arXiv:2601.01924v1 [quant-ph] 5 Jan 2026

用于里德堡微波传感器去噪的含噪数据集自监督学习

Zongkai Liu[1,2,*,§], Qiming Ren[1,2,§], Wenguang Yang[1,2], Yanjie Tong[1,2], Huizhen Wang[1,2], Yijie Zhang[1,2], Ruohao Zhi[1,2], Junyao Xie[1,2], Mingyong Jing[1,2], Hao Zhang[1,2], Liantuan Xiao[1,2], Suotang Jia[1,2], Ke Tang[3], 和 Linjie Zhang[1,2,‡]

[1] *State Key Laboratory of Quantum Optics Technologies and Devices,Institute of Laser Spectroscopy, Shanxi University, Taiyuan 030006, China .*[2] *Collaborative Innovation Center of Extreme Optics, Shanxi University, Taiyuan, Shanxi 030006, China. and*

[3] *Guangdong Provincial Key Laboratory of Brain-inspired Intelligent Computation, Department of Computer Science and Engineering,Southern University of Science and Technology, Shenzhen 518055, China.*（日期：2026年1月6日）

我们提出了一种面向里德伯传感器的自监督深度学习框架，可实现单次测量噪声抑制，达到与多次测量平均相当的精度。该框架通过使用两组统计分布相同的含噪信号进行训练，无需干净参考信号（量子传感中几乎无法获得此类信号）。在里德堡传感数据集上的评估结果表明，该框架优于小波变换和卡尔曼滤波，可实现相当于平均 10,000 组数据的去噪效果，同时将计算时间缩短三个数量级。我们还在多种不同的噪声特征下验证了其性能，并量化了 U-Net 和 Transformer架构之间的复杂度-性能权衡，为优化里德堡传感器系统中的基于深度学习的去噪提供了切实可行的指导。

关键词： 里德堡原子，微波传感器，自监督学习，去噪。

I. 引言

里德伯原子微波传感器 [1–7] 在宽带通信和雷达等应用领域前景广阔，这得益于其超高的微波电场灵敏度 [8, 9]，、宽频率响应范围（直流至太赫兹） [10–12]，以及可溯源至国际单位制（SI）的校准 [13–16]。然而，在开放环境中部署时，其应用受到噪声源的限制，这些噪声会淹没信号，例如环境电磁干扰、原子间相互作用噪声和热噪声 [3, 7]。

传统去噪方法并不适用于这一限制。多次测量平均可以抑制随机噪声，但需要重复数百次，牺牲时间分辨率，因此不适用于时变信号 [17, 18]。小波变换（基于阈值处理和信号匹配） [19–23] 以及卡尔曼滤波（依赖预定义的状态空间模型） [24] 在处理平稳噪声时表现良好，但无法在真实世界的里德堡传感器运行中遇到的非平稳噪声下保持稳定。

深度学习已成为自适应去噪的另一种方法 [25]：循环神经网络（RNN） [26–28] , 长短期记忆（LSTM） [29,30]以及一维卷积神经网络模型 [31–36] 利用时间依赖性将信号与噪声分离（例如语音处理 [37–41]），而 Transformer 则使用自注意力来平衡噪声抑制与信号细节保留 [42–45]。然而，标准深度学习结构（例如自编码器 [46–48]）需要成对的含噪-干净信号数据集进行监督学习，但对于里德伯传感器而言，干净的单次信号在实验上无法获取。此外，理论构建的理想化干净数据与实际实验条件存在偏差，容易导致模型过拟合 [49, 50]。

在此，我们开发了一种用于里德伯原子微波传感器去噪的自监督深度学习框架，如图1 （a）所示。该方法在时域和频域的里德伯传感信号上进行了验证，并与万组平均、卡尔曼滤波和小波滤波进行了比较。它在实际应用中具有三项关键优势：（1）能够实现单次去噪，且准确度可达到万组平均的水平，同时保留动态测量所需的时间分辨率；（2）通过在两组具有相同统计分布的含噪信号上进行训练，无需干净参考信号，从而解决量子传感中的标注数据稀缺问题；（3）与多次测量平均相比，计算时间缩短了三个数量级。最后，我们量化了U-Net和Transformer架构之间的复杂度-性能权衡，为特定传感器部署需求的模型选择提供指导。这项工作通过将深度学习去噪与实际量子传感约束相结合，提升了里德伯传感器的实用价值。

