© 2022 IEEE。允许将本材料用于个人用途。对于当前或未来媒体中的所有其他用途，包括为广告或宣传目的重新印刷/出版本材料、创作新的合集作品、转售或重新分发至服务器或列表，或在其他作品中重复使用本作品中任何受版权保护的组成部分，均须获得 IEEE 的许可。

IEEE生物医学工程汇刊，https://doi.org/10.1109/TBME.2021.3129459

全Elman神经网络：一种通过改进的哈里斯鹰优化算法优化、用于肺动脉楔压分类的新型深度循环神经网络

Masoud Fetanat*、Michael Stevens、Pankaj Jain、Christopher Hayward、Erik Meijering，IEEE 会士，Nigel H. Lovell，IEEE 会士

摘要——心力衰竭（HF）是最常见的危及生命的心血管疾病之一，美国有650万人患有此病，全球患者人数则超过2300万。通过为心力衰竭患者植入左心室辅助装置（LVAD），可为其提供机械循环支持，作为移植桥接治疗、心功能恢复或终末治疗；该装置可通过测量正常和异常的肺动脉楔压（PAWP）进行控制。由于目前尚无可用于长期测量PAWP的商用植入式压力传感器，因此实时、无创地估算正常和异常PAWP至关重要。本研究首先提出一种改进的哈里斯鹰优化算法，称为HHO+，并在24个单峰和多峰基准函数上进行测试。其次，提出一种新型全Elman神经网络（FENN），以提升分类性能。最后，开发并比较了四种新型的18层深度学习方法，用于根据估算的HVAD泵流量对异常和正常PAWP进行分类：卷积神经网络（CNN）与多层感知机（CNN-MLP）、CNN与Elman神经网络（CNN-ENN）、CNN与全Elman神经网络（CNN-FENN），以及由HHO+ 算法优化的CNN与全Elman神经网络（CNN-FENN-HHO+）。估算的泵流量通过嵌入商用HVAD控制器的无创方法获得。使用五折交叉验证，在一个类别不平衡的临床数据集上对所提出的方法进行评估。与所提出的CNN-MLP、CNN-ENN和CNN-FENN方法相比，CNN-FENN-HHO+方法表现更优，在五折交叉验证中的分类性能指标均有所提升，平均敏感度为79%、准确率为78%、特异度为76%。所提出的方法可降低心力衰竭患者发生肺淤血和心室吸空等危险事件的可能性，并将识别出的异常病例通知医院、临床医生和心脏病学家，以便采取紧急措施，从而降低心力衰竭患者的死亡率。

索引词——深度学习、卷积神经网络、全Elman神经网络、元启发式算法、心力衰竭、哈里斯鹰优化算法。

*Masoud Fetanat（通讯邮箱：m.fetanat@ieee.org）、Michael Stevens 和 Nigel Lovell 任职于澳大利亚悉尼新南威尔士大学生物医学工程研究生院。Pankaj Jain 和 Christopher Hayward 任职于澳大利亚悉尼圣文森特医院心脏病科、悉尼维克多·张心脏研究所，以及澳大利亚悉尼新南威尔士大学医学院。Erik Meijering 任职于澳大利亚悉尼新南威尔士大学生物医学工程研究生院和计算机科学与工程学院。

I. 引言

心血管疾病（CVD）是一种患病率很高的疾病，在美利坚合众国影响着 2670 万人 [1]。美国有 650 万人罹患心力衰竭（HF），全球则超过 2300 万人 [2]。据美国心脏协会统计，2012 年至 2030 年间，心力衰竭患病率将增加 46%，届时患有心力衰竭的成年患者将超过 800 万人 [1]。尽管心脏移植是终末期心力衰竭患者的金标准治疗方法，但供体心脏数量远少于心脏移植的需求，因此等待名单上的患者死亡率很高。机械循环支持是心力衰竭患者最适合的治疗方法之一，通过将一种称为左心室辅助装置（LVAD）的机械泵植入心力衰竭患者体内来实现 [1], [2]。

目前，左心室辅助装置以恒定速度运行，因此当生理状况变化时，它们无法灵敏地响应需求变化 [3]。这可能导致危险事件，例如心室吸空（因心室压力过低而导致心室塌陷）或肺淤血（因心室压力过高而导致肺部积液过多）[4]。左心室辅助装置的生理控制系统可用于自动调节泵速，以维持恒定的左心室舒张末期压力（LVEDP）[4], [5]。维持这一重要临床变量可补充原生心脏的弗兰克-斯塔林反应，从而预防心力衰竭患者发生这些危险事件 [6]–[9]。

这种生理控制系统方法需要植入式压力传感器来测量心力衰竭患者的左心室舒张末期压力（LVEDP）。然而，目前尚无可供商业使用的长期植入式压力传感器。另一种方法是使用肺动脉楔压（PAWP），因为通过导管插入术更容易测量该指标，并将其作为LVEDP的替代指标 [3], [4], [10], [11]。不过，肺动脉导管检查测量PAWP只能在医院环境中短期进行，因为大多数此类患者出院后会回家，而且在医院外使用这种技术并不安全。因此，对PAWP进行无创预测，判断其是否异常，变得愈发重要。如果能够预测这些数值，生理控制系统便可自动调节泵速，使PAWP恢复至安全水平。

机器学习算法可用于通过非

来自植入式泵的侵入性信号 [11]。这些算法主要包括特征提取、特征选择和分类部分。然而，手动提取和选择合适的特征既耗时，也可能导致过拟合 [12]。此外，手动提取特征可能会降低机器学习方法的泛化能力 [12]。

为解决这一问题，可以采用卷积神经网络（CNN）等深度学习方法，自动从原始输入信号或图像中提取并选择特征 [12]–[14]。此前，已有多种深度学习方法被用于基于心电图（ECG）信号对心血管疾病进行分类[15]–[27]。此外，先前的若干研究采用循环神经网络（RNN）对心血管疾病进行分类 [28], [29]。结果表明，RNN 的表现优于多层感知机（MLP）等静态传统神经网络，因为 RNN 具有动态处理能力 [12], [30]–[34]。然而，在众多经典 RNN 类型中，Elman神经网络（ENN）尤为突出，并广泛应用于不同研究领域 [31], [35]–[37]。ENN 具有动态记忆能力，能够利用输入信号的过去和当前特征来提升分类性能指标，因此更适用于本研究所用的小型不平衡数据集。对 ENN 进行改进还可进一步提升分类性能。

卷积神经网络需要设置许多超参数，并且在网络训练期间需要对这些参数进行优化。然而，手动优化超参数极具挑战性 [38]–[40]。

此外，超参数依赖数据，因此可能不适用于其他数据集。由于目前没有可用的稳健数学方法，因此确定卷积神经网络超参数的合适取值并非易事。因此，要确定卷积神经网络超参数的取值，往往需要经过多次迭代才能获得更好的性能 [39]。可以采用随机搜索和网格搜索自动确定超参数，但这两种方法都很耗时 [39]。此外，也可以使用贝叶斯优化方法来确定超参数，但这需要估算误差函数的若干统计量，可能导致结果效率低下 [41], [42]。提出一种基于元启发式算法的自动方法来优化这些参数的取值，可以显著降低计算成本并提升性能 [43]。这些元启发式算法还可以处理非连续和不可微问题 [44], [45]。

有许多元启发式算法，例如粒子群优化（PSO）[46], 差分进化（DE）[47], 引力搜索算法（GSA） [48], 哈里斯鹰优化（HHO）[44], 海洋捕食者算法（MPA）[49], 黏菌算法（SMA）[50], 平衡优化器（EO）[51], 囊泡虫群算法（SSA）[52], 灰狼优化算法（GWO） [53], 布道优化算法（POA）[54], 红狐优化算法（RFO）[55], 非洲秃鹫优化算法（AVOA）[56]和人工大猩猩群优化器（GTO） [57]。在元启发式算法中，随机搜索的探索与开发是两种主要策略。探索是指在解空间中寻找相关区域，而开发则是从这些区域中提取有用信息[58]。根据“无免费午餐（NFL）”定理[59], , 不存在能够很好地解决所有类型优化问题的理想元启发式算法[60], , 因此，任何给定问题都可能受益于改进后的元启发式算法。在不同基准函数 [44], [60], [61], 以及图像阈值分割问题[62], 、光伏模型估计 [63] 和药物设计 [64]等多种应用中，HHO算法在寻找最优解方面优于许多其他元启发式算法。HHO算法的灵感来自哈里斯鹰追捕兔子以及兔子逃跑的行为，该算法由Heidari等人近期提出[44]。此外，Heidari等人指出，HHO在某些情况下可能无法提供最优解 [44], [60]。这些发现促使我们尝试改进这一著名的HHO算法。

这是首项针对植入左心室辅助装置的心力衰竭患者，采用深度学习方法从泵流量中无创检测异常与正常肺动脉楔压的研究。本研究旨在提高异常与正常肺动脉楔压分类的性能，使其能够用于实时应用。尽管文献中已有许多深度学习方法，但迄今为止，尚无研究探讨在卷积神经网络的最后几层中引入循环神经网络对此任务的影响。所提出的网络在两个连续时间点之间的输出层、两个连续时间点之间的隐藏层、输入层到输出层，以及输出层到隐藏层之间均建立了连接。本研究的假设是，这些连接能够充分利用输入、隐藏层和输出变量中的长期、空间及时间信息。此外，文献中常见的优化方法可能无法摆脱局部最优。因此，我们提出了一种新的优化方法，不仅用于优化所提出的深度学习方法的超参数，还用于提升其在标准基准函数上的表现。基于商用 HVAD 控制器泵流量信号进行肺动脉楔压分类，可用于实时调节泵速，从而降低肺淤血和心室吸空等危险事件发生的可能性。此外，所提出的方法可部署在移动软件平台上，并将识别出的异常病例通知医院、临床医生和心脏病学家，以便采取紧急措施，从而降低心力衰竭患者的死亡率。

