arXiv:2302.00065v1 [physics.ins-det] 20 Jan 2023

基于多通道自混合干涉测量的高可用性位移传感

ROBIN MATHA 1,2，STÉPHANE BARLAND [2,*] 和 FRANÇOIS GUSTAVE[1]

[1]*DOTA，ONERA，巴黎-萨克雷大学，法国帕莱索 F-91123*[2]蔚蓝海岸大学 -法国国家科学研究中心，尼斯物理研究所，*1361 route des Lucioles*，法国瓦尔邦 *F-06560*[*]
stephane.barland@univ-cotedazur.fr

摘要：激光自混合原则上是一种简单、稳健且用途广泛的干涉测量方法，并具有非线性带来的额外表现力。然而，它对目标反射率的不期望变化相当敏感，这往往会妨碍其在非合作目标中的应用。在此，我们通过实验分析了一种多通道传感器，该传感器基于三个独立的自混合信号，并由一个小型神经网络进行处理。我们表明，该传感器能够实现高可用性运动传感，不仅能抵御测量噪声，也能应对某些通道中的信号完全丢失。作为一种基于非线性光子学和神经网络的混合传感形式，它也为全模态复杂光子传感开辟了前景。

© 2023年 Optica出版集团，依据Optica出版集团出版协议

1. 引言

复杂（非线性或无序）系统长期以来一直被视为具有高容量的“信息处理器”[1]。对于处理环境变化这一特定任务（即“传感”），复杂波和光子系统尤其有用，因为它们能够远距离处理信息。近年来，利用复杂波物理和计算机神经网络的混合方案在神经网络与光学的交叉领域取得了杰出成果[2, 3]，[4]。得益于其非线性，自混合干涉测量能够承载比其线性对应方法多得多的信息，因此可能适用于许多传感任务[5–11]。

自混合干涉测量基于延迟反馈效应：激光束被目标反射后重新进入发射它的激光器本身（大多数情况下为半导体激光器）。众所周知，这种反馈会改变激光器的工作点；通过监测该工作点（借助集成光电二极管，或直接测量二极管两端的电压），便可获取有关目标位移的信息。由于这种方案简单紧凑，预计可将其用作稳健可靠的传感技术，例如用于测量目标沿光传播轴的位移。然而，能够可靠获取信息的工作范围实际上是一项重要限制，尤其取决于重新进入发射激光器的光量。该光量通常用耦合参数 C 来表征，它也取决于目标距离。关于不同反馈状态随C 变化的详细讨论（其中 [12]还纳入了更多参数），读者可参阅例如 [5]；此处我们只强调，信号的形状通常强烈依赖于 C，这使信号处理变得困难。更重要的是，当重新进入器件的光量过小（$C << 1$）时，自混合信号会变为谐波信号，目标位移方向的信息也会丢失。在工作状态的另一端（当 $C > 4$。6时），重新注入后的激光器动力学会变为多稳态，甚至进入混沌状态而变得不稳定。因此，在这一范围内，自混合信号同样无法提供有关目标位移的可靠信息。基于这些原因，必须格外谨慎地使系统保持在有效工作

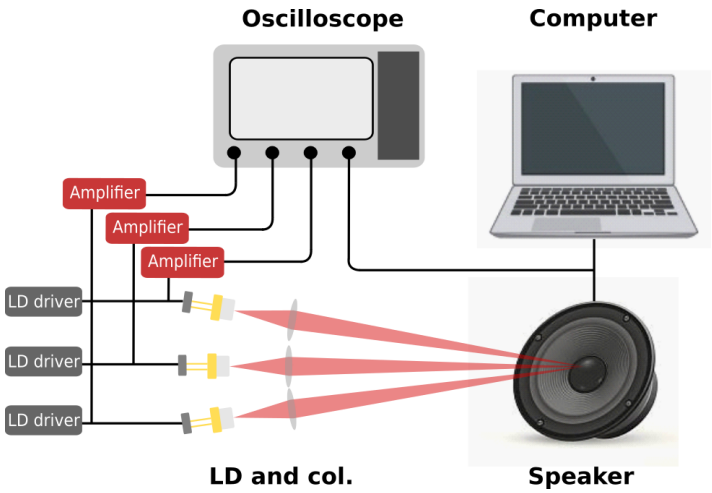

图 1. 实验装置示意图。三个独立的自混合通道监测单个非合作目标的位移，神经网络则处理由此产生的高维数据，以估算目标的位移。

范围内。为减轻 C 的不必要变化（例如由散斑效应导致的变化），人们采用了不同的方法，包括专用算法 [13], 实时参数估计 [14, 15]，或在不同对准条件下训练神经网络 [16, 17]。然而，最难克服的限制是，当 $C << 1$ 或 $C > 4$。6时，信号的有效性会逐渐丧失（最终完全消失）。由于这一限制源于物理因素，针对散斑 [18] 的跟踪硬件已被提出，同时也有人分析了适用于大位移的光束聚焦方案 [19]。