* lzk1997@sxu.edu.cn

‡ zlj@sxu.edu.cn§ Z.L 和 Q.R 对本研究的贡献相同。

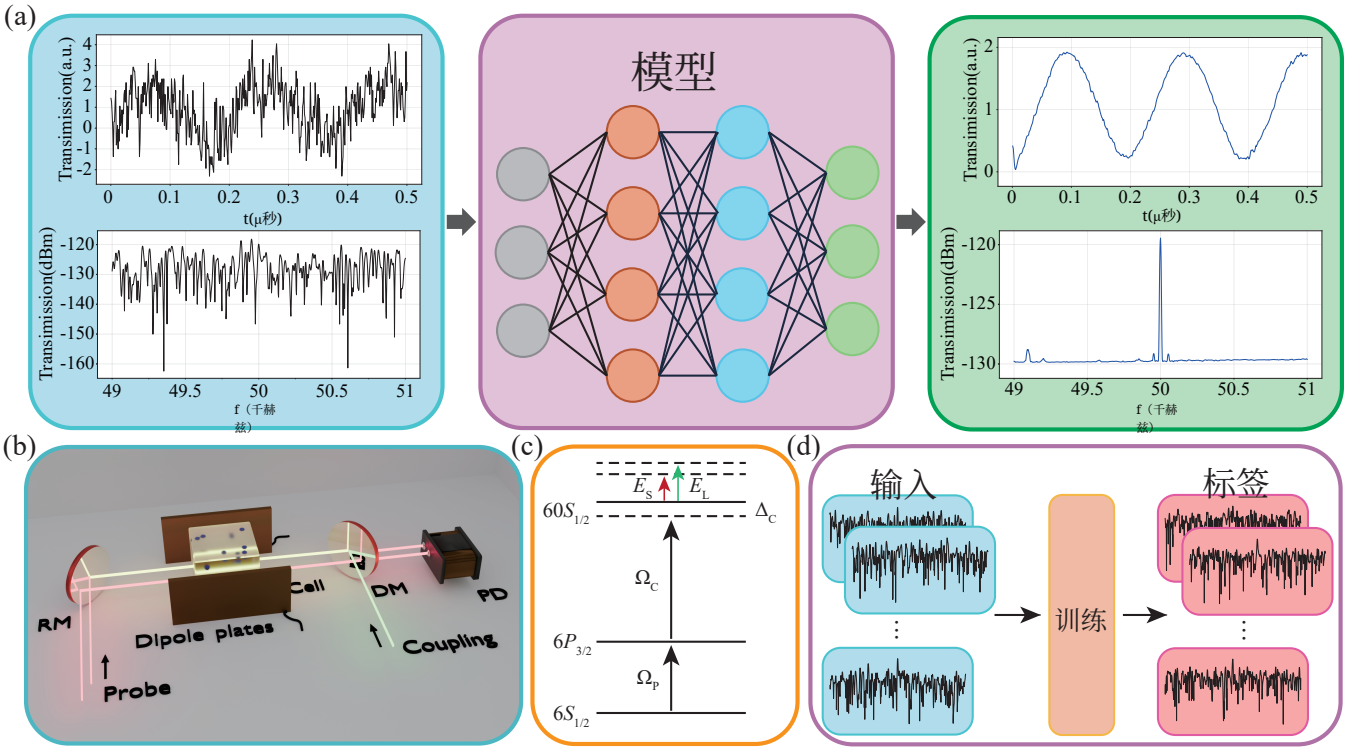

图1. 模型测试和训练过程。(a) 训练好的模型能够从输入的噪声信号中生成干净信号，包括时域（上图）和频域（下图）数据。数据采集自实验。(b) 实验装置。探测光分成两束：一束在铯蒸气池内与耦合光反向传播，另一束在池外作为参考光束，以实现平衡探测。平衡探测后，使用示波器和频谱分析仪采集时域和频域数据集。信号电场 E_S 和本振电场 E_L 通过平行板电极与原子相互作用。RM-反射镜，DM-二向色镜，PD-平衡光电探测器。(c) 能级图。探测光（拉比频率 Ω_P）和耦合光（拉比频率 Ω_c，相对于共振的频率失谐为 Δ_c）通过中间态 $6P_{3/2}$将原子从基态 $6S_{1/2}$ 激发至里德堡态 $60S_{1/2}$。振幅分别为 E_S 和 E_L、频率为 63 MHz 和 63.05 MHz 的信号场和本地场作用于里德堡态分布。(d) 训练期间，输入数据及其对应标签是对同一里德堡原子产生的微波信号进行的独立测量结果，二者仅在独立同分布噪声方面有所不同。

II. 方法

A. 实验装置

我们构建了一个里德堡原子微波探测系统，用于采集含噪中频（IF）信号，以验证深度学习降噪方法。实验装置和能级图分别如图1 （b）和（c）所示。铯原子被限制在室温玻璃池（$5 \times 5 \times 5\,\mathrm{cm}^3$）中。一个852 nm探测光束（拉比频率$\Omega_c/2\pi = 9.06$ MHz）将原子从 $|6S_{1/2}, F = 4\rangle$ 激发至 $|6P_{3/2}, F = 5\rangle$而一个510 nm耦合光束（拉比频率$\Omega_c/2\pi = 0.83$ MHz）进一步将原子激发至 $60S_{1/2}$ 里德堡态。探测光束被分成两束：一束作为玻璃池外的参考光，另一束在池内与耦合光束反向传播，形成电磁感应透明（EIT）配置，其中耦合光束对探测光束的原子透射和吸收。包含参考光束的探测光束通过差分探测器进行平衡探测（带宽为 1 赫兹，共模抑制比为 40 dB），从而产生频谱信号。两束光的频率均通过超稳腔（精细度为 $= 2 \times 10^5$）进行稳定，并锁定至上述原子跃迁。

实验在室温下于微波暗室中进行，暗室内衬有金字塔形泡沫吸波材料。对于垂直入射到材料表面、频率为 < 100 兆赫兹的射频场，该材料可提供 < 20 分贝的衰减。射频电场探测采用原子外差方案：任意波形发生器产生频率为 63 兆赫兹的待测信号 (SUT) E_S，以及频率相对 SUT 偏移 50 千赫兹的本地振荡器 (LO) 信号 E_L。这些信号输入一对平行黄铜电极（尺寸为 10 厘米 $\times$ 8 厘米，间距 5 厘米），以产生施加于原子系统的射频场。SUT 会使原子能级发生偏移，并

通过交流斯塔克频移产生局域场，该频移可由探测光透射推导得出 [7, 51]。频移 δ 的表达式为 $\delta = -\alpha|E_S + E_L|^2/2$，其中 α 为标量极化率。SUT E_S 与局域场 E_L 拍频产生一个振幅与 SUT 振幅相对应的 50 千赫兹中频信号。探测光束由平衡差分探测器检测，该探测器将光强转换为电压信号。随后，使用示波器读取该信号的时域波形，并使用频谱分析仪读取其频域信息，以进行基于深度学习的去噪。频谱分析仪的分辨率带宽 (RBW) 设置为 10 赫兹，频谱采集采用 5 次平均，扫频范围为 49–51 千赫兹，步进为 5 赫兹。此外，对中频信号施加不同程度的衰减，以模拟开放电磁环境；在这种环境中，单次信号会被噪声淹没，但可通过多次测量平均恢复。

B. 数据集设计与训练策略

训练神经网络 $f_\theta(\cdot)$的主要目标是学习一个经过优化的权重参数（$\theta^\star$）（包含权重和偏置），以最小化网络输出与实验训练标签之间的差异（最小化损失函数 $\mathcal{L}(\cdot)$）。从数学上看，训练目标被形式化为一个约束最小化问题，其优化过程如下：

$$\theta^\star = \arg\min_\theta \frac{1}{N}\sum_{i=1}^{N} \mathcal{L}\left(f_\theta(x_{\text{train},i}), y_{\text{train},i}\right), \qquad (1)$$

训练数据集的规模为 N，$x_{\text{train}} = x + n_1$，$y_{\text{train}} = y + n_2$，其中 x_{train} 和 y_{train} 表示两个相互独立的实验测量数据，它们由理想的干净信号 x, y 和从独立同分布噪声中抽取的噪声 n_1, n_2 组成，即 n_1，n_2 ∈噪声。自监督学习与监督学习的区别在于它们的训练标签。对于监督学习（例如，自编码器 [47, 52]），训练标签是理想的无噪声参考信号 $y_{\text{train}} = y$（在传感场景中，这类参考信号很少能获得）。相反，自监督学习（本文所用）中的标签对应于在与训练数据 $y_{\text{train}} = y + n_2$ 相同条件下获得的另一项测量结果，因此无需干净参考信号。噪声n_1，n_2 包括环境电磁干扰、原子间相互作用噪声、热噪声等 [3]。为调节噪声对信号的影响，我们对中频信号施加了衰减，使其从高于噪声底的状态降至被噪声淹没、但经 10000 次平均后仍可识别的状态。训练收敛后（定义为训练损失连续 10 个训练轮次保持稳定），即可获得优化后的权重 $\theta^\star$ 深度学习层。预测过程利用未见过的测试输入生成输出，表示为

$$\hat{y}_{\text{test}} = f_{\theta^\star}(x_{\text{test}}), \qquad (2)$$

其中，x_{test} 与 x_{train} 相互独立，以确保泛化评估的无偏性；预测结果$\hat{}y_{\text{test}}$ 与原始数据的10000组平均值进行比较。

