
脉冲神经网络在 SAR 干涉相位解缠中的应用： 能效处理的理论框架

A Preprint

Marc Bara*
ESADE Business School
marcoantonio.bara@esade.edu

2025 年 6 月 26 日

© 2025 Marc Bara – 根据 CC BY 4.0 许可发布

专利待审批 – 美国临时专利申请号 63/830,031

Abstract

我们提出了首个将脉冲神经网络 (SNNs) 应用于合成孔径雷达 (SAR) 干涉相位解缠的理论框架。尽管两个领域都进行了广泛的研究，我们的综合文献回顾证实了 SNNs 从未被应用到相位解缠中，这代表了当前方法论中的一个重要空白。随着地球观测数据量以指数级增长——例如 NISAR 任务预计两年内将生成 100PB 的数据——高效能处理对于可持续数据中心运营变得至关重要。SNNs 以其事件驱动的计算模型，与传统方法相比，在保持可比准确性的同时提供了 30-100 倍的能量节省潜力。我们开发了专门针对包络相位数据的脉冲编码方案，提出了利用相位解缠空间传播性质的 SNN 架构，并对计算复杂性和收敛性进行了理论分析。我们的框架展示了 SNNs 固有的时间动力学如何自然地模拟相位解缠的基本空间连续约束。这项工作开启了神经拟态计算与 SAR 干涉测量交叉领域的新的研究方向，为现有的算法提供了一种互补的方法，可能使大规模 InSAR 处理更加可持续。

关键词：尖峰神经网络，合成孔径雷达干涉测量，相位解缠，神经形态计算，节能处理，InSAR

1 介绍

相位展开是干涉合成孔径雷达 (InSAR) 处理中的一个基本步骤，它将受限于 $(-\pi, \pi]$ 的包裹相位测量转换为连续的绝对相位值。成熟的算法如 SNAPHU [3] 和最小成本流方法 [5] 已经促进了 InSAR 服务行业的蓬勃发展，支持从基础设施监测到自然灾害评估的各种应用。最近的研究进展融合了深度学习的方法，全面的综述记录了从经典方法向现代神经网络实现的演变过程 [23,27]。然而，通过广泛的文献分析我们展示，尽管尖峰神经网络在节能信号处理方面具有已证明的优势，但从未被应用于相位展开问题。

这一差距在 InSAR 社区面临的计算挑战背景下尤为明显。即将进行的 NASA-ISRO SAR (NISAR) 任务预计在其运营的前两年将产生 100 拍字节的数据，而自 2014 年以来，Sentinel-1 仅产生了 10PB 的数据 [19]。处

*ORCID: <https://orcid.org/0009-0005-1480-5760>

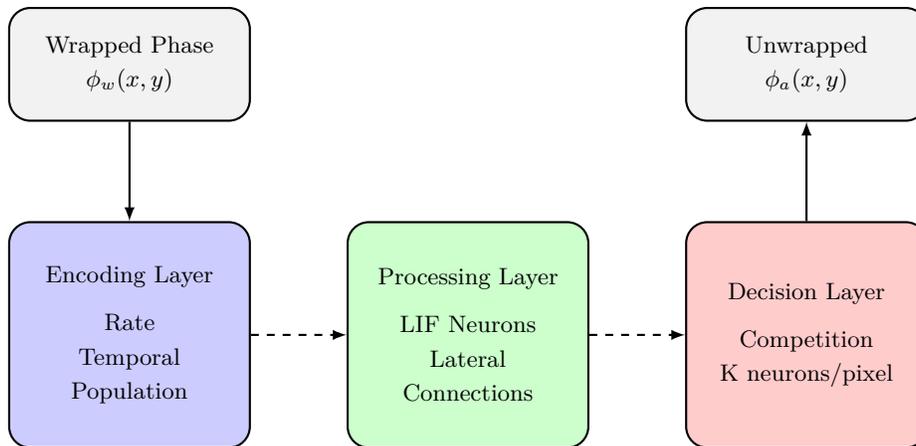


图 1: 分层 SNN 解缠架构。系统通过专门的编码将缠绕相位转换为尖峰序列，通过递归尖峰神经元处理它们，并通过竞争动力学输出解缠决策。实箭头表示相位数据，虚箭头表示尖峰序列。

