一种深度学习方法：利用可穿戴心震图描记术（心震图）诊断主动脉瓣狭窄，并预测通过四维血流磁共振成像获得的主动脉血流动力学

Mahmoud E. Khani[1], Ethan M. I. Johnson[1], Aparna Sodhi[2], Joshua D. Robinson[1,2,3], Cynthia K. Rigsby[1,2,3], Bradly D. Allen[1], 和 Michael Markl[1,4]

[1]西北大学芬伯格医学院放射科，美国伊利诺伊州芝加哥 60611

[2]安与罗伯特·H·卢里儿童医院，美国伊利诺伊州芝加哥 60611

[3]西北大学芬伯格医学院儿科，美国伊利诺伊州芝加哥 60611

[4]西北大学麦考密克工程学院生物医学工程系，美国伊利诺伊州埃文斯顿 60208

摘要

本文探讨了利用可穿戴心震图（SCG）设备获取的心震图信号，通过深度学习预测四维血流磁共振成像测得的主动脉血流指标。四维血流磁共振成像能够全面评估心血管血流动力学，但成本高且耗时。我们假设，深度学习可根据心震图信号识别血流中的病理变化，例如心脏瓣膜疾病患者收缩期峰值流速 V_{max} 升高。我们还研究了该深度学习技术区分以下人群的能力：确诊为主动脉瓣狭窄（AS）的患者、未患 AS 且有二叶式主动脉瓣（BAV）的患者、未患 AS 且有机械主动脉瓣（MAV）的患者，以及主动脉瓣正常的健康受试者（三叶式主动脉瓣（TAV））。在一项纳入 77 名受试者的研究中，所有受试者均在同一天接受了四维血流磁共振成像和心震图检查。结果发现，利用深度学习和心震图信号获得的 V_{max} 值与四维血流磁共振成像测得的结果一致性良好。此外，对 TAV、BAV、MAV 和 AS 受试者进行分类时，ROC 曲线下面积分别为 92%、95%、81% 和 83%。这表明，使用低成本可穿戴电子设备获取的心震图可能有助于补充四维血流磁共振成像检查，或作为主动脉瓣疾病的筛查工具。

引言

磁共振成像（MRI）是临床评估心血管疾病的重要工具。相位对比磁共振成像（PC-MRI），尤其是四维血流磁共振成像，已成为评估心脏瓣膜、主动脉或肺部疾病患者心血管血流功能变化的常规技术 [1-13]。四维血流磁共振成像可全面评估其时间和空间

心血管血流动力学的演变：通过三方向速度编码获取随时间分辨的三维（x-y-z）血流速度测量 [14-17]。此外，还可以根据测得的血流速度回顾性地获取多种心脏血流指标，如收缩期峰值流速、反流分数和壁面剪切应力 [18-29]。尽管已开发出高效的临床应用四维血流成像方案 [30-37]，但由于磁共振序列复杂且四维血流分析计算需求高，这项技术仍被认为成本高、耗时长。为此，在开具全面心脏磁共振成像检查前，采用经济高效的方法对主动脉血流动力学进行初步评估，有助于诊断异常。本研究旨在探究可穿戴心震图描记术（SCG）设备预测主动脉血流指标的效用，这些指标与四维血流磁共振成像所得指标相似，并评估其诊断主动脉瓣病变的能力。

心震图信号是在胸部表面测得的心脏振动的无创测量结果 [38-52]。这些振动与心脏的机械活动有关，例如心脏收缩、瓣膜关闭以及血液动量的变化 [49]。例如，研究表明，心房收缩期会产生低频心震图波形分量，而心室收缩期会产生高振幅波形；第一和第二心音则会产生两次高频振动 [43]。此外，同步采集心震图和心电图（ECG）发现，各种生理事件的发生时序（例如二尖瓣和主动脉瓣的开放与关闭，以及快速充盈或射血）与心震图波形中的各种特征相对应 [45]。然而，受体质指数、性别、年龄以及其他人口统计学和健康特征等因素差异的影响，心震图脉冲很容易出现个体间差异，因此难以得出一致的临床推断 [53]。此外，心震图设备在胸部的放置位置会影响记录到的波形形态。最后，心震图振动的振幅相对较低，且容易受到受试者运动伪影或呼吸运动的干扰，进而可能导致对诊断特征的误判 [43]。

本研究旨在采用一种新的深度学习方法，探究通过心震图（SCG）测得的胸部振动与利用四维血流磁共振成像获得的心脏血流指标之间的关系。我们将与心电图同步的心震图信号尺度图输入卷积神经网络（CNN）模型，用于心脏参数的回归或分类。此外，我们还使用基于体质指数、性别和年龄等人口统计学属性的多层感知机（MLP），以校正心震图中的个体间差异。我们假设，这种深度学习方法可用于根据心震图脉搏推断血流中的病理变化，例如主动脉瓣疾病患者收缩期峰值流速（V_{max}）升高。此外，由于血流异常（例如 V_{max} 升高）表明存在主动脉瓣并发症，我们还假设该技术可用于诊断各种主动脉瓣状况，例如二叶式主动脉瓣或机械主动脉瓣（BAV 和 MAV）以及主动脉瓣狭窄（AS），并将其与主动脉瓣正常的健康受试者（三叶式主动脉瓣，TAV）区分开来。

方法

1. 研究队列

本研究经机构审查委员会（IRB）批准，所有参与者均签署了知情同意书。我们招募了46名健康受试者（女性20名，年龄：45.9 ± 17.2岁），他们均无已知心血管疾病史；另招募了31名主动脉瓣疾病患者（女性6名，年龄：32.6 ± 20.9岁）。患者中，1人主动脉瓣正常（三叶式主动脉瓣，TAV），21人患有二叶式主动脉瓣（BAV），9人接受了机械瓣膜植入。此外，12名患者被诊断为不同程度的主动脉瓣狭窄（AS）：2人属轻度，6人属中度，4人属重度。

2. 四维血流磁共振成像的采集与分析

四维血流磁共振成像采用1–3 mm的空间分辨率、30–40 ms的时间分辨率，以及150–375 cm/s的速度编码（VENC），并使用1.5T或3T扫描仪进行。磁共振成像在自由呼吸状态下进行，采用导航呼吸控制及前瞻性或回顾性门控，扫描范围覆盖整个胸主动脉。

