

增强链路思维的浅层变压器用于无线符号检测

Li Fan¹, Peng Wang², Jing Yang^{1,2}, Cong Shen¹

¹Charles L. Brown Department of Electrical and Computer Engineering, University of Virginia, USA

²Department of Computer Science, University of Virginia, USA

E-mails: {lf2by,pw7nc,yangjing,cong}@virginia.edu

摘要—变换器在解决无线通信问题方面显示出潜力，特别是在通过上下文学习 (ICL) 的方式下，模型可以通过提示适应新任务而无需更新模型。然而，先前基于 ICL 的变换器模型依赖于具有许多层的深层架构来实现令人满意的性能，导致了显著的存储和计算成本。在本工作中，我们提出了 化学ain Of thOught Symbol dEtection (选择)，一种用于无线符号检测的 CoT 增强浅层变换器框架。通过在隐藏空间中引入自回归潜在推理步骤，选择显著提高了浅层模型 (1-2 层) 的推理能力，而无需增加模型深度。此设计使轻量级 Transformer 能够达到与更深模型相当的检测性能，使其非常适合部署在计算资源受限的移动设备上。实验结果表明，我们的方法优于传统的浅层 Transformer，并且达到了与深层 Transformer 相当的性能，同时保持了存储和计算效率。这在计算资源有限的无线接收器中实现基于 Transformer 的算法提供了一个有前景的方向。

I. 介绍

上下文学习 (ICL) [1] 是 Transformer [2] 的一项基本能力，允许模型通过基于输入-输出演示序列的条件化来执行新任务，而无需进行参数更新。典型的 ICL 提示采用形式 $(y_1, x_1, \dots, y_n, x_n, y_{n+1})$ ，其中模型根据之前的演示对 (y_i, x_i) 和新的查询 y_{n+1} 预测 \hat{x}_{n+1} 。已经证明，在适当的条件下 [3], [4]，基于 ICL 的 Transformer 可以近似一类广泛的功能。

无线通信任务，如符号检测，自然与这种 ICL 公式相吻合。在块衰落信道中，随机信道状态在一个相干符号块内保持不变。通过条件少量的导频信号对，基于 ICL 的 Transformer 可以隐式推断出潜在的信道并准确地检测后续符号。最近的研究表明，在这种范式下训练的 Transformers 可以在各种无线场景中实现接近最优的性能 [5]–[7]。值得注意的是，[7] 表明基于 ICL

的 Transformers 可以灵活地在相干和非相干检测策略之间进行插值。

尽管有这些优势，大多数现有的基于 ICL 的 Transformer 依赖于深度架构来实现竞争力性能。然而，这样的深度模型引入了显著的计算和内存开销，使得它们在资源受限的移动设备 [8] 上部署变得不切实际。即使是在推理过程中，这些模型也遭受高延迟和能源消耗的问题，这限制了它们在实时和低功耗无线系统中的适用性。

为了解决这些挑战，我们借鉴了思维链 (CoT) 推理 [9], [10] 技术，该技术最初是为提高大型语言模型 (LLMs) 的多步推理能力而开发的。CoT 鼓励模型在做出最终预测之前生成中间推理步骤，从而增强准确性和可解释性。这种想法的扩展，例如 [11], [12]，表明 CoT 可以在潜在嵌入空间中有效运行，无需显式的符号输出。

最近，理论和实证研究表明，CoT 推理可以显著提高浅层 Transformer 的表达能力，这些模型具有显著较少的层数。例如，[13], [14] 提供了形式化分析，表明 CoT 推理增加了仅解码器架构的功能容量。此外，[15] 表明即使单层 Transformer 也可以通过自回归推理来模拟多步梯度下降，突显了当浅层模型结构设计得当时近似复杂映射的潜力。

受这些见解的启发，我们提出了选择 化学ain Of thOught Symbol dEtection。选择是一种增强上下文推理的浅层 Transformer 架构 (1-2 层)，用于场景内无线符号检测。据我们所知，这是首次将 CoT 推理整合到基于 ICL 的 Transformer 中以应用于无线领域的研究工作。通过在 Transformer 的潜在空间中引入中间

推理步骤，选择显著提高了浅层模型的表现力，而无需增加其深度。广泛的实验表明，选择一直优于传统的浅层基线，并且达到了更深模型的准确性，同时大大降低了存储和计算成本，使其非常适合边缘部署。这项工作的关键贡献是：