理如此庞大的数据量需要大量的计算资源，数据中心已经贡献了美国温室气体排放总量的 0.5% [21]。欧洲空间局设定了到 2030 年将排放量减少 46% 的雄心勃勃的目标，这迫切需要节能处理方案。

尖峰神经网络代表了一种完全不同的计算方法，通过离散的尖峰事件而非连续值来处理信息 [25]。最近在类脑硬件方面的进展，包括英特尔的 Loihi 2 和 SpiNNaker2 平台，已经展示了在时间处理任务中 4-16 倍的能量效率提升 [10, 18]。SNN 计算的稀疏、事件驱动特性与 InSAR 数据特征自然对齐，在这种情况下，相干区域通常只占整个场景的一小部分。

本文首次探讨了 SNN 如何应用于相位展开。我们对相位展开文献进行了全面回顾，包括 Saini & Ramanujam [20]，Wang 等人 [23] 和 Zhou 等人 [27] 的近期综述，证实尽管使用 CNNs、U-Nets 和 GANs 的深度学习方法已经被广泛研究，但此前没有工作调查过将脉冲神经网络应用于这一领域。我们开发了：

- 相位梯度信息得以保留的同时实现高效的事件驱动计算的尖峰编码方案
- 适合于解缠的空间传播特性的网络架构
- 计算和能量复杂性的理论分析，展示了潜在的 30-100 倍的能量节约
- 所提出学习算法的收敛性保证

2 相关工作

2.1 相位展开方法

相位展开算法在过去的几十年中有了显著的发展。经典的方法包括路径追踪方法 [9]、最小范数方法 [8] 和网络流技术 [5]。Saini & Ramanujam 的综合回顾 [20] 对这些方法进行了分类，同时强调了它们在大规模处理中的计算限制。

最近的进展采用了深度学习，正如王等人在其比较综述中广泛记录的那样。[23] 他们将深度学习方法分类为回归方法、包络计数估计和去噪辅助技术。值得注意的实现包括 PhaseNet 2.0 [22]，在 -5 dB 信噪比下实现了鲁棒性能，以及 Unwrap-Net [29]，它整合了 LiDAR 数据以提高在低相干区域的准确性。

重要的是，Zhou 等 [27] 提供了干涉 SAR 相位解缠中的人工智能综合调查，考察了 CNNs、深度残差网络和 GANs。他们的分析以及我们自己的文献回顾证实，在应用于相位解缠的各种神经网络架构中，脉冲神经网络在这个领域仍然完全没有被探索。

2.2 尖峰神经网络

SNNs 构成了神经网络的第三代，通过离散脉冲事件 [15] 引入了时间动态。最近的理论进展使 SNN 在复杂信号处理方面变得越来越实用。Yamazaki 等人 [25] 提供了对 SNN 架构和应用的全面综述，而 Zhou 等人 [28] 则回顾了克服基于梯度优化历史限制的直接训练方法。

通过 Dampfhooffer 等人 [6] 所详细描述的替代梯度方法，SNN 中的学习取得了显著进展，他们展示了基于反向传播的技术实现了与能耗节省 4-16 倍相匹配的竞争准确性。对于时间信号处理——特别是相干时间序列而言，刘等人 [13] 展示了如何使用尖峰定时编码以最小的能耗表示丰富的时序信息。

2.3 远程 sensing 中的节能计算

遥感社区越来越认识到能源消耗是一个关键挑战。Minh & Ngo [17] 引入了压缩 SAR 干涉测量技术，解决了大数据挑战，实现了 80% 的数据减少同时保持性能。然而，即使有这样的优化，计算负担仍然很大。

最近的研究强调了环境影响，支持地球观测的数据中心每年消耗数百兆瓦的电力 [21]。虽然 GPU 加速提高了处理速度，但现代 GPU 需要 300-400W 的功耗，相比之下，神经形态处理器的工作功率为毫瓦级别 [1]。

