A. Rezaee、F. Hajati 和 S. Uddin，《利用优化混合深度模型预测医院再入院和住院时长》，Future Internet，第15卷，第9期，第304页，2023年。[41] S. Wang、H. Lu、A. Khan、F. Hajati、M. Khushi 和 S. Uddin，《用于多类别分类的机器学习软件工具》，Software Impacts，第13卷，第100383页，2022年。[42] M. Karimi 和 A. Rezaee，《利用Meyer小波对亥姆霍兹方程的柯西问题进行正则化》，Journal of Computational and Applied Mathematics，第320卷，第76-95页，2017年。[43] B. Mohamadzade 和 A. Rezaee，《适用于GSM、WiMAX和WLAN的紧凑型宽带双套筒单极天线》，Microwave and Optical Technology Letters，第59卷，第6期，第1271-1277页，2017年。[44] M. Ramezani、M. Amiri Atashgah 和 A. Rezaee，《用于无人机—无人地面车辆覆盖路径规划的容错多智能体强化学习框架》，Drones，第8卷，第10期，第537页，2024年。[45] A. Rezaee，《利用遗传共生算法为约束自动机生成测试数据》，Applied and Computational Mathematics，第6卷，第1期，第126-137页，2008年。[46] A. Rezaee，《利用遗传算法设计FIR数字滤波器》，ICTACT Journal on Soft Computing，第1卷，第1期，第18-22页，2010年。[47] A. Rezaee，《利用模糊逻辑确定焊接机器人移动电机的PID控制器系数》，Automatic Control and Computer Sciences，第51卷，第2期，第124-132页，2017年。[48] A. Rezaee，《数字式手推贯入仪的设计、制造与评估》，International Journal of Advanced Smart Sensor Network Systems，第7卷，第1期，第1-10页，2017年。[49] A. Rezaee，《移动机器人控制的模型预测》，Transactions on Environment and Electrical Engineering，第2卷，第2期，第17-22页，2017年。[50] A. Rezaee 和 M. K. Golpayegani，《利用情感学习实现制冷制热系统的智能控制》，Electronics and Electrical Engineering，第18卷，第4期，第26-30页，2012年。[51] A. Rezaee 和 M. Pajohesh，《基于模糊逻辑的悬架系统控制》，Journal of Communications Technology, Electronics and Computer Science，第6卷，第1-5页，2016年。[52] A. Sadeghi、F. Hajati、A. Rezaee、M. Sadeghi、A. Argha 和 H. Alinejad-Rokny，《 3DECG-Net：用于多标签心律失常检测的心电图融合网络》，Computers in Biology and Medicine，第182卷，第109126页，2024年。[53] H. Taghvaee、S. M. Seyyedi 和 A. Rezaee，《超材料双频吸收器的设计》，载于第三届伊朗工程电磁学会议，2014年。[54] A. Tavakolian、F. Hajati、A. Rezaee、A. O. Fasakhodi 和 S. Uddin，《优化并行 Inception的源代码：一种快速COVID-19筛查软件》，Software Impacts，第13卷，第100337页，2022年。[55] E. Gavagsaz、A. Rezaee 和 H. Haj Seyyed Javadi，《利用可扩展简单随机抽样为MapReduce系统中的偏斜数据进行归约器负载均衡》，The Journal of Supercomputing，第74卷，第7期，第3415-3440页，2018年。[56] A. Rezaee、A. M. Rahmani、A. Movaghar 和 M. Teshnehlab，《模糊推理云服务的形式化进程代数建模、验证与分析》，The Journal of Supercomputing，第67卷，第2期，第345-383页，2014年。

[57] S. Sarvghad、A. Rezaee 和 F. Masomi, 《设拉子大学预科学生思维方式与自我效能感之间的关系》, 2011年。[58] I. Shahramian、E. Akhlaghi、A. Ramezani、A. Rezaee、N. Noori 和 E. Sharafi, 《重型β地中海贫血患者瘦素血清浓度研究》, 《伊朗儿科血液学与肿瘤学杂志》, 第3卷, 第2期, 第59页, 2013年。[59] I. Shahramian、M. Razzaghian、A. A. Ramazani、G. A. Ahmadi、N. M. Noori 和 A. R. Rezaee, 《重型β地中海贫血患者肌钙蛋白与铁蛋白血清水平之间的相关性》, International Cardiovascular Research Journal, 第7卷, 第2期, 第51页, 2013年。