四维血流数据的预处理包括涡流校正、速度反混叠，以及应用深度学习工具自动生成胸主动脉的三维分割[54]。该分割用于对四维血流速度数据进行掩膜处理，并通过在靠近分支血管处放置一个垂直于中心线的平面，将升主动脉（AAo）从主动脉根部至分支血管处手动勾画出来。如图1(a)所示，通过对升主动脉内所有体素进行体积分析并剔除离群值，计算升主动脉内的收缩期峰值流速V_{max} [55]。所有四维血流磁共振成像分析均使用MATLAB（MathWorks，美国马萨诸塞州纳蒂克）的自定义代码完成。

3. 心震图分析

我们使用定制设计的可穿戴心脏传感器（图 1(b)）采集磁共振成像前的胸部三方向加速度。该传感器内置微机电系统加速度计（采样率为 1 kHz，灵敏度为 2 μs/m² ）。受试者仰卧时，将心震图设备放置在其胸骨上。加速度记录以同步采集的心电信号中的 R 波为时间参考，逐搏进行对齐。图 1(c) 展示了门控心电图信号示例，图 1(d-f) 展示了加速度计在 5 s 内记录的三个方向上的加速度。每次心搏时，根据三个方向加速度的合幅值计算一个心震图脉搏，即，

$$\mathrm{scg_i}(t) = \sqrt{\mathrm{acc}_{i,x}^2(t) + \mathrm{acc}_{i,y}^2(t) + \mathrm{acc}_{i,z}^2(t)} \quad (1)$$

其中，下标 i 表示心搏编号，下标 x、 y 和 z 表示测得加速度的方向。图 1(g) 展示了如何利用心电图记录对心震图信号进行门控。通过这种方式，为每位受试者测量并处理了多条心震图信号，每条

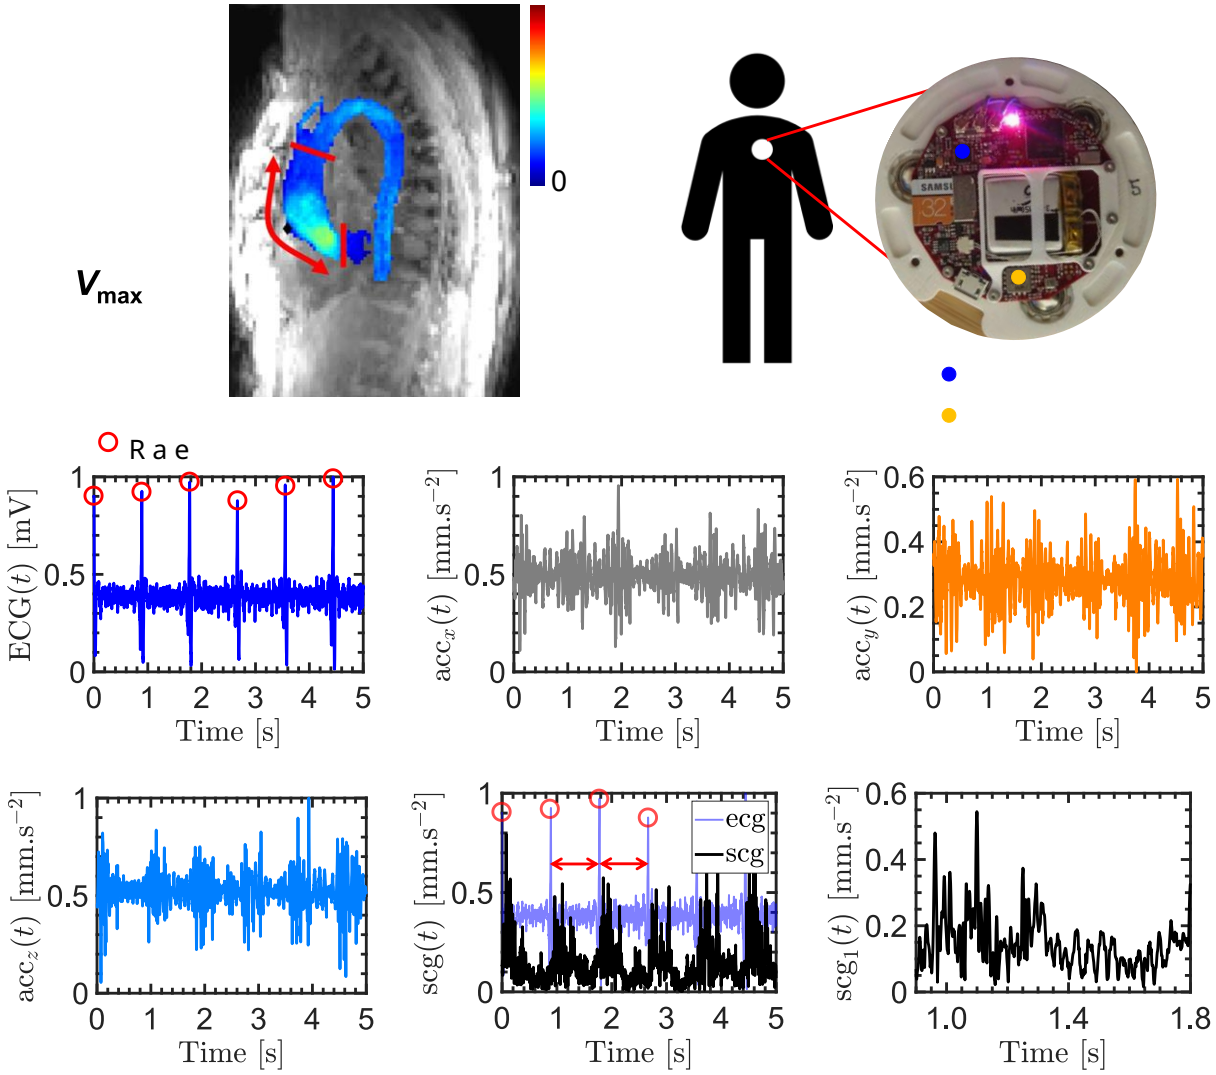


图1。**(a)**通过以下方式推导 V_{max}： 在完整的四维血流磁共振成像测量中，使用基于人工智能的三维分割对胸主动脉进行分割，并手动勾画升主动脉；**(b)**心震图设备；**(c)**心电图信号示例；**(d-f)**分别在x、 y和z 方向测得的加速度信号；**(g)**将心震图与同步采集的心电信号中的 R 波进行门控；**(h)**一个心搏周期内测得的心震图脉搏示例。