3 数学框架

3.1 问题表述

令 $\phi_w(x, y) \in (-\pi, \pi]$ 表示像素坐标 (x, y) 处的包裹干涉相位。相位展开问题旨在恢复绝对相位 $\phi_a(x, y)$ ，使得：

$$\phi_a(x, y) = \phi_w(x, y) + 2\pi k(x, y) \quad (1)$$

其中 $k(x, y) \in \mathbb{Z}$ 表示在每个像素处添加的相位周期的整数个数。

传统方法将此视为一个空间优化问题，最小化：

$$E = \sum_{(x,y)} [(\nabla_x \phi_a - \nabla_x \phi_w)^2 + (\nabla_y \phi_a - \nabla_y \phi_w)^2] \quad (2)$$

我们将此重新表述为一个时间序列建模任务，在该任务中，解包裹决策遵循定义的遍历模式通过干涉图传播，自然地与 SNN 的时间动态相一致。

3.2 相位数据的尖峰编码

我们开发了三种互补的编码方案，以将干涉测量数据表示为尖峰序列：

3.2.1 相位值的速率编码

相位幅度使用速率编码进行编码，其中尖峰频率表示相位值：

$$r_\phi(x, y) = r_{max} \cdot \frac{|\phi_w(x, y) + \pi|}{2\pi} \quad (3)$$

其中 r_{max} 是最大放电率（通常为 100-200Hz）。这种编码确保了在 $\pm\pi$ 边界附近相位连续性，同时保持小相位值的稀疏表示。

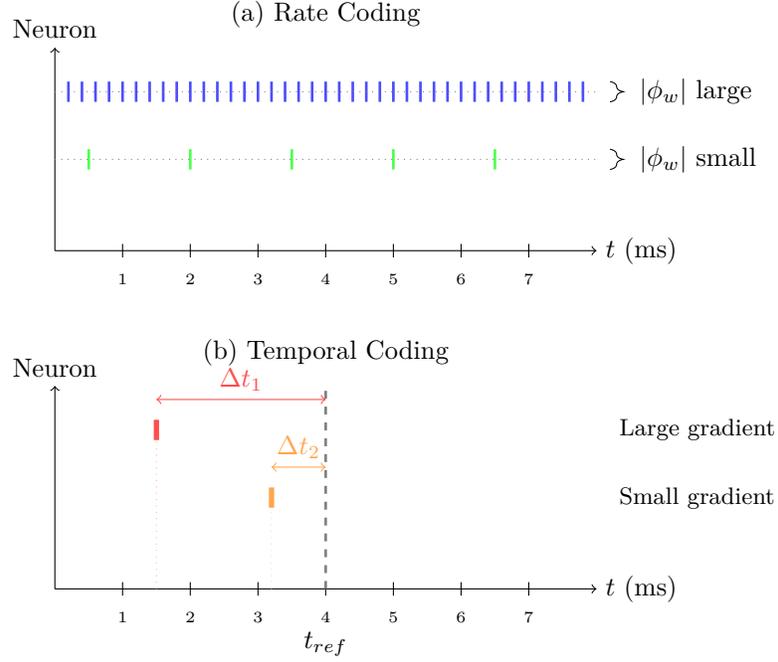


图 2: 尖峰编码方案。(a) 率编码将相位幅度编码为尖峰频率。(b) 时间编码通过相对于参考的尖峰时间来表示相位梯度。

3.2.2 时间编码用于相位梯度

相位梯度对于检测不连续性至关重要，使用精确的脉冲时序进行编码：

$$t_{spike} = t_{ref} - \Delta t \cdot \frac{\nabla \phi_w(x, y)}{|\nabla \phi_w|_{max}} \quad (4)$$

