强化学习量化语义嵌入的不等差错保护

Moirangthem Tiken Singh[a]，Adnan Arif[a]

[a]迪布鲁加尔大学工程技术学院计算机科学与工程系，迪布鲁加尔大学，迪布鲁加尔，*786004*，阿萨姆邦，印度

arXiv:2601.00186v1 [cs.LG] 1 Jan 2026

摘要

本文探讨了带宽受限的通信系统中保持语义含义这一紧迫挑战。我们提出了一种新颖的强化学习框架，通过自适应重复编码实现逐维不等差错保护。我们的方法核心是一种复合语义失真度量，它在全局嵌入相似度与实体级保留之间取得平衡，使强化学习智能体能够以感知上下文的方式分配保护。实验表明，与均匀保护相比，该方法取得了统计学上显著的提升：在信噪比为 1 分贝时，chrF分数提高了 6.8%，实体保留效果提升了 9.3%。该框架的关键创新在于证明，简单且经过智能分配的重复编码能够实现细粒度语义保护——这是 LDPC 或里德-所罗门码等传统码无法达到的优势。我们的研究结果挑战了传统信道编码范式，指出码结构必须与语义粒度相匹配。这种方法尤其适用于边缘计算和物联网场景，在这些场景中带宽资源稀缺，但语义保真度至关重要，为下一代语义感知网络提供了一条切实可行的路径。

关键词： 语义通信；强化学习；不等差错保护；带宽高效通信；逐维保护；自适应重复编码

1. 引言

传统通信范式旨在确保比特级保真度，如今已越来越难以满足下一代智能系统的需求。从6G网络到大规模物联网部署，各类应用都会产生语义含义至关重要的信息，这要求我们从精确恢复比特转向在资源受限、存在噪声的信道上可靠传达意图。

基于香农分离定理的传统方法 [1], 以比特重构为优化目标，因此在需要保留含义时并非最优选择 [2]。语义通信通过直接编码和恢复语义内容来应对这一问题，从而提升鲁棒性和频谱效率 [3]。这一范式与超可靠低时延通信（URLLC）和大规模物联网尤为相关，相较于经典方法，它在理论和实践上都具有优势。

电子邮箱地址： tiken.m@dibru.ac.in（Moirangthem Tiken Singh），rs_adnanarif@dibru.ac.in（Adnan Arif）

深度联合信源信道编码（JSCC）已在图像和语音传输领域取得显著成功 [2]。对于文本，预训练语言模型会生成紧凑的高维嵌入，以捕捉句子级语义 [4, 5]。然而，如何高效传输这些嵌入仍然是一项挑战。不同维度的语义重要性差异显著，但当前方法通常采用均匀量化和保护。这种均匀处理效率低下，因为它未能优先保障更关键的维度，造成资源浪费，并降低了含义保留效果。

这凸显了现有文献中的两个关键空白。首先，当前系统缺乏自适应不等差错保护（UEP）机制，无法根据各维度的语义重要性动态调整保护。大多数方法采用均匀或启发式冗余分配，忽略了维度特定脆弱性 [6, 7]。因此，语义上至关重要的维度与不那么重要的维度一样容易受到信道噪声的影响。其次，尽管强化学习（RL）已应用于联合信源信道编码（JSCC）中的资源分配，但以往工作关注的是连续调制或粗粒度的

速率控制，而非基于直接语义反馈[8, 9]，针对各维度进行细粒度的离散保护决策。因此，现有框架均无法同时根据语义内容和信道条件，在维度层面动态分配保护。

为弥补这些不足，我们提出一种强化学习驱动框架，动态为各个量化嵌入维度分配离散的重复次数。我们采用简单的重复编码，并非因为它具有经典意义上的最优性，而是看重其结构特性：能够逐维进行细粒度调整——这一关键特性是在严格带宽约束下，里德-所罗门码和低密度奇偶校验码等分组码所不具备的。训练过程中采用梯度裁剪和熵正则化，并通过双时间尺度随机逼近分析提供形式化的收敛保证。