在此，我们提出，采用配备简单、可嵌入式神经网络的多通道自混合干涉仪，可以实现高可用性运动传感。多通道自混合早已被设想用于复杂测量（参见例如 [20–23]），但很少被视为增强单次测量采集的潜在手段 [24]

另一方面，机器学习已越来越多地用于自混合应用，包括条纹检测 [25–27], 参数估计 [15], 信号增强 [28, 29],振动测量 [30] 和位移推断 [16]。在此，我们表明，得益于神经网络处理高维数据的内在能力，多通道自混合传感器能够提供高可用性的位移测量，即使信号丢失也能保持稳健，并提升分辨率。

第 2 节介绍实验装置（2.1）、神经网络设计（2.2.1）及其训练过程（2.2.2）。第 3 节从准确度（ 3.1 ）、抗噪声鲁棒性（ 3.2 ）和测量可用性（ 3.3 ）等方面评估系统性能。第 4 节给出结论。

2. 实验装置、模型与训练

2.1. 实验

图1展示了实验装置的原理。该装置由三个相互独立的自混合测量通道组成，并配有一个经过（校准的）扬声器作为目标，即运动表面。每个通道均由电源、激光二极管和信号放大级组成。通道1和通道2的激光器发射波长为 $\lambda = 1310$ nm（ML725B8F），其

相干发射阈值为6.5 mA。通道3的激光器发射波长为 λ=1550 nm（ML925B45F），其阈值约为10 mA。对于下文将介绍的所有采集，激光器分别由7.7mA（通道1和2）和41.7mA（通道3）的直流电流驱动。激光束聚焦于扬声器表面，该表面距每个激光器约15cm。激光器彼此紧邻放置，以尽量减小光束与扬声器表面法线之间的夹角，从而减小实际位移与沿各自光束传播方向的投影位移之间的误差。

通过测量两个激光二极管两端的电压，以及第三个激光二极管内部光电二极管中的电流（受可用设备所限），获得三路自混合信号。这些信号的振幅较低，因此每路电压信号都通过交流耦合放大器放大，该放大器的增益为 10^4，带宽为数 MHz；光电二极管电流则通过跨阻放大器放大。由于使用非合作目标进行自混合干涉测量时，信号质量往往参差不齐（主要是散斑效应所致），我们特意以略有不同的方式对准各激光器，使每个激光器都在略有不同的工作状态下运行。图 2 展示了一个示例。第一行中，自混合信号的噪声并不明显，但其再注入值较低，因此干涉条纹的不对称性并不明显。第二行中，信号质量极佳，噪声很低，且不对称干涉条纹清晰可辨。最后，第三行所示的信号几乎完全无法利用，信噪比极低。

扬声器的位移已完成校准。在 5 至 100 Hz 的范围内，扬声器对谐波信号的响应具有线性特性，因此我们能够获得表面的有效位移。在此频率范围内，扬声器的响应没有相移。这些谐波信号由计算机声卡生成，振幅归一化为 0.1 至 1，对应的位移为 3.5μm 至 7.5μm。实验期间会记录这一电信号，并在经过下文所述的预处理后作为真实信号的依据。位移信号示例见图 2 最下面一行。

2.2. 模型与训练

2.2.1. 模型设计

在本实验中，神经网络需要根据三个干涉信号推断目标的位移。因此，原则上这是一个（多）序列到序列任务。然而，正如 [16], 所指出的，为待测位移定义工作频谱带后，可通过对位移信号进行下采样，将任务转化为更简单的回归任务。在本例中，我们定义的工作频率范围为 10 至 100 Hz。在此位移频率范围内，针对信号采集（包括干涉信号和位移）的4 μs 采样时间，我们选择以 1.024 ms 为片段分析时间序列，每个片段包含每个干涉通道和每次位移测量的 256 个数据点。根据所选频带和奈奎斯特定理，每段 256 个扬声器电压测量值都可以替换为 256 个时间步内的单个平均位移值。这样便将序列到序列任务转化为简单得多的回归任务：从三个干涉序列中推断一个位移值。此时，我们可以采用 [16], 提出的非常简单的卷积神经网络架构，因为它似乎具备足够的信息容量，能够高效处理单通道数据。然而，现在每个输入向量由三个通道组成，每个干涉信号对应一个通道。尽管多种传感模态的高级应用本身是一个非常重要的研究领域（参见例如 [31–34]），但这里我们处理的是更简单的情况：多个测量通道采用相似的模态。因此，我们采用非常简单的“早期融合”方法：第一卷积层对三个输入通道进行处理，并将生成的卷积核融合到单个输出空间中，