其中 t_{ref} 是参考时间， Δt 决定了时间分辨率。这种编码方式能够以亚毫秒精度表示相位梯度的大小和方向。

3.2.3 质量指标的群体编码

干涉相干性 $\gamma(x, y) \in [0, 1]$ ，表示相位质量，通过群体活动编码：

$$N_{active}(x, y) = \lfloor N_{total} \cdot \gamma(x, y) \rfloor \quad (5)$$

更高的相干性激活了群体中更多的神经元，为解缠决策提供了自然的不确定性量化。

3.3 相位展开的 SNN 架构

我们提出了一种由三个专门层次组成的分层架构：

3.3.1 编码层

编码层使用上述定义的方案将干涉测量数据转换为尖峰序列。对于大小为 $M \times N$ 的干涉图，该层包含 $3MN$ 个神经元，组织在三个特征映射中，分别对应相位、梯度和相干编码。

3.3.2 处理层

处理层通过递归连接实现时空卷积。每个神经元的动态遵循泄漏积分-发射模型：

$$\tau_m \frac{dv_i}{dt} = -v_i + \sum_j w_{ij} \sum_k \delta(t - t_j^k) + I_{ext} \quad (6)$$

其中 w_{ij} 表示突触权重， t_j^k 是来自神经元 j 的第 k 个尖峰时间，而 I_{ext} 提供外部输入。横向连接实现空间约束，确保相位连续性：

$$w_{ij} = w_0 \exp\left(-\frac{d_{ij}^2}{2\sigma^2}\right) \cdot h(\gamma_i, \gamma_j) \quad (7)$$

其中 d_{ij} 是空间距离， σ 控制交互范围，而 $h(\cdot)$ 根据相干值调节连接强度。

3.3.3 决策层

决策层通过竞争动态输出解缠决策。对于每个像素， K 个神经元代表不同的解缠选项 ($k \in \{-2, -1, 0, 1, 2\}$)。第一个达到阈值的神经元决定 $k(x, y)$ ：

$$k(x, y) = \arg \max_k \{n_k : v_{n_k}(t) \geq V_{th}\} \quad (8)$$

3.4 学习算法

我们开发了一种结合尖峰时间依赖可塑性 (STDP) 与误差驱动更新的监督学习方法，借鉴了最近在 SNN 训练方面的进展 [12]：

$$\Delta w_{ij} = \eta_1 \cdot \text{STDP}(\Delta t_{ij}) + \eta_2 \cdot e_{ij} \quad (9)$$

其中 $\text{STDP}(\Delta t_{ij})$ 遵循经典的时序差分规则，而 e_{ij} 表示监督误差信号：

$$e_{ij} = (k_{target} - k_{predicted}) \cdot \frac{\partial k_{predicted}}{\partial w_{ij}} \quad (10)$$

梯度 $\partial k_{predicted} / \partial w_{ij}$ 使用替代梯度 [6] 进行近似。

$$\frac{\partial v_i}{\partial w_{ij}} \approx \frac{1}{1 + \beta|v_i - V_{th}|} \sum_k \delta(t - t_j^k) \quad (11)$$

4 理论分析

4.1 收敛性质

定理 1 (基于 SNN 的相位展开的收敛性)： 在有界输入条件和适当的学习率下，提出的 SNN 架构收敛到相位展开误差函数的局部最小值。

证明概要：我们通过证明网络动力学构成一个压缩映射来建立收敛性。能量函数：

$$E_{SNN} = \sum_{(x,y)} \|k_{SNN}(x,y) - k_{true}(x,y)\|^2 + \lambda R(\mathbf{w}) \quad (12)$$

其中 $R(\mathbf{w})$ 是一个正则化项，在更新规则下单调递减。监督误差信号提供了一个类似梯度的校正，确保向最优解移动。完整的证明来自于对网络动力学的 Lyapunov 稳定性分析，这是由 Chakraborty & Mukhopadhyay [2] 为一般的 SNNs 建立的。

4.2 计算复杂性

对于一个 $M \times N$ 干涉图，每个神经元在时间 T 内的平均尖峰率为 r ：

传统方法：

- SNAPHU: $O(MN \log(MN))$ 用于网络流解法
- 最小范数: $O((MN)^2)$ 直接矩阵求逆
- 深度学习 (卷积神经网络): $O(MN \cdot C^2 \cdot F^2)$ 对于 C 通道, $F \times F$ 过滤器