- 我们提出了选择，一种用于上下文无线符号检测的 CoT 增强浅层 Transformer，以极小的深度实现了强大的性能。
- 我们引入了一种训练策略，该策略能够在没有显式监督的情况下实现潜在推理。
- 我们通过广泛的实验表明，CoT 推理显著提高了浅层变压器的表达能力和检测准确性，同时保持了较低的计算开销。

II. 无线系统模型

我们考虑一个窄带单输入单输出 (SISO) 通信系统，该系统在块衰落信道上运行，遵循标准公式化 [16]。复数信道系数 $h \sim P_H$ 在每个相干块中的 T 个符号周期内保持不变，并且在不同的块中独立同分布 (i.i.d.) 采样。时间 t 处接收到的信号建模为：

$$y_t = hx_t + z_t, \quad (1)$$

其中 $x_t \in \mathcal{X}$ 是从调制星座图中均匀随机采样的发送符号。噪声项 z_t 被建模为加性高斯白噪声 (AWGN)，来自分布 $z_t \sim \mathcal{CN}(0, \sigma^2)$ 。平均发射功率被归一化为 1，即， $\mathbb{E}[\|x_t\|^2] = 1$ ，并且假设信道的方差也为 1，从而导致接收信号信噪比 (SNR) 为 $\text{SNR} = \frac{1}{\sigma^2}$ 。

在每个长度为 T 的连贯块中，前 k 个符号被指定为导频符号，这些导频符号为发射机和接收机所知晓。这些导频对 (y_i, x_i) 作为上下文信息，有助于推断底层信道状况。目标是仅使用接收到的信号和导频参考来检测剩余的 $T - k$ 个数据符号，而不依赖于显式的信道估计。

III. 基于 ICL 的符号检测

A. 基于 ICL 的符号检测公式

我们将无线符号检测公式化为 ICL 范式下的回归任务。在此设置中，模型基于一系列 pilots 示范示例预测新查询输入的传输符号，而无需更新其参数。

每个检测任务 τ 由一个潜在信道系数 h 和噪声水平 σ^2 定义，这些是从联合任务分布 $P_\tau = P_H P_{\sigma^2}$ 中抽

取的。接收器没有直接了解具体任务实现 τ 的知识，必须完全从观察到的导频对推断相关信道状态。给定一个固定的任务 τ ，先验配对 (x_i, y_i) 和查询 (x_t, y_t) 对于 $t = k + 1, \dots, T$ 都是 i.i.d. 抽样的。我们将先验上下文表示为：

$$D_k^\tau = \{(y_1, x_1), \dots, (y_k, x_k)\}, \quad (2)$$

其中每个 (y_i, x_i) 是在相同任务 τ 下的收发符号对。给定一个新的查询观测值 $y_t, t = k + 1, \dots, T$ ，模型通过一个学习到的函数 f 预测相应的传输符号：

$$\hat{x}_t = f(D_k^\tau, y_t). \quad (3)$$

模型使用 k 个导频符号的性能通过均方误差 (MSE) 进行评估，该误差是在任务分布上取平均值：

$$\text{MSE}_k = \mathbb{E}_{\tau \sim P_\tau} \mathbb{E}_{(D_k^\tau, y_t) | \tau} [\|x_t - f(D_k^\tau, y_t)\|^2]. \quad (4)$$

除了 MSE，我们还使用 k 导频符号评估符号误差率 (SER)：

$$\text{SER}_k = \mathbb{E}_{\tau \sim P_\tau} \mathbb{E}_{(D_k^\tau, y_t) | \tau} [\mathcal{P}(\hat{x}_t) \neq x_t]. \quad (5)$$

由于 Transformer 具有连续值输出，我们添加了一个最近邻投影操作，其形式定义如下：

$$\mathcal{P}(\hat{x}_t) = \arg \min_{x' \in \mathcal{X}} \|\hat{x}_t - x'\|, \quad (6)$$

其中 \mathcal{X} 表示调制星座集。此投影选择与软估计 \hat{x}_t 在欧几里得距离上最接近的星座符号。

B. vanilla 在上下文中的符号检测

我们介绍如 Figure 1 所示的基于 ICL 的符号检测基线架构，遵循 [5], [6]。该模型接收一个展平的序列，包含 k 个试点演示，其中第 i 个演示由接收到的符号 y_i 及其对应的传输符号 x_i 组成，随后是一个新的查询符号 y_t ，需要预测其传输符号 x_t 对应于 $t = k + 1, \dots, T$ 。每个复数符号被分解为其实部 (I) 和虚部 (Q)，并表示为一个实值交错的 I/Q 序列。