对应心电图中的一个 R-R 周期，图 1(h) 展示了一个示例。需要注意的是，并非所有受试者的测量时长都相同，因此不同受试者获得的心震图信号数量也有所不同。

4. 信号调理

在 MATLAB 中，我们采用以下步骤对心震图信号进行预处理。首先，使用具有无限冲激响应（IIR）函数的最小阶椭圆滤波器进行高通滤波，以去除低频伪影。该滤波器的阻带衰减为 60 dB，阻带频率为 8.4 Hz，通带频率为 10 Hz，通带

波纹为 0.1。使用布莱克曼窗将边界点平滑渐变至零。随后进行小波去噪，以提高信号的信噪比（SNR）。采用具有四个消失矩的对称小波（“sym4”），所用的去噪方法为结合硬阈值规则的错误发现率（FDR）方法。噪声估计采用依赖分解层级的方式，分解层数取以下数值的整数部分 $\log_2 N$，其中 N 为信号点数。图2(a)展示了原始心震图信号和去噪后心震图信号的示例。对心震图信号进行去噪后，我们使用信号质量指数（SQI）识别并去除离群值。SQI 用于衡量信号质量，根据每个心震图信号与参考信号之间的距离计算得出。此步骤有助于确保最终信号具有较高质量，并能准确反映受试者的生理状况。有关 SQI 的详细信息，请参阅文献 [56]。简而言之，对于每位受试者，第 i个心震图信号$scg_i(t)$的 SQI 根据其与$\widehat{scg}(t)$之间的距离计算，表示为:

$$\mathrm{SQI_i} = \exp\left(-\frac{\mathcal{D}(scg_i, \widehat{scg})}{\mathcal{L}(scg_i, \widehat{scg})}\right), \tag{2}$$

其中，$\widehat{scg}(t)$表示该受试者所有心震图的逐点平均值，$\mathcal{D}(scg_i, \widehat{scg})$表示$scg_i$ 与$\widehat{scg}$之间的距离，而 $\mathrm{L}(scg_i, \widehat{scg})$表示$scg_i$ 与$\widehat{scg}$的长度。按照[56], 中所述的方法，我们使用动态时间规整（DTW）计算 $\mathcal{D}(scg_i, \widehat{scg})$。DTW 算法用于求取两条心震图信号之间的最小欧几里得距离，即使两者长度不同也是如此。该距离记为 $\mathrm{L}(scg_i, \widehat{scg})$，通过拉伸或压缩信号使其长度相匹配来计算。$D$ 中的距离较小表示信号质量较高，而距离较大则表示信号质量较差。

为确定哪些信号属于高质量信号，我们计算了每个信号的信号质量指数评分。随后按照信号质量指数评分对信号进行排序，并选取排名前 95% 的信号作为“良好”信号。信号质量指数低于 5% 阈值的信号被视为离群值，并从后续处理中剔除。图 2(b-c) 展示了单个受试者的良好心震图信号和离群值示例。离群信号波动剧烈，与典型的心震图信号并不相似。

5. 时频表示 – 心震图尺度图

为获得剩余心震图信号的时频表示，我们使用了连续小波变换（CWT）。我们采用解析莫尔斯小波，构建了一个每倍频程包含 48 个滤波器的连续小波变换滤波器组。对滤波器幅值进行了归一化，使所有通带的峰值幅度均为 2。最高通带频率经过设计，使其幅度在奈奎斯特频率处降至峰值的一半。

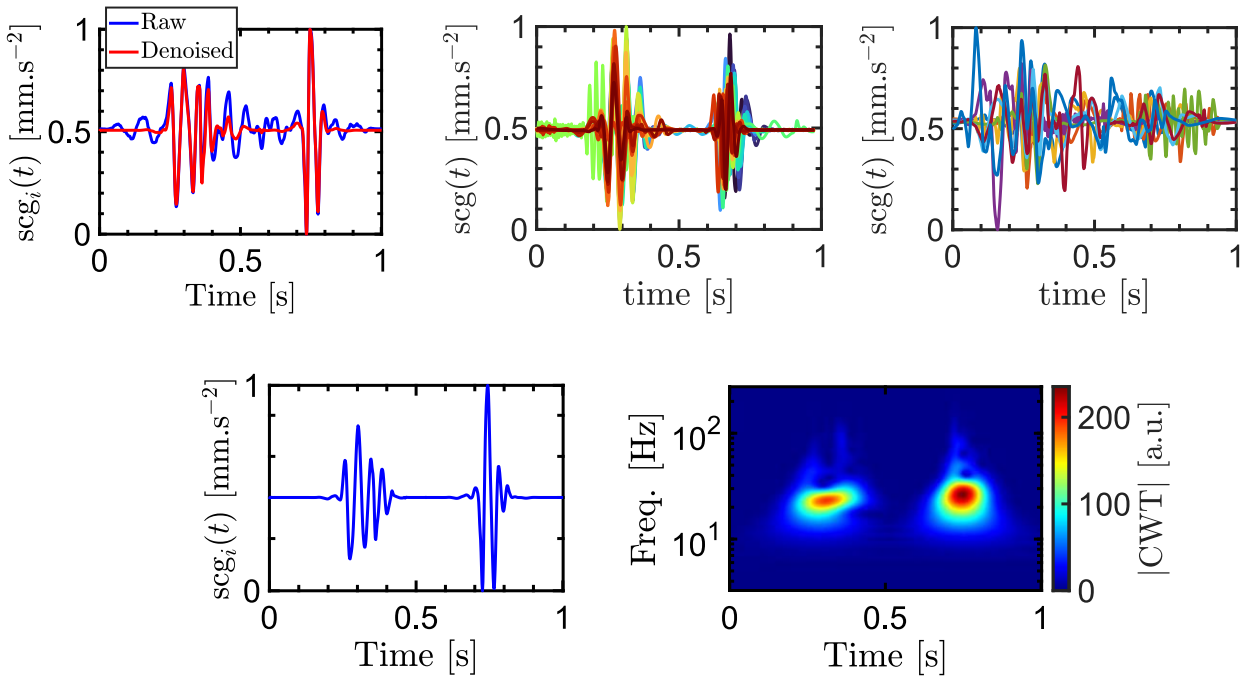


图 **2. (a)** 原始心震图信号与去噪心震图信号的比较，**(b-c)**：根据健康受试者的信号质量指数评分识别出的非离群和离群脉搏，**(d)** 由两个主要特征构成的心震图脉搏示例，**(e) (d)** 中信号的尺度图，表示其连续小波变换系数的绝对值。