具体而言，构建了一个基于Transformer的端到端模型，并配套制定了专用数据集和训练方案，主要细节如下。在统一实验中，采集了10000组独立同分布（i.i.d.）的含噪光谱/时域数据（每组包含1000个连续点），并按照4:4:2的比例将其划分为训练集、标注集和测试集。具体而言，训练集包括测量结果数据 x_{train} （维度：4000、1000、1），以及另一组相互独立的测量结果 y_{train} （维度：4000、1000、1）；测试集由x_{test} 组成（维度：2000、1000、1）。其中，$x_{(\cdot)}$ 和$y_{(\cdot)}$ 分别表示训练数据及其对应的标签；数据的第一维表示数据组数，第二维表示连续点数，第三维是深度学习模型的要求。未标注的测试数据 x_{test} 与10000组原始数据集的平均值进行比较。

接下来，为了提高训练的稳定性并避免幅值偏差，我们对每个数据点进行了标准化：$x' = \frac{x-\mu}{\sigma}$，其中 $x =$ 表示原始数据，$\mu =$ 表示均值，$\sigma =$ 表示标准差，而 $x' =$表示标准化后的数据。随后将数据输入深度学习模型进行训练，其架构如附录A所示。

C. 含噪数据集中的训练过程为何能够降噪

为了阐明所提出训练过程的降噪机制，我们结合噪声的统计特性和大数定律（LLN），分析目标函数的优化过程，具体如下（为简便起见，采用均方误差损失 $\mathcal{L}(a, b) = (a-b)^2$，该分析可推广至其他损失函数）。

首先，假设噪声为 n_1，$n_2 \in$ 噪声满足两个一般性质：(1)零均值：$\mathrm{E}[n_1] = \mathrm{E}[n_2] = 0$（不存在系统偏差）；(2)与干净信号独立：$\mathrm{E}[x \cdot n_1] = \mathrm{E}[y \cdot n_2] = 0$（噪声不携带与信号相关的信息）。训练目标是最小化经验损失：

$$\min_\theta J(\theta) = \min_\theta \frac{1}{N}\sum_{i=1}^{N} \mathcal{L}\left(f_\theta(x_{\text{train},i}), y_{\text{train},i}\right). \qquad (3)$$

代入 $x_{\text{train},\ i} = x_i + n_{1,\ i}$ 和 $y_{\text{train},\ i} = y_i + n_{2,\ i}$，其中 x_{train} 和 y_{train} 是对应于同一里德堡原子微波信号的独立测量结果

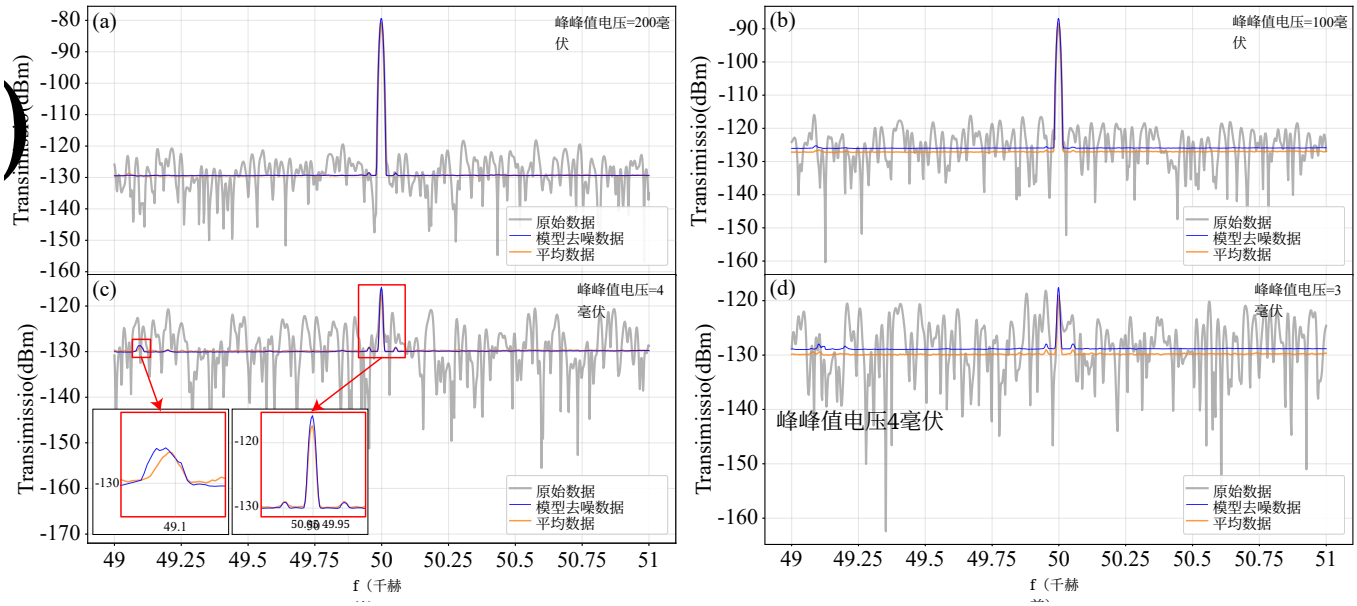

图2. 不同衰减水平下的中频（IF）频域信号。子图(a)–(d)右上角标出了中频信号强度。灰色曲线：探测光束透射信号的单次测量结果（衰减程度从高于噪声底逐渐降至噪声底水平）。绿色曲线：10,000次测量的平均结果（无噪声真实值，未用于模型训练），显示了噪声消除效果，仅保留中频信号（以及中频边带和(c)–(d)中弱衰减条件下的49 kHz弱信号）。蓝色曲线：基于Transformer的模型（仅使用含噪信号进行训练）的去噪结果，其性能与多次测量平均相当，并揭示了中频信号、中频边带和49.1 kHz弱信号。(c)中的两个红色方框分别放大显示了50 kHz和49.1 kHz处的平均结果及深度学习去噪结果，以说明保留的被噪声淹没的信号。

它们仅在噪声方面有所不同， x 和 y 是干净数据。目标函数变为：

$$J(\theta) = \frac{1}{N}\sum_{i=1}^{N}\left[f_\theta(x_i + n_{1,i}) - (y_i + n_{2,i})\right]^2. \qquad (4)$$