输入序列首先通过**输入标题**映射到一个更高维度的嵌入空间。得到的嵌入随后由因果性的**变压器**主干进行处理——通常由多个堆叠的解码器层组成（如我们在实验中使用的 GPT-2）——其中遮蔽自注意力确保每个位置只能关注前面的标记。最后，查询位置的隐藏嵌入通过**输出头部**传递以生成一个连续值符号估计 $\hat{x}_t \in \mathbb{C}$ 。

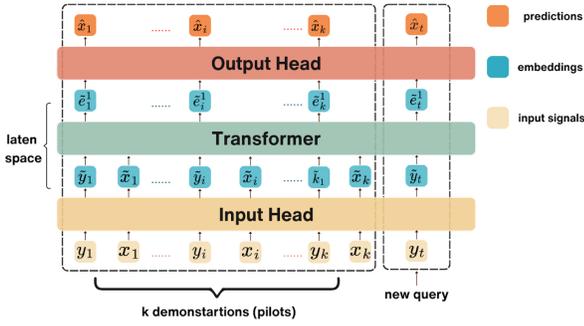


图 1. 原味上下文符号检测架构。输入头嵌入飞行员对和查询。因果 Transformer 在掩码自注意力下处理嵌入序列，输出头从其最终嵌入预测查询符号。

IV. 增强的上下文符号检测

为了减少内存和计算需求，使基于 Transformer 的无线符号检测能够在资源受限设备上实现，我们需要减小 Transformer 的规模。然而，直接减少深度通常会导致推理性能不佳。为了解决这个困境，我们提出了选择，这是一种在查询位置的隐藏空间中结合自回归潜在推理步骤（称为想法）的 CoT 增强浅层 Transformer 架构，如 Figure 2 所示。受到 [12] 中潜在 CoT 机制的启发，选择通过在生成最终预测之前迭代地精炼查询嵌入的一系列思维步骤，直接将多步推理嵌入到 Transformer 的隐藏空间中。这种方法允许浅层 Transformer（只有 1 或 2 层）模拟更深层 Transformer 的推理能力而不增加模型深度，提供了一种存储和计算效率高的解决方案，非常适合边缘设备部署，并完全保留了标准 ICL 输入输出结构。

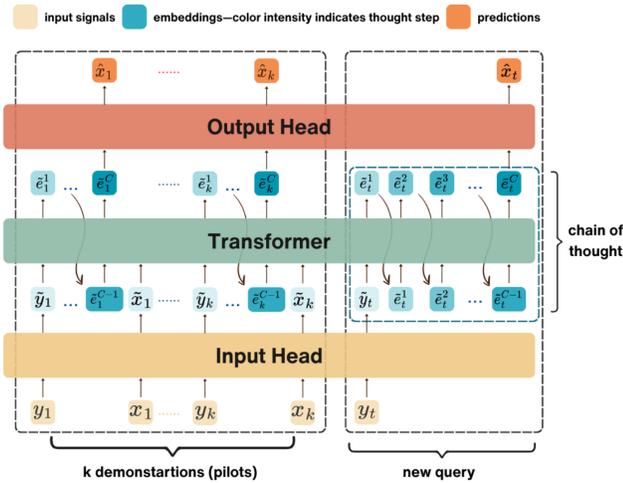


图 2. 架构为选择。输入头将试点演示和查询符号嵌入到潜在空间中。浅层 Transformer 主干通过因果遮罩处理序列。在查询位置， C 潜在思想嵌入 $\tilde{e}_t^1, \dots, \tilde{e}_t^C$ 通过隐藏空间内的自回归反馈生成。最终的思想 \tilde{e}_t^C 经过输出头传递以产生符号估计 \hat{x}_t 。

A. 模型架构

选择的整体结构保持标准的 ICL 框架，其中输入序列由先演示后跟查询符号组成。输入首先通过**输入标题**嵌入，然后由具有掩码自注意力的浅层因果 Transformer 进行处理，以尊重顺序排序。

关键创新在于查询位置。与传统的 ICL 直接从 Transformer 输出进行预测不同，选择引入了 C 个潜在思维步骤，在此期间逐步优化查询嵌入。在每个推理步骤 $j = 1, \dots, C$ 中，查询嵌入会关注整个输入序列——包括演示飞行员和查询本身——以及之前的思维嵌入：

$$\tilde{e}_t^j = \text{Transformer}(D_k, y_t, \tilde{e}_t^1, \dots, \tilde{e}_t^{j-1}), \quad (7)$$