CWT 系数的绝对值生成了每个心震图对应的尺度图。图2(d-e) 展示了去噪后的心震图及其对应尺度图的示例。可以看出，心震图脉搏中的两个主要特征分别出现在 0 至 0.5 秒和 0.5 至 1 秒之间，在尺度图中的位置也相同。此外，图中 y 轴显示了这些特征的频率分量，其范围为 10 至 100 Hz。这些频率值直接根据对应的小波尺度估算得出。

所有尺度图都通过双三次插值转换为 256×256 图像，其中每个插值像素代表其最近 4×4 邻域内像素的加权平均值。这便于可视化和分析心震图信号的时频特征。

6. 深度学习

图 3(a)展示了用于收缩期峰值流速回归的深度学习模型。心震图尺度图作为卷积神经网络（CNN）模型的输入数据，用于预测升主动脉中的 V_{max} 。CNN 架构由五个卷积块堆叠而成，每个卷积块依次包含 Conv2D、ReLU（修正线性单元）激活、批归一化和最大池化层。Conv2D 层会生成多个卷积核，与输入数据进行卷积并生成输出张量。卷积核权重和偏置向量会在反向传播过程中进行调整。所有卷积块的卷积核大小、步幅和填充参数分别设置为 3×3、1、

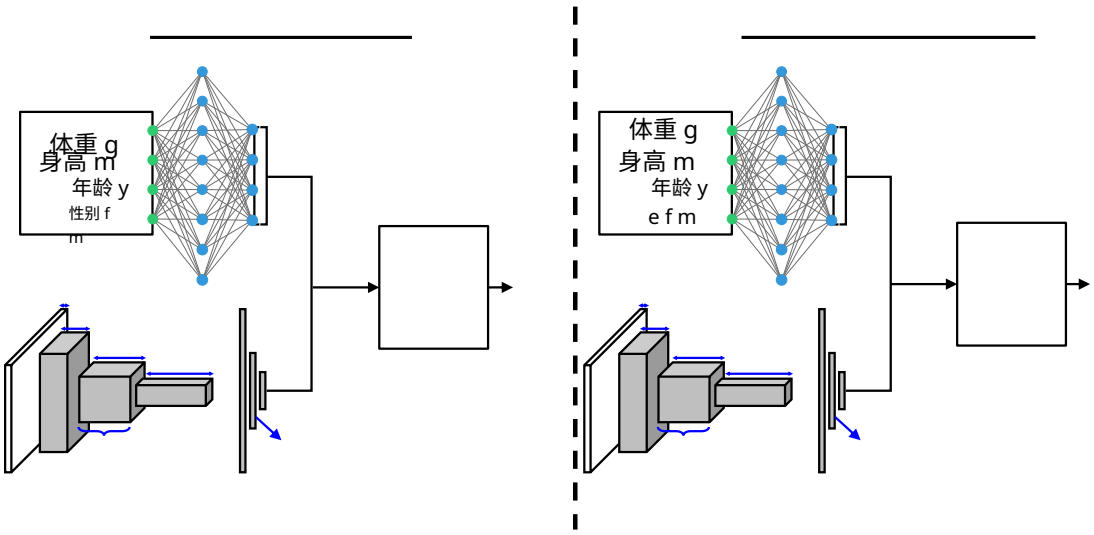


图 **3.** 混合深度神经网络模型由多层感知机和 CCN 组成，用于**(a)**预测主动脉 V_{max}，以及**(b)**根据受试者的人口统计学属性和心震图信号的尺度图，将受试者分类为不同的瓣膜状况：非 AS 三尖瓣主动脉瓣、非 AS 二叶式主动脉瓣、非 AS 多叶式主动脉瓣和主动脉瓣狭窄。

和“same”。ReLU 激活函数在输入为正时输出该输入，否则输出零。这会为模型学习到的特征增添非线性。批归一化层使用每批数据的均值和标准差对其进行归一化，以便于反向传播。最后，最大池化层输出输入张量每个2×2 窗口中的最大值，通过下采样提取越来越通用的特征。这些层协同工作，使 CNN 能够高效地学习并提取心震图尺度图中的有用特征。最后一个卷积块的输出经过展平后连接到两个全连接稠密单元；第一个单元依次包含稠密层、ReLU 激活、批归一化和丢弃层。第二个单元仅包含稠密层和 ReLU 激活层。

为了将受试者的人口统计学属性（体重、身高、年龄和性别）纳入深度学习模型，我们构建了一个包含两个全连接层的多层感知机（MLP）。三个连续属性均经过最小-最大归一化，参与者的性别则经过独热编码（即女性 = 1、男性 = 0），随后输入 MLP。

MLP 和 CNN 的输出均包含四个节点，将二者拼接后输入一个单独的全连接层，随后经过线性激活单元。该最终层利用人口统计学属性与心震图信号时频特征的综合信息，对所需的流量指标进行回归，例如 V_{max} 收缩期峰值流速。

该模型还用于将受试者分类为不同的瓣膜状况：非 AS 三尖瓣主动脉瓣、非 AS 二叶式主动脉瓣、非 AS 多叶主动脉瓣和主动脉瓣狭窄。然而，如图 3(b) 所示，对于分类任务，最终密集层中的节点数等于

瓣膜状况类别的数量，并使用 SoftMax 激活函数来生成输出属于各类别的概率。这使模型能够根据受试者的心震图信号和人口统计学属性对其进行准确分类。

在回归模型和分类模型中，同时优化了多层感知机和卷积神经网络的训练参数，以最小化损失函数。对于回归任务，损失函数计算为预测速度与真实速度之间的平均百分比误差；对于分类任务，则采用分类交叉熵。模型使用 Python 3.8 中的 TensorFlow 2.6 和 Keras 库实现，并在西北大学 Quest 计算集群中的一个 GPU 节点（配备 40 GB Tesla A100 GPU）上运行。