本研究的创新之处主要体现在以下几个方面：首先，提出了一种改进的HHO算法，称为HHO+ 。其次，提出了一种新的全Elman神经网络，称为FENN，该网络利用输入和输出变量的长期信息与时间信息，从而提高分类性能。第三，利用所提出的HHO+ 算法对FENN的超参数进行优化，以进一步提高分类

性能。最后，提出并比较了四种基于泵流量信号、结合CNN、ENN、FENN和HHO+ 对异常和正常肺动脉楔压进行分类的非侵入性方法。CNN会从输入泵流量信号中自动提取相关特征。

以下各节首先介绍临床数据集和预处理。接着介绍HHO、卷积神经网络和 ENN 算法。然后，提出一种改进的哈里斯鹰优化算法（HHO+）和一种新型全Elman神经网络（FENN）。将所提出的 HHO+ 与近期的元启发式算法进行比较，包括 HHO [44], MPA [49], SMA [50],平衡优化算法 [51], SSA [52] 和 GWO [53]。随后，全面提出四种用于肺动脉楔压分类的新方法，即 CNN-MLP、CNN-ENN、CNN-FENN 和 CNN-FENN-HHO+。之后介绍性能评价指标、K 折分层交叉验证流程以及加权交叉熵损失函数。然后，在 24 个单峰和多峰基准函数上验证所提出的 HHO+。随后，展示使用临床患者数据集进行五折交叉验证时，CNN-MLP、CNN-ENN、CNN-FENN 和 CNN-FENN-HHO+ 的分类结果比较。最后，本文以对结果、研究局限性和未来工作的讨论作结。

II. 方法

A. 数据集

临床数据集来自25名病情稳定且可自由活动、植入了HVAD（HeartWare，美敦力）泵的患者。通过右心导管检查（7.5 French 双传感器 Swan-Ganz CCO导管；爱德华生命科学，尔湾，加利福尼亚州）测量植入患者的肺动脉楔压（PAWP）。HVAD泵流量由嵌入商用HVAD控制器中的非侵入性方法估算。在不同泵速和运动负荷下记录PAWP和泵流量。压力和流量测量的采样率为50 Hz。本实验研究已获圣文森特医院研究伦理委员会批准 [11]。这些数据用于构建五折交叉验证数据集，以评估所提出的方法。根据澳大利亚悉尼圣文森特医院临床医生的建议，PAWP低于8 mmHg或高于16 mmHg被视为异常，其他数值则视为正常。记录的数据集是不平衡数据集，其中包含459个PAWP异常样本和1338个PAWP正常样本。

B. 数据预处理 Butterworth 低通滤波器 f

采用截止频率为 15赫兹的滤波器去除高频噪声，并平滑肺动脉楔压和泵流量信号。随后，将泵流量信号划分为长度为 6 s（300 个样本）的片段。使用滤波后的肺动脉楔压，计算每个片段中两个连续极小值之间所有样本的平均肺动脉楔压。肺动脉楔压具有脉动波形，这是由心肌收缩力、吸气和呼气造成的。该过程如图 1 所示。

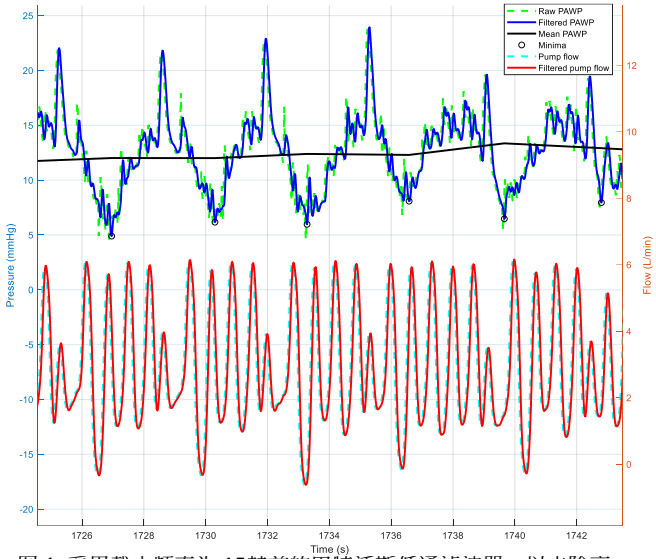

图 1. 采用截止频率为 15赫兹的巴特沃斯低通滤波器，以去除高频噪声并平滑肺动脉楔压和泵流量信号。根据滤波后的肺动脉楔压，计算每个片段中两个连续极小值之间所有样本的平均肺动脉楔压。肺动脉楔压：肺动脉楔压。

C. 背景材料

HHO算法是一种基于群体的无梯度优化算法，其灵感来自对猎物（兔子）的探索、鹰的突袭扑击与协同行为，以及捕捉猎物时采用的不同攻击策略。尽管鹰最初会寻找不同的潜在狩猎位置，兔子则会表现出逃跑行为以提高生存机会。在这一类比中，兔子代表最优解，而鹰代表每次迭代中的候选解[44]。

卷积神经网络是最流行的深度学习方法之一，由 Fukushima 于1980年提出，并由 Lecun 在 1998 [65], [66] 中改进。卷积神经网络可以使用一些滤波器自动从原始输入信号中提取特征，然后将这些特征映射到标记类别 [31]。

回声状态神经网络与前馈神经网络相似，不同之处在于其隐藏层与每个神经元之间存在具有一定延迟的循环连接，使网络能够对时变输入数据作出动态响应，从而提高分类性能 [12]。

由于稿件篇幅有限，HHO、卷积神经网络和 ENN 算法的详细说明分别见补充材料的第 1、2 和 3 节。

D. 改进的哈里斯鹰优化算法 (HHO+)

1) 改进的探索与开发算法（IEEA）

在传统的 HHO 算法中，探索与开发阶段仅根据兔子的逃逸能量来定义。然而，这无法提供捕捉猎物时采用不同攻击策略所需的全部信息，因为在 HHO 算法的每一步中，鹰和兔子的速度等其他因素也非常重要。

海洋捕食者算法（MPA） [49] 是一种新的元启发式算法，它根据捕食者与猎物的速度模拟二者的整个生命周期。结果表明，

MPA能够广泛地探索和开发解空间[49]。然而，MPA得出的解可能会陷入局部最优。因此，本文提出了一种受MPA启发的新算法，以改进全局解并避免陷入局部最优。在改进的探索与开发算法（IEEA）中，MPA的若干阶段经过修改后进行了组合，并在算法中加入了自适应递减阈值；这些改动均通过实验确定。该算法根据鹰捕猎兔子以及兔子逃跑时的速度和快速移动，模拟这一过程。因此，采用IEEA可以防止解陷入局部最优，并改进最优解。

改进的探索与开发算法包括两个部分：（1）兔子逃跑速度等于或快于鹰的移动速度时；（2）鹰的移动速度快于逃跑中的兔子时。第一阶段发生在优化的初始迭代中，此时探索比开发更重要。第二阶段发生在优化的中间和最后阶段，此时探索尝试会逐渐转为开发，或者开发比探索更重要。

These two phases are mathematically described as follows:

$$X_{t+1} = \begin{cases} X_t + rand \times R_G \times (X_{rabbit,t} - R_G \times X_t) & if\ rand < a \\ (X_{rabbit,t} + rand \times R_G \times (R_G \times X_{rabbit,t} - X_t) & otherwise \end{cases} \quad (1)$$

其中，X_{t+1} 和 X_t 分别是鹰在第$t+1$次和第t次迭代中的位置向量。$X_{rabbit,\ t}$ 表示兔子（最优解）在第 t次迭代中的位置。 a 是用于在探索与开发算法之间切换的自适应递减阈值。$rand$ 表示区间 (0,1) 内的均匀分布随机数， R_G 是一个向量，其中包含基于零均值和单位方差高斯分布的随机数:

$$R_G(x) = \frac{1}{\sqrt{2\pi\sigma^2}} exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) = \frac{1}{\sqrt{2\pi}} exp\left(-\frac{x^2}{2}\right) \quad (2)$$

μ 和 σ 分别表示高斯分布的均值和方差。 Gaus

自适应递减阈值a 定义如下:

$$a = tanh(-\left(\frac{t}{T}\right) + 1) \quad (3)$$

其中， t 和 T 分别为当前迭代次数和最大迭代次数。HHO+ 算法采用最大迭代次数作为停止准则。为比较莱维飞行和高斯分布，图 S4a 和图 4b 分别展示了莱维飞行和高斯分布的二维轨迹。

2）准反向学习（QOBL）反向学习（OBL）最初

由 Tizhoosh [67], 首先提出了反向点的概念。Tizhoosh 表明，与随机数相比，反向数能够提升基于种群的优化算法的搜索能力、解的精度和收敛速度 [67]。Rahnamayan 等人 [68] 提出了一种新的 OBL 方法，称为准反向学习，它能够进一步提高寻找全局最优点时的解的精度，如下所示。