其中 D_k 表示 k 个飞行员配对，而 y_t 是接收到的查询符号。经过 C 次潜隐推理后，仅将最终的思维 \tilde{e}_t^C 通过**输出头部**产生软符号估计： $\hat{x}_t = \text{OutputHead}(\tilde{e}_t^C)$ 。

值得注意的是，中间思想 $\tilde{e}_t^1, \dots, \tilde{e}_t^{C-1}$ 被保留为无监督，允许模型自由探索潜在的推理轨迹。监督仅应用于最终预测 \hat{x}_t ，鼓励有效多步推理的出现，而无需在中间步骤进行明确指导。

该设计的一个关键优势是其与广泛采用的无线系统 Transformer 模型完全架构兼容。潜在的 CoT 机制可以无缝集成到现有的 ICL 管道中，无需更改输入或输出结构，提供了一种简单而强大的方法来增强推理深度，同时保持适合边缘部署的轻量级足迹。

B. 训练方法论

1) 数据生成：训练数据是根据 Section II 中描述的模型合成生成的。为了增强鲁棒性，每个训练样本都通过从指定范围内均匀采样的信噪比进行模拟：在我们的实验中，对于 16QAM 为 25 – 35 dB，对于 64QAM 为 30 – 45 dB。这使模型在训练期间暴露于多样的信道条件。评估是在固定信噪比值下进行的，以确保跨方法的一致基准测试。

2) 潜在的 CoT 训练和损失设计：选择的训练目标遵循其自回归潜在推理机制，在每个查询位置 t ，模型生成 C 个潜在想法并从最终想法 \tilde{e}_t^C 输出符号估计 \hat{x}_t 。监督仅应用于每个查询的最终预测，而中间想法保持无监督状态。

给定完整的输入序列的 T 演示对，整体训练损失被定义为所有查询位置上的 MSE 损失之和：

$$\mathcal{L}_{\text{MSE}} = \sum_{t=1}^T \mathbb{E} [\|x_t - \hat{x}_t\|^2], \quad (8)$$

其中 \hat{x}_t 通过以下方式获得：

$$\hat{x}_t = \text{OutputHead}(\tilde{e}_t^C). \quad (9)$$

不对外部中间思维 $\tilde{e}_t^1, \dots, \tilde{e}_t^{C-1}$ 应用显式损失，允许模型在没有外部约束的情况下自由探索其潜在推理轨迹。此设计鼓励有效多步推理模式的出现，使浅层架构能够以最小的模型深度实现高检测精度。

C. 参数效率和模型紧凑性

选择 架构设计为高度参数高效，采用仅包含 1 或 2 层的浅 Transformer 主干网络，嵌入维度为 $d = 32$ ，并有 4 个注意力头。潜在思想的数量 C 设置在 1 到 4 之间，导致总参数数量约为 27,000。

相比之下，来自 [7] 的 Transformer 基线模型使用了 $L = 8$ 层， $d = 64$ 嵌入维度和 $h = 8$ 注意力头，产生了大约 0.42 百万个参数。尽管如此，**模型大小减少了十倍**接近，选择 实现了可比的检测性能，这将在 Section V 中显现，它通过利用潜在的 CoT 推理来增强浅层架构的表达能力。这种紧凑的模型足迹直接转化为更低存储需求和减少内存消耗，为无线通信系统中边缘设备部署提供了一种实用的解决方案，在这些系统中，硬件资源通常受到高度限制。

D. 通过 KV 缓存提高计算效率

另一个重要的特性是，尽管选择 每个查询引入了 C 个自回归潜在推理步骤，但由于使用了键值 (KV) 缓存 [17]——这是 GPT-2 等 Transformer 架构中的标准优化方法，相关的计算开销仍然很小。

潜藏的 CoT 推理循环在选择 中完全兼容因果掩码自注意力。在每个思维步骤 j 中，查询嵌入 \tilde{e}_t^j 会关注整个输入序列（包括试点演示和查询）及其先前的思维嵌入 $\tilde{e}_t^1, \dots, \tilde{e}_t^{j-1}$ 。至关重要的是，因为输入标记和较早的想法在整个推理过程中保持不变，它们的关键和值投影可以预先计算、存储并重复使用。在每个新步骤中，模型只需计算最新想法的投影并对缓存的关键和值执行注意力操作。这使得多步潜藏 CoT 过程能够与延长序列上的单次前向传递相当的效率运行。