当 N 足够大时，根据大数定律，经验风险收敛于期望风险：

$$J(\theta) \xrightarrow{N\to\infty} \mathrm{E}\left[\left(f_\theta(x + n_1) - (y + n_2)\right)^2\right]. \qquad (5)$$

展开期望项并应用噪声假设：

$$\mathrm{E}\left[\cdots\right] = \mathrm{E}\left[\left(f_\theta(x + n_1) - y\right)^2\right] + \sigma_{n2}^2, \qquad (6)$$

其中交叉项为零（$\mathrm{E}[n_2] = 0$，且相互独立），而 $\mathrm{E}[n_2^2] = \sigma_{n2}^2$ 为常数噪声方差，与 θ 无关。由于 σ_{n2}^2 固定，最小化 $J(\theta)$ 等价于最小化信号拟合误差

$$\mathrm{E}\left[\left(f_\theta(x + n_1) - y\right)^2\right]. \qquad (7)$$

为此，模型必须学习一种与噪声无关的映射， $f_\theta(x + n_1) \to y$。

因此， n_1 和 n_2 的随机波动会根据大数定律（当 N足够大时）得到平均，模型则会自发地抑制噪声，专注于干净的 $x - y$关系，而不是拟合噪声。这解释了训练过程为何能降低含噪数据集中的噪声。

III. 结果

A. 频域信号的去噪性能

该深度学习模型能够对时域和频域信号的量子传感数据进行去噪。图 2 展示了其对频谱分析仪测得的中频频域信号的去噪结果，并与对含有独立同分布噪声的 10,000 个重复数据集取平均后的结果进行比较。由图 2 (a-d)可见，电极上的被测信号振幅逐渐从 200 mV 衰减至 3 mV，用以模拟数据逐渐被噪声淹没的情形。由于中频信号由被测信号与本振信号拍频产生，且本振信号的频率可调节以跟踪被测信号，因此中频信号的频率固定为 50 kHz。一般而言，这一配置可推广至其他频率的被测信号。

对于强幅度信号（图2 (a)–(b)），模型可将噪声数据恢复到与10,000次测量平均值相当的水平，同时完整保留50 kHz中频（IF）信号。模型在时间效率方面优于多次测量平均：测量时间缩短了三个数量级（10,000次测量的平均处理需1小时 +，而深度学习去噪仅需0.7秒）。对于

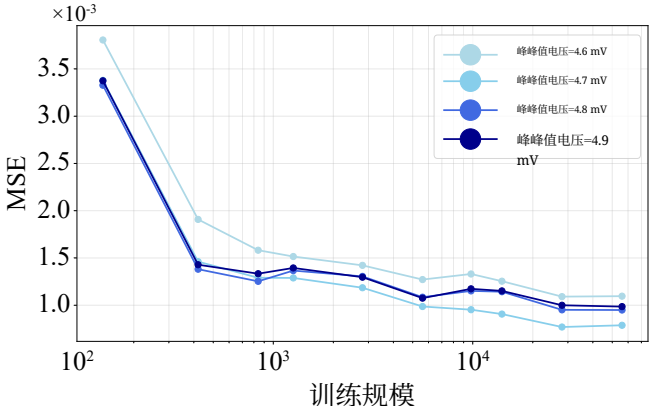

图3. 频域中均方误差随训练数据集大小的变化。该图展示了在偶极板上施加不同电压（4.6 mV 至 4.9 mV）时，深度学习模型的去噪结果与万组平均结果之间的均方误差。随着训练数据集大小增加，均方误差逐渐减小。

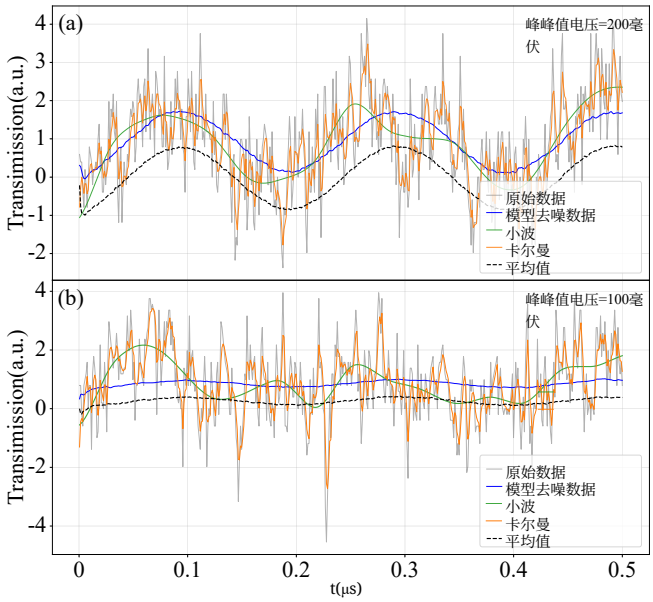

图4. Vpp=200 mV（a）和 100 mV（b）时，不同去噪模型对时域信号的处理效果。采用的去噪方法包括小波去噪（绿色实线）、卡尔曼滤波（橙色实线）、多次测量平均（黑色虚线），以及所提出模型的去噪结果（蓝色实线）；这些方法均应用于探测光束透射信号的单次测量结果（灰色实线）。小波去噪和卡尔曼滤波的参数通过最小化各自去噪结果与多次测量平均结果之间的误差进行优化，详情见正文。

振幅衰减40 dB的频谱数据（图2 (c)–(d)）中，原始信号完全淹没在噪声中，但模型仍能恢复中频信号并保留其特征成分。值得注意的是，非噪声成分也得到了保留，如图2 (c)红框及插图所示：在50 kHz中频信号附近（两个对称的小峰）以及49至49.25 kHz范围内（小峰），平均结果和模型去噪结果中均有信号从噪声中显现出来。这些可能是特征信号，表明模型不仅能够识别远高于噪声底的平均后信号，也能识别接近噪声底、被噪声淹没的信号。深度学习模型成功识别出这些特征信号，且它们与平均结果中的信号一致。这种一致性不仅验证了模型捕捉有意义模式的能力，也证实去噪过程并非深度学习框架产生的虚假伪影。在其他频率区域，去噪结果比平均结果更平坦，表明模型在噪声占主导的范围内具有更优的噪声抑制效果。