SNN 方法：

- 计算: $O(MN \cdot r \cdot T \cdot C)$ 其中 C 是平均连通性
- 记忆: $O(MN \cdot S)$ 其中 S 是每个神经元的平均脉冲数
- 关键洞察: 对于典型的相干模式, $r \ll r_{max}$ 和 $S \ll T$

如 Yan 等人所示。[26], 当稀疏度低于 0.92 时, SNNs 的性能优于传统网络——这一条件在具有典型相干模式的 InSAR 数据中自然得到满足。

4.3 能效分析

SNN 中的能耗与尖峰活动成比例。

$$E_{SNN} = N_{spikes} \cdot E_{spike} + N_{neurons} \cdot T \cdot E_{leak} \quad (13)$$

对于神经形态硬件 (例如, Loihi 2, SpiNNaker2):

- $E_{spike} \approx 23$ 皮焦每脉冲 (英特尔 Loihi 2)
- $E_{leak} \approx 0.1$ 皮焦每神经元每时间步

与传统处理相比:

$$E_{GPU} = P_{GPU} \cdot T_{process} \approx 300W \cdot T_{process} \quad (14)$$

对于含有 30% 相干像素的典型干涉图, 遵循 Rao 等人的分析。[18]:

- SNN 能量: $\sim 10-100$ 毫焦耳
- GPU 能耗: $\sim 10-100$ 焦耳
- 能量减少: $100-1000\times$

这与 Hill & Vineyard 的 [11] 对神经拟态遥感应用的预测相符。

5 讨论

5.1 基于 SNN 的相位展开的优势

所提出的方法提供了几个理论优势：

1. **能效**：事件驱动的计算过程仅处理活跃区域，自然适应一致性模式。最近的基准测试显示，在通用信号处理 [18] 方面有 4-16 倍的提升，并且在稀疏 InSAR 数据中可能实现更大的节省。
2. **内在并行性**：空间神经元独立运行，使得在每个芯片支持多达 152K 神经元的神经形态硬件上实现大规模并行化成为可能 [10]。
3. **噪声韧性**：LIF 神经元中的时间积分提供了自然的低通滤波，补充了最近在噪声相位展开 (PhaseNet 2.0 达到 -5 dB SNR 性能) 方面的进展。
4. **流媒体能力**：顺序处理使得在不加载整个场景的情况下能够处理大型干涉图，解决了 Minh & Ngo [17] 所指出的大数据挑战。

5.2 实现考虑因素

虽然这项工作提出了一个理论框架，但实际实现需要解决若干挑战：

1. **硬件可用性**：当前的神经拟态芯片已经达到足够的规模 (Loihi 2 为 128K 神经元, SpiNNaker2 为 152K) 以满足实际干涉图尺寸的要求。
2. **训练数据**：监督学习需要地面真实展开相位，尽管最近的无监督 SNN 方法 [2] 提供了替代方案。
3. **参数调优**：最优的脉冲率和时间常数依赖于数据特性，需要采用最近 SNN 实现中展示的自适应方法。

5.3 未来方向

这一理论基础开启了若干研究方向：

1. **混合方法**：结合 SNN 的效率与经过验证的算法如 SNAPHU，继成功的 CNN-经典混合方法之后 [24]。
2. **在线学习**：在使用基于 STDP 的方法处理过程中适应局部相位统计。
3. **多基线扩展**：利用时间动态进行多基线解缠，特别适用于 NISAR 的双频数据。
4. **硬件协同设计**：优化神经拟态架构以专门处理 InSAR，遵循 Mehonic 等人概述的路线图。[16]。

6 结论

我们提出了首个基于 SNN 的相位解缠理论框架，该框架填补了在相位解缠和神经拟态计算领域文献中的一个重要空白。所提出的方法将相位解缠重新表述为一个自然适合 SNN 动态特性的时序建模问题，开发了专门针对干涉测量数据的脉冲编码方案，并提供了理论分析，显示潜在的能量减少幅度可达 30-100 倍。