设 X（x_1，x_2，…，x_n）为一个点， X^0（x_1^0，x_2^0，…，x_n^0）为一个反向点，X^{q0}（x_1^{q0}，x_2^{q0}，…，x_n^{q0}）为一个准反向点，它们均位于n维空间中。x_i^0 和x_i^{q0} 可定义为:

$$x_i^0 = a_i + b_i - x_i \quad (4)$$

其中，$x_i \in R$ 和$x_i \in [a_i, b_i]$、$\forall i \in$ 1、2、…、 n。

$$x_i^{q0} = rand(\frac{a_i + b_i}{2}, x_i^0) \quad (5)$$

如果当前解距离最优解太远，计算准反向位置可能会得到相反方向的位置，从而使其更接近最优解。因此，采用 QOBL 算法可以提高基于种群的优化算法的探索能力，并防止解陷入局部最优 [69]。 (QOBL) 的伪代码见算法 S2。 3) 提出的 HHO+

所提出的 HHO+ 由 HHO、IEEA 和 QOBL 组合而成。HHO+ 的伪代码见算法1。如伪代码所示，首先随机生成鹰群。随后，计算每只鹰的适应度，并将鹰群中的最佳位置存储在 X_{rabbit} 中，与经典 HHO 相同。然后，根据 E 和 r 的值，使用公式 (S4)、(S6)、(S10) 和 (S11) 更新鹰的位置。之后，执行 IEEA 和 QOBL，并更新 X_{rabbit} 。最后，如果当前迭代次数超过最大迭代次数，则算法返回 X_{rabbit}；否则，重复该过程。

在实验中，将所提出的 HHO+ 与一些知名且较新的元启发式算法进行比较，例如 HHO [44], MPA [49], SMA [50], EO [51], SSA [52] 和 GWO[53]。采用非参数统计方法 Friedman 检验和 Wilcoxon 秩和检验，对所提出的 HHO+ 及其他算法的平均结果进行排序。

E. 提出的全Elman神经网络（FENN）

在标准 ENN 中，时刻 t的上下文层与隐藏层之间只有一条反馈连接。这种反馈无法充分利用输入和输出变量的长期、空间和时间信息 [31], [37]。因此，为了提高 ENN 的性能，本研究构建了一种全Elman神经网络结构，其中包含输出层在两个连续时刻之间的连接、隐藏层在两个连续时刻之间的连接、输入层到输出层的连接，以及输出层到隐藏层的连接。

图2展示了所提出的 FENN 模型的架构。FENN 的数学模型如下所示:

$$y(t) = f(w_2\, x(t) + w_3\, u(t-1) + y_{c2}(t) + b_2) \quad (6)$$

$$x(t) = g(x_c(t) + w_1\, u(t-1) + y_{c1}(t) + b_1) \quad (7)$$

$$x_c(t) = w_4\, x_c(t-1) + w_5\, x(t-1) \quad (8)$$

$$y_{c1}(t) = w_6\, y_{c1}(t-1) + w_7\, y(t-1) \quad (9)$$

$$y_{c2}(t) = w_8\ y_{c2}(t-1) + w_9\, y(t-1) \quad (10)$$

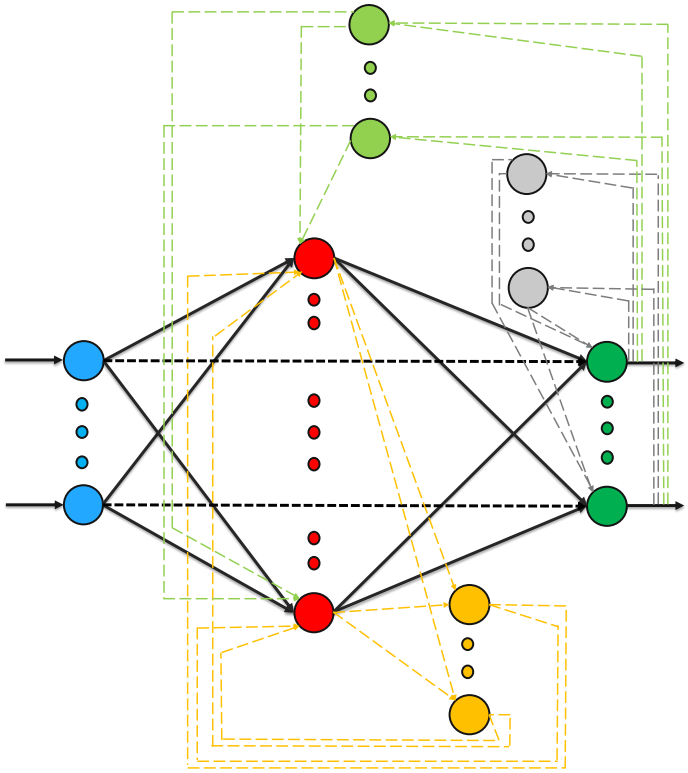

图 2. 所提出的 FENN 模型架构。u(t-1) 是时刻 t-1 输入层的向量，$\boldsymbol{x(t)}$ 表示隐藏层的向量，$\boldsymbol{x_c(t)}$、$\boldsymbol{y_{c1}(t)}$和 $\boldsymbol{y_{c2}(t)}$分别表示时刻 $\boldsymbol{t}$ 的隐藏层上下文层、输出上下文层1和输出上下文层2，$\boldsymbol{y(t)}$ 是时刻 t 输出层的向量。

算法1 所提出的 HHO+ 算法的伪代码

输入：种群规模 N 和最大迭代次数 T

在以下位置初始化随机鹰群 $X_i(i = 1, 2, \dots, N)$：

特定搜索空间

当（未达到最大迭代次数时）执行

  计算鹰的适应度值

  设置 X_{rabbit} 为鹰的最优解

  对于（每只鹰（X_i））执行

    更新初始能量 E0 和跳跃强度 J

    使用公式 (S3) 更新 E

    如果 ($|E| \geq 1$)，则进入探索阶段

      使用公式 (S1) 更新鹰向量，否则如果 ($|E| < 1$)，则进入开发阶段

      如果 ($r \geq 0.5$ 且 $|E| \geq 0.5$)，则软围攻

        使用公式 (S4) 更新鹰向量

      否则，如果 ($r \geq 0.5$ 且 $|E| < 0.5$)，则硬围攻

        使用公式 (S6) 更新鹰向量

      否则，如果 ($r < 0.5$ 且 $|E| \geq 0.5$)，则执行软围攻渐进快速俯冲

        使用公式 (S10) 更新鹰向量

      否则，如果 ($r < 0.5$ 且 $|E| < 0.5$)，则执行硬围攻渐进快速俯冲

        使用公式 (S11) 更新鹰向量

      end

    end

    更新 $X_{兔子}$ 通过所提出的 IEEA，使用公式 (1)，(2) 和 (3)

    在算法 S2 中应用 QOBL 并更新 $X_{兔子}$

  end

end

返回兔子的位置（X_{rabbit}）及其适应度值

其中，w_2、w_3 和 w_1 分别表示隐藏层与输出层、输入层与隐藏层，以及输入层与隐藏层之间的连接权重。$y_{c1}(t)$、$y_{c2}(t)$和 $x_c(t)$分别表示t处的输出上下文层1、输出上下文层2和隐藏层的上下文层。b_2 和 b_1 分别是输出层和隐藏层的偏置。w_4、w_6 和 w_8 分别表示x_c、y_{c1} 和 y_{c2}在时刻t 与 $t-1$ 之间的循环连接权重。

w_5、w_7 和w_9 表示x（$t-1$）到x_c（t）、y（$t-1$）到y_{c1}（t）以及y（$t-1$）到y_{c2}（t）的连接权重。y（t）和x（t）分别表示t时刻的输出层和隐藏层向量，而

$$u \quad t-1 \qquad\qquad t- \quad (\ ) \text{ 是时}$$

1 f g

刻的输入层向量。和分别表示输出层和隐藏层的激活函数，分别选用 Softmax 和双曲正切 S 形函数。

F. 提出的 FENN 与 HHO+ 结合的 CNN（CNN-FENN 和 CNN-FENN-HHO+）

本研究提出了采用 FENN 的 CNN（CNN-FENN）以及通过 HHO+ 优化的 FENN-CNN（CNN-FENN-HHO+），并将其与采用多层感知机的 CNN（CNN-MLP）进行比较，以利用泵流量信号的特征对异常和正常肺动脉楔压进行分类。所有三种卷积神经网络均使用相同的患者数据集进行训练和验证。

在标准卷积神经网络中，最后几层采用多层感知机将特征映射到标记类别。然而，卷积神经网络与多层感知机的结合可能导致其在时间相关数据上的分类性能较差 [12]。因此，本研究将CNN-MLP的最后两层（全连接层）替换为FENN（CNN-FENN），

并使用Adam算法 [70] 进行训练，以分类异常和正常的肺动脉楔压。图 3展示了所提出的CNN-FENN模型的架构。

通过测试不同的滤波器尺寸、层数以及各层的类型，并使用网格搜索最小化损失函数，对所提出的深度学习方法进行了优化。为进一步提升 CNN-FENN 的分类性能，使用所提出的 HHO+优化了与卷积神经网络训练相关的三个超参数，即初始学习率 (ILR)、学习率衰减因子 (LRDF) 和丢弃概率 (DP)。图 4 展示了所提出的 CNN-FENN-HHO+ 系统对异常和正常肺动脉楔压进行分类的流程图。在这一混合算法中，首先按照经典 HHO算法随机生成鹰群。随后，通过训练 CNN-FENN 并计算 10 个训练数据集结果的平均值，得到式 (14) 中的适应度函数值。之后，使用所提出的算法1更新鹰的位置。当当前迭代达到最大迭代次数后，将得到的 ILR、LRDF 和 DP 最优值输入 CNN-FENN，在测试数据集上进行验证。最后，利用所提出的 HHO+ 算法找到的最优参数，通过 5 折交叉验证计算 5 个测试数据集结果的平均值，得到最终结果。