通过均方误差（MSE，与万组测量平均结果进行比较）量化去噪性能：

$$\mathrm{MSE} = \frac{1}{N}\sum_{i=1}^{N}(y_i - \bar{y}_i)^2, \tag{8}$$

其中 N 为数据点的数量，y_i 为去噪输出，而 $\bar{y}_i$ 为对应的10000次测量平均值参考值，作为真实值。在图 3 中，训练数据的数量从100变化至 5×10^4，峰峰值电压 Vpp 的范围为4.6 mV至4.9 mV。每次训练过程结束后，都会计算均方误差（MSE），以评估去噪结果与平均结果的吻合程度。当训练数据点的数量超过500时，均方误差显著降低，这表明适度增加训练数据量可大幅提升去噪效果——并且随着训练数据点数量接近 5×10^4，去噪效果趋于稳定。

总之，该模型实现了与多次测量平均相当的噪声抑制性能。它的独特之处在于能够从单次测量数据中提取被噪声淹没的信号，并识别潜在的特征信号。

B. 去噪性能的定量验证：深度学习与传统方法

图 4 利用里德堡原子微波外差探测的中频时域信号，验证了所提出的深度学习模型在抑制示波器记录的时间序列噪声方面优于传统方法（对10000组数据取平均、小波变换和卡尔曼滤波器）。

小波变换去噪 [22, 53]（绿色实线）使用 Coiflets小波（第4类），阈值为 0.55。卡尔曼滤波 [24] （橙色实线）的参数设置如下：过程噪声方差 $Q = 0.0175$ 和测量噪声方差 $R = 0.06$。为进行公平比较，通过网格搜索优化了上述传统方法的参数，以最小化这些方法去噪后的数据与以下数据之间的均方误差：

表 I. Vpp= 200、100 mV 情况下时域数据采用不同去噪方法的均方误差。

	深度学习	卡尔曼滤波	小波
峰峰值电压=200 毫伏	$\mathbf{7.71 \times 10^{-4} \pm 1.5 \times 10^{-4}}$	$7.0 \times 10^{-2} \pm 1.6 \times 10^{-2}$	$7.1 \times 10^{-2} \pm 2.5 \times 10^{-2}$
峰峰值电压=100 毫伏	$\mathbf{7.9 \times 10^{-5} \pm 4.5 \times 10^{-5}}$	$1.4 \times 10^{-1} \pm 3.6 \times 10^{-2}$	$2.5 \times 10^{-1} \pm 6.4 \times 10^{-2}$

具有相同中频信号和独立同分布噪声的 10,000 次重复测量的平均值。

10,000次测量平均值（黑色虚线）在视觉上比单次测量结果（灰色实线）更加平滑，噪声得到抑制，中频信号更加突出。与传统方法相比，深度学习模型的去噪结果（蓝色实线）更接近这一平均值，使含噪单频中频信号的曲线更加平滑，同时时间效率提高了三个数量级。

对于偶极板上的不同电压，200 mV（图4 (a)）和 100 mV（图4 (b)），这三种方法相对于平均结果的均方误差（均值± 测试集中 2000 个不同的时域信号的标准差）如表I所示。均方误差相差两个数量级，证实了深度学习模型在去噪方面具有显著优势。

C. 模型复杂度与去噪性能的关系

为探究模型复杂度对去噪性能的影响，图5 比较了两种深度学习架构（即 Transformer 模型与 U-Net 模型 [54–56],结构示意图见附录A），用于处理含噪时域和频域数据。Transformer模型（U-Net 模型）的参数规模为 4.50×10^5 (1.59×10^4)，训练时间分别为每训练轮次 2000 秒（每训练轮次 10 秒）；其他参数（如训练轮次、数据集配置和优化器）均保持一致。

在两个域中，基于Transformer模型的去噪结果都比其替代模型更接近10,000次测量的平均值。在时域中，替代架构无法捕捉中频信号特征，导致输出结果在50 kHz振荡的同时包含明显的高频噪声。相比之下，Transformer模型能够识别并提取共有的中频信号，同时抑制噪声干扰。在频域中，替代架构的结果中只有中频信号较为明显。然而，Transformer模型保留了中频信号及其边带和微弱的49.1 kHz信号，与10,000次测量的平均值表现出更高的相似度。这些结果表明，尽管训练时间更长，但增加计算复杂度（以训练参数量化）能够增强弱信号提取能力。这使得从噪声中更稳健地恢复弱信号成为可能；未来的工作可以采用更深或更高复杂度的架构，以进一步提升性能。

IV. 讨论

在本研究中，我们提出了一种用于里德堡原子微波传感器去噪的自监督深度学习框架。该框架在微波传感信号的频域和时域中均实现了与平均法相当的去噪性能，同时具有极低的延迟。与平均法相比，该方法将处理时间缩短了三个数量级。与卡尔曼滤波器和基于小波变换的去噪方法相比，所提出的方法展现出更优的去噪效果。此外，通过替换深度学习框架中的计算单元，我们确定了进一步提升性能的优化方向，即增加模型的计算复杂度。

深度学习去噪框架的性能，本质上源于模型学习目标信号 [57]内在属性的能力。里德堡原子微波信号受能级跃迁物理规律的约束，其振幅变化、频率分布和时间演化均呈现明确的内在结构。相比之下，环境干扰和量子涨落表现为遵循特定统计规律的随机噪声分量。模型通过从大型数据集中提取常见信号的特征，能够利用这些先验知识，从单次含噪测量中提取稳定的共有分量，同时抑制不同样本间的随机噪声变化。这一过程相当于以数据驱动的方式实现“虚拟平均”，既保留了单次测量的时间分辨率，又避免了传统平均方法在速度方面的限制。

与传统技术相比，所提出的用于量子传感的基于深度学习的去噪方法具有三项显著优势。首先，模型推理过程极快，单条数据可在毫秒内完成处理，完全满足动态过程监测的速度要求。其次，该方法以数据驱动学习为核心，无需预先建立噪声模型，因此能够更好地适应开放环境中常见的非平稳噪声。第三，模型训练无需干净的参考信号，因此适用于量子传感领域标注数据稀缺的场景。