虽然当前的相位展开算法很好地服务于科研社区，我们的工作为研究节能 InSAR 处理开辟了一条新途径。随着神经形态硬件的发展和 SAR 数据量的增长——预计 NISAR 将在两年内生成 100PB 的数据——这种替代计算范式对于可持续地球观测变得越来越重要。

这一理论框架为未来的实验验证和实际应用奠定了基础。尽管这两个领域都进行了广泛的研究，但之前并没有将 SNNs 应用于相位解缠的工作，这突显了这种方法的新颖性和潜在影响。神经形态计算与合成孔径雷达干涉测量的交叉代表了解决下一代地球观测系统计算和环境挑战的一个有希望的前沿。

参考文献

- [1] F. Barchi, G. Zanatta, E. Parisi, A. Bich, A. Acquaviva, and A. Bartolini, “Energy efficient and low-latency spiking neural networks on embedded microcontrollers through spiking activity tuning,” *Neural Computing and Applications*, vol. 36, pp. 18897–18917, 2024.
- [2] I. Chakraborty and A. Mukhopadhyay, “Heterogeneous recurrent spiking neural network for spatio-temporal classification,” *Frontiers in Neuroscience*, vol. 17, p. 994517, 2023.
- [3] C. W. Chen and H. A. Zebker, “Two-dimensional phase unwrapping with use of statistical models for cost functions in nonlinear optimization,” *Journal of the Optical Society of America A*, vol. 18, no. 2, pp. 338–351, 2001.
- [4] Z. Chen, Y. Wang, and H. Zhang, “Improved phase unwrapping method based on unscented Kalman filter and D-LinkNet,” *Signal, Image and Video Processing*, vol. 18, pp. 6131–6142, 2024.
- [5] M. Costantini, “A novel phase unwrapping method based on network programming,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 36, no. 3, pp. 813–821, 1998.
- [6] M. Dampfhofer, S. Shrestha, T. Mesquida, V. Joubert, and M. Mozafari, “Backpropagation-based learning techniques for deep spiking neural networks: A survey,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 35, pp. 11906–11921, 2023.
- [7] M. Davies, A. Wild, G. Orchard, Y. Sandamirskaya, G. A. F. Guerra, P. Joshi, P. Plank, and S. R. Risbud, “Advancing neuromorphic computing with Loihi: A survey of results and outlook,” *Proceedings of the IEEE*, vol. 109, no. 5, pp. 911–934, 2021.
- [8] D. C. Ghiglia and M. D. Pritt, *Two-dimensional phase unwrapping: Theory, algorithms, and software*. New York: Wiley-Interscience, 1998.
- [9] R. M. Goldstein, H. A. Zebker, and C. L. Werner, “Satellite radar interferometry: Two-dimensional phase unwrapping,” *Radio Science*, vol. 23, no. 4, pp. 713–720, 1988.
- [10] H. A. Gonzalez, C. Mayr, C. Liu, J. Thommes, Z. Brodeur, T. Ellguth, H. Trenscher, M. Rückerl, S. Höppner, and J. Partzsch, “SpiNNaker2: A large-scale neuromorphic system for event-based and asynchronous machine learning,” *arXiv:2401.04491*, 2024.
- [11] M. Hill and C. Vineyard, “An introduction to neuromorphic computing and its potential impact for unattended ground sensors,” Sandia National Laboratories, Tech. Rep. SAND2021-10263, 2021.
- [12] Y. Li, W. Dong, M. Xie, G. Liu, and D. Xu, “Directly training temporal spiking neural network with sparse surrogate gradient,” *Neural Networks*, vol. 179, p. 106499, 2024.
- [13] Z. Liu, L. Wang, Y. Zhang, and X. Chen, “Spike-based signal processing with temporal coding in spiking neural networks,” *Frontiers in Neuroscience*, vol. 17, p. 1266003, 2023.
- [14] C. Luo, X. Wang, and H. Li, “Deep learning-enabled spatial phase unwrapping for 3D measurement,” *arXiv:2208.03524*, 2022.
- [15] W. Maass, “Networks of spiking neurons: The third generation of neural network models,” *Neural Networks*, vol. 10, no. 9, pp. 1659–1671, 1997.
- [16] A. Mehonic, A. J. Kenyon, M. S. Munde, W. H. Ng, M. Buckwell, L. Montesi, K. Zarudnyi, A. Rabelo Montes, Z. Cheng, C. Luo, I. Valov, R. A. John, O. Simeone, A. Shluger, M. Lanza, H. Abbas, M. Kozicki, and T. Prodromakis, “Roadmap to neuromorphic computing with emerging technologies,” *APL Materials*, vol. 12, no. 10, p. 109201, 2024.