为了评估模型的性能，我们采用了留一受试者交叉验证方法。这意味着在每次迭代中，我们使用 80% 的可用心震图脉冲（N = 6249）训练模型，并将剩余的 20% 留作测试。重要的是，每位受试者的心震图脉冲只会被纳入训练集或测试集中的一方，而不会同时纳入两者，以避免性能指标出现任何潜在偏倚。我们重复这一过程 10 次，每次试验都随机选择不同的受试者纳入训练集和测试集。这样可以确认所报告的性能指标不受训练集和测试集分布中的特定模式影响。每次迭代中，模型训练 150 个训练轮次。

为评估深度神经网络和四维流所获得数值之间的一致性，我们进行了相关性分析和 Bland-Altman 分析。我们使用皮尔逊相关系数确定两组数值之间的线性关系，并使用 Bland-Altman 方法计算一致性界限（LOA）。在 Bland-Altman 图中，每个样本在 x 轴上以两种测量技术所得数值的均值表示，在 y 轴上以两种技术所得数值之差表示。差值均值是对偏倚的估计，差值的标准差（SD）衡量均值周围的随机波动，而 LOA 定义为 1.96×SD。如果基于单样本 t 检验（显著性水平 $\alpha = 0.05$ ），差值均值与 0 存在显著差异，则表明存在固定偏倚。需要注意的是，对于每位受试者，我们都记录了多个不同心搏的心震图尺度图。深度神经网络模型为每个尺度图分配一个 V_{max} 值，并将每位受试者所有尺度图的平均 V_{max} 值作为该受试者的代表值。

为评估分类模型的性能，我们使用了受试者工作特征（ROC）曲线。ROC曲线根据模型为每个观测值属于特定瓣膜状况组所赋予的概率绘制。ROC曲线以不同预测概率所选定的阈值为参照，绘制真正率（TPR）与假正率（FPR）的关系；ROC曲线下面积（ROC-AUC）越大，表示模型性能越好。我们还使用了测试分类模型得到的混淆矩阵。在混淆矩阵中，对角线元素表示各类别中的真正例数量（TP），而

非对角线元素则分别显示每行和每列中的假阴性数量（FN）和假阳性数量（FP）。此外，我们还计算并比较了诊断每种瓣膜状况时的精确率（$\frac{TP}{TP+FP}$）和召回率（$\frac{TP}{TP+FN}$）。

结果

1. V_{max}的预测

我们的深度学习模型预测的收缩期峰值流速与四维血流磁共振成像测得的流速吻合良好，在十次随机试验中的均方误差仅为0.2 m/s。图4(a)展示了测试对象的DNN预测V_{max} 值的平均值与四维血流磁共振成像测得流速之间的关系。如前所述，我们将每位受试者所有尺度图上的V_{max} 值平均值作为代表值。图中显示，估算值与测量值V_{max} 之间存在很强的线性相关（$y = 0.89x$，$r = 0.76$，$p \ll 0.01$）。此外，图4(b)展示了DNN模型与四维血流磁共振成像测量所得V_{max} 值的Bland-Altman图。该图表明偏倚较低且无统计学显著性（-0.08 m/s，$p = 0.18$），一致性界限适中（±0.86 m/s）。

2. 主动脉瓣状况分类

图 4(c) 展示了分类模型的结果。该模型根据受试者的心震图尺度图和人口统计学属性，将其分为四种不同类型：非 AS 三叶式主动脉瓣、非 AS 二叶式主动脉瓣、非 AS 多叶式主动脉瓣和主动脉瓣狭窄。模型通过受试者工作特征（ROC）曲线进行评估，该曲线绘制了真正率（召回率）与假正率之间的关系。ROC 曲线上的实线表示模型在 10 次随机迭代中的平均性能，误差区域则显示各次迭代中性能的标准差。ROC 曲线下面积数值反映了模型对四个类别的分类性能；对于非 AS 三叶式主动脉瓣、非 AS 二叶式主动脉瓣、非 AS 多叶式主动脉瓣和主动脉瓣狭窄受试者，这些数值分别为 91.8±5.3%、94.8±5.1%、81.2±10.8 和 83.1±11.1%。

图 4(d) 展示了混淆矩阵，该矩阵用于评估模型在一次随机试验中的测试集表现。矩阵的行表示真实类别，列表示模型预测的类别。精确率和召回率反映了模型正确分类四个类别中受试者的能力。四个类别的精确率分别为 93%、82%、83% 和 49%，召回率分别为 81%、94%、68% 和 86%。

讨论与结论

本研究评估了使用深度学习和心震图尺度图预测主动脉收缩期峰值流速，以及诊断患有各种主动脉瓣并发症的患者的有效性。与四维血流磁共振成像测得的流速相比，我们的深度学习模型能够准确预测收缩期峰值流速，均方误差为 = 0.2 m/s，r 为 = 0.76（$p<0.01$）。

