arXiv:2603.04610v1 [cs.CE] 4 Mar 2026

建筑能否作为储备池运行：利用嵌入式加速度计网络进行脚步定位

Jun Wang[a]、Rodrigo sarlo[b]、Suyi Li[a]

[a]弗吉尼亚理工大学，*Goodwin Hall*，布莱克斯堡，*VA 24061*，美国[b]弗吉尼亚理工大学，巴顿楼，布莱克斯堡，*VA 24061*，美国

摘要

利用楼板振动准确预测居住者的脚步位置，对于智能建筑运营和保护隐私的室内感知至关重要。然而，现有方法主要分为两类：一类是依赖简化波传播假设和精细校准的基于物理的模型；另一类是需要大量标注数据集、且往往难以适应对象和环境变化的数据驱动方法。本文提出一种新方法，将装有仪器的建筑楼板视为物理储备池计算机，利用其固有的结构动力学直接执行非线性时空计算和信息提取。具体而言，分布式加速度计网络记录的足部撞击引起的楼板振动，经过轻量级物理储备池计算（PRC）流程处理，该流程包括短时波形提取、均方根（RMS）归一化、主成分分析（PCA）和加权线性读出。本研究涉及 2 名参与者和 12 个加速度计，结果表明，均方根归一化和主成分分析投影成功地从楼板振动波形数据中提取出与居住者无关的特征，因此，单一线性读出即可在重复行走遍次及不同参与者之间预测足部着地点。在传感覆盖范围适中的情况下，沿走廊方向的定位精度达到亚米级；跨参与者测试则在无需针对特定对象重新校准或重新训练的情况下，实现了米级精度。这些发现表明，建筑尺度的结构能够作为有效的物理储备池计算机，用于智能监测。

关键词：脚步位置预测、物理储备池计算、智能结构

1. 引言——利用建筑作为物理储层计算脚步位置

在建筑内准确定位人类脚步，是智能土木基础设施的一项重要能力，因为它能够支持居住者跟踪、节能型暖通空调控制、安全监控和应急响应等众多应用 [1, 2, 3]。目前，室内定位策略大致包括基于摄像头的系统 [4, 5], 基于可穿戴设备的感知 [6],以及利用楼板响应的基于振动的方法 [7, 8, 9]。其中，基于摄像头的定位可能引发隐私顾虑，且通常需要持续的视觉覆盖和视线通路。与此同时，基于可穿戴设备的方法受用户依从性、设备可用性和可靠通信的限制，难以大规模被动部署于整栋建筑。相比之下，基于振动的定位仅使用楼板安装式加速度计，因此天然具有保护隐私的特性，无需视线通路，即使传感器部署稀疏，也能在杂乱的室内环境中稳定运行。当人类脚步

冲击楼板时，会激发弯曲波和剪切波，产生具有频散特性的传播；这些波呈现出独特的时空模式，具体取决于激励位置、行走动力学以及楼板系统的结构特性。因此，由空间分布的加速度计网络进行采样时，这些振动场能够在真实建筑环境中以亚米级精度揭示脚步位置 [10, 11]。

1.1. 基于振动的脚步定位研究现状

现有的基于振动的脚步定位方法大致可分为两种范式：基于物理的建模方法和数据驱动方法。基于物理的方法利用结构动力学、兰姆波理论和有限元表示，明确地对脚步诱发振动的传播过程建模。代表性技术包括到达时间差（TDoA） [12, 13], 基于能量的定位 [7, 14], 和误差域模型证伪（EDMF） [15, 16], ，通过考虑频散、衰减和结构非均匀性来推断声源位置。这些方法在真实建筑物中通常能达到约 0.4–0.8 米的平均定位误差，并且在复杂或存在障碍物的环境中表现良好。不过，其精度取决于是否具备可靠的结构模型和适当的参数校准，而且可能受到建模不确定性或边界条件变化的影响。

相比之下，数据驱动和机器学习方法（如支持向量机（SVM） [17]和卷积神经网络（CNN） [18, 19], ）能够学习从振动特征或原始波形到脚步位置的直接映射。借助大型数据集，这些方法擅长捕捉非线性关系、处理重叠信号，并适应新环境，从而提升在不同地板类型和居住者步态下的泛化能力 [20, 21]。尽管精度较高，数据驱动方法通常需要大量标注数据，计算成本也更高，而且物理可解释性有限——这些缺点可能妨碍其实时部署，并削弱其在条件变化时的稳健性。因此，近期研究日益关注将物理洞见与基于学习的适应能力相结合的混合策略 [16, 22], ，尽管许多方法仍依赖显式模型或大型标注数据集。

1.2. 面向信息感知的物理储备池计算

在本研究中，我们展示了**物**理**储**层**计**算（**PRC**）如何通过弥合基于物理的方法与数据驱动方法，为脚步定位提供一条独特路径：将物理动力学直接嵌入学习过程。从宏观角度看，具有非线性动态特性的物理系统（例如真实建筑）可以将输入信号（脚步）映射到一个高维状态空间（加速度计读数）中，从而携带丰富的物理信息。因此，通过一组经训练的“读出权重”对该状态空间进行简单的加权线性求和，便能提取有关输入的信息（例如脚步位置）（图 1） [23, 24]。PRC 已成为一种强大的框架，可借助不同的物理基底实现信息感知。例如，光子和光电储层已实现用于视觉和嗅觉传感的超高速、低功耗处理 [25, 26, 27]。与此同时，机械储层——如折纸启发结构 [28], 、软体机器人 [29, 30], 和柔性材料 [31]——在传感与感知任务中取得了显著成效，其非线性变形或振动能够自然地编码环境信息。例如，我们此前的研究表明，一种简单的、具有承载能力的纸基折纸结构可以充当物理储层 [32], ，能够预测负载

重量和位置，以及输入频率，所依据的是其高维动力学。在各种信息处理任务中，PRC 系统的准确率往往可与传统机器学习模型相媲美，甚至超过后者，同时还具备计算效率高、硬件简单和实时运行等优势。

然而，迄今为止，PRC 主要在微观和中观尺度系统中得到探索。其在大型建筑尺度结构中的应用——尤其是脚步定位等空间推断问题——仍鲜有研究。然而，土木结构本身具有丰富的非线性动态振动，可通过嵌入式加速度计网络进行采样。这些特性表明，PRC 在建筑尺度上的应用具有巨大潜力。

1.3. 研究贡献与论文结构

因此，本文要回答的核心问题是：配备嵌入式传感器的楼板系统能否充当物理储层，将脚步引发的振动转换为可通过线性方式解码、且实时呈现脚步位置的表征？我们对这一问题的回答构成了本文的三项主要贡献

- 建筑尺度的*PRC*定位：我们的实验表明，配备稀疏嵌入式加速度计网络的钢筋混凝土走廊地板构成了一个高维时空储层，能够在其振动响应中编码脚步位置。

- 精简的基于振动的*PRC*流程：我们提出了一种高效、由波形驱动的基于振动的PRC架构，采用短采样窗口、均方根归一化、主成分分析投影和线性读出。该流程无需复杂的数据处理、结构建模或循环训练。

- 数据高效且具备跨受试者性能：我们展示了仅使用少量训练行走数据即可实现准确定位，并证明在一名受试者的数据上训练的读出模型能够泛化到未见过的受试者，误差低于 1 米。

本文其余部分安排如下。第 2 节介绍实验设置和评估方案。第 3 节详细说明所提出的 PRC流程。第 4 节报告单受试者和跨受试者的定位结果，包括训练和传感器精简研究。第 5 节讨论物理可观测性及其对建筑尺度 PRC 的影响。第 6 节总结本文并展望未来研究方向。

2. 方法——概念框架、实验设置与感官数据处理

本节首先阐述利用基于振动的物理储备池计算实时预测脚跟着地位置背后的物理直觉。随后，我们介绍建筑尺度的实验设置以及训练/测试方案。后续小节将详细说明事件检测算法、储层状态形式化、线性读出训练和误差指标计算。

2.1. 概念框架：将仪器化建筑用作物理储层

当人的脚跟着地对楼板施加局部脉冲激励时，会产生瞬态振动场，并以色散波包的形式沿走廊传播。从脉冲输入到色散波场的这种转换具有高维、非线性的特性，因此我们将仪器化走廊及其传感器网络视为一个物理储层

计算机。更具体地说，传感化走廊结构执行一种物理转换：

$$\text{foot strike impulse at position } \mathbf{p}_k = (x_k, y_k) \;\mapsto\; \left\{a_j(t)\right\}_{j=0}^{N_s-1}, \tag{1}$$

这意味着，位置 $\mathbf{p}_k = (x_k, y_k)$ 处的局部机械输入会被转换为高维振动响应场。（在本研究中，索引 $_k$ 指代不同的脚步撞击。）这一转换完全由建筑的几何形状、材料特性和边界条件决定。由植入式加速度计组成的网络在不同位置对该场进行采样，生成波形数据集 $a_j(t)$。（索引 $_j$ 指代不同的传感器，见图 1a）。这些波形构成原始储备池状态，其中隐式编码了脚步的空间