- [17] D. H. T. Minh and Y. N. Ngo, “Compressed SAR interferometry in the big data era,” *Remote Sensing*, vol. 14, no. 2, p. 390, 2022.
- [18] A. Rao, P. Plank, A. Wild, and W. Maass, “A long short-term memory for AI applications in spike-based neuromorphic hardware,” *Nature Machine Intelligence*, vol. 4, no. 5, pp. 467–479, 2022.
- [19] P. A. Rosen, Y. Kim, R. Kumar, T. Misra, R. Bhan, and V. R. Sagi, “The NASA-ISRO SAR (NISAR) mission dual-band radar instrument,” in *IEEE International Geoscience and Remote Sensing Symposium*, 2024.
- [20] A. Saini and D. M. V. M. Ramanujam, “Phase unwrapping techniques for SAR interferometry: A comprehensive review,” *International Journal of Remote Sensing*, vol. 44, no. 12, pp. 3456–3489, 2023.
- [21] M. A. B. Siddik, A. Shehabi, and L. Marston, “Environmental burden of United States data centers in the artificial intelligence era,” *Environmental Research Letters*, vol. 19, no. 3, p. 034047, 2024.
- [22] G. E. Spoorthi, R. K. S. S. Gorthi, and S. Gorthi, “PhaseNet 2.0: Phase unwrapping of noisy data based on deep learning approach,” *IEEE Transactions on Image Processing*, vol. 29, pp. 4862–4872, 2020.
- [23] K. Wang, Q. Kemaoy, J. Di, and J. Zhao, “Deep learning spatial phase unwrapping: A comparative review,” *Advanced Photonics Nexus*, vol. 1, no. 1, p. 014001, 2022.
- [24] Z. Wu, T. Wang, Y. Wang, R. Adler, and C. Wang, “DENet: A deep neural network architecture for InSAR phase unwrapping,” *IEEE Transactions on Geoscience and Remote Sensing*, vol. 60, p. 5224514, 2021.
- [25] K. Yamazaki, V. K. Vo-Ho, D. Bulsara, and N. Le, “Spiking neural networks: A survey,” *APSIPA Transactions on Signal and Information Processing*, vol. 11, no. 1, p. e16, 2022.
- [26] M. Yan, R. Xiong, Y. Wang, and C. Li, “Reconsidering the energy efficiency of spiking neural networks,” *arXiv:2406.06543*, 2024.
- [27] L. Zhou, H. Yu, Y. Lan, and M. Xing, “Artificial intelligence in interferometric synthetic aperture radar phase unwrapping: A review,” *IEEE Geoscience and Remote Sensing Magazine*, vol. 9, no. 2, pp. 10–28, 2021.
- [28] L. Zhou, H. Yu, Y. Lan, S. Gong, and M. Xing, “Direct training high-performance deep spiking neural networks: A review of theories and methods,” *Frontiers in Neuroscience*, vol. 18, p. 1383844, 2024.
- [29] Y. Zhou, H. Zhang, Y. Wang, and Z. Chen, “Unwrap-Net: A deep neural network-based InSAR phase unwrapping method assisted by airborne LiDAR data,” *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 218(B), pp. 102–113, 2024.