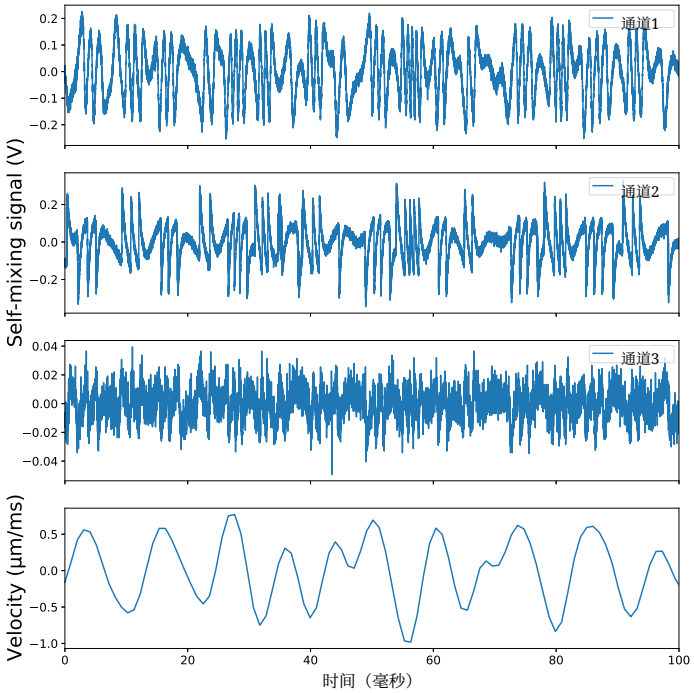

图2. 实验数据示例。上面三行显示每台激光器提供的自混合信号，底下一行显示相应的位移。激光器经过特意设置，以提供质量不同的自混合信号（见正文）。

无论具体是哪个通道激活了这些卷积核。经过这一阶段后，网络由一组逐渐收缩的下采样层和单通道一维卷积层构成。在这组网络层的末端，两个全连接层执行最终回归，为每个时间间隔预测一个位移值。除最后一层采用线性激活函数外，所有层均使用修正线性单元激活函数。有关网络的详细信息，请参见附录。

2.2.2. 训练

训练集 [35] 仅由实验数据组成。我们同时记录三路自混合信号和扬声器电压，并将后者校准为位移。采样率为4 μs，记录长度为 499968 个点。训练集仅包含谐波位移：扬声器输入的频率在 53Hz 至 93Hz 之间等间隔取八个值，振幅在 0.4 至 0.9 V 之间等间隔取六个值，分别对应 3.5 和 7.5 μm。因此，训练集包含 48 种不同的周期性位移频率和振幅组合。

在网络处理之前，将干涉信号除以其标准差，并减去整个记录长度内信号的平均值，使其归一化并以零为中心。为增强网络对噪声的鲁棒性，我们向每个信号添加标准差为 $\sigma_n = \sigma_s$ 的高斯白噪声，其中 σ_s 是原始自混合信号的标准差。

对于真实信号，首先，我们使用Savitsky-Golay滤波器对位移信号进行平滑处理，以去除电子噪声（示波器固有噪声和数字化噪声）；该滤波器的参数为1001个点的滑动区间和次数为2的多项式。然后，我们计算256个采样点的时间窗口内的平均位移，从而得到以每个时间窗口内的伏特数表示的信号

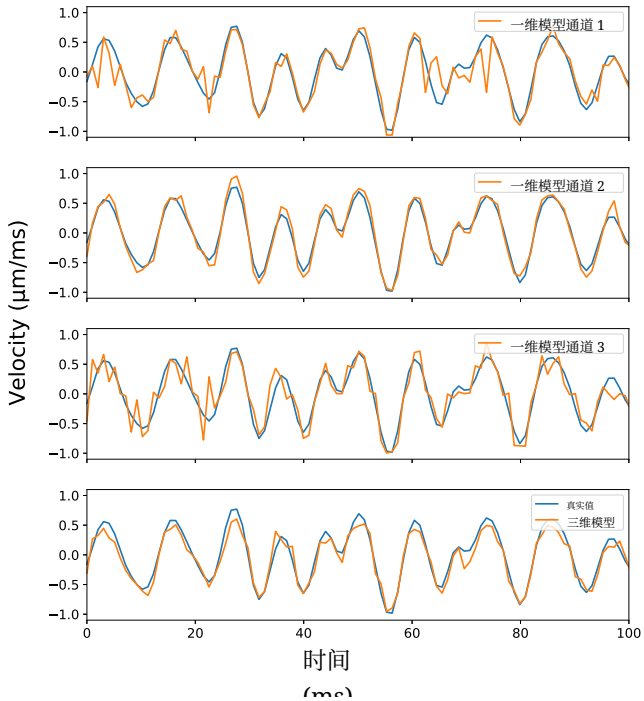

图3. 单独基于各单通道（前三行为三个一维模型）以及同时基于三个通道（底行为三维模型）的重建性能。

。随后，我们使用采样率的持续时间 $dt = 4\mu$s（对应于1.024 ms的时间窗口）以及31.3μm/V的扬声器校准值，将信号转换为 $\mu m/ms$的物理单位。