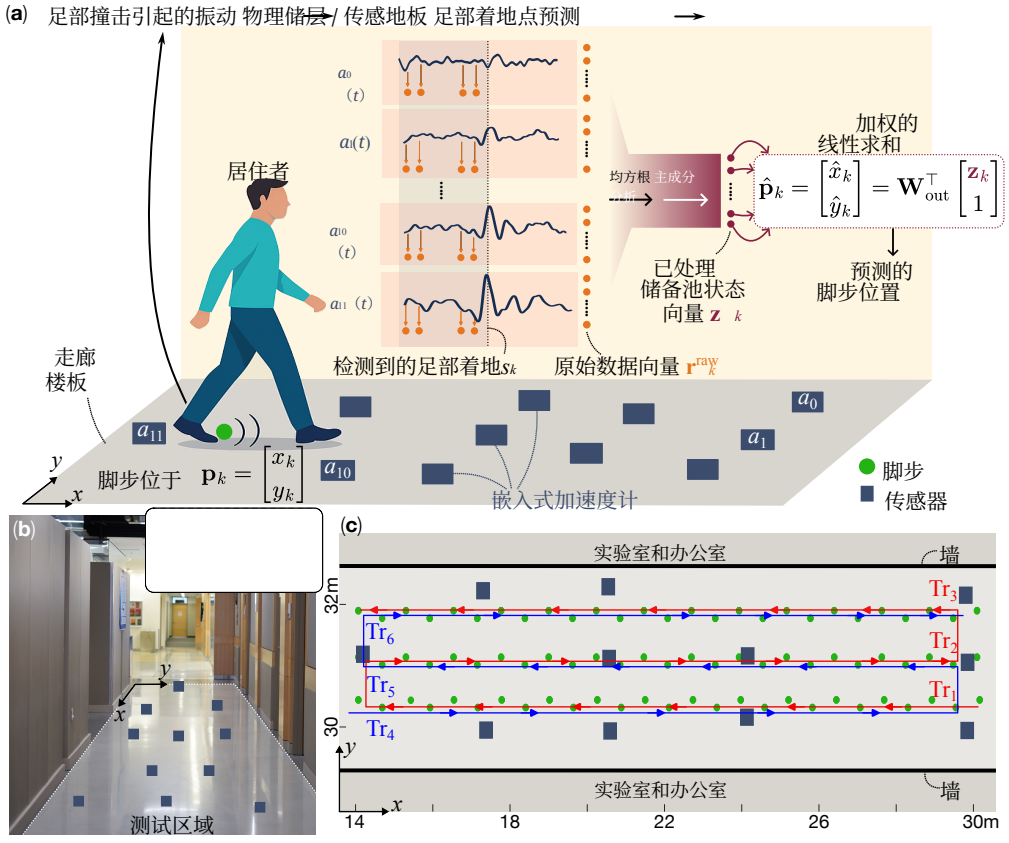

图 1：**利用仪器化建筑作为物理储备池计算机进行脚步定位。**（**a**）行走人体受试者在位置$\mathbf{p}_k = (x_k, y_k)$处向走廊地面施加机械脉冲，激发色散振动场。由嵌入式地板加速度计组成的网络对这些振动场进行采样，生成高维信号流$a_j(t)$。随后，从这些信号中提取短波形窗口，经均方根归一化后通过主成分分析投影为“紧凑”的储备池状态向量$\mathbf{z}_k$。因此，对$\mathbf{z}_k$ 进行简单的加权线性求和，并使用训练好的读出权重 $\mathbf{W}^{\top}_{\text{out}}$，即可准确估计脚步位置$\hat{\mathbf{z}}_k = (\hat{x}_k, \hat{y}_k)$。（**b**）仪器化走廊的照片。（**c**）走廊布局俯视图，显示了加速度计的位置、行走遍次（Tr_i）以及全局坐标系。

信息，包括传感信号时延、相位关系和振动模态内容。储备池计算框架提出，通过适当的数据处理设置，对这些储备池状态进行加权线性求和，即可直接提取脚跟着地位置。

2.2. 实验设置

所有步行实验均在弗吉尼亚理工大学校园内 Goodwin Hall 四楼的一条走廊中进行 [14]。测试区域是一段笔直、长约 16 米的钢筋混凝土走廊地面（图 1b、c）。全局坐标系（x，y）与走廊对齐，其中 x 轴沿行走方向，y 轴则横跨走廊。在仪器化地面区域内，x 的范围约为 14 至 30 米，而 y 则局限在 31.2 米附近的一段狭窄区域，对应于走廊的中心线。测试区域由结构墙和相邻的实验室空间围成，形成了具有强烈反射和模态相互作用的真实室内振动环境。

十一台压电加速度计被永久安装在楼板底面。每个传感器的工作频率范围为 2–10,000 Hz，标称灵敏度为 1000 mV/g，分辨率约为 $8 \times 10^{-4}\mathrm{m/s^2}$。加速度数据通过配备内置抗混叠滤波器和 24 位模数转换器的 EMX-4250数字信号分析仪卡进行记录。所有加速度计通道均以 1024 Hz 的采样率同步采样。

两名成年受试者（分别记为 S_1 和 S_2）参与了实验。每名受试者沿预定义路线穿过仪器化走廊六次，分别记为 Tr_1 至 Tr_6（图 1c），两名受试者共完成十二次行走遍次。在每次行走遍次中，受试者以舒适且自行选择的步速行走，直到通过传感地板区域；随后转身返回走廊，开始下一次行走遍次。为确保一致性，研究人员用胶带在地板上标记了每个脚跟着地点，以便受试者尽可能准确地踩在这些标记上。这些标记定义了 81 个足部着地点，沿着横跨走廊的三条平行行走线排列，名义步长为 0.62米，站立宽度为 0.15米。需要注意的是，尽管行走路线是预定义的，但每次脚步着地点在时间、冲击强度和横向位置方面仍会自然变化。

2.3. 物理储备池计算（*PRC*）流程

为适应本研究中独特的动力学特性和计算任务需求，我们设计了一种新的物理储备池计算流程，将短时振动波形窗口作为储备池状态。这样，学习过程就简化为训练这些储备池状态的加权线性求和，以推断足部着地点$\mathbf{p}_k$。

图 2 总结了本研究的 PRC 流程。在实时运行中，我们持续流式采集并监测地面加速度信号 $a_i(t)$，并使用峰值拾取算法检测脚跟着地的发生。当在时间戳 s_k检测到一个脚步时，我们从所有传感器中提取一个振动波形数据窗口，并将这些数据向量化为原始储备池状态向量 $\mathbf{r}^{\mathrm{raw}}{}_k$。该窗口长度固定为 t^w，位置紧邻 s_k 之前（图 1a）。随后，我们使用均方根（RMS）和主成分分析（PCA）对原始数据进行归一化和处理，得到一组新的紧凑储备池状态向量 $\mathbf{z}_k$。其中，均方根归一化可降低不同受试者之间的差异，而 PCA 则将数据投影到包含最相关特征的低维空间。最后，我们使用一组训练得到的读出权重 $\mathbf{W}_{\mathrm{out}}$ 对 $\mathbf{z}_k$进行加权线性求和，从而得出预测值