本工作的主要贡献如下：

- 一种强化学习框架，通过分配离散重复次数，实现自适应的逐维不等差错保护。
- 一种复合语义失真指标，兼顾全局嵌入相似度和实体级正确性。
- 实证表明，在中等（8位）量化下训练的策略能够有效泛化至更激进的（4位）量化，在带宽减半的同时保持高保真度。
- 代码结构必须与语义粒度相匹配，这一洞见表明：重复编码能够实现逐维自适应，而传统分组码无法做到这一点，甚至会阻碍这种自适应。
- 一种稳健的行动者-评论家算法，结合熵正则化并具备形式化收敛保证。
- 在不同信噪比区间、量化级别和信道模型下，对 AG News 数据集进行了全面评估。

本文其余部分安排如下：第2节回顾相关工作；第3节详述方法；第4节介绍实验结果；第5节讨论其影响；第6节总结全文。

2. 相关工作

本研究处于语义通信、表示压缩与自适应差错保护和强化学习的交叉领域。以下综述将介绍相关基础，并明确指出本框架旨在解决的研究空白。

通信范式已从严格保证比特级保真度，逐步转向保留语义。DeepSC 等奠基性模型采用 Transformer 实现端到端联合信源信道编码（联合信源信道编码），优化语义相似度指标，而非比特错误率 [10]。后续综述阐述了面向 6G 的智能驱动语义系统的发展历程，其中纳入了大语言模型和知识库 [11, 12, 13]。这些研究普遍存在一个局限：将语义嵌入视为不可分割的整体。这种整体式方法忽视了各潜在维度在重要性上的差异。在带宽约束严苛的情况下，承载关键信息的维度与承载较不重要信息的维度获得的保护并无差别，从而形成了根本性的性能瓶颈。

高效通信需要压缩高维语义嵌入。4位量化等技术已成功应用于检索系统中的向量嵌入，在几乎不损失准确率的情况下减少了内存占用 [14]。更复杂的学习式量化方法能够保留语义结构，但往往计算成本较高 [15, 16]。这表明亟需开发低复杂度量化方法，以便将其集成到通信流水线中。

差错保护策略历来采用不等错误保护（UEP），根据数据优先级分配冗余。典型应用包括视频流传输 [17]和联邦学习 [18]。然而，这些方案处理的是粗粒度数据块（例如图像帧和模型参数片段），并非针对语言嵌入中固有的细粒度、依赖上下文的重要性结构而设计。在实现与语义显著性相匹配的自适应逐维保护方面，仍存在显著差距。此外，此类保护与实用量化方法的协同优化也鲜有研究。

经典信道编码，如里德-所罗门码（RS） [19]和低密度奇偶校验码（LDPC） [20], ，旨在高效纠正数据块中的错误。尽管性能强大，但将其整合进动态的逐维不等差错保护框架并非易事。其固定的码块长度以及复杂的编码／解码算法，使得在精简、可训练的系统中，难以为数百乃至数千个嵌入维度分别分配独特且动态选定的码率

精简且可训练的系统。

在此背景下，尽管简单的重复编码在经典信息论中频谱效率低下，但对本研究问题而言，它具有独特的实用优势。它提供了一组离散的保护等级，由整数重复次数n定义。这种结构为负责逐维分配的强化学习智能体构建了一个易于处理的动作空间。其解码机制（例如多数投票）计算开销极低，并且可以在各维度间并行执行。因此，我们并不将重复编码视为最优信道编码，而是将其视为一种灵活且简约的基本方法，使我们能够隔离并研究如何学习最优的重要性加权保护映射这一问题。核心挑战由编码设计转向对简单资源的智能分配。