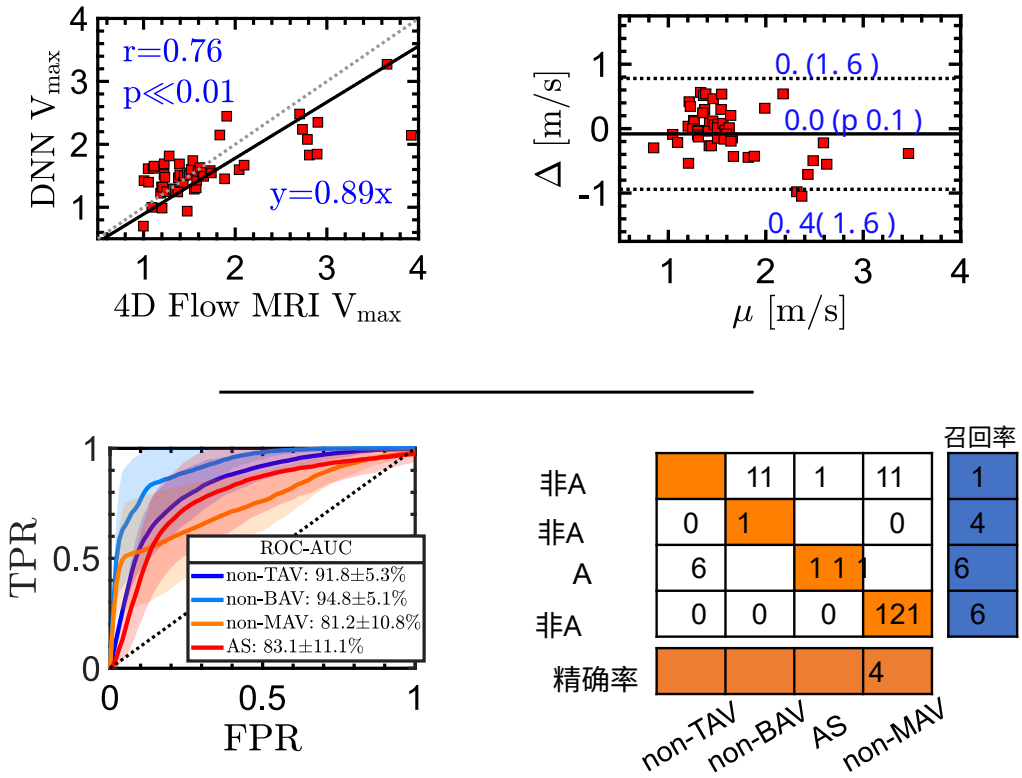


图 **4.** 基于4D flow MRI获得的V_{max} 值与基于DNN和尺度图预测的V_{max} 值的统计比较：(a)相关性；(b)Bland-Altman分析；(c)非TAV、非BAV、非MAV受试者及AS患者的分类ROC曲线（均值±标准差）；(d)分类模型一次训练和测试迭代的混淆图（SCG级别）。

尽管不同类型主动脉瓣病变受试者的分布不均衡，我们仍能在诊断这些疾病时取得较高的精确率（除非二尖瓣主动脉瓣类别外，所有类别均超过 82%）和召回率（除主动脉瓣狭窄外，所有类别均超过 81%）。我们的研究结果表明，深度学习和心震图有望替代四维血流磁共振成像等更先进的成像技术，或作为其筛查工具。

此前，深度学习模型已被用于从心震图信号中提取多种信息。例如，研究人员开发了一种卷积神经网络模型，可持续、高灵敏度地从心震图信号中识别R峰；研究还证实，该模型从心震图信号中获得的心率变异性指标与从心电信号中获得的指标高度一致 [57]。一项针对36名健康受试者的研究表明，深度学习能够准确地将心震图信号片段映射到全身心冲击图 [51]。此外，还有研究提出了基于U-Net的级联框架，用于根据心电图和心震图信号估算呼吸频率 [58]。其他研究则探讨了使用机器学习和深度学习从心震图信号中检测心搏及心搏率 [59, 60]。与这些先前的研究不同，本文考察了可穿戴心震图脉搏与心脏收缩峰值

血流速度之间的相关性，其真实值通过全面的四维血流磁共振成像确定。因此，本研究拓展了心震图的潜在应用范围，可依据血流速度而非仅依据心率来诊断心脏异常。

本研究所述技术的一项潜在应用，是提高相位对比磁共振成像（PC-MRI）中主动脉速度估算的准确性。进行PC-MRI前需要设定的一个关键参数是VENC阈值 [61]。该参数应设定为能够捕捉目标血管内预期的最高速度，同时保持足够的速度噪声比。尽管VENC值对于相位对比脉冲序列的正常运行至关重要，但由于事先无法确定其最佳值，通常只能对其进行估算；有时还需要采用不同的VENC值重复检查，才能获得最佳结果。本研究提出的技术有望在成像前可靠地估算最佳VENC值，从而减少磁共振成像时间和成本。

本研究的一项主要局限是受试者分布不均衡。在预测收缩期峰值流速时，大多数研究参与者均为健康人，因此训练集中速度大于2 m/s的样本仅占很小比例（约20%）。这使模型更难以准确预测测试集中的较高峰值流速，如图4(a)所示，与较低速度相比，较高速度与真实值的相关性较弱。在瓣膜状况分类方面，非TAV组有46名受试者，而非BAV组、非MAV组和AS组分别仅有10名、9名和12名受试者。这可能导致模型在诊断非MAV和主动脉瓣狭窄类别时，预测准确度低于诊断非TAV受试者时。此外，进一步划分主动脉瓣狭窄严重程度（如轻度、中度和重度）固然有价值，但这样做可能会使各组受试者人数进一步减少。因此，未来研究有必要扩大患者队列，纳入更多主动脉速度较高且主动脉瓣狭窄严重程度不同的受试者。

参考文献

[1] N. J. Pelc, R. J. Herfkens, A. Shimakawa, and D. R. Enzmann,《相位对比电影磁共振成像》，《磁共振杂志》，第7卷，第4期，第229-254页，1991年。[2] J. Lotz, C. Meier, A. Leppert, and M. Galanski, 《采用相位对比磁共振成像进行心血管血流测量：基本原理与实施》，《放射学图谱》，第22卷，第3期，第651-671页，2002年。[3] P. D. Gatehouse 等，《相位对比血流与速度成像在心血管磁共振成像中的应用》，《欧洲放射学》，第15卷，第10期，第2172-2184页，2005年。[4] M. B. Srichai, R. P. Lim, S. Wong, and V. S. Lee, 《相位对比磁共振成像的心血管应用》，《美国放射学杂志》，第192卷，第3期，第662-675页，2009年。