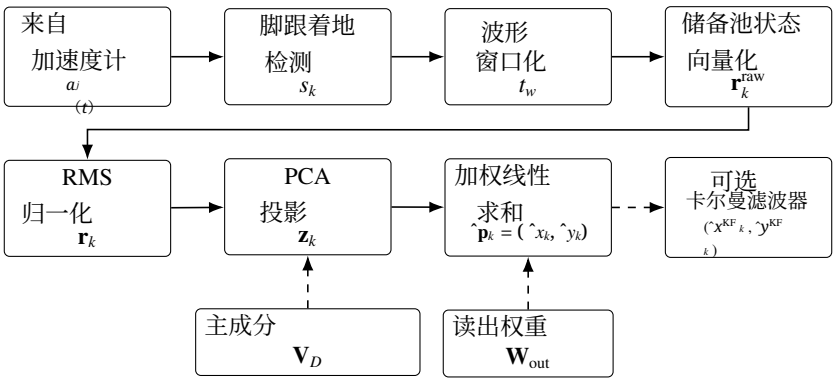

图2：实时 PRC 脚步定位流程。

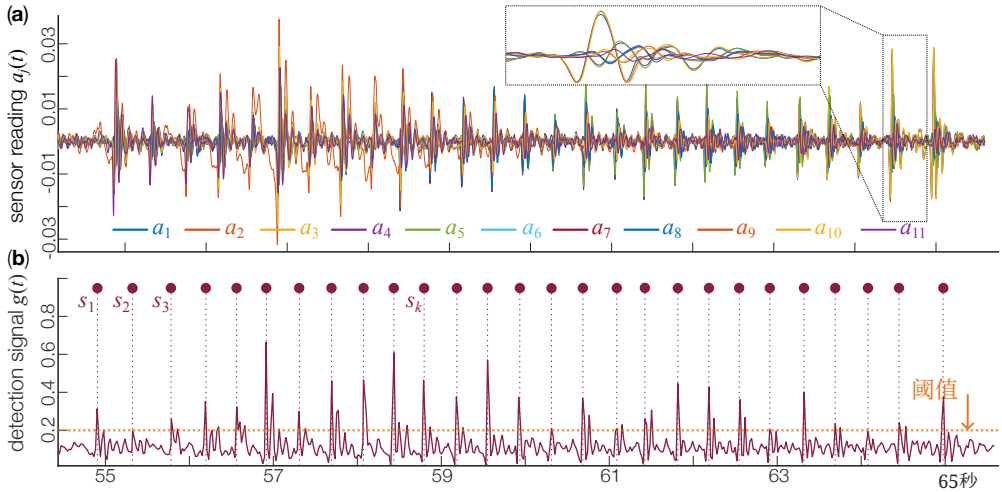

图3：**基于分布式地板加速度计信号的足部着地事件检测**。(a) 所有传感器同时记录的代表性原始加速度信号 $a_j(t)$ 。(b) 通过对原始加速度计读数取平均得到的复合检测信号$g(t)$ 。检测到的足部着地事件 s_k 对应于明显高于固定阈值（橙色虚线）且满足最小间隔约束的峰值，从而确保每一步仅检测一次。

脚步位置 $\hat{\mathbf{p}}_k = (\hat{x}_k, \hat{y}_k)$。此外，还可以使用卡尔曼滤波器对脚步预测进行细化，以平滑这些输出预测值。下文将逐步详细介绍这一物理储备池计算流程。

脚步事件检测

PRC流程的第一步是从地板加速度计的原始数据中实时检测各个脚步冲击。

在每个时间瞬间，来自所有$N_s(= 11)$传感器的绝对加速度信号在空间上

被平均以形成复合检测信号，

$$g(t) = \frac{1}{N_s} \sum_{j=1}^{N_s} |a_j(t)|, \tag{2}$$

这可以突出冲击振动事件并抑制传感器噪声。随后使用短时移动平均滤波器对合成信号进行平滑，以衰减与脚步冲击无关的高频波动。

为检测脚跟着地，我们将标称阈值定义为$g(t)$最大值的一部分。这样，当$g(t)$超过该阈值时，就能检测到脚步。此外，为考虑到强烈的脚跟着地可能产生多个振动峰值这一情况，我们采用分离原则：间隔在200毫秒以内的连续峰值属于同一次脚跟着地（成年人的典型行走脚步之间至少间隔200毫秒，见图3）。通过启发式调整该阈值并强化分离规则，我们可以实时、稳健地检测脚跟着地，并为后续步骤生成脚跟着地时间戳s_k。

储备池状态向量构建

在s_k检测到脚跟着地后，立即使用一个t_w秒的波形窗口，从s_k之前的所有传感器中提取数据，得到

$$\mathbf{A}_k = \begin{bmatrix} a_1(s_k - l + 1) & \cdots & a_{N_s}(s_k - l + 1) \\ \vdots & \ddots & \vdots \\ a_1(s_k) & \cdots & a_{N_s}(s_k) \end{bmatrix} \in \mathbb{R}^{l \times N_s}, \qquad l = \lfloor t_w f_s \rfloor, \tag{3}$$

其中，$a_j(t)$表示来自j^{th}号传感器的加速度数据，N_s为传感器总数，f_s为采样频率。随后，将该多传感器波形窗口$\mathbf{A}_k$重塑为一个高维向量，

$$\mathbf{r}_k^{\text{raw}} = \text{vec}\,(\mathbf{A}_k) \in \mathbb{R}^{1 \times d}, \; d = lN_s, \tag{4}$$

该向量表示对应于第k^{th}次脚跟着地的原始储备池状态。该向量表示保留了传感器网络中振动响应的完整时空结构。在本研究中，窗口长度t_w设为 120 毫秒，以捕捉单个脚步的主要瞬态响应，同时避免与后续脚步重叠；对于以$f_s \approx 1\,\text{kHz}$采样的$N_s = 11$个传感器，得到$d \approx 1320$。

均方根（*RMS*）归一化

人类受试者在体重、鞋类和步态习惯方面存在差异；这些差异会在传感器数据中引入显著且无关的变化，而这些变化与脚步位置无关。为抑制这些不利变化，同时保留编码脚步位置的时空波形结构，我们将每个向量化的储备池状态都除以其全局均方根（RMS）幅值进行归一化：

$$\mathbf{r}_k = \frac{\mathbf{r}_k^{\text{raw}}}{\text{RMS}(\mathbf{r}_k^{\text{raw}})} = \frac{\mathbf{r}_k^{\text{raw}}}{\sqrt{\frac{1}{d}\left\|\mathbf{r}_k^{\text{raw}}\right\|_2^2}}. \tag{5}$$

主成分分析（*PCA*）压缩

归一化后的储备池状态向量$\mathbf{r}_k$包含丰富的信息；然而，由于传感器之间以及不同时间步之间存在相关性，其中也包含大量冗余。为解决这一问题，我们采用主成分分析（PCA）。假设我们要使用来自N个脚步的储备池状态向量进行读出权重训练，可以先将它们组成一个矩阵$\mathbf{R} \in \mathbb{R}^{N\times d}$，使得：

$$\mathbf{R} = \begin{bmatrix} \mathbf{r}_1 \\ \mathbf{r}_2 \\ \vdots \\ \mathbf{r}_N \end{bmatrix}. \tag{6}$$

这样，经验协方差矩阵

$$\mathbf{C} = \frac{1}{N-1}\mathbf{R}^\top\mathbf{R} \tag{7}$$

可进行特征分解 $\mathbf{C} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^\top$，其特征值 $\{\lambda_i\}$ 按降序排列 .
然后，可以将第 $\#k$ 步的储备池状态投影到前 D 个主方向上，

$$\mathbf{z}_k = \mathbf{r}_k\mathbf{V}_D, \tag{8}$$

其中，矩阵 $\mathbf{V}_D \in \mathbb{R}^{d\times D}$ 是 $\mathbf{V}$的一部分，包含其前 D 个特征向量；而$\mathbf{z}_k \in \mathbb{R}^{1\times D}$ 称为对应于第 $\#k$步的前 D 个主成分 。所有传感器数据的累积方差由此次压缩保留的方差比例表示：

$$\eta(D) = \frac{\sum_{i=1}^{D}\lambda_i}{\sum_{i=1}^{d}\lambda_i}. \tag{9}$$

该数值迅速上升—— $\eta(40) \approx 97\%$ 和 $\eta(60) \approx 99\%$——这表明，尽管原始数据的维度很高，建筑物对脚步激励的振动响应本质上仍是低维的。

主成分分析还可以帮助我们直观呈现均方根归一化如何增强储层状态空间的特征，从而支持PRC学习。为此，我们使用每次脚跟着地的前两个主成分，即$\mathbf{z}_k$的前两个元素——$\mathbf{z}_k(1)$和$\mathbf{z}_k(2)$，$k = 1 \ldots N$——作为两个坐标，以生成图4中的投影图。在这些图中，每个点代表一次独特的脚步。图4(a)和图4(b)分别比较均方根归一化之前和之后的主成分。在均方根归一化之前，两名受试者的结果落入部分分离的簇。相比之下，经过均方根归一化后，两名受试者的数据汇聚到一个连续、弯曲的低维区域（通常称为流形）。此外，我们根据相应脚步沿全局x–轴的位置对这些图进行着色，如图4(c)和图4(d)所示。可以看出，经过均方根归一化后，脚步数据沿流形的轨迹平滑且单调地分布。

这些主成分分析的结果表明，在均方根归一化之前，$\mathbf{z}_k(1)$ 和 $\mathbf{z}_k(2)$ 所捕获的数据方差，主要受与振幅相关且因受试者而异的影响因素影响，例如受试者的体重、鞋类、冲击强度和步态习惯。因此，即使是来自同一足部着地点的数据，也可能被映射到图中的不同区域。均方根归一化可以消除受试者之间的振幅差异，同时保留振动波形相对的时空形态。因此，来自这两位

位受试者的数据会“塌缩”并合并到同一流形中，使该流形内的方差基本不受居住者影响，而仅由建筑的振动波传播物理特性决定。重要的是，这种重叠有利于后续的储备池计算训练，因为它使储备池状态到脚步位置的映射在不同受试者之间保持一致。