随后，网络可以使用约 $9.5 * 10^4$ 个数组作为输入进行训练，每个数组的大小为 3×256，对应于在长度为 $256 \times dt$ 的时间窗口内采集的三路干涉信号；相应的真实值则是每个时间窗口内的平均位移，其中 10% 的样本留作验证。当然，训练过程中每个训练轮次都会随机打乱样本顺序，同时还会额外随机打乱通道本身的顺序，即 单个位移值可以对应测量通道的任意排列。这意味着网络必须以 μ 米/毫秒为物理单位进行训练，但我们发现，这能显著提升重建性能。我们认为，这是因为训练得以覆盖所有权重，尤其是第一层的权重，而不是一开始就只关注最显著的通道。除了随机打乱顺序外，训练期间我们还会随机将其中一路自混合信号替换为白噪声（概率为 1/4），使网络能够应对推理阶段可能出现的通道丢失。我们通过最小化推断位移与真实位移之间的均方误差，以批量大小为 32 个样本训练网络 18 个训练轮次。在一块（消费级）GTX1080 GPU 上，训练时间约为 20 分钟。

3. 结果

训练后，我们首先从准确度方面比较多通道测量方法与常见单通道方法的性能，其次评估该方法在测量噪声影响下的鲁棒性，直至其中一个通道完全失效。由于每个通道

都提供独立测量，因此我们将处理全部三个通道的模型称为三维（3D）模型，而将处理单个维度的模型称为一维（1D）模型。

3.1. 准确度

图3展示了根据各测量通道重建的目标轨迹，以及同时基于三个通道进行的重建。位移重建预计能够正确处理任意复杂的位移，因此我们分析其在带宽预设的随机位移（此处为10至100 Hz）上的性能（如 [16]所示）。为此，我们生成一个随机的 δ相关信号，并使用五阶巴特沃斯滤波器对其进行傅里叶滤波，滤波范围为10至100 Hz。随后将该信号发送至扬声器，使其产生随机运动。在上方三条曲线上，我们使用三个基于上述实验数据集训练的一维模型，每个模型只处理三个自混合信号中的一个。我们通过测量真实位移与重建结果之间的皮尔逊相关系数和均方根误差，量化重建质量；测量对象是这段随机位移长达512秒的时间轨迹（$5 * 10^5$ 个持续1.024 ms的样本）。在最上方的曲线上，重建效果相当不错，真实位移与重建结果之间的相关系数为 $r = 0$。83，均方根误差为 $RMSE < 0$。23 μm/ms。第二行基于性能最佳的测量通道，该通道检测噪声较低，且干涉条纹形状清晰、定义明确并明显不对称。相应地，目标位移的重建质量极佳，真实位移与重建结果之间的相关系数为 $r = 0$。97，误差为 $RMSE < 0$。11 μm/ms。第三行的位移重建质量则再次较低；这并不令人意外，因为自混合信号确实非常差（见图2第三行）。不过我们注意到，该重建结果与第一通道的基本相当，相关系数为 $r = 0$。83，误差为 $RMSE < 0$。24 μm/ms。最后，最下方一行展示了使用三维模型同时处理三个通道得到的重建结果。其效果几乎与仅使用质量最高的单个测量通道（通道2）所得结果一样好，而且明显优于基于质量最差的两个通道（1和3）所得结果（$r = 0$。96，$RMSE = 0$。13μm/ms）。

3.2 信号退化下的鲁棒性

如上所述（至少对于我们在神经网络中采用的简单早期融合方法而言），测量通道的冗余并不会立即转化为更高的测量精度。然而，正如我们接下来将看到的，它确实能显著增强系统对一个或多个通道中噪声的抵抗能力。

为量化这一效果，我们在上述同一数据集上评估重建性能：向一个或多个通道添加标准差为 σ_n 的 δ 相关高斯噪声，以模拟自混合测量中由噪声诱导的退化。该流程的结果如图4所示。图中上排展示了真实位移与多个模型所提供的位移重建结果之间的相关系数，下排展示了各模型的重建均方根误差随添加到一个或多个通道中的噪声而变化的情况。

三个一维模型的曲线（红色、绿色和紫色三角形）供参考，它们表现出基本相同的行为。对于每种情况，我们都使用单个通道进行重建，并通过向该通道添加噪声使其退化。起初，每个模型的表现都尚可，但当添加的噪声大于 $\sigma_n = 3 * \sigma_s$ 时，即使是最佳信号（通道2）也会变得非常不可靠，其中 σ_s 是未受污染的原始自混合信号的标准差。这些曲线存在一个非零的最佳噪声水平，是训练过程所致：为了提高鲁棒性，所有模型都使用 $\sigma_n = 1$ 进行了训练，而且