在高维离散动作空间中优化保护策略，难以通过解析方法求解。强化学习（RL）是一种成熟的方法，可用于在不确定性下进行动态决策。在通信领域，RL已用于资源块分配、 [21], 带宽自适应 [22], 和任务卸载 [23]。然而，这些应用通常涉及宏观尺度的资源（例如子载波和功率等级）。利用RL对语义嵌入保护进行细粒度的逐维管理，仍是一个有待探索的领域。

评估语义通信系统的性能，需要采用与意义保留相关的指标，而非符号准确率。相关研究包括用于机器翻译的实体感知评估 [24], 以及旨在量化偏差的指标[25]。然而，能够平衡全局语义相似度与任务特定保真度的广泛采用的综合语义失真指标仍在开发中。将此类指标整合为强化学习驱动的通信优化的奖励信号，仍是一项挑战。

现有文献在语义通信、量化、不等错误保护、强化学习和语义评估方面取得了显著进展，但彼此孤立。由此可见，当前缺少一个能够有机整合以下内容的统一框架：

1. 来自冻结模型的高带宽效率量化语义嵌入[1],2. 一种在单个嵌入维度层面运行的、经过学习的细粒度不等差错保护策略，通过重复编码等灵活的基本方法实现，3. 一种基于强化学习的优化器，根据语义内容和信道状态动态分配保护资源，4. 以复合语义失真度量作为优化目标提供指导。

DeepSC 等先前研究 [10], 未对维度级重要性建模，而先进的量化研究 [15] 则忽略了集成的信道适配。经典的不等错误保护和现代强化学习资源分配都缺乏所需的粒度。我们的贡献是提出并评估一个弥合这些差距的端到端流程，证明在约束条件下，动态学习的逐维保护对于语义保真度而言切实可行，且优于整体式或均匀保护方案。

3. 方法

本节介绍一种端到端语义通信系统，该系统旨在通过带宽受限的噪声信道传输离散消息$m \in \mathcal{M}$，同时将语义失真降至最低。所提出的框架集成了冻结的语义嵌入、逐维量化、变码率重复编码以及基于强化学习的分配策略。

如图 1 所示，该系统由四个顺序组件组成：

1. 冻结的语义嵌入器$E(\cdot)$，将离散消息映射为连续向量表示；2. 逐维标量量化器，将连续嵌入转换为离散符号；3. 变码率重复编码模块，在维度级别实现不等错误保护（UEP）；以及 4. 学习得到的分配策略 π_θ，根据语义重要性动态分配各维度的重复次数。

给定源消息$m \in \mathcal{M}$，预训练且冻结的句子编码器$E(\cdot)$会生成一个D维嵌入：

$$\mathbf{z} = E(m) \in \mathbb{R}^D, \tag{1}$$

其中，D 表示由所选编码器架构确定的嵌入维度。为促进稳定的量化，我们应用逐元素归一化：

$$s = \max_{i=1,\dots,D} |z_i| + \epsilon, \qquad \mathbf{u} = \mathbf{z}/s \in [-1, 1]^D, \tag{2}$$