通过岭回归实现线性读出

经过均方根归一化和主成分分析投影后，每个脚步产生的动态响应都由一个低维储备池状态 $\mathbf{z}_k \in \mathbb{R}^{1\times D}$ 表示。PRC流程的最后一步是使用加权线性求和，将该储备池状态映射为对此次脚跟着地位置的预测值。具体而言，估计的足部着地点 $\hat{\mathbf{p}}_k = (\hat{x}_k\ \hat{y}_k)^\top \in \mathbb{R}^{2\times 1}$ 表示为

$$\hat{\mathbf{p}}_k = \mathbf{W}_{\text{out}}^\top \begin{bmatrix} \mathbf{z}_k \\ 1 \end{bmatrix}, \tag{10}$$

其中，附加的常数项表示偏置项，$\mathbf{W}_{\text{out}} \in \mathbb{R}^{(D+1)\times 2}$ 表示读出权重向量。读出权重通过对训练数据进行岭回归学习得到。将所有用于训练的脚步所对应的投影储备池状态 $[\mathbf{z}_k^\top \quad 1]$ 堆叠起来，记为训练数据矩阵 $\mathbf{Z}_{\text{tr}} \in \mathbb{R}^{N_{\text{tr}}\times(D+1)}$，矩阵 $\mathbf{P}_{\text{tr}} \in \mathbb{R}^{N_{\text{tr}}\times 2}$ 则收集相应的真实值

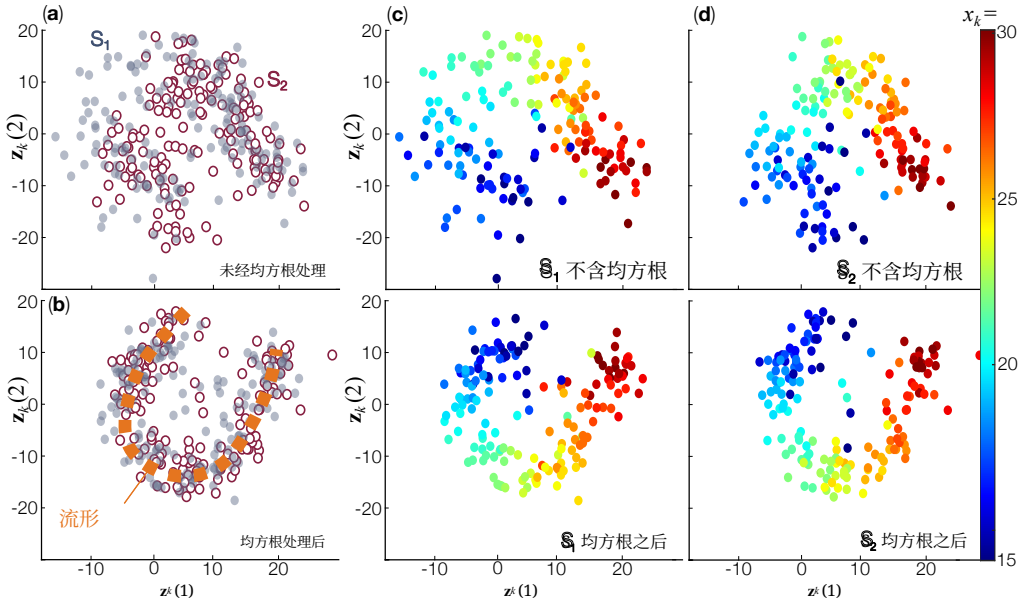

图4：**均方根归一化使不同居住者的储备池状态相互对齐，并揭示与位置相关的特征**。在此图中，每个点对应一个独立的脚步，其依据是归一化并投影后的储备池状态向量的前两个主成分（即 $[\mathbf{z}_k(1), \mathbf{z}_k(2)], k = 1 \ldots N$）。（**a,b**）两位受试者在应用均方根归一化前后的脚步数据。显然，经过均方根归一化后，数据收敛为一个紧凑的“流形”。**(c,d)** 更详细的图，其中颜色映射表示脚步在走廊中的位置（沿x– 轴）。均方根归一化和主成分分析投影有助于不同参与者之间的物理储备池学习。

位置$\mathbf{p}_k = (x_k\ y_k)^\top$。读出结果通过求解以下问题得到：

$$\mathbf{W}_{\text{out}} = \left(\mathbf{Z}_{\text{tr}}^\top \mathbf{Z}_{\text{tr}} + \varepsilon \mathbf{I}\right)^{-1} \mathbf{Z}_{\text{tr}}^\top \mathbf{P}_{\text{tr}}, \tag{11}$$

其中，$\varepsilon > 0$是一个正则化参数，可改善数值条件并缓解过拟合。

通过二维卡尔曼滤波器进行可选的在线后处理

为减少步与步之间的抖动并平滑物理储备池计算的输出，可以选择使用线性卡尔曼滤波器和匀速运动模型，对式（10）中的脚步位置预测值 $\hat{\mathbf{p}}_k$ 进行后处理。需要特别指出的是，这一步仅 作用于读出预测值，与储层构建、特征提取和训练完全无关。因此，卡尔曼滤波不会提高储备池计算的容量，也不会改变传感器读数所依托的物理表征。相反，它会对连续脚步施加轻量级的运动学一致性约束。我们将检测到的第 #k 个脚步的潜在运动学状态定义为

$$\mathbf{p}_k^* = \begin{bmatrix} x_k & y_k & \dot{x}_k & \dot{y}_k \end{bmatrix}^\top, \tag{12}$$

其中，(x_k, y_k)是平面上的脚步位置，而$(\dot{x}_k, \dot{y}_k)$是相应的逐步速度。状态按照离散时间匀速运动模型演化，即

$$\mathbf{p}_k^* = \mathbf{F}\mathbf{p}_{k-1}^* + \mathbf{n}_{k-1}, \qquad \hat{\mathbf{p}}_k = \mathbf{H}\mathbf{p}_k^* + \mathbf{u}_k, \tag{13}$$

以及状态转移矩阵和观测矩阵

$$\mathbf{F} = \begin{bmatrix} 1 & 0 & \Delta & 0 \\ 0 & 1 & 0 & \Delta \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}, \qquad \mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}. \tag{14}$$

这里，Δ 是相邻两个检测到的脚步之间的离散时间增量。由于卡尔曼滤波器在步数索引域而非物理时间域中运行，因此我们不失一般性地令 $\Delta = 1$ 。实际步伐间隔和步行速度的变化则由过程噪声项吸收：具体而言，过程噪声$\mathbf{n}_k \sim \mathcal{N}(0, Q)$捕捉未建模的步行速度和方向变化（例如加速、减速或轻微转向），而测量噪声项$\mathbf{u}_k \sim \mathcal{N}(0, R)$描述物理储层计算读出预测瞬时值的不确定性。在本研究中，我们采用各向同性协方差矩阵$Q = q\mathbf{I}_4$ 和$R = r\mathbf{I}_2$，，其中标量参数q 和r 通过启发式方法选取，以兼顾脚步轨迹平滑度与保留真实运动变化的需求。每一步的滤波后位置估计取后验均值的位置分量，

$$\hat{\mathbf{p}}_k^{\text{KF}} = \begin{bmatrix} \hat{x}_k^{\text{KF}} & \hat{y}_k^{\text{KF}} \end{bmatrix}^\top. \tag{15}$$

总体而言，卡尔曼滤波步骤会抑制由测量噪声或较弱的侧向可观测性造成的高频、逐步波动，同时保留由 PRC 预测值决定的全局轨迹形状。它基于四维状态向量进行闭式更新，因此卡尔曼滤波器的计算开销可以忽略不计，并且适用于实时脚步定位。

误差指标

我们使用对所有检测到的脚步计算的均方根误差（RMSE）来评估脚步预测值的准确性。对于每一步 k，总体均方根误差为

$$\mathrm{RMSE} = \sqrt{\frac{1}{N}\sum_{k=1}^{N} \|\hat{\mathbf{p}}_k - \mathbf{p}_k\|_2{}^2}, \tag{16}$$

其中，$\mathbf{p}_k = [x_k\, y_k]^\top$ 和 $\hat{}\mathbf{p}_k = [\hat{}x_k\, \hat{}y_k]^\top$ 分别表示真实值和预测的脚步位置。N 表示评估数据集中的脚步总数。为了评估方向定位性能，我们还分别报告了纵向（x）和横向（y）方向上的误差:

$$\mathrm{RMSE}_x = \sqrt{\frac{1}{N}\sum_{k=1}^{N}(\hat{x}_k - x_k)^2}, \qquad \mathrm{RMSE}_y = \sqrt{\frac{1}{N}\sum_{k=1}^{N}(\hat{y}_k - y_k)^2}. \tag{17}$$