未来的研究将重点关注以下局限性：对于数据驱动范式而言，模型性能高度依赖训练数据

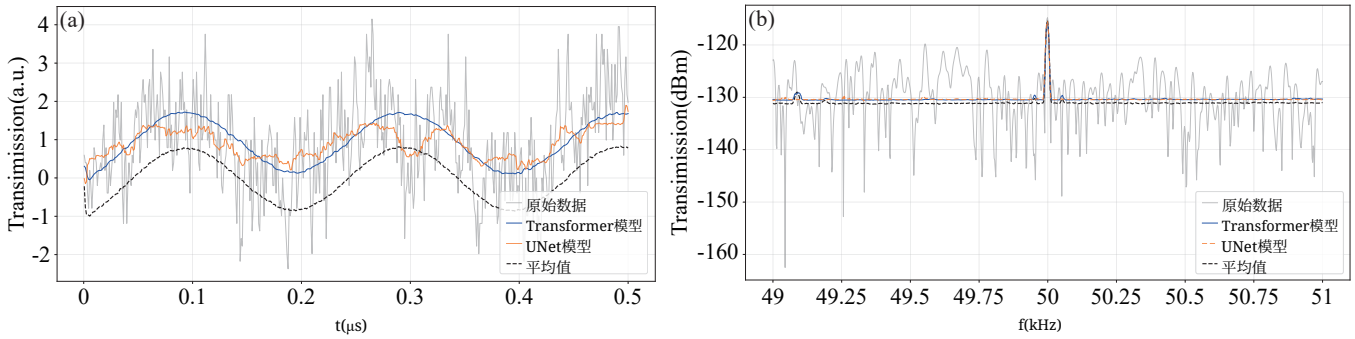

图 5. 相同自监督架构下不同深度学习模型的去噪结果。(a) Transformer（蓝色实线）和基于卷积的U-Net结构（橙色实线）对探测光束透射信号单次测量结果（灰色实线）的去噪结果；10,000次测量的平均结果（黑色虚线）作为真实值参考。(b) Transformer（蓝色实线）和基于卷积的U-Net结构（橙色虚线）对单次测量结果（灰色实线）的频域数据进行去噪的结果。Transformer的结果不仅呈现了中频（IF）信号，还呈现了其边带和微弱的49.1 kHz信号，并且比U-Net的结果更接近平均结果。

集的质量，而涵盖各种噪声场景的充足数据是确保去噪效果的前提。此外，尽管Transformer架构能够带来卓越的去噪性能，但其计算复杂度给在计算资源有限的嵌入式传感系统中的部署带来了挑战。

V. 致谢

我们感谢中国国家重点研发计划（项目编号：2022YFA1404003）、国家自然科学基金（项目编号：T2495252、12104279、123B2062、12574318）、量子科学与技术创新计划（项目编号：2021ZD0302100）以及山西省“1331工程”重点学科建设基金的资助。

六、数据可用性

当前研究中生成和/或分析的数据集可在 Zenodo 存储库中获取，访问地址为以下数字对象标识符（DOI）：10.5281/zenodo.18091258

附录A：模型结构

Transformer模型和U-Net 模型的结构分别如图所示：6和7。

Transformer模型的结构如下。首先，全连接层将数据维度投影到64维空间，以进行特征映射。其次，正弦编码层（SinePosEncoding）通过正弦值分配唯一向量，以保留序列顺序。随后，三个堆叠的编码器块（每个块均包含用于建模局部与全局依赖关系的8头多头自注意力、具有高斯误差线性单元（GELU）激活函数的128维前馈神经网络以表示信号、用于融合的残差连接，以及Dropout（比率为 $p = 0.1$））。最后，全连接层将64维特征映射回光谱强度，以实现去噪。上述各层的权重通过反向传播进行更新，所用优化器为Adam优化器（其一阶动量衰减系数为 $\beta_1 = 0.9$、二阶动量衰减系数为 $\beta_2 = 0.999$、用于防止除以零的稳定性参数为$\epsilon = 10^{-7}$，学习率为1.0×10^{-5}），损失函数为预测值与 y_{train}之间的均方误差（MSE）损失（$\mathcal{L}$）。深度学习模型运行所用的硬件为CPU，参数如下：第12代英特尔®酷睿™ i7-12700（2.10 GHz）。

U-Net 模型由编码器、解码器和一维卷积层组成，其中编码器和解码器通过层拼接连接。编码器包含三个组件。第一个卷积层包含 24 个卷积核，后接 LeakyReLU 激活函数。随后，应用池化尺寸为 2 的最大池化层，将时间分辨率减半。第二个卷积层进一步提取下采样时间尺度上的高层时间特征。解码器使用倍率为 2 的一维上采样层恢复时间分辨率。通过跳跃连接，上采样后的特征

与编码器中对应的高分辨率特征进行拼接，形成典型的 U-Net 形网络结构。这种设计使网络能够有效融合低层时间细节信息，.....信息和高层语义特征。最后，使用一维卷积层（包含48个卷积核，核大小为3）融合多尺度特征，并采用 LeakyReLU 激活函数。