[1]我们使用冻结的嵌入器，以隔离自适应保护层对性能的贡献。嵌入器的端到端训练与本研究互为补充，但不在本文的研究范围内。

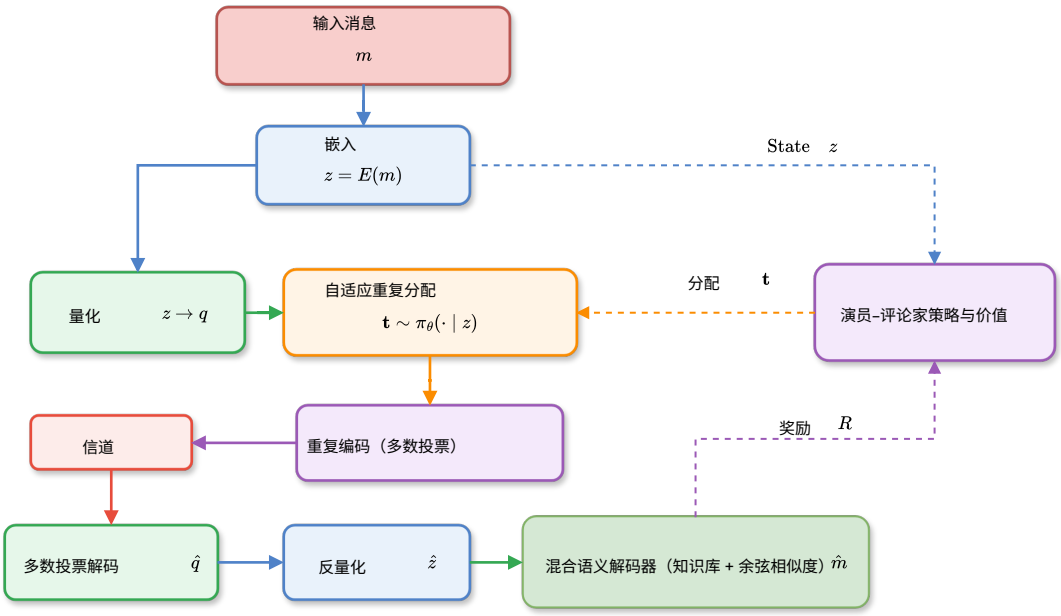

图 1：端到端语义通信流程。策略 π_θ 为量化后的嵌入分配各维度的重复次数 $\mathbf{t}$，并对其进行优化，以在固定的信道使用预算 B 下最小化语义失真 D_S。

其中，$\epsilon = 10^{-6}$ 以确保数值稳定性。每个归一化分量 u_i 都经过均匀b位有符号整数化：

$$q_i = \lfloor u_i \cdot q_{\max} \rceil, \qquad q_{\max} = 2^{b-1} - 1, \tag{3}$$

其中，$\lfloor \cdot \rceil$表示舍入到最近的整数，$q_i \in \{-q_{\max}, \ldots, q_{\max}\}$。接收端对应的反量化操作为：

$$\hat{z}_i = s \cdot \frac{q_i}{q_{\max}}. \tag{4}$$

为实现维度级不等差错保护，每个量化符号 q_i 都会在信道上传输 $n_i = 1 + t_i$ 次，其中 $t_i \in \mathbb{Z}_{\geq 0}$ 表示分配给维度i的额外重复次数。总传输量必须满足信道使用预算：

$$\sum_{i=1}^{D} (1 + t_i) \leq B. \tag{5}$$

这对应于总比特预算 $b \cdot B$。等价地，定义总额外重复预算

$$T \triangleq B - D \quad \left(\approx \lfloor D \cdot \text{ecc_rate} \rfloor \right), \tag{6}$$

使得 $\sum_{i=1}^{D} t_i \leq T$。在接收端，通过对$n_i$ 个接收副本进行多数投票来恢复每个符号，若出现平票，则均匀随机打破平局。多数投票得到纠错后的量化向量 $\hat{\mathbf{q}}$后，通过式 (4) 进行反量化，得到恢复的嵌入 $\hat{\mathbf{z}}$ 。

接收端通过计算 $\hat{\mathbf{z}}$ 与所有归一化知识库嵌入 $\{E(d_i)\}_{d_i \in \mathcal{D}}$ 之间的余弦相似度，执行封闭词汇表重建。选择嵌入为 $\mathbf{z}_k$ 且得分最高的条目作为候选重建 $\hat{m}$，其相似度分数为$s_{\text{rec}} = \cos(\hat{\mathbf{z}}, \mathbf{z}_k)$。采用双阈值决策规则 (τ_r, τ_g) 控制输出保真度和置信度：若$s_{\text{rec}} \geq \tau_r$，则原样返回知识库条目 $\hat{m}$；若$s_{\text{rec}} \leq \tau_g$，则输出固定的失败标记；否则返回 $\hat{m}$，但将其标记为不确定。这种封闭词汇表检索策略使语义成功具有可解释性，并能在嵌入恢复足够准确时实现精确重建。