3. 结果——在不同参与者中成功预测脚步位置

本研究的实验旨在评估所提出的 PRC流程在训练数据有限且传感器有限的情况下定位脚步的效果。这体现了核心前提：建筑的非线性结构动力学能够完成大部分信息处理。因此，训练和测试按步行行程（即 Tr_i）组织，而非按单个脚步组织。此外，我们系统地调整训练数据多样性（即行走遍次数量）和空间传感覆盖范围（即传感器数量），以深入了解相关情况并总结最佳实践。

3.1. 单参与者脚步预测

我们首先评估 PRC 在训练和测试均使用同一参与者的步行行程时的预测性能。在此方案中，所有训练数据和测试数据均来自同一受试者。具体而言，我们选取若干行走遍次$\{\mathrm{Tr}_i\}$ 的数据进行读出训练（公式10–11），并使用其余行走遍次的数据进行测试。

例如，我们使用受试者1前三次行走遍次（即 $\{\mathrm{S}_1 : \mathrm{Tr}_1 – \mathrm{Tr}_3\}$）的归一化和投影后储备池状态数据，训练一组线性读出，然后使用第六次行走遍次（$\{\mathrm{S}_1 : \mathrm{Tr}_6\}$）的数据测试该读出。图5总结了此次训练和测试的准确性。可以看到，在纵向上，建筑储备池的预测值在训练和测试期间均能成功跟随真实值，误差低于1米（训练时均方根误差为 = 0.49米，测试时为0.65米）。这一结果证实，脚跟着地产生的时空振动动力学确实能够沿走廊形成稳定且依赖位置的特征。然而，横向脚步预测的误差更为显著，均方根误差从训练时的0.20米增至测试时的0.47米。

读出训练设置的影响

继图5中的成功示例之后，我们进一步研究了建筑储备池在不同训练设置下的性能。首先，我们从分布层面考察预测准确率（图6a）。图6(a)从分布层面展示了定位精度。

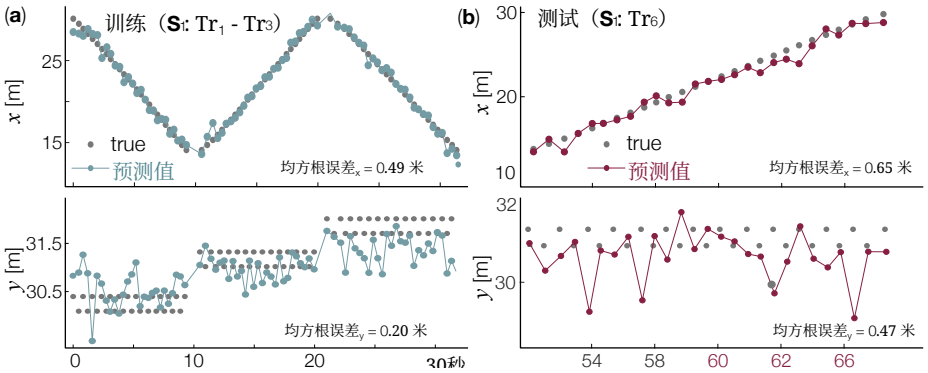

图5：**使用受试者 S_1的数据进行建筑储备池预测，未使用卡尔曼滤波。(a,b)** 使用行走遍次 Tr_1–Tr_3进行训练的结果。**(c,d)** 在读出训练期间未见过的行走遍次 Tr_6, 上的测试结果。

训练误差集中在较小的数值范围内，而测试误差的分布更广，反映出在未见过的行走遍次中存在额外变异。不过，没有出现极端异常值，这表明泛化失效是逐渐发生的，而非灾难性的。接下来，我们改变传感器的数量及其空间覆盖范围（图6b）。如果储备池计算仅使用一个楼层传感器，均方根误差显然会非常大。随着将更多传感器纳入储层计算流程，训练误差和测试误差都会迅速下降。值得注意的是，超过六个传感器后，脚步预测准确率开始趋于稳定，这意味着六个楼层传感器足以捕捉最有价值的振动响应，以实现信息感知。随后，我们改变训练数据的数量（图6c、d）。图5所示的示例使用了三次行走遍次的传感器数据进行读出训练。增加训练行走次数可以降低测试误差，但可能会略微增加训练误差，表明存在一定程度的过拟合。分别绘制纵向和横向方向上的均方根误差后，可以看出，额外训练行走数据带来的益处主要体现在纵向分量的均方根误差上 $_x$ （图6d）。相比之下，额外训练数据对RMSE$_y$ 的改善较为有限，这反映出楼板动力学的侧向可观测性较弱。

3.2. 跨参与者脚步预测

接下来，我们评估建筑储层管道能否在步态特征不同的个体之间实现泛化。在这种跨参与者设置中，使用一名受试者的数据训练线性读出 $\mathbf{W}_{\text{out}}$ ，然后在另一名受试者身上进行测试；同时，建筑、传感器布局和信号处理流程保持不变。这是一项严格的泛化测试，因为参与者在体重、步频、鞋类和冲击条件方面的差异，可能会显著改变振动响应和短时波形结构。

图7展示了一个示例结果：读出层仅使用参与者 $\{S_1 : Tr_1 – Tr_3\}$ 的数据进行训练，并应用于另一位参与者 $\{S_2 : Tr_1 – Tr_3\}$ 的所有脚步。尽管建筑储备池在训练期间从未观察过受试者 S_2 的数据，却成功重建了他的脚步轨迹，正确预测了落脚顺序和方向，且没有出现累积漂移。误差在速度快速变化（即转弯）附近最为明显，因为此时步间运动偏离了平滑的匀速轨迹。

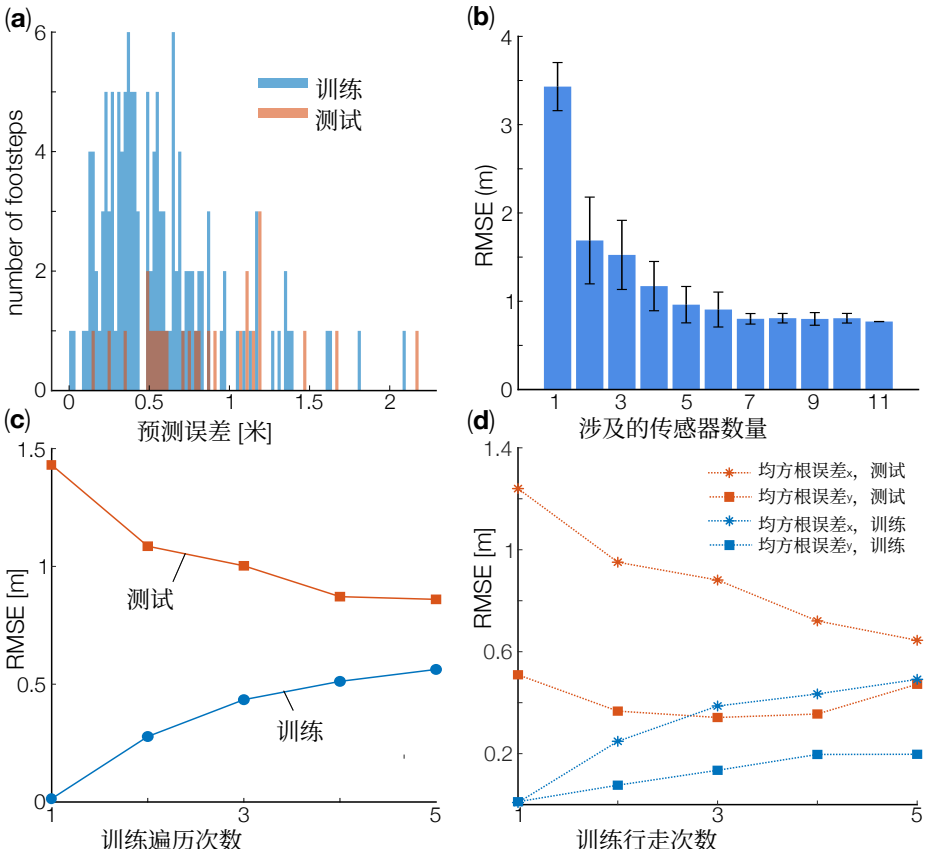

图6：**物理储备池训练设置的影响**。 (a) 训练与测试的每步欧几里得定位误差直方图。(b) 测试均方根误差随涉及的传感器数量的变化。(c) 训练与测试的平均欧几里得均方根误差随用于读出训练的行走遍次数量的变化。(d) 均方根误差$_x$ 与均方根误差$_y$ 随训练行走次数变化的进一步分解。

卡尔曼滤波的影响

为提高脚步预测的时间一致性，我们将第2.3节介绍的可选匀速卡尔曼滤波器作为后处理步骤。图8比较了PRC预测值及其经过卡尔曼滤波后的结果。卡尔曼滤波主要缩小了误差分布的中心区域，并减少了中等程度的误差，使平均均方根误差从1.10米降至0.91米。尤其是，大幅异常值有所减少——这是预期之中的，因为滤波能够确保短期运动学一致性。图8(b,c)中的示例轨迹展示了这一效果：高频的步间波动受到抑制，轨迹因此更加平滑，也更符合物理规律。重要的是，卡尔曼滤波只是细化了底层PRC预测值，并未从根本上改变它们。