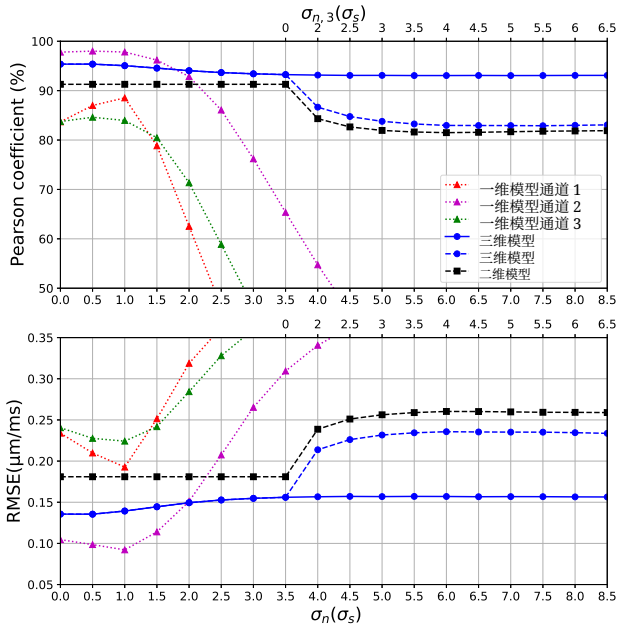

图4. 重建对一个或多个自混合信号中噪声的鲁棒性。上图：模型提供的重建结果与真实位移之间的皮尔逊相关系数。下图：位移重建的均方根误差。

因此从未见过未受污染的信号。

基于三维模型的两条曲线（蓝色圆点）展示了同时使用三个通道运行的模型的鲁棒性。连续蓝线表示仅在第二个自混合通道中加入噪声时的结果即该通道单独使用时性能最佳。我们观察到，即使单个通道完全退化（例如 $\sigma_n = 8\sigma_s$ ），该模型仍能保持非常高的性能水平（$r = 0。93$， $RMSE = 0。16$）。这在测量质量和测量可用性方面都是一个出色的结果。就测量可用性而言，这表明三维测量系统在高度退化的条件下仍能很好地运行即即使性能最高的通道基本上已失效。虚线蓝线表示在第二个自混合通道中加入噪声，并从 $\sigma_n > 3。5\sigma_s$ 开始也在第三个测量通道中加入噪声时的结果。当这一噪声项 $\sigma_{n,3}$ 加入第三个通道时，测量质量自然会下降，因为模型最终基本上只依赖一个剩余通道运行。因此，当通道2和通道3都因噪声过高而无法使用时（例如 $\sigma_n = 7$，$\sigma_{n,3} = 5$），三维模型的性能水平基本上等同于在未受污染的通道1上运行的一维模型的性能水平$r = 0。83$， $RMSE = 0。23$。同样，这在测量可用性方面是一个出色的结果，因为当其他两个通道失效时，三通道测量系统仍可达到单个通道的性能水平。

最后，为完整起见，图中还以黑色方形虚线展示了二维模型（仅使用质量最差的自混合信号1和3进行训练）的性能。当然，该模型的性能不会受到添加到其不处理的通道2中的噪声影响，但需要强调的是，该二维模型的性能优于仅基于

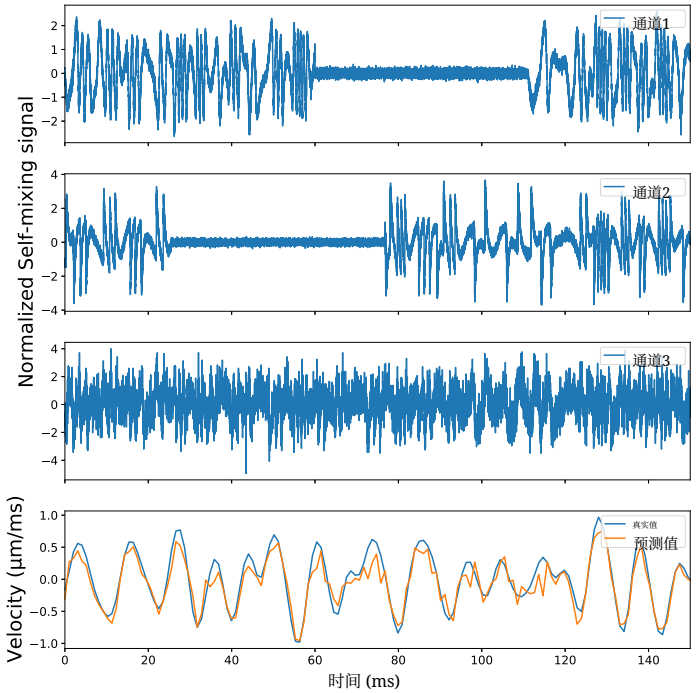

图 5. 通道丢失与测量可用性。在不同时间，一个或多个自混合信号（上方三行）被白噪声替代，以模拟 $C = 0$，例如散斑可能造成的情况。三维模型能够灵活利用可用数据，即使在两个通道同时不可用这一最坏情况下，仍能给出有意义的位移重建（下方一行）。