由于最终目标是保留含义，而非原始比特，因此我们使用一种综合语义失真指标来量化端到端性能，该指标兼顾全局嵌入对齐和任务特定的事实准确性。对于原始消息m 及其重建结果 $\hat{m}$，我们定义

$$\begin{aligned} D_S(m, \hat{m}) = \alpha[1 - \cos(E(m), E(\hat{m}))] \\ + (1 - \alpha)\, L_{\text{entity}}(m, \hat{m}), \end{aligned} \tag{7}$$

其中，$\alpha \in [0, 1]$ 控制着以下两者之间的权衡：

嵌入级相似度与实体级正确性。实体损失为

$$L_{\text{entity}}(m,\hat{m}) = \frac{\sum_{e\in\mathcal{E}(m)} w(e)\,\mathbb{I}\{e \notin \mathcal{E}(\hat{m})\}}{\sum_{e\in\mathcal{E}(m)} w(e)}, \qquad (8)$$

其中，$\mathcal{E}(\cdot)$提取关键实体（例如名称、日期、数值），$w(e) \geq 0$ 表示这些实体的相对重要性。

我们采用D_S 作为主要的优化和评估指标：它既驱动策略学习，也为强化学习器提供所用的标量奖励。具体而言，对于任意分配$\mathbf{t}$，端到端传输和检索流程会产生$\hat{m}(\mathbf{t})$，而语义失真$D_S(m, \hat{m}(\mathbf{t}))$用于衡量效用。因此，在冗余预算约束下最小化$D_S$ 的期望值，可使学得的分配与意义保留这一系统级目标保持一致。

令T 为式（6）中定义的额外重复预算。分配问题旨在学习一个随机策略 $\pi_\theta(\mathbf{t} \mid \mathbf{z})$，该策略给定 $\mathbf{z} = E(m)$后，分配整数型额外重复次数$\mathbf{t} = (t_1, \ldots, t_D)^\top \in \mathbb{N}_0^D$，以便在冗余约束下最小化预期语义失真：

$$\begin{aligned} \min_{\pi_\theta} \quad & \mathbb{E}_{m\sim\mathcal{D}}\Big[\mathbb{E}_{\mathbf{t}\sim\pi_\theta(\cdot|\mathbf{z})}\big[D_S\big(m,\hat{m}(\mathbf{t})\big)\big]\Big] \\ \text{s.t.} \quad & \mathbb{E}_{m\sim\mathcal{D}}\Big[\mathbb{E}_{\mathbf{t}\sim\pi_\theta(\cdot|\mathbf{z})}\Big[\sum_{i=1}^{D} t_i\Big]\Big] \leq T. \end{aligned} \qquad (9)$$

我们通过带熵奖励的拉格朗日松弛来求解这一约束问题。引入非负惩罚项 λ_{reg} 和熵系数 $\beta \geq 0$，我们优化以下正则化目标：

$$\begin{aligned} \max_{\theta} \mathbb{E}_{m,\mathbf{t}\sim\pi_\theta}\Big[-D_S\big(m,\hat{m}(\mathbf{t})\big) - \lambda_{\text{reg}} \sum_{i=1}^{D} t_i\Big] \\ + \beta\,\mathbb{E}_m\big[H(\pi_\theta(\cdot \mid \mathbf{z}))\big], \end{aligned} \qquad (10)$$