读出训练设置的影响

与单参与者测试类似，我们量化读出训练设置的变化对跨使用者泛化的影响。首先，我们改变用于读出

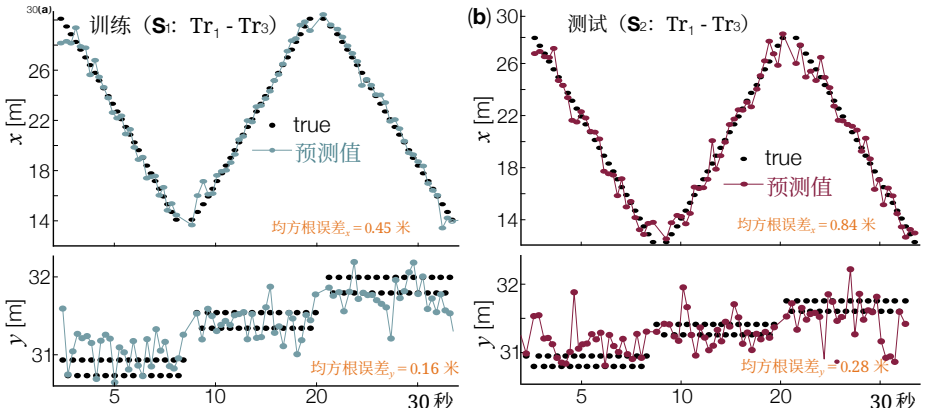

图7：**使用建筑储备池进行跨居住者预测**。在受试者1（**a**）上训练，并在受试者2（**b**）上测试。建筑储备池成功重建了不同参与者的脚跟着地轨迹。

训练的行走遍次数。具体而言，我们从合计十二次行走遍次（每位受试者六次）中随机选取一至十次，构建训练数据集。同时，其余行走遍次用于测试。结果汇总于图 9。

图9(a、c、d)显示，随着训练中使用的行走数据遍次增加，跨参与者泛化能力稳步提升。仅使用一到两次训练行走遍次时，测试误差较大且波动明显。随着更多行走遍次纳入读出训练，测试均方根误差的大小和波动幅度均有所下降，这表明更丰富的激励多样性有助于储层表征更好地捕捉不同参与者的脚步动态。在训练行走遍次达到约六到八次后，性能趋于稳定；此后进一步提升的幅度很小。值得注意的是，图9(d)中均方根误差的细分结果显示，这些改进主要体现在纵向坐标均方根误差$_x$上，与单参与者测试中的情况相似。还值得注意的是，卡尔曼滤波始终能降低绝对误差，但并未从根本上改变总体趋势。

接下来，我们改变传感器数量及其空间覆盖范围（图9b）。与单参与者测试相似，随着更多传感器纳入读出训练，测试均方根误差迅速下降：使用四个传感器时约为1.5米，超过六个传感器后则收敛至1.0–1.1米。

总体而言，跨参与者测试结果表明，基于振动的建筑储层计算能够提供一种大体上与受试者无关的脚步诱发动态表征。在传感覆盖范围适中、训练数据有限的情况下，该系统仍能实现稳定的米级预测精度，无需大量仪器布设或针对特定受试者的重新训练。

4. 讨论

总而言之，测试结果表明，将仪器化建筑视为物理储层，为我们提供了一种简单而强大的脚步定位工具。所提出的物理储备池计算流程保留了行走轨迹的几何与时间结构

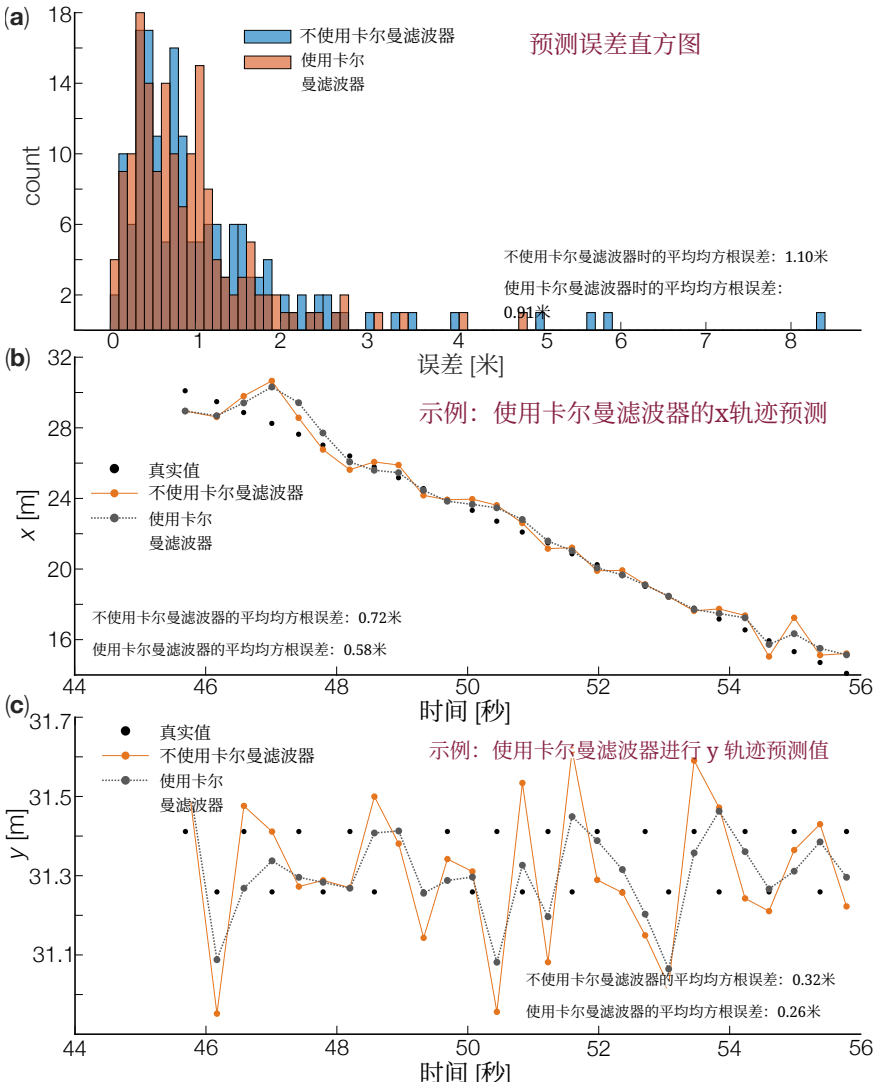

图8：**使用卡尔曼滤波进行跨参与者 PRC预测**。**(a)** 使用和不使用卡尔曼滤波时的逐步预测误差分布。**(b)** 沿走廊方向的示例轨迹。**(c)** 横穿走廊方向的示例轨迹。

——预测出的脚步沿着走廊行进，并横穿走廊，追随参与者的行走路线（不会向走廊中心线收缩），保持正确的脚步顺序，并重现步行速度和横向运动的自然变化，同时平均误差较低。训练和测试中的储备池结果一致，在跨参与者测试中也保持稳定。尤为重要的是，这些优势仅依靠短时波形数据窗口、简单的数据处理（均方根和主成分分析）以及线性读出即可实现，这表明性能提升源自建筑结构本身提供的物理时空编码，而非模型复杂度的增加、递归滤波或轨迹——