通道1和通道3分别单独训练的一维模型。当通道3也加入噪声时，该模型的性能会平稳下降，直至与仅基于未受干扰的通道1的一维模型相当。

总体而言，以上观察结果展现了三维位移测量方法在准确度和鲁棒性方面的若干卓越特性：

- 在无噪声的情况下，三维模型的性能几乎与最佳一维模型相当，并显著优于另外两个一维模型
- 当噪声使信息量最大的通道性能下降时，三维模型显著优于所有一维模型，也优于基于未受干扰通道的二维模型
- 即使噪声使三个可用通道中的两个性能严重下降，三维模型的性能也不会低于基于唯一未受干扰通道的一维模型
- 在所有3个通道均存在噪声的情况下，我们验证了三维模型的性能与最佳一维模型（通道2）基本相当；在无噪声情况下也观察到了同样的结果（图3）。

3.3. 测量可用性

如我们下文所述，上述特征对测量可用性有重大影响。我们的目标是证明，基于三个同步测量通道并由经过充分训练的神经网络进行处理的位移测量系统

为实现高可用性自混合位移传感器迈出了重要一步。事实上，众所周知，对于非合作目标，散斑会显著改变自混合信号的形状，甚至导致反馈率实际上降为零。对此，有多种可能互为补充的解决方法，包括专用跟踪硬件 [18],专用算法 [13], 实时参数估计 [14] , 或在多种反馈条件下训练神经网络，使其能够在多种工作范围内进行自混合信号处理 [16]。本文重点讨论散斑（或任何其他不期望的扰动）导致自混合测量通道完全失效的情况。

为模拟这一现象，我们在某个时间区间内用高斯白噪声替换其中一个通道（模拟该通道因散斑或其他干扰而出现 $C = 0$ 的情况），并将修改后的干涉测量数据输入三维模型。图5上方三行显示了三个自混合信号，底行显示了真实位移和重建结果。本分析针对的位移片段与图2相同。在 $60 < t < 110$ ms区间内，通道1的信号质量下降；在 $25 < t < 75$ ms区间内，通道2的信号质量下降，同样模拟了 $C = 0$。可以看到，即使在最差的条件下，三维模型也始终能提供有意义的重建结果，例如中央区域的 $60 < t < 75$ ms区间内，三个通道中有两个无法使用。对于高可用性测量系统而言，最重要的是，三维模型能够透明地充分利用可用信息；而且，一旦自混合数据本身的质量恢复，重建结果的最佳质量也会随之恢复。

4. 结论

总之，我们分析了一种高可用性位移传感器的性能。该传感器基于三个独立的自混合干涉测量通道，并由轻量级神经网络进行处理。得益于神经网络处理高维输入的固有能力，多通道传感器能够灵活地充分利用自混合信号，并根据输入通道的可用情况使用一个或多个通道。在没有任何干扰时，多通道系统的性能几乎与质量最佳的通道相当；一旦某个通道性能下降，多通道传感器的表现便优于任何单通道传感器。即使两个通道完全失效，多通道传感器仍能基于唯一剩余的通道可靠地推断位移。网络经过训练，无需依赖物理建模即可推断位移，因此该方法不需要进行参数估计。结合神经网络能够学习多种形态的自混合信号的能力 [16], , 我们认为，多通道方法是解决长期存在的、面向非合作目标的散斑影响自混合干涉测量问题的关键。

由于该神经网络专为处理自混合数据而设计，且参数数量近乎最少，因此适合嵌入微型计算设备中 [36, 37], , 这为利用自混合干涉测量内在简洁性的紧凑型低功耗智能传感器铺平了道路。

对于未来的工作，我们强调，此处概述的方法仅作为概念验证。首先谈谈神经网络本身：正如 [16], 所示，该网络极为基础，当然还有改进空间，尤其是采用更先进的通道融合方法。此外，关于光子阶段，目前的工作为更先进的多模态传感开辟了发展方向 [11, 38], , 或许还可纳入压缩感知 [39] , 以便应用于低占用组件。

附录

该网络的结构与 [16] 相同，但采用了更多卷积核，以适配三个而非一个测量通道。网络的关键要素如表 1 所示。该网络借助 Keras 库 [40] 实现，并

网络结构：顺序				
层类型	Main 超参数	可训练 参数	输出形状	激活 函数- tion
一维卷积	卷积核大小：7 滤波器：32	704	（250，32）	relu
最大池化	池化大小：2	0	(125, 32)	
一维卷积	卷积核大小：7 滤波器：64	14400	(119, 64)	relu
最大池化	池化大小：2	0	(59, 64)	
一维卷积	卷积核大小：7 滤波器 128	57472	(53, 128)	relu
最大池化	池化大小：2	0	(26, 128)	
随机失活	10%	0	(26, 128)	
一维卷积	卷积核大小：7 滤波器：128	114816	(20, 128)	relu
最大池化	池化大小：2	0	(10, 128)	
展平		0	1280	
全连接	单元数：16	20495	16	relu
全连接	单位：1	17	1	线性