[1]Jonathon A Sedlacek, Arne Schwettmann, Harald K¨ubler, Robert L¨ow, Tilman Pfau 和 James P Shaf- fer. 在蒸气室中利用明亮原子共振实现里德堡原子微波电测量. Nat Phys, 8(11):819–824, 2012年. [2] J. P. Shaffer 和 H. K¨ubler. 利用里德堡原子微波电场传感的读出增强. 收录于 J¨urgen Stuhler, Andrew J. Shields 和 Miles J. Pad- gett 编, Quantum Technol 2018，第10674卷，第106740C页. 国际光学与光子学学会，SPIE，2018年.[3] Mingyong Jing, Ying Hu, Jie Ma, Hao Zhang, Linjie Zhang, Liantuan Xiao 和 Suotang Jia. 基于微波缀饰里德堡光谱的原子超外差接收器. Nat Phys, 16(9):911–915, 2020年. [4] Charles T. Fancher, David R. Scherer, Marc C. St. John 和 Bonnie L. Schmittberger Marlow. 用于通信和传感的里德堡原子电场传感器. IEEE Trans Quantum Eng, 2:1–13, 2021年.[5]Jinpeng Yuan, Wenguang Yang, Mingyong Jing, Hao Zhang, Yuechun Jiao, Weibin Li, Linjie Zhang, Liantuan Xiao 和 Suotang Jia. 基于里德堡原子的微波电场量子传感. Rep Prog Phys, 86(10):106001, 2023年.[6] Bang Liu, Lihua Zhang, Zongkai Liu, Zian Deng, Dong- sheng Ding, Baosen Shi 和 Guangcan Guo. 基于里德堡原子的电场测量及其应用. EMS, 1(2):1–16, 2023年.[7]Hao Zhang, Yu Ma, Kaiyu Liao, Wenguang Yang, Zongkai Liu, Dongsheng Ding, Hui Yan, Wenhui Li 和 Linjie Zhang. 用于计量学、通信和混合量子系统的里德堡原子电场传感. 《科学通报》, 69(10):1515–1535, 2024年.[8] Bowen Yang, Yuhan Yan, Xuejie Li, Ling Xiao, Xi- aolin Li, L.Q. Chen, Jianliao Deng 和 Huadong Cheng. 通过增强瞬时带宽实现高灵敏度微波电测量. Phys. Rev. Appl., 21:L031003, 2024年3月.[9] Aojie Zhou, Yi Lin, Ruiqi Mao, Kai Yang, Zhenke Ding, Weipeng Wan 和 Yunqi Fu. 利用微型谐振器增强基于里德堡原子的高灵敏度场传感. IEEE Trans Antennas Propag, 73(12):10948– 10952, 2025年. [10] David A Anderson 和 Georg Raithel. 利用原子蒸气室连续测量高强度微波电场. Appl Phys Lett, 111(5), 2017年.[11] Charles S Adams, Jonathan D Pritchard 和 James P Shaffer. 里德堡原子量子技术. J Phys B: Atom Mol Phys, 53(1):012002, 2019年.[12] David H Meyer, Zachary A Castillo, Kevin C Cox 和 Paul D Kunz. 评估里德堡原子用于宽带电场传感的性能. J Phys B: Atom Mol Phys, 53(3):034001, 2020年1月. [13] Christopher L. Holloway, Joshua A. Gordon, Steven Jefferts、Andrew Schwarzkopf、David A. Anderson、Stephanie A. Miller、Nithiwadee Thaicharoen 和 Georg Raithel。用于 SI 溯源、自校准测量的宽带基于里德堡原子的电场探针。《IEEE Trans Antennas Propag》，62(12):6169–6182，2014年。[14] Christopher L. Holloway、Matthew T. Simons、Joshua A. Gordon、Andrew M. Dienstfrey、David Alexander An- derson 和 Georg Raithel。SI 溯源性电场计量：原子蒸气中电磁感应透明的系统测量不确定度。《应用物理学杂志》，121:233106–233106，2017年。[15] David Alexander Anderson、Rachel Elizabeth Sapiro 和 Georg Raithel。一种自校准、SI 溯源的基于里德堡原子的射频电场探针和测量仪器。《IEEE Trans Antennas Propag》，69(9):5931–5941，2021年。[16]Noah Schlossberger、Nikunjkumar Prajapati、Samuel Berweger、Andrew P Rotunno、Alexandra B Artusio- Glimpse、Matthew T Simons、Abrar A Sheikh、Eric B Norrgard、Stephen P Eckel 和 Christopher L Hol- loway。碱金属原子原子蒸气中的里德堡态：用作 SI 溯源场探针和通信接收器。《自然评论：物理》，6(10):606–620，2024年。[17] G. Boudreaux-Bartels 和 T. Parks。使用维格纳分布合成技术进行时变滤波和信号估计。《IEEE Trans on Acoust, Speech, and Signal Process》，34(3):442–451，1986年。[18] Marcos Dantus 和 Vadim V Lozovoy。物理化学过程的实验性相干激光控制。《化学评论》，104(4):1813–1860，2004年。[19] Quan Pan、Lei Zhang、Guanzhong Dai 和 Hongai Zhang。两种基于小波变换的去噪方法。《IEEE Trans Signal Process》，47(12):3401–3406，1999年。[20] L. Pasti、B. Walczak、D.L. Massart 和 P. Reschiglian。离散小波变换中的信号去噪优化。《Chemometr Intell Lab Syst》，48 34，1999 1 21( ): – 。[21] A. Grossmann 和 J. Morlet。将 Hardy 函数分解为形状恒定的平方可积小波，第126–139页。普林斯顿大学出版社，普林斯顿，2006年。[22] 崔慧敏、赵瑞梅和侯艳丽。基于小波变换的改进阈值去噪方法。《Phys Procedia》，33:1354–1359，2012年。2012年国际医学物理与生物医学工程会议（ICMPBE2012）。[23] C¸i˘gdem Polat Dautov 和 Mehmet Sira¸c ¨Ozerdem。小波变换与基于小波方法的信号去噪。载于：2018年第26届信号处理与通信应用会议（SIU），第1–4页，2018年。[24] Tamer Basar。《线性滤波与预测问题的新方法》，第167–179页。Wiley–Blackwell，2001年。[25] Siwei Yu、Jianwei Ma 和 Wenlong Wang。用于去噪的深度学习