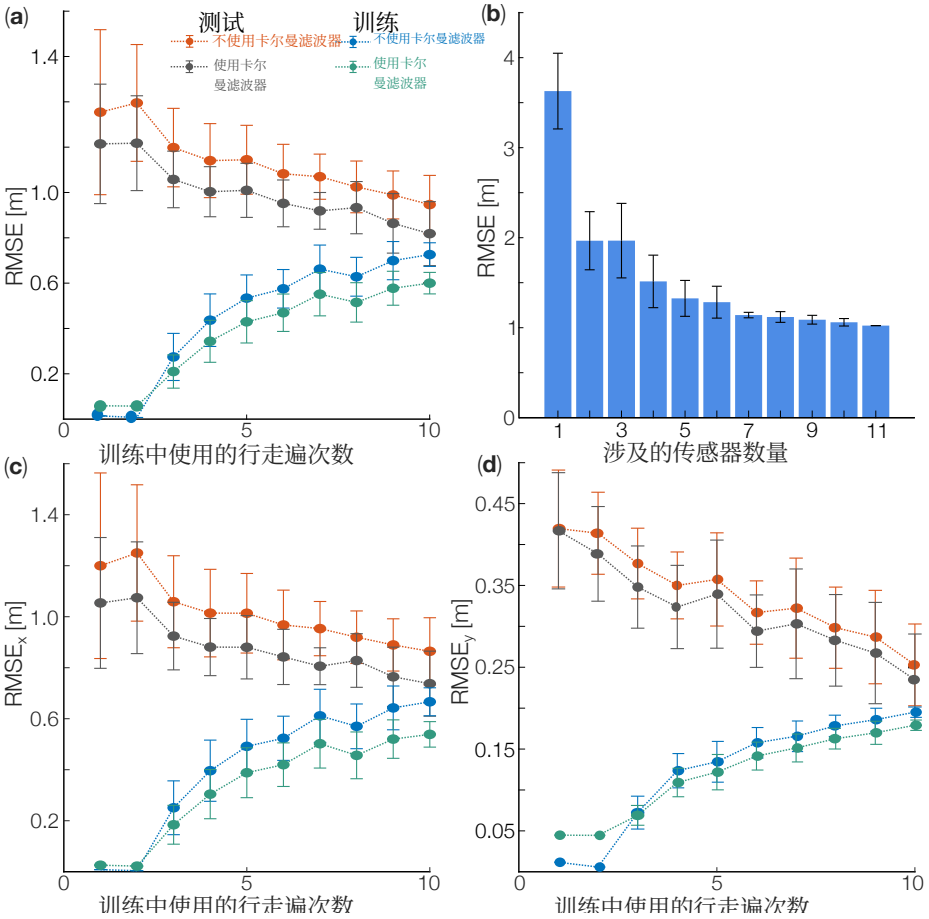

图 9：**训练数据设置和传感器选择对跨居住者定位精度的影响**。(a) 训练和测试均方根误差与训练遍历次数的关系。(b) 跨居住者测试均方根误差与传感器数量的关系。(c,d) 按两个方向进一步细分测试及测试误差：均方根误差$_x$ 和均方根误差$_y$。

层级约束。

4.1. 与基于能量的方法比较

在此，我们在同一数据集上（表 1）对比了我们的储层计算流程与先前采用基于能量的方法所取得的性能。这些能量方法包括启发式接收信号强度（RSS）方法、改进的启发式方法变体，以及最大似然（MaxLik）估计器。它们使用了完全相同的传感器布局和测试数据，但在方法原理上存在根本差异：基于能量的方法依赖手工设计的能量特征和衰减模型，而 PRC 则通过学习得到的线性读出，直接处理高维振动波形。与已发表的基于能量的方法相比，我们提出的 PRC 流程有两项显著优势。

(1) 误差降低：采用均方根归一化和主成分分析压缩的建筑储层管道，在两名测试对象上的总体欧几里得均方根误差最低。相较于启发式 RSS 基线，PRC 使受试者1的总均方根误差降低约 38%，受试者2降低约 33%。

(2) 跨参与者预测：需要强调的是，现有大多数基于振动的脚步研究——包括此处列出的基于能量的方法——主要报告同一参与者的数据结果。也就是说，训练数据和测试数据来自同一个人，或者使用所有可用数据隐式校准受试者相关参数（例如衰减系数或参考能量轮廓）。很少有研究报告明确的跨参与者评估，即在一名参与者的数据上训练预测模型，再在另一名参与者的数据上测试。目前没有直接证据表明能量方法可以实现跨参与者预测；尽管如此，我们在表 1 中强调的结果展示了一个颇具前景的新方向。

表 1：落脚位置预测的均方根误差比较。单位为米。请注意，带星号的（*）数值为跨参与者测试结果，而此前没有研究对此进行过考察。

算法	测试受试者1			测试受试者2		
	RMSE_x	RMSE_y	RMSE_T	RMSE_x	RMSE_y	RMSE_T
启发式残差平方和 [33]	1.39	0.35	1.43	1.36	0.35	1.40
改进的启发式方法 [7]	0.79	0.66	1.03	0.93	0.64	1.13
最大似然残差平方和 [14]	0.67	0.58	0.89	0.74	0.58	0.94
传统PRC（无均方根、无主成分分析）	1.21	0.34	1.33	2.60*	0.37*	2.69*
基于振动的PRC（本研究）	**0.63**	**0.47**	**0.86**	**0.98***	**0.32***	**1.13***

4.2. 为什么预测脚步着地点的横向位置更具挑战性？

图10(a)和(b)展示了通过将走廊空间离散为若干空间“区间”，并将每次脚步的真实区间与PRC预测值进行比较而得到的混淆矩阵。混淆矩阵中明显的对角线模式表明，脚步着地点的空间位置可以清晰区分；而向非对角线扩散则表示存在歧义。如图10(a)所示，沿走廊方向（即x– 方向）的混淆矩阵呈现出清晰的对角线，误差基本局限于局部范围。这表明该方向具有很强的物理可分离性。相比之下，图10(b)所示的y方向混淆矩阵呈现出明显的非对角线扩散，并部分集中到少数几个区间，说明不同横向位置的脚步往往会产生非常相似的振动响应，因此PRC流程难以将其区分。

图 10(c) 使用 Fisher可判别性分析 [34] 从传感器层面提供了补充证据。对于每个加速度计 j，都可以计算一个 Fisher比，计算公式如下：

$$J_j = \frac{\sum_c N_c(\mu_c - \mu)^2}{\sum_c N_c \sigma_c^2}, \tag{18}$$

其中每个空间分箱c 对应于一组位置相近的脚步，μ_c 和 σ_c^2 是该分箱内传感器振动特征的均值和方差，N_c 是该分箱中的脚步数量，μ是所有分箱的全局均值。从物理意义上讲，式*(18)*的分子衡量传感器读数随脚跟着地位置变化的程度，而分母衡量该响应因噪声、步态变异性以及其他

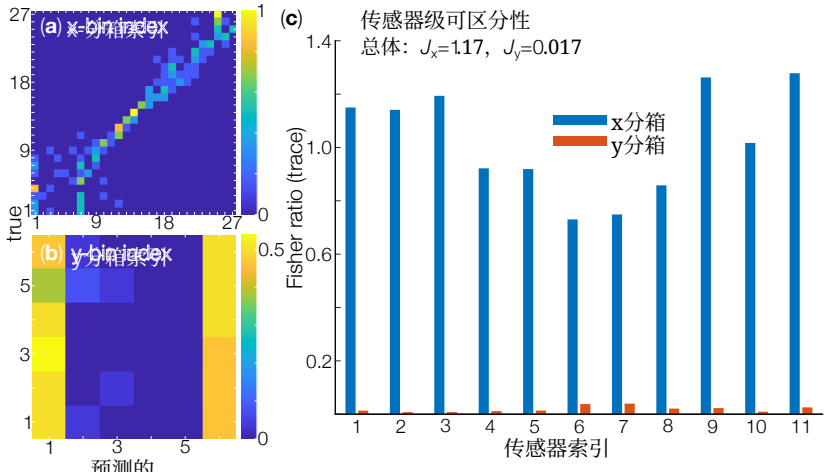

图10：**纵向和横向方向上脚步位置的可观测性**。(a) 离散化x分箱位置的混淆矩阵。(b) 离散化y分箱位置的混淆矩阵。(c) 直接根据原始振动特征计算的x分箱和y分箱的传感器级Fisher比。

非关键的效应。因此，较大的Fisher比表明传感器读数对足部着地点的变化较为敏感，反之亦然。为此，图10(c)的结果表明，在所有传感器上，Fisher比沿x– 方向始终较高，而对y接近于零，这表明基于原始振动测量，脚步着地点的纵向位置已经线性可分。

因此，从基本物理原理的角度来看，混淆矩阵和Fisher可判别性分析得出结论：建筑结构的振动响应本身能够区分沿x轴的脚跟着地位置，因此，RPC流程可以通过简单的线性读出准确提取这一信息；但有关y–轴位置的信息则受到压缩。因此，提高沿y–轴的预测准确率，需要对建筑储备池进行物理重构，例如重新布置楼层传感器、引入具有额外感知模态的新传感器，或调整建筑施工方案，以进一步丰富非线性动力学。

5. 结论

本研究探索了一种定位建筑居住者脚步位置的新方法：将仪器化建筑改作物理储层，利用其固有的结构动力学在物理域中执行机器学习。与基于物理的建模或纯粹的数据驱动机器学习不同，所提出的物理储备池计算（PRC）方法利用了建筑的非线性时空响应这一物理现象，可将脚步激励转换为特征丰富的振动波形，而这些波形本身就编码了有关脚跟着地位置的信息。因此，通过简单的线性读出即可从这些波形中提取该信息。

本研究的一项核心贡献是提出了一种新颖的基于振动的*PRC*流程，将短波形储备池状态与均方根归一化和主成分分析投影相结合。均方根归一化可抑制传感数据中的受试者相关变异，而主成分分析投影则会选取