[5] S. Uribe, P. Beerbaum, T. S. Sørensen, A. Rasmusson, R. Razavi, and T. Schaeffter, 《采用实时呼吸自门控进行全心脏和大血管四维血流成像》，《磁共振医学》，第62卷，第4期，第984-992页，2009年。[6] M. D. Hope 等，《二叶式主动脉瓣：升主动脉收缩期血流模式的四维磁共振评估》，《放射学》，第255卷，第1期，第53-61页，2010年。[7] M. D. Hope 等，《四维血流心血管磁共振在瓣膜相关升主动脉疾病评估中的应用》，《美国心脏病学会杂志：心血管成像》，第4卷，第7期，第781-787页，2011年。[8] M. Markl, P. J. Kilner, and T. Ebbers, 《通过心血管磁共振对心脏和大血管进行全面的四维速度映射》，《心血管磁共振杂志》，第13卷，第1期，第1-22页，2011年。[9] R. E. Clough, M. Waltham, D. Giese, P. R. Taylor, and T. Schaeffter, 《一种采用四维相位对比磁共振成像评估主动脉夹层的新型成像方法》，《血管外科》，第55卷，第4期，第914-923页，2012年。[10] P. Dyverfeldt 等，《四维血流心血管磁共振共识声明》，《磁共振杂志》，第17卷，第1期，第1-19页，2015年。[11] A. Azarine 等，《四维血流磁共振成像：原理与心血管应用》，《放射学图谱》，第39卷，第3期，第632-648页，2019年。[12] D. T. Wymer, K. P. Patel, W. F. Burke III, and V. K. Bhatia, 《相位对比磁共振成像：物理原理、技术与临床应用》，《放射学图谱》，第40卷，第1期，第122-140页，2020年。[13] J. Rizk, 《四维血流磁共振成像在先天性心脏病中的应用》，《欧洲放射学》，第31卷，第2期，第1160-1174页，2021年。[14] M. Markl 等，《时间分辨三维相位对比磁共振成像》，《磁共振成像杂志》，第17卷，第4期，第499-506页，2003年。[15] M. Markl, A. Frydrychowicz, S. Kozerke, M. Hope, and O. Wieben, 《四维血流磁共振成像》，《磁共振成像杂志》，第36卷，第5期，第1015-1036页，2012年。[16] Z. Stankovic, B. D. Allen, J. Garcia, K. B. Jarvis, and M. Markl, 《磁共振四维血流成像》，《心血管诊断与治疗》，第4卷，第2期，第173页，2014年。[17] G. Soulat, P. McCarthy, and M. Markl, 《磁共振四维血流成像》，《生物医学工程年度评论》，第22卷，第103-126页，2020年。[18] S. Schnell 等，《主动脉四维血流磁共振成像的 k-t GRAPPA 加速：对扫描时间、图像质量以及血流和壁面剪切应力量化的影响》，《磁共振医学》，第72卷，第2期，第522-533页，2014年。[19] A. J. Barker 等，《成年患者肺动脉高压的肺动脉血流与壁面剪切应力四维血流评估：来自两家机构的结果》，《磁共振医学》，第73卷，第5期，第1904-1913页，2015年。[20] M. Gabbour, S. Schnell, K. Jarvis, J. D. Robinson, M. Markl, and C. K. Rigsby, 《四维血流磁共振成像：血流定量与二维相位对比

磁共振成像和多普勒超声心动图，《儿科放射学》，第45卷，第6期，第804-813页，2015年。[21] D. G. Guzzardi 等，《瓣膜相关血流动力学介导人类二叶式主动脉病变》，《美国心脏病学会杂志》，第66卷，第8期，第892-900页，2015年。[22] P. van Ooij 等，《利用四维血流磁共振成像表征人类二叶式主动脉病变中的异常壁面剪切应力》，《Annals of Biomedical Engineering》，第43卷，第6期，第1385-1397页，2015年。[23] P. Van Ooij 等，《从四维血流磁共振成像获得的健康主动脉收缩期血流速度和三维壁面剪切应力的可重复性及观察者间变异》，《磁共振成像杂志》，第43卷，第1期，第236-248页，2016年。[24] F. Piatti 等，《二叶式主动脉瓣相关流体动力学改变的四维血流分析：临床相关主动脉解剖重塑缺失时壁面剪切应力改变的证据》（英文），《生理学前沿》，第8卷，2017年。[25] J. F. Feneis 等，《四维血流磁共振成像对二尖瓣和三尖瓣反流的定量：相对于常规磁共振成像的可重复性和一致性》，《磁共振成像杂志》，第48卷，第4期，第1147-1158页，2018年。[26] J. F. Rodríguez-Palomares 等，《通过四维血流心血管磁共振成像获得的主动脉血流模式和壁面剪切应力图谱：用于评估二叶式主动脉瓣疾病中的主动脉扩张》，心血管磁共振杂志，第20卷，第1期，第1-15页，2018年。[27] B. Fidock 等，《四维血流磁共振成像衍生的二尖瓣反流定量方法系统综述》（英文），《心血管医学前沿》，第6卷，2019年。[28] J. Garcia、A. J. Barker 和 M. Markl，《四维血流磁共振成像在主动脉瓣狭窄血流模式成像中的作用》，《美国心脏病学会杂志：心血管成像》，第12卷，第2期，第252-266页，2019年。[29] P. Garg 等，《心血管磁共振成像评估二尖瓣反流》，《自然评论：心脏病学》，第17卷，第5期，第298-312页，2020年。[30] B. Jung、M. Honal、P. Ullmann、J. Hennig 和 M. Markl，《高度 k-t 空间加速相位对比磁共振成像》，磁共振医学，第60卷，第5期，第1169-1177页，2008年。[31] A. Stadlbauer、W. van der Riet、G. Crelier 和 E. Salomonowitz，《利用灵敏度编码和 k-t BLAST 加速主动脉血流模式的时间分辨三维磁共振速度映射》，《欧洲放射学杂志》，第75卷，第1期，第e15-e21页，2010年。[32] U. Tariq、A. Hsiao、M. Alley、T. Zhang、M. Lustig 和 S. S. Vasanawala，《采用并行成像压缩感知四维相位对比磁共振成像进行静脉和动脉血流定量，准确度和精确度相当》，《磁共振成像杂志》，第37卷，第6期，第1419-1426页，2013年。[33] H. Dyvorne 等，《屏气状态下的腹部四维血流磁共振成像：结合螺旋采样与动态压缩感知实现高度加速采集》，《放射学》，第275卷，第1期，第245-254页，2015年。