结合浅层 Transformer 主干（1 或 2 层）和适度的链长度（ $C = 1$ 到 4），KV 缓存使选择 能够在推理过程中支持表达性的多步推理，同时保持较低的计算成本。这种潜在 CoT 推理与缓存之间的协同作用确保了选择 仍然适合部署在资源受限的无线边缘设备上。

V. 实验

A. 实验设置

我们在瑞利块衰落信道模型下评估了选择 在单输入单输出符号检测任务中的表现，该信道模型描述于 Section II 中。传输的符号均匀地从给定的调制星座（16QAM 或 64QAM）中抽取，每个相干块包含 $T = 11$ 个符号。模型训练遵循在 Section IV-B 中概述的合成数据生成程序。在评估过程中，我们测试了固定信噪比水平下的性能，同时变化导频符号的数量 k 和潜在推理步骤的数量 $C \in \{1, 2, 3, 4\}$ 对于选择 。性能通过均方误差 (MSE) 和符号误码率 (SER) 进行评估，定义见 Section III-A。连续符号预测 \hat{x}_t 使用最近邻映射投影到最近的星座点以计算 SER。所有结果都在每个配置下的 10,000 个独立生成的测试任务上取平均值，以确保统计可靠性。

B. 基线算法

我们将选择 与代表性基线进行了比较。为保持一致性，所有模型均使用 32 维的嵌入维度和 4 个注意力头。仅改变 Transformer 层数量以评估在普通 ICL 和选择 模型中深度的影响。

a) 原味 ICL: 该基线遵循在 Section III-B 中描述的标准 ICL 架构，其中 Transformer 直接将输入上下文（先导演示和查询）映射到符号估计值，而不进行潜在的 CoT 推理。为了研究模型容量的影响，我们评估了具有不同深度的 Vanilla ICL Transformers: 1 层、2 层 和 4 层。这些模型与选择 具有相同的输入输出结构，并作为公平比较的非-CoT 基线。

b) 最小均方误差估计器: 我们实现了最小均方误差 (MMSE) 估计器 [16] 作为参考基线，提供了 Rayleigh 块衰落模型下 MSE 的理论下界。此估计器假设已知信道分布 $h \sim \mathcal{CN}(0, 1)$ 和高斯白噪声 $z_t \sim \mathcal{CN}(0, \sigma^2)$ ，但不知晓瞬时信道实现。给定导频信号 $x_{1:k}$ 、接收序列 $y_{1:k}$ 和查询 y_{k+1} ，MMSE 估计对应于条件均

值估计器 (CME)。传输符号 $x_{k+1} = x$ 的后验概率与每个 $x \in \mathcal{X}$ 成正比, 比例关系为高斯似然:

$$\mathbb{P}(x_{k+1} = x | y_{1:k+1}, x_{1:k}) \propto \frac{1}{\sqrt{|\det(C(x))|}} \exp\left(-\frac{1}{2}y_{1:k+1}^H C^{-1}(x)y_{1:k+1}\right). \quad (10)$$

其中协方差矩阵 $C(x)$ 由下式给出:

$$C(x) = \frac{1}{2}X_{1:k+1}X_{1:k+1}^H + \sigma^2 I_{k+1}, \quad (11)$$

且 $X_{1:k+1}$ 包括了 k 导频符号和位置 $k+1$ 处的候选者 x 。最小均方误差估计是通过星座图的加权和获得的:

$$\hat{x}_{k+1}^{\text{MMSE}} = \sum_{x \in \mathcal{X}} x \cdot \mathbb{P}(x_{k+1} = x | y_{1:k+1}, x_{1:k}). \quad (12)$$