对足部着地点最敏感的主导振动模态。这些数据处理技术相结合，显著提高了建筑储备池的准确性，使其能够在无需针对特定受试者重新训练的情况下，实现准确的跨参与者预测值。

通过利用非线性结构动力学作为特征扩展的主要机制，*PRC*流程还最大限度地降低了训练数据需求。仅需少量训练行走次数和适量传感器，即可可靠地预测脚步位置；相比之下，传统机器学习方法通常需要大量标注数据集并进行广泛的重新训练。随着训练数据覆盖范围和传感器数量的增加，脚步预测性能迅速收敛，这凸显了物理储备池范式的数据效率。

与传统的基于能量的脚步定位方法相比，所提出的方法表现出具有竞争力且往往更优的性能，尤其是在传感地板区域边界附近。这一改进凸显了利用完整波形结构而非仅基于振幅的特征的价值。最后，混淆矩阵和费舍尔比率分析表明，纵向与横向之间的性能差距源于建筑储备池的物理限制，而非算法缺陷。

总体而言，本研究确立了基于振动的物理储备池计算是一种可扩展、数据高效且实时的智能感知框架，适用于建筑、桥梁及其他工程系统，在这些系统中，分布式振动会自然编码与任务相关的信息。

致谢本研究由美国国家科学基金会 DCSD 项目（编号 #2328522）及弗吉尼亚理工大学（启动资金）资助。

参考文献

[1] M. Mirshekari、S. Pan、J. Fagert、E. Schooler、P. Zhang、H. Noh，基于脚步诱发的结构振动的人员定位，机械系统与信号处理（2018年）。doi:10.1016/j.ymssp.2018.04.026.[2] M. Mirshekari等，利用MEMS加速度计上的物理储备池计算进行步态事件检测（2019年）。[3] M. Mirshekari、J. Fagert、S. Pan、P. Zhang、H. Noh，基于脚步诱发的结构振动的障碍物不变人员定位，机械系统与信号处理153（2021年）107499。doi:10.1016/j.ymssp.2020.107499.[4]F. Li、J. Clemente、M. Valero、Z. Tse、S. Li、W. Song，基于脚步诱发振动的智能家居监测系统，IEEE系统期刊14（2020年）3383–3389。doi:10.1109/jsyst.2019.2937960.[5] Y. Dong、J. Liu、H. Noh，Gaitvibe+：利用临时摄像头增强基于结构振动的脚步定位，用于居家步态分析，第20届ACM嵌入式网络传感器系统会议论文集（2022年）。doi:10.1145/3560905.3568435.[6] R. Chen、Y. Zhu、Q. Chen、C. Zhu，基于深度学习的脚步振动信号运动目标定位方法，应用科学（2024年）。doi:10.3390/app14209361.

[7] S. Alajlouni、P. Tarazaga，一种基于被动能量的脚步冲击定位方法：利用带卡尔曼滤波的地板下加速度计传感器网络，《振动与控制杂志》26（11-12）（2020年）941–951。[8] J. D. Poston、R. M. Buehrer、P. Tarazaga，基于结构动力学仪器布设的室内脚步定位，机械系统与信号处理88（2017年）224–239。doi:10.1016/j.ymssp.2016.11.023.[9]S. Drira、I. Smith，一种利用地板振动信号进行占用检测与跟踪的框架，机械系统与信号处理（2022年）。doi:10.1016/j.ymssp.2021.108472.[10] S. Alajlouni、P. Tarazaga，面向基于被动能量的脚步定位的最大似然估计，机械系统与信号处理（2021年）。[11] P. Tarazaga、S. Alajlouni，土木结构中基于能量的脚步定位，《振动与控制杂志》（2018年）。[12] A. e. a. Appelle，利用深度卷积神经网络进行到达时间差估计的行人脚步定位（2024年）。[13] T.-C. Yang等，近期室内定位场景与方法综述，传感器（2021年）。[14] S. Alajlouni、J. Baker、P. Tarazaga，面向基于被动能量的脚步定位的最大似然估计，机械系统与信号处理163（2022年）108158。[15] S. Drira等，通过识别脚步接触动力学提高占用者定位精度，高级工程信息学（2021年）。[16]M. Ambarkutuk、P. Plassmann，面向振动定位的结构波色散传播建模与分析，传感器（瑞士巴塞尔）24（2024年）。doi:10.3390/s24237744.[17] Y. Yu、O. Carl、S. Hussain、W. Hou、T. Weis，一种基于地板振动的隐私保护步级行走方向检测算法，IEEE传感器期刊23（2023年）10814–10824。doi:10.1109/jsen.2022.3209909.[18]Y. Yu、M. Waltereit、V. Matkovic、W. Hou、T. Weis，基于深度学习的振动信号人员定位系统，IEEE Access 8（2020年）226108–226118。doi:10.1109/access.2020.3044497.[19] Y. Dong、J. Fagert、H. Y. Noh，面向开放环境人员识别的脚步诱发结构振动变异性表征，机械系统与信号处理（2023年）。doi:10.1016/j.ymssp.2023.110756.[20] M. Mirshekari、J. Fagert、S. Pan、P. Zhang、H. Noh，利用模型迁移，通过脚步诱发的地板振动在不同结构中实现步级占用者检测，ASCE工程力学期刊146（2020年）04019137。doi:10.1061/(asce)em.1943-7889.0001719.

[21] M. Mirshekari, J. Fagert, S. Pan, P. Zhang, H. Noh, 基于物理引导的模型迁移：利用脚步诱发的地板振动监测人体步态,《结构健康监测：国际期刊》(2019年). doi:10.12783/shm2019/32337.[22] T. Imbiriba, O. Straka, J. Duník, P. Closas, 用于导航与跟踪的增强型基于物理的机器学习, IEEE航空航天与电子系统汇刊 60 (2024年) 2692–2704. doi:10.1109/taes.2023.3328853.[23] K. Nakajima, 物理储备池计算——入门视角,《日本应用物理学杂志》59 (2020年). doi:10.35848/1347-4065/ab8d4f.[24] G. Tanaka, T. Yamane, 等, 物理储备池计算的最新进展：综述,《神经网络》115 (2019年) 100–123.[25] Y.-B. Leng, Z. Lv, S. Huang, P. Xie, H. Li, S. Zhu, T. Sun, Y. Zhou, Y. Zhai, Q. Li, G. Ding, Y. Zhou, S. Han, 一种具有高维储备池表征的近红外视网膜形态器件,《先进材料》(佛罗里达州迪尔菲尔德比奇) 36 (2024年). doi:10.1002/adma.202411225.[26] H. Huang, X. Liang, Y. Wang, J. Tang, Y. Li, Y. Du, W. Sun, J. Zhang, P. Yao, X. Mou, F. Xu, J. Zhang, Y. Lu, Z. Liu, J. Wang, Z. Jiang, R. Hu, Z. Wang, Q. Zhang, B. Gao, X. Bai, L. Fang, Q. Dai, H. Yin, H. Qian, H. Wu, 用于多样化传感器内计算的全集成多模式光电忆阻器阵列,《自然·纳米技术》20 (2024年) 93–103. doi:10.1038/s41565-024-01794-z.[27] J. Lao, M. Yan, B. Tian, C. Jiang, C. Luo, Z. Xie, Q. Zhu, Z. Bao, N. Zhong, X. Tang, L. Sun, G. Wu, J. Wang, H.-Q. Peng, J. Chu, C. Duan, 利用自供能传感器储备池实现超低功耗机器视觉,《先进科学》9 (2022年). doi:10.1002/advs.202106092.[28] P. Bhovad, S. Li, 基于折纸的物理储备池计算及其在机器人爬行中的应用,《科学报告》11 (1) (2021年) 13002.[29] J. Wang, S. Li, 将模块化折纸机械臂改造为适用于机器学习和机器人感知的自适应物理计算机,《先进科学》(2025年) e09389doi:10.48550/arxiv.2505.02744.[30] J. Wang, Z. Qiao, W. Zhang, S. Li, 通过物理储备池计算，以最少训练数据实现织物软体机械臂的本体感受与外感受信息感知,《先进智能系统》7 (2024年). doi:10.1002/aisy.202400534.[31] M. Cucchi, S. Abreu, G. Ciccone, D. Brunner, H. Kleemann, 储备池计算实践指南：实操教程,《神经形态计算与工程》2 (3) (2022年) 032002.[32] J. Wang, S. Li, 在机械领域构建智能——利用折纸中的储备池计算能力实现信息感知任务,《先进智能系统》5 (2023年). doi:10.1002/aisy.202300086.[33] S. Alajlouni, P. Tarazaga, 一种用于传感地板上脚步冲击定位的快速免校准新方法,《振动与控制杂志》25 (10) (2019年) 1629–1638.

[34] G. Giorgetti、S. K. Gupta、G. Manes，使用信号强度进行定位：测距还是不测距？，载于：第一届ACM无 GPS 环境中的移动实体定位与跟踪国际研讨会论文集，2008 年，第 91–96 页。