G. HHO+、CNN-FENN 和 CNN-FENN-HHO+ 的实验设置、结构与参数

表 S2 展示了优化算法的参数设置：HHO [44], MPA [49], SMA [50], EO [51], SSA[52] 和 GWO [53]。将所提出的 HHO+ 与这些算法在 24 个单峰和多峰基准优化函数 [53], [71] 上进行比较，函数维度为 1000。表 S3 展示了这些基准函数的数学方程，如图 S5 所示。所有优化算法的种群规模和最大迭代次数分别设为 30 和 500 [44]。所有优化算法均采用随机初始化。为提高因优化算法中使用随机值而导致的结果鲁棒性，每种算法均初始化并运行 30 次。

表 S4 分别列出了所提出的 CNN-FENN 和 CNN-FENN-HHO+ 中各层的类型、卷积核尺寸、激活函数及其他参数。第 1 至 8 层由卷积层和带有 LeakyReLU激活的批归一化层构成。随后，第 9 至 12 层由带有 LeakyReLU激活的卷积层、步幅为 2 的最大池化层以及批归一化层构成。接着，第 13 至 16 层由卷积层和带有 LeakyReLU激活的批归一化层构成。最后，在 CNN-FENN 和 CNN-FENN-HHO+ 的第 17 层和第 18 层中，分别采用了一个 ENN 和一个 FENN；两者的隐藏层均包含 20 个神经元，激活函数为双曲正切 S 形函数（Tansig），输出层包含两个神经元，并采用 Softmax激活。

从表 S1 和表 S4 可以看出，CNN-MLP、CNN-FENN 和 CNN-FENN-HHO+ 使用了相同的卷积层、批归一化层、卷积核尺寸和激活函数。这些方法之间的主要区别在于用于分类的最后两层

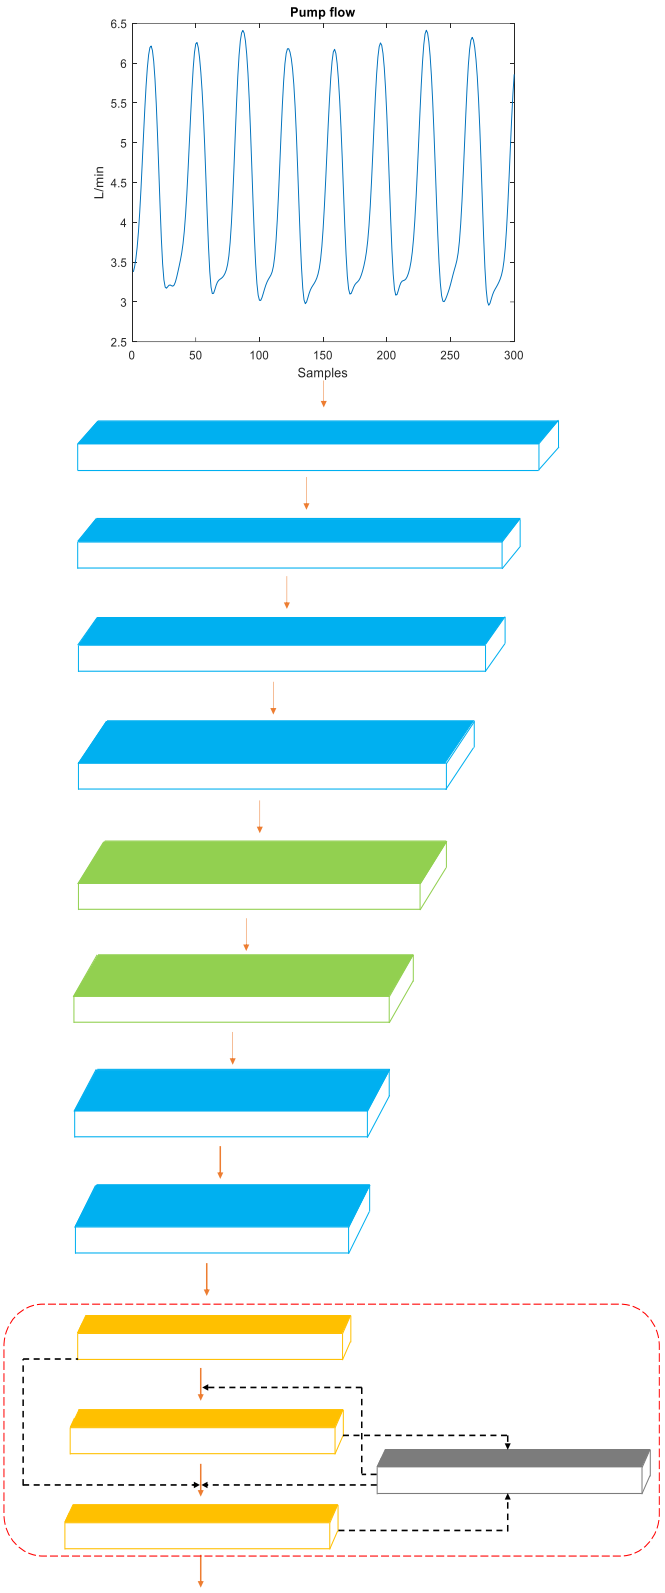

图 3. 所提出的用于异常和正常肺动脉楔压分类的 CNN-FENN模型架构。将 300 个泵流量信号样本作为输入馈入 CNN-FENN。随后是三个卷积层以及批归一化层。接下来的层中设置了五个步幅为 2 的卷积、最大池化层以及批归一化层。所提出的 FENN 层位于 CNN-FENN模型的最后一层，用于对异常和正常肺动脉楔压进行分类。

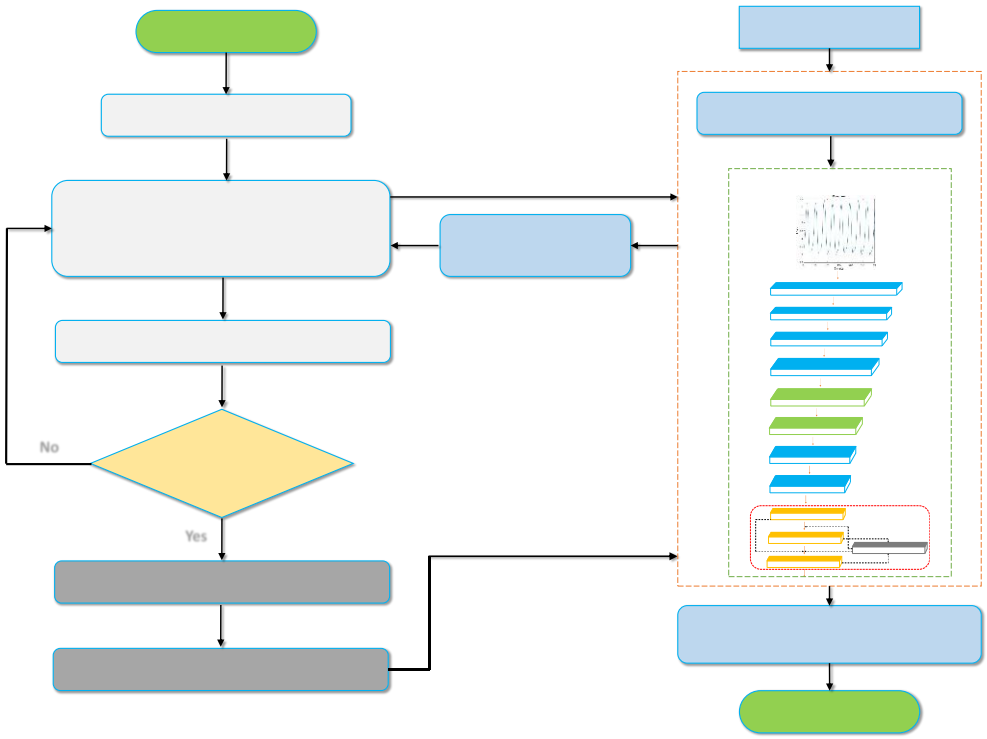

图 4. 所提出的 CNN-FENN-HHO 流程图+ 系统。

卷积核自动提取的特征。

采用Adam算法优化所提出的CNN-MLP、CNN-FENN和CNN-FENN-HHO+ 方法[70]的权重和偏置。由于He算法优于广为人知的Xavier算法[72]，因此采用He算法初始化CNN-MLP、CNN-FENN和CNN-FENN-HHO+ 的权重。此外，所提出的CNN-MLP、CNN-FENN和CNN-FENN-HHO+ 经过了1000次迭代训练，批量大小为179。该批量大小设为本研究所用样本总数的十分之一。

所有方法均在MATLAB 2020b版本（MathWorks，美国）中实现并运行，实验在一台配备16 GB RAM、Core i7-8700K CPU@3.70 GHz的计算机上进行。

H. 性能评价指标

使用准确率、敏感度和特异度这三项标准性能指标来评估所提出的方法：

$$Accuracy = \frac{TP + TN}{TP + FN + TN + FP} \quad (11)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (12)$$

$$Specificity = \frac{TN}{TN + FP} \quad (13)$$

其中，真阳性（TP）表示被正确分类为异常的肺动脉楔压数量，真阴性（TN）表示被正确分类为正常的肺动脉楔压数量，假阳性（FP）表示被错误分类为异常的正常肺动脉楔压数量，假阴性（FN）表示被错误分类为正常的异常肺动脉楔压数量。