此预言机提供了在均方误差损失下的最优连续预测, 并作为评估基于学习的模型如选择的参考。

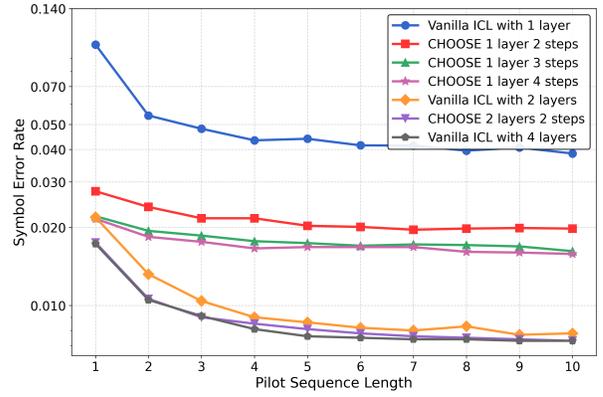
C. 结果与分析

1) 符号检测性能: Figures 3a and 3b 报告了在不同导频长度下, 选择在 16QAM (30 dB SNR) 和 64QAM (40 dB SNR) 的 SER。我们将浅层选择模型 (1 - 2 层) 与隐式推理步骤 $C = 2, 3, 4$ 相比较, 对比了使用 1、2 和 4 层 Transformer 的普通 ICL 基线模型。所有模型共享相同的 ICL 设置, 仅在架构深度和隐式 CoT 推理的使用上有所不同。

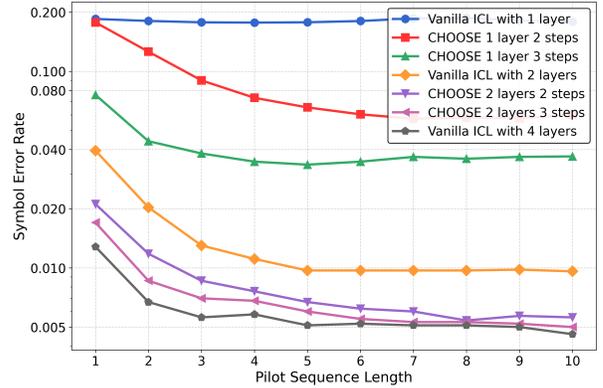
结果表明, 潜在推理显著提高了性能, 特别是在浅层模型中。在 16QAM (Figure 3a) 上, 一个具有 4 个推理步骤的单层选择模型比普通版本 SER 降低了超过 50%。此外, 一个两层选择模型通过两个步骤匹配了四层普通 Transformer 的表现, 这表明潜在推理有效增强了模型的表现力而无需增加深度。

在更具挑战性的 64QAM 任务 (Figure 3b) 中, 这种趋势持续并增强。一个包含 3 步的 2 层选择模型接近了 4 层基础模型的表现, 同时始终优于 2 层基线模型。这些发现证实了潜在的 CoT 推理能很好地扩展到更高阶的调制, 并使紧凑型模型保持高检测精度。

2) 思想精炼动力学: 为了深入了解选择如何在极浅的架构深度下实现强大的性能, 我们检查了其潜在推理过程的内部进展。具体来说, 我们在 30 dB SNR 下针对 16QAM 检测任务分析了一个具有 $C = 4$ 个潜在步骤的 1 层选择模型。此分析旨在可视化模型在推理过程中如何在其潜在思维序列中完善其预测。



(a) 16QAM 在 30 分贝信噪比下。



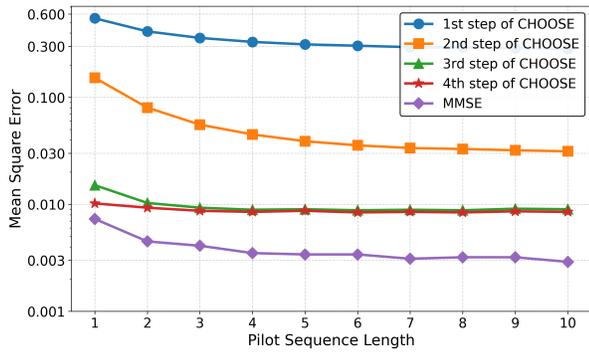
(b) 64QAM 在 40 dB 的信噪比下。

图 3. 符号错误率与导频序列长度的关系对于选择和普通 ICL 模型。选择模型在较少的层和推理步骤下表现出强大的性能。

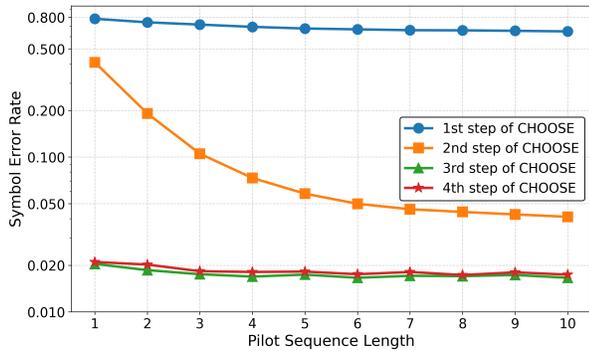
如 Section IV-B 所述, 监督仅应用于最终输出——中间思维没有直接的损失反馈。为了检查它们的行为, 我们在推理时通过将每个查询位置的中间嵌入 $\tilde{e}_t^1, \dots, \tilde{e}_t^4$ 传递到共享输出头来展开潜在的推理轨迹。然后使用 MSE 和 SER 指标评估每一步产生的软符号预测。