表 1. 本文所用网络的主要参数。该网络由一系列一维卷积层和随机失活层组成，后接两个用于最终回归的全连接层。可训练参数总数为 207 905。

有关背景信息，请读者参阅深度学习基础知识 [41] 及其实现 [40]。可训练参数总数为 207 905。每层包含更多单元、但架构相同的网络并未带来显著改进。在消费级图形处理器（NVIDIA GeForce GTX 1080）上训练该网络约需二十分钟。

利益披露

作者声明不存在利益冲突。

参考文献。

1 G Nicolis 和 C. Nicolis，《复杂系统基础：涌现、信息与预测》*Foundations of complex systems: emergence, information and predicition*（World Scientific，2012年）。2. P. Caramazza、A. Boccolini、D. Buschek、M. Hullin、C. F. Higham、R. Henderson、R. Murray-Smith 和 D. Faccio，“利用单像素单光子探测器识别视线遮挡下的人物的神经网络识别”，《科学报告》**8**，1 6 2018–（）。3. M. Del Hougne、S. Gigan 和 P. Del Hougne，“利用混响编码孔径实现深亚波长定位”，《物理评论快报》**127**，043903（2021年）。4. D. Mengu、M. S. S. Rahman、Y. Luo、J. Li、O. Kulce 和 A. Ozcan，“光学与深度学习的交汇：统计推断、计算与逆向设计”，Adv. Opt. Photonics **14**，209–290（2022年）。5. G. Giuliani、M. Norgia、S. Donati 和 T. Bosch，“用于传感应用的激光二极管自混合技术”，《光学A：纯粹与应用光学》**4**，S283（2002年）。