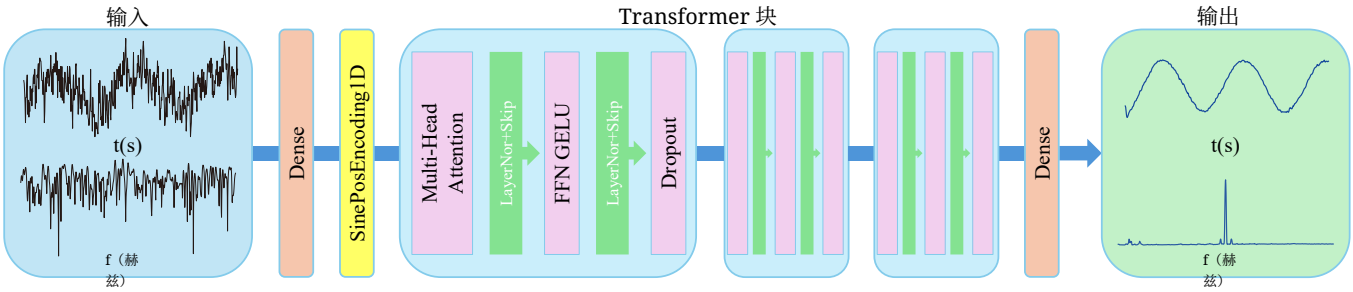

图 6. 基于 Transformer 的模式结构。

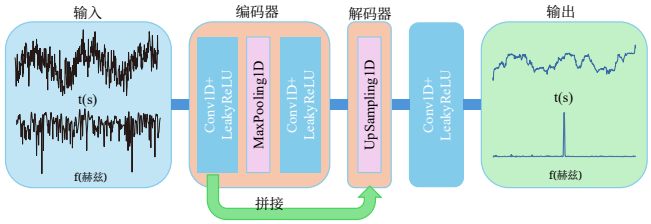

图 7. U-Net 结构。

。《Geophysics》，84(6):V333–V350，2019年。[26] Stephen Grossberg。循环神经网络。Scholarpedia，8(2):1888，2013年。[27] Dong Eui Caterini、Anthony L.and Chang。循环神经网络，第59–79页。Springer International Publishing，Cham，2018年。[28] Jingyang Wang、Xiaolei Li、Jiazheng Li、Qiuhong Sun 和 Haiyao Wang。NGCU：一种用于时间序列数据预测的新型循环神经网络模型。《Big Data Res》，27:100296，2022年。[29] Sepp Hochreiter 和 J¨urgen Schmidhuber。长短期记忆。《Neural Comput》，9(8):1735–1780，1997年。[30] Greg Van Houdt、Carlos Mosquera 和 Gonzalo N´apoles。长短期记忆模型综述。《Artif intell rev》，53(8):5929–5955，2020年。[31] Zhiguang Wang、Weizhong Yan 和 Tim Oates。基于深度神经网络从头进行时间序列分类：一种强基准方法。载于：2017年国际神经网络联合会议（IJCNN），第1578–1585页，2017年。[32] Serkan Kiranyaz、Turker Ince、Osama Abdeljaber、Onur Avci 和 Moncef Gabbouj。用于信号处理应用的一维卷积神经网络。载于：ICASSP 2019–2019年IEEE国际声学、语音与信号处理会议（ICASSP），第8360–8364页，2019年。[33] Hassan Ismail Fawaz、Germain Forestier、Jonathan We- ber、Lhassane Idoumghar 和 Pierre-Alain Muller。用于时间序列分类的深度学习：综述。《Data min knowl disc》，33(4):917–963，2019年。[34] Chih-Cheng Chen、Zhen Liu、Guangsong Yang、Chia- Chun Wu 和 Qiubo Ye。使用一维卷积神经网络模型改进故障诊断。《Electronics》，10(1)，2021年。[35] Sana Tonekaboni、Danny Eytan 和 Anna Golden- berg。利用时间邻域编码进行时间序列无监督表示学习。arXiv 预印本 arXiv:2106.00750，2021年。

[36] Pengfei Zhou、Yunlong Liu、Junli Liang、Qi Song 和 Xi- angyang Li。Crosslinear：用于含外生变量时间序列预测的即插即用互相关嵌入。载于第31届ACM SIGKDD知识发现与数据挖掘会议论文集第2卷，KDD '25，第4120–4131页，美国纽约，2025年。美国计算机协会。[37] Alex Graves、Abdel-rahman Mohamed 和 Geoffrey Hinton。基于深度循环神经网络的语音识别。载于2013年IEEE国际声学、语音与信号处理会议，页码6645–6649，2013年。[38] Ha.sim Sak、Andrew Senior 和 Fran.coise Beaufays。基于长短期记忆的循环神经网络架构，用于大词汇量语音识别。arXiv预印本 arXiv:1402.1128，2014年。[39] Felix Weninger、Hakan Erdogan、Shinji Watanabe、Em- manuel Vincent、Jonathan Le Roux、John R Hershey 和 Bj¨orn Schuller。利用长短期记忆循环神经网络进行语音增强及其在抗噪自动语音识别中的应用。载于潜变量分析与信号分离国际会议，页码91–99。施普林格，2015年。[40]Jane Oruh、Serestina Viriri 和 Adekanmi Adegun。用于自动语音识别的长短期记忆循环神经网络。《IEEE Access》，10：30069–30079，2022年。[41] Jing Wang、Nasir Saleem 和 Teddy Surya Gunawan。迈向高效循环架构：用于语音增强与识别的深度长短期记忆神经网络。《Cogn Comput》，16(3)：1221–1236，2024年。[42]Ashish Vaswani、Noam Shazeer、Niki Parmar、J akob Uszkoreit、Llion Jones、Aidan N Gomez、 Lukasz Kaiser 和 Illia Polosukhin。注意力机制就是一切。《神经信息处理系统进展》，30，2017年。[43] Ze Liu、Yutong Lin、Yue Cao、Han Hu、Yixuan Wei、Zheng Zhang、Stephen Lin 和 Baining Guo。Swin Transformer：利用移位窗口的分层视觉Transformer。载于2021年IEEE/CVF国际计算机视觉会议（ICCV），页码9992–10002，2021年。[44] Chi-Mao Fan、Tsung-Jung Liu 和 Kuan-Hsien Liu。SUNet：用于图像去噪的Swin Transformer U-Net。载于2022年IEEE电路与系统国际研讨会（ISCAS），页码2333–2337，2022年。[45] Hongzhou Wang、Jun Lin、Yue Li、Xintong Dong、Xun- qian Tong 和 Shaoping Lu。用于地震数据去噪的自监督预训练Transformer。《IEEE Trans Geosci》，62：1–25，2024年。[46]Pascal Vincent、Hugo Larochelle、Yoshua Bengio 和

Pierre-Antoine Manzagol。利用去噪自编码器提取并组合鲁棒特征。载于第25届国际机器学习大会论文集，ICML '08，第1096–1103页，美国纽约，2008年。美国计算机协会。[47] Xugang Lu、Yu Tsao、Shigeki Matsuda 和 Chiori Hori。基于深度去噪自编码器的语音增强。载于Interspeech，2013年。[48] Dor Bank、Noam Koenigstein 和 Raja Giryes。自编码器。《数据科学机器学习手册：数据挖掘与知识发现手册》，页码353–374，2023年。[49] Jake Lever、Martin Krzywinski 和 Naomi Altman。显著性要点：模型选择与过拟合。《Nat methods》，13(9)：703–705，2016年。[50]Osval Antonio Montesinos L´opez、Abelardo Montesinos L´opez 和 Jose Crossa。过拟合、模型调优与预测性能评估。载于《用于基因组预测的多元统计机器学习方法》，页码109–139。施普林格，2022年。[51]Bang Liu、Li-Hua Zhang、Zong-Kai Liu、Zheng-Yuan Zhang、Zhi-Han Zhu、Wei Gao、Guang-Can Guo、Dong- Sheng Ding 和 Bao-Sen Shi。利用里德堡原子对兆赫兹射频电场进行高灵敏度测量传感器。《Phys Rev Appl》，18(1):014045，2022年。[52] Ryandhimas E. Zezario、Tassadaq Hussain、Xugang Lu、Hsin-Min Wang 和 Yu Tsao。采用线性回归解码器的自监督去噪自编码器，用于语音增强。载于《ICASSP 2020 - 2020 IEEE国际声学、语音与信号处理会议（ICASSP）》，第6669–6673页，2020年。[53] Hai-Tao Fang 和 De-Shuang Huang。基于离散小波变换的激光雷达信号降噪。《Opt Commun》，233(1):67–76，2004年。[54] Olaf Ronneberger、Philipp Fischer 和 Thomas—Brox。U-net：用于生物医学图像分割的卷积网络。载于《医学图像计算与计算机辅助干预国际会议》，第234–241页。施普林格，2015年。[55] Maximilian P. Reymann、Tobias W¨urfl、Philipp Ritt、Bernhard Stimpel、Michal Cachovan、A. Hans Vija 和 Andreas Maier。用于SPECT图像去噪的U-net。载于《2019年IEEE核科学研讨会暨医学成像会议（NSS/MIC）》，第1–2页，2019年。[56] Nabil Ibtehaz 和 M. Sohel Rahman。MultiResUNet：重新思考用于多模态生物医学图像分割的U-Net架构。《Neural Netw》，121:74–87，2020年。[57] Saeed Izadi、Darren Sutton 和 Ghassan Hamarneh。深度学习时代的图像去噪。《Artif Intell Rev》，56(7):5929–5974，2023年。