如 Figure 4 所示, MSE 和 SER 都随着 CoT 步骤稳步下降。第一个潜在想法提供了相对误差较高的粗略近似。后续步骤逐渐纠正早期的不准确之处, 其中最大改进发生在第一步和第二步之间。超过这一点后, 性能提升减少——表明单层主干的表示能力已经接近饱和。值得注意的是, 在 Figure 4a 中最终步骤的 MSE 接近 MMSE 预言机, 尽管由于架构限制仍存在较小的性能差距。

这一展开分析说明选择自主地学习将其潜在在空间组织成一个有效的多阶段优化过程。即使没有中间监督, 模型也能发现一条逐步提高预测准确性的推理轨



(a) 中间思想的均方误差与 MMSE 最优估计器。



(b) 中间思想的符号误差率。

图 4. 在 30 dB 信噪比下, 针对具有 $C = 4$ 的 1 层选择模型, 在不同 CoT 步骤中展开的性能, 使用 16QAM。每条曲线对应于在每个查询位置评估的不同潜在思想。尽管仅在最后一步进行监督, 但该模型显示出一致的内部完善。

迹——完全由最终步骤的损失反馈驱动。这些结果强调了隐式 CoT 在紧凑型 Transformer 模型中实现结构化内部计算的能力。

3) 参数和计算效率: 为了验证选择的轻量化特性, 我们将其参数数量和推理效率与各种配置下的普通 ICL 基线模型进行了比较。如图 5 所示, 普通 ICL 模型主要通过增加 Transformer 层数来提升性能——例如, 4 层的 ICL 模型超过 50,000 个参数。相比之下, 选择只使用 1 或 2 层 Transformer 和少量潜在推理步骤 ($C = 2, 3, 4$) 就能达到相当的检测精度, 从而拥有显著更少的参数。参数量随着较大的 C 在选择中的轻微增加来源于输入序列长度的扩展, 这是由于隐含思想嵌入的包含所致。这为位置编码和注意力投影增加了极小的开销, 并且仍然比增加模型深度要高效得多。

我们进一步通过测量在相同硬件条件下处理整个测试集所需的时间来评估计算效率。如图 5 所示, 与相同层数的普通 ICL 相比, 选择仅引入了适度的推理时间增加。这主要是由于自回归推理步骤所致。然而, 通过应用键值 (KV) 缓存技术 (如 Section IV-D

中所述), 我们有效消除了 CoT 风格自回归解码过程中的冗余计算。因此, 选择在计算和准确性之间实现了有利的权衡: 运行时间略有增加带来了显著的性能提升。

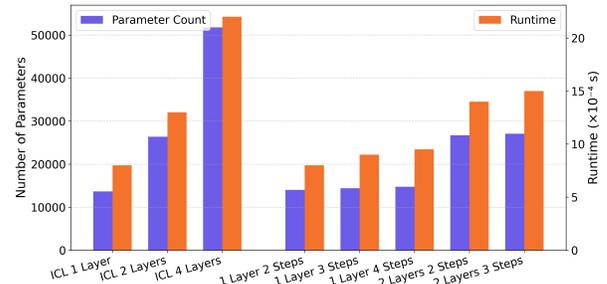


图 5. 不同模型配置下的参数数量和推理时间比较。

4) 综合分析: 总体而言, 我们的结果显示选择在参数显著少于更深的 vanilla ICL 模型的情况下实现了高检测准确性。通过引入少量自回归潜在推理步骤, 选择使得浅层 Transformer 能够进行有效的迭代推理, 在各个步骤中优化预测。尽管增加了推理步骤, 选择仍然保持了计算效率。借助键值缓存, 与深层 ICL 模型相比, 推理时间开销极小, 同时提供了更高的准确性。这些结果突出了选择在模型大小和运行时间上的效率, 使其非常适合部署在资源受限的无线系统中。