[34] L. Feng、T. Benkert、K. T. Block、D. K. Sodickson、R. Otazo 和 H. Chandarana，《全身磁共振成像中的压缩感知》，《磁共振成像杂志》，第45卷，第4期，第966-987页，2017年。[35] S. Schnell 等，《用于神经血管应用的加速双速度编码四维流动磁共振成像》，《磁共振成像杂志》，第46卷，第1期，第102-114页，2017年。[36] L. E. Ma 等，《利用压缩感知、呼吸控制自适应 k 空间重排和在线重建，在2分钟内完成主动脉四维流动磁共振成像》，磁共振医学，第81卷，第6期，第3675-3690页，2019年。[37] E. Neuhaus、K. Weiss、R. Bastkowski、J. Koopmann、D. Maintz 和 D. Giese，《采用压缩感知加速主动脉四维流动心血管磁共振成像：适用性、验证和临床整合》，心血管磁共振杂志，第21卷，第1期，第65页，2019年。[38] D. M. Salerno 和 J. Zanetti，《利用心震图监测缺血期间左心室功能的变化》，《Chest》，第100卷，第4期，第991-993页，1991年。[39] I. Korzeniowska-Kuba ka、M. Biliń ka 和 R. Piotrowi z，《心震图在冠状动脉疾病患者缺血诊断中的作用》，《Annals of Noninvasive Electrocardiology》，第10卷，第3期，第281-287页，2005年。[40] P. Castiglioni、A. Faini、G. Parati 和 M. D. Rienzo，《可穿戴心震图描记术》，载于2007年第29届年度生物医学工程会议，2007年，第3954-3957页。[41] C. A. Wick 等，《基于心震图识别心脏静止期的系统：对心脏成像的启示》，《IEEE生物医学信息技术汇刊》，第16卷，第5期，第869-877页，2012年。[42] M. Di Rienzo 等，《可穿戴心震图描记术：迈向对活动受试者心脏力学的逐搏评估》，《自主神经科学》，第178卷，第1期，第50-59页，2013年。[43] J. M. Zanetti 和 K. Tavakolian，《心震图：过去、现在与未来》，载于2013年第35届年度生物医学工程会议，2013年，第7004-7007页。[44] M. Becker 等，《利用心震图简化心肌缺血检测》，《Herz》，第39卷，第5期，第586-592页，2014年。[45] O. T. Inan 等，《心冲击描记术和心震图：近期进展综述》，《IEEE生物医学与健康信息学杂志》，第19卷，第4期，第1414-1427页，2015年，doi: 10.1109/JBHI.2014.2361732。[46] J. Wahlström 等，《用于心震图的隐马尔可夫模型》，《IEEE生物医学工程汇刊》，第64卷，第10期，第2361-2372页，2017年。[47] O. T. Inan 等，《新型可穿戴心震图和机器学习算法可评估心力衰竭患者的临床状态》，《循环：心力衰竭》，第11卷，第1期，第e004313页，2018年。

[48] T. Choudhary、L. N. Sharma 和 M. K. Bhuyan，《利用心震图自动检测健康个体的主动脉瓣开放》，《IEEE生物医学与健康信息学杂志》，第 23 卷，第 3 期，第 1032-1040 页，2019 年。[49] A. Taebi、B. E. Solar、A. J. Bomar、R. H. Sandler 和 H. A. Mansy，《心震图的最新进展》，《Vibration》，第 2 卷，第 1 期，第 64-86 页，2019 年。[50] E. M. I. Johnson 等，《利用心震图和心脏磁共振成像检测主动脉瓣诱发的异常血流》，《Ann. Biomed .Eng.》，第 48 卷，第 6 期，第 1779-1792 页，2020 年。[51] S. Hersek、B. Semiz、M. M. H. Shandhi、L. Orlandic 和 O. T. Inan，《基于深度学习的可穿戴心震图信号与全身心冲击图信号映射全局化模型》，《IEEE生物医学与健康信息学杂志》，第 24 卷，第 5 期，第 1296-1309 页，2020 年。[52] D. Rai、H. K. Thakkar、S. S. Rajput、J. Santamaria、C. Bhatt 和 F. Roca，《心震图综述：采集、标注与应用的最新进展》，《Mathematics》，第 9 卷，第 18 期，文章编号 2243，2021 年。[53] M. Jafari Tadi 等，《一种利用希尔伯特变换实时监测心震图心率的方法》，《Physiol. Meas.》，第 37 卷，第 11 期，文章编号 1885，2016 年。[54] H. Berhane 等，《利用深度学习对四维血流磁共振成像进行全自动三维主动脉分割以开展血流动力学分析》，《Magn. Reson. Med.》，第 84 卷，第 4 期，第 2204-2218 页，2020 年。[55] M. J. Rose 等，《利用四维血流磁共振成像评估峰值血流速度体积的高效方法》，《磁共振成像杂志》，第 44 卷，第 6 期，第 1673-1682 页，2016 年。[56] J. Zia、J. Kimball、C. Rozell 和 O. T. Inan，《利用心脏力学信号的流形结构实现出血期间的生理监测》，《IEEE生物医学工程汇刊》，第 68 卷，第 6 期，第 1759-1767 页，2021 年。[57] P. Suresh、N. Narayanan、C. V. Pranav 和 V. Vijayaraghavan，《利用心震图实现可靠心脏活动监测的端到端深度学习》，2020 年第 19 届 IEEE ICMLA，第 1369-1375 页，2020 年。[58] M. Chan、V. G. Ganti 和 O. T. Inan，《基于 U-Net 级联框架的心电图和心震图信号呼吸频率估计》，《IEEE生物医学与健康信息学杂志》，第 26 卷，第 6 期，第 2481-2492 页，2022 年。[59] H. K. Thakkar 和 P. K. Sahoo，《利用机器学习实现心震图信号的自动快速标注》，《IEEE Sensors Journal》，第 20 卷，第 5 期，第 2578-2589 页，2020 年。[60] M. Haescher、F. Höpfner、W. Chodan、D. Kraft、M. Aehnelt 和 B. Urban，《应用卷积自编码器将心震图转换为心电图》，载于 2020 年 IEEE ICASSP，第 4122-4126 页，2020 年。

[61] A. F. Stalder、M. F. Russe、A. Frydrychowicz、J. Bock、J. Hennig 和 M. Markl，《定量二维和三维相位对比磁共振成像：血流和血管壁参数的优化分析》，磁共振医学，第 60 卷，第 5 期，第 1218–1231 页，2008 年。