6. D. M. Kane 和 K. A. Shore，《解锁动力学多样性：光学反馈对半导体激光器的影响》*Unlocking dynamical diversity: optical feedback effects on semiconductor lasers*（John Wiley & Sons，2005年）。7. S. Donati，“发展用于仪器与测量的自混合干涉测量”，Laser & Photonics Rev. **6**，393–417（2012年）。8. T. Taimre、M. Nikolić、K. Bertling、Y. L. Lim、T. Bosch 和 A. D. Rakić，“激光反馈干涉测量：相干传感中的自混合效应教程”，Adv. Opt. Photonics **7**，570–631（2015年）。9. J. Li、H. Niu 和 Y. X. Niu，“激光反馈干涉测量及其应用：综述”，Opt. Eng. **56**，050901（2017年）。10. A. Rakić、T. Taimre、K. Bertling、Y. Lim、P. Dean、A. Valavanis 和 D. Indjin，“利用量子级联激光器进行激光反馈干涉传感与成像”，Appl. Phys. Rev. **6**，021320（2019年）。11. M. Brambilla、L. L. Columbo、M. Dabbicco、F. De Lucia、F. P. Mezzapesa 和 G. Scamarcio，“基于无探测器、无扫描光学反馈干涉测量的多功能多模态成像系统——面向未来愿景的回顾”，Sensors **20**，5930（2020年）。12. K. Bertling、X. Qi、T. Taimre、Y. L. Lim 和 A. D. Rakić，“激光反馈干涉传感器的反馈状态：实验研究”，Sensors **22**，9001（2022年）。13. A. A. Siddiqui、U. Zabit、O. D. Bernal、G. Raja 和 T. Bosch，“散斑影响下自混合干涉信号的全模拟处理”，IEEE Sensors J. **17**，5892–5899（2017年）。14. O. D. Bernal、U. Zabit、F. Jayat 和 T. Bosch，“面向位移传感的光学反馈因子 c 在线估计”，Sensors **21**，3528（2021年）。15. L. An 和 B. Liu，“基于反向传播神经网络测量激光自混合干涉传感器参数”，Opt. Express **30**，19134–19144（2022年）。16. S. Barland 和 F. Gustave，“用于自混合干涉位移传感的卷积神经网络”，Opt. Express **29**，11433–11444（2021年）。17. S. Barland 和 F. Gustave，“通过自混合干涉测量位移及神经网络训练集”，10.5281/zenodo.7303745（2022年）。18. O. D. Bernal、U. Zabit 和 T. M. Bosch，“利用自适应光学稳定自混合微干涉仪激光位移传感器的光学反馈状态的稳健方法”，IEEE J. Sel. Top. Quantum Electron. **21**，336 343 2014–（）。19. F. De Lucia、M. Putignano、S. Ottonelli、M. Di Vietro、M. Dabbicco 和 G. Scamarcio，“高斯光束近似下的激光自混合干涉测量：实验与理论”，Opt. Express **18**，10323–10333（2010年）。20. S. Ottonelli、M. Dabbicco、F. De Lucia 和 G. Scamarcio，“利用激光自混合同时测量线性位移和横向位移”，Appl. Opt. **48**，1784–1789（2009年）。21. S. Ottonelli、M. Dabbicco、F. De Lucia、M. Di Vietro 和 G. Scamarcio，“面向机电一体化应用的激光自混合干涉测量”，Sensors **9**，3527–3548（2009年）。22. Y. L. Lim、M. Nikolic、K. Bertling、R. Kliese 和 A. D. Rakić，“采用单片 VCSEL 阵列并行读出的自混合成像传感器”，Opt. Express **17**，5517–5525（2009年）。23. Y. L. Lim、R. Kliese、K. Bertling、K. Tanimizu、P. Jacobs 和 A. D. Rakić，“采用单片 VCSEL 阵列并行读出的自混合流量传感器”，Opt. express **18**，11720–11727（2010年）。24. J. R. Tucker、A. Mowla、J. Herbert、M. A. Fuentes、C. S. Freakley、K. Bertling、Y. L. Lim、R. S. Matharu、J. Perchoux、T. Taimre 等，“基于非制冷垂直腔面发射激光器阵列的自混合传感系统：多通道运行与性能提升之间的联系”，Opt. letters **39**，394–397（2014年）。25. H. Li、C. Zhang、N. Song 和 H. Li，“基于深度学习、利用卷积神经网络检测干涉条纹”，IEEE Photonics J. **11**，1–14（2019年）。26. K. Kou、C. Wang、T. Lian 和 J. Weng，“利用人工神经网络判别激光自混合干涉测量中的条纹斜率”，Opt. & Laser Technol. **132**，106499（2020年）。27. A. A. Siddiqui、U. Zabit 和 O. D. Bernal，“利用深度神经网络进行基于可变光学反馈的自混合干涉测量中的条纹检测与位移传感”，Sensors **22**，9831（2022年）。28. L. Wei、J. Chicharo、Y. Yu 和 J. Xi，“利用神经网络对激光二极管自混合干涉测量所观测信号进行预处理”，载于*2007*年*IEEE*智能信号处理国际研讨会，（IEEE，2007年），第1–5页。29. I. Ahmed、U. Zabit 和 A. Salman，“利用生成对抗网络增强用于激光计量传感应用的自混合干涉信号”，IEEE Access **7**，174641–174650（2019年）。30. H. Liang、M. Chen、C. Jiang、L. Kan 和 K. Shao，“结合特征提取与随机森林的激光自混合振动测量，无需确定反馈强度”，Sensors **22**，6171（2022年）。31. K. Gadzicki、R. Khamsehashari 和 C. Zetzsche，“多模态卷积神经网络中的早期融合与后期融合”，载于*2020*年*IEEE*第*23*届信息融合国际会议（*FUSION*），（IEEE，2020年），第1–6页。32. L. Khacef、L. Rodriguez 和 B. Miramond，“利用细胞神经形态计算实现脑启发式自组织，以进行多模态无监督学习”，Electronics **9**，1605（2020年）。33. G. M. Dimitri，“多模态集成深度学习简述：应用、未来展望与挑战”，Computers **11**，163（2022年）。34. P. P. Liang、A. Zadeh 和 L.-P. Morency，“多模态机器学习的基础与最新趋势：原理、挑战与开放问题”，arXiv 预印本 arXiv:2209.03430（2022年）。35. R. Matha、S. Barland 和 F. Gustave，“通过自混合干涉测量进行多通道位移测量，并

神经网络：训练和测试数据集，” 10.5281/zenodo.7554008（2023年）。36. P.-E. Novac, G. Boukli Hacene, A. Pegatoquet, B. Miramond, 和 V. Gripon，“在微控制器上对深度神经网络进行量化和部署，” Sensors **21**，2984（2021年）。37. S. S. Saha, S. S. Sandha, 和 M. Srivastava，“面向微控制器级硬件的机器学习综述，” arXiv 预印本 arXiv:2205.14550（2022年）。38. L. Columbo, M. Brambilla, M. Dabbicco, 和 G. Scamarcio，“多横模半导体激光器中的自混合：模型及其在多参数传感中的潜在应用，” Opt. express **20**，6286–6305（2012年）。39. L. Li, Y. Zhang, Y. Zhu, Y. Dai, X. Zhang, 和 X. Liang，“基于自混合干涉测量和压缩感知的绝对距离测量，” Appl. Sci. **12**，8635（2022年）。40. F. Chollet 等，“keras，” https://keras.io （2015年）。41. I. Goodfellow, Y. Bengio, A. Courville, 和 Y. Bengio，深度学习，第1卷（MIT出版社（剑桥），2016年）。