VI. 结论

我们引入了选择, 一种用于上下文无线符号检测的轻量级 Transformer 架构, 通过自回归潜在推理步骤增强了浅层模型。通过一系列内部思维嵌入来精炼预测, 选择在准确性及表达能力上取得了显著提升, 而无需增加模型深度。尽管其基础结构较浅, 选择在 SER 和 MSE 方面与更深的普通 ICL 基线相比表现相当, 同时保持了参数数量大幅减少且推理高效的特点——尤其是在结合键值缓存时更为突出。这些结果证明了将潜在思维链机制整合到紧凑型 Transformer 架构中对于无线接收器的有效性。选择提供了一种可扩展且资源高效的边缘部署解决方案, 并为物理层通信任务中的基于推理的推断铺平了道路。

参考文献

[1] T. Brown, B. Mann, N. Ryder, M. Subbiah, J. D. Kaplan, P. Dhariwal, A. Neelakantan, P. Shyam, G. Sastry, A. Askell *et al.*, “Language models are few-shot learners,” *Advances in neural information processing systems*, vol. 33, pp. 1877–1901, 2020.

- [2] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, "Attention is all you need," *Advances in neural information processing systems*, vol. 30, 2017.
- [3] S. Garg, D. Tsipras, P. S. Liang, and G. Valiant, "What can transformers learn in-context? a case study of simple function classes," *Advances in Neural Information Processing Systems*, vol. 35, 2022.
- [4] Y. Bai, F. Chen, H. Wang, C. Xiong, and S. Mei, "Transformers as statisticians: Provable in-context learning with in-context algorithm selection," *Advances in neural information processing systems*, vol. 36, pp. 57 125–57 211, 2023.
- [5] V. T. Kunde, V. Rajagopalan, C. S. K. Valmeekam, K. Narayanan, J.-F. Chamberland, D. Kalathil, and S. Shakkottai, "Transformers are provably optimal in-context estimators for wireless communications," in *Proceedings of the 28th International Conference on Artificial Intelligence and Statistics*, 2025.
- [6] M. Zecchin, K. Yu, and O. Simeone, "In-context learning for mimo equalization using transformer-based sequence models," in *IEEE International Conference on Communications Workshops*, 2024.
- [7] L. Fan, J. Yang, and C. Shen, "Transformer-based wireless symbol detection over fading channels," *arXiv preprint arXiv:2503.16594*, 2025.
- [8] J. Xu, L. Chen, K. Liu, and C. Shen, "Designing security-aware incentives for computation offloading via device-to-device communication," *IEEE Transactions on Wireless Communications*, vol. 17, no. 9, pp. 6053–6066, 2018.
- [9] J. Wei, X. Wang, D. Schuurmans, M. Bosma, F. Xia, E. Chi, Q. V. Le, D. Zhou *et al.*, "Chain-of-thought prompting elicits reasoning in large language models," *Advances in neural information processing systems*, vol. 35, pp. 24 824–24 837, 2022.
- [10] X. Wang, J. Wei, D. Schuurmans, Q. Le, E. Chi, S. Narang, A. Chowdhery, and D. Zhou, "Self-consistency improves chain of thought reasoning in language models," *arXiv preprint arXiv:2203.11171*, 2022.
- [11] Y. Deng, Y. Choi, and S. Shieber, "From explicit cot to implicit cot: Learning to internalize cot step by step," *arXiv preprint arXiv:2405.14838*, 2024.
- [12] S. Hao, S. Sukhbaatar, D. Su, X. Li, Z. Hu, J. Weston, and Y. Tian, "Training large language models to reason in a continuous latent space," *arXiv preprint arXiv:2412.06769*, 2024.
- [13] Z. Li, H. Liu, D. Zhou, and T. Ma, "Chain of thought empowers transformers to solve inherently serial problems," in *The Twelfth International Conference on Learning Representations*, 2024.
- [14] W. Merrill and A. Sabharwal, "The expressive power of transformers with chain of thought," in *The Twelfth International Conference on Learning Representations*, 2024.
- [15] J. Huang, Z. Wang, and J. D. Lee, "Transformers learn to implement multi-step gradient descent with chain of thought," in *The Thirteenth International Conference on Learning Representations*, 2025.
- [16] D. Tse and P. Viswanath, *Fundamentals of wireless communication*. Cambridge university press, 2005.
- [17] X. Jin, X. Li, H. Zhang, R. Soulé, J. Lee, N. Foster, C. Kim, and I. Stoica, "Netcache: Balancing key-value stores with fast in-network caching," in *Proceedings of the 26th symposium on operating systems principles*, 2017, pp. 121–136.