准确率指所提出方法正确识别异常和正常肺动脉楔压的能力；敏感度指所提出方法正确检测异常肺动脉楔压的能力；特异度指所提出方法正确识别正常肺动脉楔压的能力。

I. K折分层交叉验证

采用5折分层交叉验证 [23] 来评估所提出的方法对异常和正常肺动脉楔压进行分类的能力。由于数据集不平衡，因此选择了分层交叉验证。该方法为数据集的每一折选取相同比例的异常和正常肺动脉楔压样本。首先，将异常和正常肺动脉楔压样本划分为十份，使用其中九份异常和正常肺动脉楔压样本训练所提出的方法，剩余一份用于测试。随后，重复这一过程九次，以依次将十折中的每一折用于测试，其余各折用于训练。此外，通过交叉验证，将训练数据集的10%划分为验证子集。在每一折中，每次迭代都将五名未在训练数据集中出现过的患者纳入测试数据集。

J. 损失函数

由于本研究使用的临床数据集存在类别不平衡，经典的交叉熵函数并不适合作为损失函数。该函数可能导致准确率较高，但敏感度或特异度极低，或者会偏向多数类。尽管所提出的方法能够正确检测异常肺动脉楔压（高敏感度）非常重要，但它们还应能够正确识别正常肺动脉楔压（高特异度）。以下加权交叉熵损失函数 [73] 被用于训练所提出的深度神经网络，以对异常和正常肺动脉楔压进行分类：

$$Loss\ Function = -\sum_{j=1}^{K} w_j \times T_j \times log(p_j) \quad (14)$$

$$w_j = 1 - \frac{number\ of\ samples\ in\ the\ j^{th} class}{number\ of\ total\ samples}, \sum_{j=1}^{K} w_j = 1 \quad (15)$$

其中，$w_j$is the weight assigned to the class j $K$is the类别数量，T_j 是地面真实值（目标）向量的 j^{th} 元素，p_j 是估计向量的j^{th} 元素。

III. 结果

A. 基准函数验证

表 S5 展示了所提出的 HHO+ 在 24 个维度为 1000 的单峰和多峰基准优化函数上的比较结果。

表中列出了 HHO+、HHO、MPA、SMA、EO、SSA 和 GWO 算法各自 30 次运行的均值和标准差。根据该表，HHO+ 在所有单峰和多峰基准优化函数上均取得了最优解。可以看出，所提出的 HHO+ 在 F1、F2、F7、F8、F11、F13、F21、F22、F23 和 F24 基准函数上，在 500 次迭代内达到了最优适应度 0，且均值和标准差均为 0。

表 I 展示了针对维度 1000 的两种非参数统计检验的比较结果：Wilcoxon 秩和检验 [74] 和 Friedman 检验 [75]。Wilcoxon 秩和检验是一种非参数统计检验，可用于确定两种算法的结果是否存在显著差异。Friedman 检验能够根据优化方法在不同基准函数上的整体表现对其进行排序。根据该表，HHO+ 取得了最佳平均排名，其后依次为 HHO、SMA、MPA、EO、GWO 和 SSA。表中符号‘+’、‘=’和‘-’分别表示，在显著性水平为 5% 时，使用 Wilcoxon 秩和检验所得结果表明，所提出的 HHO+ 显著优于、与其他优化算法平局或劣于它们。Friedman 检验还给出了各优化方法在所有基准函数上的总体排名。表 S5 和表 I 中以粗体标出了最佳结果。从表 I 可以看出，当 p值小于 0.05 时，HHO+ 在 12、22、18、24、24 和 24 个基准函数上分别优于 HHO、MPA、SMA、EO、SSA 和 GWO。尽管 Wilcoxon 秩和检验显示，HHO+ 在大多数基准函数上的结果优于其他优化方法，但在其余函数上，这一优势在统计学上并不显著。Friedman 检验结果还显示，与其他竞争算法相比，HHO+ 位列第一。

图 S6 分别展示了 F1 至 F24 的收敛曲线。从这些图中可以看出，对于单峰和多峰基准优化函数，除 F11、F12 和 F13 外，HHO+的收敛曲线均优于（收敛速度快于）其他优化算法；在 F11、F12 和 F13 上，HHO+ 排名第二。

图 S7 以对数尺度展示了所提出的 HHO+在 100 至 5000 的不同维度下，对所选基准函数 F5、F6、F9、F15、F16 和 F19（如表 S3 所示，这些函数最具挑战性，即结果并不十分接近全局最小值）的可扩展性结果。图 S8 还以普通尺度展示了所提出的 HHO+ 在 F16 和 F19 的不同维度下的可扩展性结果，以更清晰地体现 HHO+ 的优越性。从这些图中可以观察到，在低维和高维问题中，HHO+ 的表现均优于其他优化算法。

表 I 维度为 1000 时 Wilcoxon 秩和检验和 Friedman’s 检验的统计结果。非数值表示使用 Wilcoxon 秩和检验比较的两个向量中的所有元素均为零。

Fun.	HHO+	HHO	MPA	SMA	EO	SSA	GWO
F1	-	1.21e-12	1.21e-12	1.27e-05	1.21e-12	1.21e-12	1.21e-12
F2	-	3.02e-11	3.02e-11	3.02e-11	3.02e-11	3.02e-11	3.02e-11
F3	-	1.21e-12	1.21e-12	6.25e-10	1.21e-12	1.21e-12	1.21e-12
F4	-	3.02e-11	3.02e-11	5.57e-10	3.02e-11	3.02e-11	3.02e-11
F5	-	7.96e-01	3.02e-11	9.92e-11	3.02e-11	3.02e-11	3.02e-11
F6	-	7.28e-01	3.02e-11	8.10e-10	3.02e-11	3.02e-11	3.02e-11
F7	-	1.21e-12	1.21e-12	2.93e-05	1.21e-12	1.21e-12	1.21e-12
F8	-	1.21e-12	1.21e-12	3.34e-01	1.21e-12	1.21e-12	1.21e-12
F9	-	9.03e-04	3.02e-11	6.70e-11	3.02e-11	3.02e-11	3.02e-11
F10	-	1.26e-01	3.02e-11	1.44e-03	3.02e-11	3.02e-11	3.02e-11
F11	-	NaN	NaN	NaN	5.51e-03	1.21e-12	1.21e-12
F12	-	NaN	1.21e-12	NaN	1.21e-12	1.21e-12	1.21e-12
F13	-	NaN	2.85e-04	NaN	4.17e-13	1.21e-12	1.21e-12
F14	-	5.20e-01	3.02e-11	3.82e-10	3.02e-11	3.02e-11	3.02e-11
F15	-	7.28e-01	3.02e-11	3.02e-11	3.02e-11	3.02e-11	3.02e-11
F16	-	1.05e-01	3.02e-11	1.86e-09	3.02e-11	3.02e-11	3.02e-11
F17	-	3.02e-11	3.02e-11	3.02e-11	3.02e-11	3.02e-11	3.02e-11
F18	-	NaN	NaN	1.21e-12	1.21e-12	1.21e-12	1.21e-12
F19	-	3.50e-09	1.86e-06	2.61e-10	4.08e-11	4.08e-11	3.02e-11
F20	-	4.04e-01	3.02e-11	5.49e-01	3.02e-11	3.02e-11	3.02e-11
F21	-	1.21e-12	1.21e-12	1.37e-03	1.21e-12	1.21e-12	1.21e-12
F22	-	1.21e-12	1.21e-12	4.57e-12	1.21e-12	1.21e-12	1.21e-12
F23	-	1.21e-12	1.06e-12	1.21e-12	9.56e-13	1.21e-12	1.21e-12
F24	-	NaN	8.93e-13	NaN	1.14e-12	1.19e-12	1.21e-12
胜者 (+) / 平局 (=) / 败者 (-)	-	12/12/0	22/2/0	18/6/0	24/0/0	24/0/0	24/0/0
Friedman mean rank	**1.52**	2.41	4.11	2.64	4.70	6.62	5.98
Rank	**1**	2	4	3	5	7	6

表 S6 和表 S7 分别展示了优化方法（HHO+、HHO、MPA、SMA、平衡优化算法、SSA 和 GWO）在 24 个基准函数上以 1000 维度运行 30 次的计算时间，以及所提出的深度学习方法（CNN-MLP、CNN-ENN、CNN-FENN 和 CNN- FENN-HHO+）进行 30 次训练运行（10 个周期）的计算时间。从这些表中可以看出，HHO 优化算法和 CNN+MLP 网络结构的计算复杂度最低。

表 II
所提出分类方法的性能比较
在五折交叉验证中的表现。数值为平均值（标准差和p值），基于五折计算。p值根据 Wilcoxon 秩和检验计算，针对 CNN-FENN-HHO+ 与每折的性能指标另外三种方法。

方法论	网络结构	准确率 (%)	敏感度 (%)	特异度 (%)
CNN-MLP	卷积神经网络+多层感知机	72.58 (3.65, 0.03)	73.17 (3.16, 0.03)	67.31 (4.069, 0.03)
CNN-ENN	CNN+ENN	74.92 (3.43, 0.30)	75.75 (3.03, 0.30)	70.26 (3.97, 0.30)
CNN-FENN	卷积神经网络+FENN	76.37 (2.70, 0.54	77.15 (2.78, 0.54)	72.59 (3.24, 0.54)
卷积神经网络-FENN-**HHO+**	卷积神经网络+FENN	**78.25** (2.61, -)	**79.06** (2.54, -)	**73.83** (2.86, -)

B. 所提出的 FENN 和 HHO+ 在肺动脉楔压分类中的应用

表 II 比较了四种 18 层深度学习方法（CNN-MLP、CNN-ENN、CNN-FENN 和 CNN-FENN-HHO+ ），这些方法利用泵流量对 PAWP 异常和正常情况进行分类。该表给出了 PAWP 分类结果在五折交叉验证中的平均值和标准差。结果表明，所提出的 CNN-FENN-HHO+ 提高了准确率、敏感度和特异度，且优于 CNN-MLP、CNN-ENN 和 CNN-FENN 方法。表 II 还根据 Wilcoxon 秩和检验给出了 p值（95% 置信水平），以展示各方法之间的统计显著性。结果表明，所提出的 CNN-FENN-HHO+ 方法在统计上优于 CNN-MLP 方法。

IV. 讨论

本研究通过结合 HHO、IEEA 和 QOBL 算法，提出了一种改进的 HHO（HHO+）算法，并在 24 个单峰和多峰基准函数上进行了验证。尽管如表 S6 所示，结合 IEEA、QOBL 和 HHO 算法增加了 HHO+ 算法的计算复杂度，但可以更有效地避免 HHO 陷入停滞。所提出的 IEEA 和采用的 QOBL 概念生成了一组解，能够改善原始 HHO 算法的收敛速度和全局解。正如图 S6 所示，这正是所提出的 HHO+ 在计算时间成本方面的优势，因为单纯增加迭代次数并不能提升优化方法的性能。在该图中，对于大多数基准函数，除 HHO+ 之外的所有优化算法的收敛曲线在若干次迭代后均保持不变。基准函数 F1、F3、F7、F8、F11、F13、F21、F22、F23 和 F24 上的均值和标准差均为 0，这表明所提出的 HHO+ 在单峰和多峰基准函数上都具有鲁棒性。总体而言，表 S5 和表 I 中的实验分析和统计分析（Friedman 平均秩和 Wilcoxon 秩检验）表明，与经典 HHO 和其他先进算法相比，所提出的 HHO+ 在寻找全局最优解方面具有优越性。图 S7 和图 S8 表明，即使在高维问题中，HHO+ 的性能仍始终优于其他方法，而其他方法的性能会随着维度增加而下降。

本文提出了一种名为 FENN 的新型 Elman神经网络，以提升所研究问题的分类性能。此外，本文采用所提出的 HHO+ 优化 CNN-FENN 的三个超参数，即 ILR、LR DF 和 DP，以对异常和正常肺动脉楔压进行分类。表 II 所示的结果表明，所提出的 CNN-FENN-HHO+ 方法提升了准确率、敏感度和特异度。这一改进支持了本研究的假设：循环神经网络中输出层在两个连续时间点之间、隐藏层在两个连续时间点之间、输入层到输出层以及输出层到隐藏层的连接，可能充分利用输入、隐藏和输出变量特征中的长期、空间和时间信息，从而实现更高的性能。在这四种深度学习方法中，卷积滤波器从泵流量信号中自动提取了适当的特征。尽管表 S7 所示的 CNN-FENN-HHO+训练和测试时间表明，由于 FENN 中神经元之间增加了额外连接，其计算复杂度高于其他算法，但该算法在测试数据集中处理每次心跳仅需约 1 毫秒，足以支持该方法的实时应用。

本研究使用了一个不平衡的临床数据集，用于分类异常和正常的肺动脉楔压。不平衡的训练数据集可能使训练算法偏向多数类，从而阻碍训练过程的收敛。此外，这还可能影响所提出方法的泛化能力以及在测试数据集上的性能。尽管过采样和欠采样等数据增强策略可以平衡各类别的样本数量，但它们容易导致过拟合或丢失有用信息 [76], [77]。因此，本研究提出了加权损失函数，以解决这一问题。

Lai 等人 [11] 采用多元线性回归，利用心力衰竭患者舒张期 HVAD 血流波形的斜率估算肺动脉楔压。然而，该方法得到的 r^2 仅为 0.54，表现较差。此外，还通过敏感度和特异度评估舒张期 HVAD 血流波形斜率区分肺动脉楔压 ≥ 20 mmHg（高肺动脉楔压）的能力。结果显示，识别高肺动脉楔压的敏感度为 77%，特异度为 86%。然而，在本研究中，低肺动脉楔压和高肺动脉楔压均被设定为异常肺动脉楔压，其余则设定为正常肺动脉楔压。此外，训练、验证和测试所使用的数据量尚不明确，而这可能会显著改变结果。

Grinstein 基于 15 名 HVAD 患者提出，利用心室充盈期的斜率估算高肺动脉楔压（肺动脉楔压 ≥ 18 mmHg）。不过，此处同样未明确训练、验证和测试所使用的数据量；多变量回归得出的结果显示，仅针对高肺动脉楔压的敏感度为 87%，特异度为 95%。然而，在这项研究中，低肺动脉楔压和高肺动脉楔压均被设定为异常肺动脉楔压，并采用 25 名 HVAD 患者进行 5 折交叉

验证以评估结果。Imamura 等人 [79] 采用线性回归，利用心室充盈期的斜率估算高肺动脉楔压（肺动脉楔压 ≥ 18 mmHg）。结果显示，仅针对高肺动脉楔压的预测敏感度和特异度分别为 91.5% 和 95.2%。

尽管本研究仅关注利用泵流量对正常和异常肺动脉楔压进行分类，但它有望借助所提出的深度学习方法，扩展至检测多种心律失常，并利用心电信号进行实时监测。此外，所提出的 HHO+ 算法可用于解决搜索空间未知的实际问题，例如路径规划、特征选择、发电系统、制造流程、图像处理、生物信息学和太阳能光伏参数估计[80]。

本研究的局限之一是，所采用的方法是在一个规模较小的临床数据集上进行比较和验证的。因此，需要更大规模的临床数据集来训练和验证所提出的方法。此外，CNN-FENN-HHO+ 的优化和训练的计算复杂度高于其他方法。不过，CNN-FENN-HHO+ 方法的优化和训练是离线进行的，因此在一定程度上可以避免这一问题。

通过采用更复杂的神经网络，将 CNN 滤波器提取的最终特征映射到标记类别，可以进一步提高所提方法的准确率、敏感度和特异度。此外，使用更大的训练数据集可能会提升深度网络的性能。本研究使用的临床数据集相对较小，这可能限制了所比较网络的性能。因此，未来的工作将包括测试其他神经网络架构，并收集更多临床数据，以便在独立数据集上对这些网络进行训练和验证。

V. 结论

本文提出了一种新型改进的 HHO（HHO+）优化算法，并通过对 24 个单峰和多峰基准函数进行优化验证了该算法。结果表明，所提出的 HHO+ 能够进一步提升全局解并加快收敛速度。此外，本文提出了一种名为 FENN 的新型 Elman神经网络，以提升分类问题的性能指标。采用所提出的 HHO+ 对 CNN-FENN 的三个超参数 ILR 、 LRDF 和 DP 进行优化。此外，本文开发并比较了四种 18 层深度学习方法，即 CNN-MLP、CNN-ENN、CNN-FENN 和 CNN-FENN-HHO+ ，用于利用泵流量对异常和正常 PAWP 进行分类。采用五折交叉验证，在不平衡的临床数据集上评估所提出的方法。通过卷积滤波器从低通滤波后的泵流量信号中自动提取有用特征。结果表明，结合 CNN、FENN 和 HHO+ 对异常和正常 PA WP 进行分类，可提升分类性能。基于泵流量信号对 PAWP 进行分类，可用于实时调整泵速，从而降低心力衰竭患者发生肺淤血和心室吸空等危险事件的可能性。此外，所提出的方法可在移动软件平台上实现，并将识别出的异常病例报告给医院，从而降低心力衰竭患者的死亡率。

致谢

作者谨此感谢国家卫生与医学研究委员会卓越研究中

参考文献

[1] M. A. Simon, J. Watson, J. T. Baldwin, W. R. Wagner, 和 H. S. Borovetz, 《机械循环支持装置应用中的当前与未来考量》, Annu. Rev. Biomed. Eng., 第 10 卷, 第 1 期, 第 59–84 页, 2019, doi: 10.1146/annurev.bioeng.9.060906.151856。[2] A. W. Cai, S. Islam, S. R. Hankins, W. Fischer, 和 H. J. Eisen, 《晚期心力衰竭治疗中的机械循环支持》, Am. J. Transplant., 第 17 卷, 第 12 期, 第 3020–3032 页, 2017, doi: 10.1111/ajt.14403。[3] S. D. Gregory, M. C. Stevens, 和 J. F. Fraser, 《机械循环与呼吸支持》。Academic Press, 2017。[4] M. Fetanat, M. Stevens, C. Hayward, 和 N. H. Lovell, 《一种适用于植入式心脏泵的生理控制系统，可适应患者间和患者内差异》, IEEE生物医学工程汇刊, 第 67 卷, 第 4 期, 第 1167–1175 页, 2020, doi: 10.1109/tbme.2019.2932233。[5] M. Fetanat, M. Stevens, C. Hayward, 和 N. H. Lovell, 《基于实时深度卷积神经网络的植入式心脏泵无传感器控制系统》, IEEE生物医学工程汇刊, 第 68 卷, 第 10 期, 第 3029–3038 页, 2021, doi: 10.1109/TBME.2021.3061405。[6] M. C. Stevens 等, 《左心室辅助装置的弗兰克-斯塔林控制》, 2011年 IEEE 工程医学与生物学学会年度国际会议, 第 1335–1338 页, 2011, doi: 10.1109/IEMBS.2011.6090314。[7] A. C. Guyton 和 J. E. Hall, 《医学生理学》。2006。[8] M. C. Stevens, S. Wilson, A. Bradley, J. Fraser, 和 D. Timms, 《采用主从方法对作为双心室辅助装置的双旋转泵进行生理控制》, Artif. Organs, 第 38 卷, 第 9 期, 第 766–774 页, 2014, doi: 10.1111/aor.12303。[9] M. C. Stevens 等, 《将左心室辅助装置用作右心室辅助装置时三种不同泵运行模式的体外和体内表征》, Artif. Organs, 第 38 卷, 第 11 期, 第 931–939 页, 2014, doi: 10.1111/aor.12289。[10] M. Fetanat, M. Stevens, C. Hayward, 和 N. Lovell, 《基于深度卷积神经网络的LVAD自适应无传感器控制》, J. Hear. Lung Transplant., 第 40 卷, 第 4 期, 第 S172 页, 2021, doi: 10.1016/j.healun.2021.01.507。[11] J. V. Lai, K. Muthiah, P. S. Macdonald, P. Jansz, 和 C. S. Hayward, 《基于泵流量波形分析的左心室辅助装置预负荷估计》, J. Hear. Lung Transplant., 第 36 卷, 第 2 期, 第 240–242 页, 2017, doi: 10.1016/j.healun.2016.10.015。[12] J. Wang, 《一种基于卷积神经网络和改进型Elman神经网络的心房颤动信号分类深度学习方法》, 《未来一代计算机系统》, 第 102 卷, 第 670–679 页, 2020, doi: 10.1016/j.future.2019.09.012。[13] R. U. Haque, A. L. Pongos, C. M. Manzanares, J. J. Lah, A. I. Levey, 和 G. D. Clifford, 《利用分布式平板电脑环境中的眼动追踪，通过深度卷积神经网络和迁移学习测量认知障碍》, IEEE生物医学工程汇刊, 第 68 卷, 第 1 期, 第 11–18 页, 2021, doi: 10.1109/TBME.2020.2990734。[14] B. Alizadeh Kharazi 和 A. H. Behzadan, 《利用图像处理和深度神经网络从街景照片绘制洪水深度图》, Comput. Environ. Urban Syst., 第 88 卷, 3月号, 第 101628 页, 2021, doi: 10.1016/j.compenvurbsys.2021.101628。[15] G. Sannino 和 G. De Pietro, 《一种用于心律失常检测的基于深度学习的心电图心搏分类方法》, 《未来一代计算机系统》, 第 86 卷, 第 446–455 页, 2018, doi: 10.1016/j.future.2018.03.057。[16] U. B. Baloglu, M. Talo, O. Yildirim, R. S. Tan, 和 U. R. Acharya, 《利用多导联心电信号和深度卷积神经网络对心肌梗死进行分类》, Pattern Recognit. Lett., 第 122 卷, 第 23–30 页, 2019, doi: 10.1016/j.patrec.2019.02.016。[17] D. Cimr 等, 《利用卷积神经网络从心冲击图信号中计算机辅助检测呼吸障碍

》，《信息科学》，第 541 卷，第 207–217 页，2020，doi: 10.1016/j.ins.2020.05.051。[18] S. Zhou 和 B. Tan，《利用混合深度学习 CNN-ELM进行心电图软计算》，应用软计算期刊，第 86 卷，105778，2020，10 1016 2019 105778 p. doi: . /j.asoc. . .[19] M. U. Zahid 等，《利用一维卷积神经网络检测低质量动态心电图中的R峰》，IEEE生物医学工程汇刊，第 1–1 页，2021，doi: 10.1109/tbme.2021.3088218。[20] X. Xu 和 H. Liu，《利用卷积神经网络进行心电图心搏分类》，IEEE Access，第 8 卷，第 8614–8619 页，2020，doi: 10.1109/ACCESS.2020.2964749。[21] W. Cai 等，《利用深度神经网络从12导联心电图中准确检测心房颤动》，计算机生物学与医学，第 116 卷，2019年5月号，第 103378 页，2020，doi: 10.1016/j.compbiomed.2019.103378。[22] O. Yildirim, U. B. Baloglu, R. S. Tan, E. J. Ciaccio, 和 U. R. Acharya，《利用深度编码特征和长短期记忆网络进行心律失常分类的新方法》，生物医学计算方法与程序，第 176 卷，第 121–133 页，2019，doi: 10.1016/j.cmpb.2019.05.004。[23] U. R. Acharya 等，《利用卷积神经网络自动识别可电击和不可电击的危及生命的室性心律失常》，《未来一代计算机系统》，第 79 卷，第 952–959 页，2018，doi: 10.1016/j.future.2017.08.039。[24] H. M. Lynn, S. B. Pan, 和 P. Kim，《一种基于循环神经网络的生物特征心电图分类深度双向门控循环单元网络模型》，IEEE Access，第 7 卷，第 145395–145405 页，2019，doi: 10.1109/ACCESS.2019.2939947。[25] R. He 等，《结合深度残差网络和双向长短期记忆网络的自动心律失常分类》，IEEE Access，第 7 卷，第 102119–102135 页，2019，doi: 10.1109/access.2019.2931500。[26] M. M. Al Rahhal, Y. Bazi, H. Almubarak, N. Alajlan, 和 M. Al Zuair，《采用焦点损失和图像生成的密集卷积网络用于心电图分类》，IEEE Access，第 7 卷，第 182225–182237 页，2019，doi: 10.1109/ACCESS.2019.2960116。[27] R. Srivastva, A. Singh, 和 Y. N. Singh，《PlexNet：一种用于人体识别的快速、稳健的心电图生物特征识别系统》，《信息科学》，第 558 卷，第 208–228 页，2021，doi: 10.1016/j.ins.2021.01.001。[28] K. Jafarian, V. Vahdat, S. Salehi, 和 M. Mobin，《利用浅层和端到端深度神经网络自动检测和定位心肌梗死》，应用软计算期刊，第 93 卷，第 106383 页，2020，doi: 10.1016/j.asoc.2020.106383。[29] Y. Chen, J. Lv, Y. Sun, 和 B. Jia，《利用持续时间长短期记忆神经网络进行心音分割》，应用软计算期刊，第 95 卷，第 106540 页，2020，doi: 10.1016/j.asoc.2020.106540。[30] G. Wang 等，《基于循环神经网络和主动学习的全局可更新心电图心搏分类系统》，《信息科学》，第 501 卷，第 523–542 页，2019，doi: 10.1016/j.ins.2018.06.062。[31] J. Wang，《基于卷积神经网络和改进型Elman神经网络自动检测心电信号中的心房颤动和心房扑动》，《Knowledge-Based Syst.》，第 193 卷，第 105446 页，2020，doi: 10.1016/j.knosys.2019.105446。[32] C. He 等，《迈向安全的视网膜显微手术：基于循环神经网络的主动介入控制框架的开发与评估》，IEEE生物医学工程汇刊，第 67 卷，第 977 页，2020，4，第 966 页，doi: . /TBME. . .[33] A. Chocron 等，《利用深度循环神经网络远程估计心房颤动负荷》，IEEE生物医学工程汇刊，第 68 卷，第 8 期，第 2447–2455 页，2021。[34] M. Wang, C. Lian, D. Yao, D. Zhang, M. Liu, 和 D. Shen，《利用卷积循环网络对功能性磁共振成像进行时空依赖建模和网络枢纽检测》，IEEE生物医学工程汇刊，第 67 卷，第 8 期，第 2241–2252 页，2020，doi: 10.1109/TBME.2019.2957921。[35] G. Ren, Y. Cao, S. Wen, T. Huang, 和 Z. Zeng，《一种具有新学习率方案的改进型Elman神经网络》，《神经计算》，第 286 卷，第 11–18 页，2018，doi: 10.1016/j.neucom.2018.01.046。[36] K. H. Lu, C. M. Hong, 和 Q. Xu，《采用改进型引力搜索算法控制的循环小波Elman神经网络，用于海上风能与波浪能一体化发电系统》，《能源》，第170卷，第40–52页，2019年，doi: 10.1016/j.energy.2018.12.084。

[37] Y. Wang、L. Wang、F. Yang、W. Di 和 Q. Chang，“神经网络中直接输入到输出连接的优势：用于股票指数预测的 Elman 网络”，信息科学，第547卷，第1066–1079页，2021，doi：10.1016/j.ins.2020.09.031。

[38] Y. Xu 等，“用于全局优化任务的高效混沌变异蛾焰启发式优化器”，《Expert Syst. Appl.》，第129卷，第2019期，第135–155页，2019年，doi: 10.1016/j.eswa.2019.03.043。

[39] A. Darwish、D. Ezzat 和 A. E. Hassanien，“一种基于卷积神经网络和正交学习粒子群优化算法的优化模型，用于植物病害诊断”，Swarm Evol. Comput.，第 52 卷，2019 年 7 月，第 100616 页，2020年，doi：10.1016/j.swevo.2019.100616。

[40] R. ZahediNasab 和 H. Mohseni，“基于神经进化的卷积神经网络及自适应激活函数”，《神经计算》，第 381 卷，第 306–313 页，2020年，doi：10.1016/j.neucom.2019.11.090。

[41] I. Ilievski、T. Akhtar、J. Feng 和 C. A. Shoemaker，“使用确定性径向基函数代理模型高效优化深度学习算法的超参数”，第 31 届 AAAI 人工智能大会（ AAAI 2017 ），第 822–829 页，2017 年。

[42] S. Nazir、S. Patel 和 D. Patel，“评估卷积神经网络的超参数优化与加速”，《国际人工智能与机器学习杂志》，第 10 卷，第 2 期，第 1–17 页，2020年，doi：10.4018/ijaiml.2020070101。

[43] E. Bochinsk、T. Senst 和 T. Sikora，“基于进化算法的卷积神经网络委员会超参数优化”，2017 IEEE 国际图像处理会议，第 3–7 页，2017年。

[44] A. A. Heidari、S. Mirjalili、H. Faris、I. Aljarah、M. Mafarja 和 H. Chen，“哈里斯鹰优化：算法与应用”，《未来一代计算机系统》，第 97 卷，第 849–872 页，2019年，doi：10.1016/j.future.2019.02.028。

[45] M. Fetanat、S. Haghzad 和 S. Bagheri Shouraki，《基于进化方法的动态移动机器人路径规划优化》，载于 2015 年 AI & Robotics (IRANOPEN)，2015 年 4 月，第 1–7 页，doi：10.1109/RIOS.2015.7270743。

[46] R. Eberhart 和 James Kennedy，《一种采用粒子群理论的新型优化器》，国际微型机械与人类科学研讨会，第 39 43, 1999，页–在线。可访问：https://bytebucket.org/12er/pso/raw/b448ff0db375c1ac0c55855e9f19aced08b44ca6/doc/literature/Variants/topology/A new Optimizer using Particle Swarm Theory.pdf。

[47] R. Storn 和 K. Price，《差分进化——一种在连续空间中进行全局优化的简单高效启发式算法》，《全球优化期刊》，第 11 卷，第 341–359 页，1997 年，doi：10.1071/AP09004。

[48] E. Rashedi、H. Nezamabadi-pour 和 S. Saryazdi，“GSA：一种引力搜索算法”，信息科学，第 179 卷，第 13 期，第 2232–2248 页，2009 年，doi: 10.1016/j.ins.2009.03.004。

[49] A. Faramarzi、M. Heidarinejad、S. Mirjalili 和 A. H. Gandomi，“海洋捕食者算法：一种自然启发式元启发算法”，《Expert Syst. Appl.》，第 152 卷，文章编号 113377，2020年，doi：10.1016/j.eswa.2020.113377。

[50] S. Li、H. Chen、M. Wang、A. A. Heidari 和 S. Mirjalili，“黏菌算法：一种随机优化新方法”，《未来一代计算机系统》，第 111 卷，第 300–323 页，2020 年，doi：10.1016/j.future.2020.03.055。

[51] A. Faramarzi、M. Heidarinejad、B. Stephens 和 S. Mirjalili，“平衡优化器：一种新型优化算法”，《Knowledge-Based Syst.》，第 191 卷，文章编号 105190，2020年，doi：10.1016/j.knosys.2019.105190。

[52] S. Mirjalili、A. H. Gandomi、S. Z. Mirjalili、S. Saremi、H. Faris 和 S. M. Mirjalili，“囊泡虫群算法：一种用于工程设计问题的生物启发式优化器”，《Adv. Eng. Softw.》，第 114 卷，第 163–191 页，2017，doi: 10.1016/j.advengsoft.2017.07.002。

[53] S. Mirjalili、S. M. Mirjalili 和 A. Lewis，“灰狼优化算法”，《Adv. Eng. Softw.》，第 69 卷，第 46–61 页，2014，doi: 10.1016/j.advengsoft.2013.12.007。

[54] D. Wei、Z. Wang、L. Si 和 C. Tan，“受布道启发的群体智能算法及其应用”，《Knowledge-Based Syst.》，第 211 卷，页码 106552，2021，doi: 10.1016/j.knosys.2020.106552。

[55] D. Połap 和 M. Woźniak，“红狐优化算法”，《Expert Syst. Appl.》，第 166 卷，2019年11月号，文章编号 114107，2021，doi:

10.1016/j.eswa.2020.114107.[56] B. Abdollahzadeh、F. S. Gharehchopogh 和 S. Mirjalili，“非洲秃鹫优化算法：一种用于全局优化问题的新型自然启发式元启发式算法”，Comput. Ind. Eng.，第 158 卷，1 月号，文章编号 107408，2021，doi：10.1016/j.cie.2021.107408.[57] B. Abdollahzadeh、F. Soleimanian Gharehchopogh 和 S. Mirjalili，“人工大猩猩群优化器：一种用于全局优化问题的新型自然启发式元启发式算法”，Int. J. Intell. Syst.，第 36 卷，第 10 期，第 5887–5958 页，2021，doi：10.1002/int.22535.[58] S. Gupta、K. Deep 和 S. Mirjalili，“一种用于数值优化的高效平衡优化器及其变异策略”，应用软计算期刊，第 96 卷，文章编号 106542，2020，doi：10.1016/j.asoc.2020.106542.[59] D. H. Wolpert 和 W. G. Macready，“优化中的免费午餐定理”，IEEE Trans. Evol. Comput.，第 1 卷，82，1997，1，67 10 1109 4235 585893，第 期，第 页 – doi：. / . .[60] S. Gupta、K. Deep、A. A. Heidari、H. Moayedi 和 M. Wang，“采用高级转换规则的基于对立学习的哈里斯鹰优化：原理与分析”，《Expert Syst. Appl.》，第 158 卷，文章编号 113510，2020，doi：10.1016/j.eswa.2020.113510.[61] H. Chen、A. A. Heidari、H. Chen、M. Wang、Z. Pan 和 A. H. Gandomi，“多种群差分进化辅助哈里斯鹰优化框架与案例研究”，《未来一代计算机系统》，第 111 卷，第 175–198 页，2020，doi：10.1016/j.future.2020.04.008.[62] M. A. Elaziz、A. A. Heidari、H. Fujita 和 H. Moayedi，“用于全局优化和多级图像阈值分割问题的竞争链式哈里斯鹰优化器”，应用软计算期刊，第 95 卷，文章编号 106347，2020，doi：10.1016/j.asoc.2020.106347.[63] S. Jiao 等，“用于光伏模型参数估计的正交自适应哈里斯鹰优化”，《能源》，第 203 卷，文章编号 117804，2020，doi：10.1016/j.energy.2020.117804.[64] E. H. Houssein、M. E. Hosney、D. Oliva、W. M. Mohamed 和 M. Hassaballah，“一种用于药物设计与发现的新型哈里斯鹰优化与支持向量机混合方法”，Comput. Chem. Eng.，第 133 卷，文章编号 106656，2020，doi：10.1016/j.compchemeng.2019.106656.[65] K. Fukushima，“Neocognitron：一种用于模式识别机制的自组织神经网络模型，不受位置移动影响”，Biol. Cybern.，第 36 卷，第 4 期，第 193–202 页，1980年，doi：10.1007/BF00344251.[66] Y. LeCun、L. Bottou、Y. Bengio 和 P. Haffner，“应用于文档识别的基于梯度的学习”，Proc. IEEE，第 86 卷，第 11 期，第 2278–2323 页，1998年，doi：10.1109/5.726791.[67] H. R. Tizhoosh，“基于对立的学习：一种机器智能新方案”，Proc. - Int. Conf. Comput. Intell. Model. Control Autom. CIMCA 2005 Int. Conf. Intell. Agents, Web Technol. Internet，第1卷，第695–701页，2005年，doi: 10.1109/cimca.2005.1631345。

[68] S. Rahnamayan、H. R. Tizhoosh和M. M. A. Salama，“准反向差分进化”，载于IEEE进化计算大会，2007年，第2229–2236页。

[69] H. Chen、W. Li和X. Yang，“一种基于准反向的混沌机制鲸鱼优化算法，用于全局优化问题”，《Expert Syst. Appl.》，第158卷，第113612页，2020年，doi: 10.1016/j.eswa.2020.113612。

[70] D. P. Kingma和J. L. Ba，“Adam：一种随机优化方法”，载于第3届国际学习表征会议，ICLR 2015 - 会议论文集，2015年，第1–15页。

[71] M. A. Elaziz 和 S. Mirjalili，“一种用于改进鲸鱼优化算法初始种群的超启发式”，Knowledge-Based Syst.，第172卷，第42–63页，2019年，doi：10.1016/j.knosys.2019.02.010。

[72] K. He、X. Zhang、S. Ren 和 J. Sun，“深入研究整流器：在 ImageNet分类上超越人类水平的表现”，Proc. IEEE Int. Conf. Comput. Vis.，第2015 Inter卷，第1026–1034页，2015年，doi：10.1109/ICCV.2015.123。

[73] M. Ben naceur、M. Akil、R. Saouli 和 R. Kachouri，“基于深度学习的选择性注意力机制，利用重叠图像块和多类加权交叉熵实现全自动脑肿瘤分割”，Med. Image Anal.，第63卷，2020年，doi：10.1016/j.media.2020.101692。

[74] B. Bulletin，“通过排序方法进行个体比较”，《Biometrics Bull.》，第1卷，第6期，第80–83页，1945年。

[75] J. Demšar，“多个数据集上分类器的统计比较”，《J. Mach. Learn. Res.》，第7卷，第1–30页，2006年。

[76] P. Cao 等，“一种用于增强深度神经网络以检测心房颤动的新型数据增强方法”，《Biomed. Signal Process. Control》，第56卷，第101675页，2020年，doi：10.1016/j.bspc.2019.101675。

[77] J. Jiang、H. Zhang、D. Pi 和 C. Dai，“一种用于不平衡心搏分类的新型多模块神经网络系统”，《Expert Syst. Appl.》，第1卷，第100003页，2019年，doi：10.1016/j.eswax.2019.100003。

[78] J. Grinstein 等人，“HVAD 波形分析作为肺毛细血管楔压的无创标志物：迈向开发智能左心室辅助装置泵的第一步”，ASAIO J.，第 64 卷，第 1 期，第 10–15 页，2018年，doi: 10.1097/MAT.0000000000000604。

[79] T. Imamura 等人，“HVAD 血流波形估算左心室充盈压”，J. Card. Fail.，第 26 卷，第 4 期，第 342–348 页，2020年，doi: 10.1016/j.cardfail.2020.01.012。

[80] S. Mirjalili、J. S. Dong、A. Lewis 和 L. Reviews，《自然启发式优化器：理论、文献综述与应用》。Springer，2020年。