其中，$H(\cdot)$ 表示香农熵。惩罚项用于确保预算在期望意义上得到满足；熵项则促进探索。

策略 π_θ 由一个轻量级多层感知机参数化，该感知机将归一化嵌入$\mathbf{z}$ 映射为类别概率向量$\mathbf{p} = \pi_\theta(\mathbf{z}) \in \Delta^{D-1}$。另一个评论器 $v_\phi(\mathbf{z})$ 用于估计状态价值，以降低梯度方差。我们使用针对离散分配空间调整的优势演员-评论家（A2C）算法优化式（10）。

由于可行分配集合具有组合性质，直接通过 argmax 式分配进行求导是难以实现的。因此，我们采用一种直通式、有偏的策略梯度方案，将确定性前向分配与用于反向传播的可微松弛采样相结合。具体而言，前向模拟采用确定性分配

$$\mathbf{t}^{\text{det}} = \lfloor \mathbf{p}\,T \rfloor, \qquad (11)$$

任何剩余量 $T - \|\mathbf{t}^{\text{det}}\|_1$ 均贪心地分配给小数部分 $\{p_i T\}$ 最大的维度。该$\mathbf{t}^{\text{det}}$用于端到端地产生轨迹奖励（量化、每个维度重复 $1 + t_i^{\text{det}}$次的重复编码、信道传输、多数投票解码、反量化、检索，以及对 D_S 的评估）。

为进行梯度计算，我们从可微代理中采样一个松弛的分配$\mathbf{t}^{\text{relax}}$，代理可以是多项分布$(T; \mathbf{p})$或 Gumbel–top-$k$ 松弛，并通过 $\log \pi_\theta(\mathbf{t}^{\text{relax}} \mid \mathbf{z})$计算策略梯度。这种直通式方法能提供低方差且实用的估计量：前向传播反映确定性部署行为，反向传播则允许梯度流动。

逐步标量奖励为

$$R = -D_S(m,\hat{m}) - \lambda_{\text{reg}} \sum_{i=1}^{D} t_i^{\text{det}}, \qquad (12)$$

优势为 $\hat{A} = R - v_\phi(\mathbf{z})$，演员/评论器参数根据标准A2C目标进行更新，并采用熵正则化（见算法1）。实际训练中，我们按批次对优势进行归一化、裁剪梯度，并加入熵奖励以稳定学习。

所有策略均在固定的 0 分贝加性高斯白噪声信道下训练，并采用确定性8位均匀量化；这种选择使策略在强噪声环境下接受考验，以增强其鲁棒性和跨量化迁移能力。在推理时，学习得到的策略以确定性方式使用：仅应用$\mathbf{t}^{\text{det}}$，因此不会产生采样方差，并符合规定的冗余预算。

定理1（演员—评论家策略的收敛性）。 假设：*(i)* 奖励均匀有界；*(ii)* 策略和价值近似器均为 *Lipschitz* 连续；*(iii)* 梯度估计器的二阶矩有界；*(iv)* 步长 $\{\alpha_k\}$（评论器）和 $\{\gamma_k\}$（演员）满足 *Robbins–Monro* 条件，其中 $\sum_k \alpha_k = \sum_k \gamma_k = \infty, \sum_k \alpha_k^2, \sum_k \gamma_k^2 < \infty$，且 $\gamma_k/\alpha_k \to 0$（演员处于较慢时间尺度）；*(v)* 策略参数化确保了充分探索。则由算法*1*生成的序列 $\{\theta_k\}$ 几乎必然收敛到式（10）中正则化拉格朗日函数的驻点集合，采样偏差除外；该偏差随 $T \to \infty$而消失。

算法1 用于逐维重复分配的优势演员-评论家

要求： 数据集 $\mathcal{D}$、嵌入器 E、信道预算 B、比特数 b、额外重复预算 T、学习率 γ（演员）和 α（评论器）、系数 λ_{reg}、β

初始化演员参数 θ、评论家参数 ϕ
对于 训练轮次 = 1至 Nepochs **执行**
  对于小批次 $\{m^j\}_{j=1}^{N} \subset \mathcal{D}$ **执行**
    对小批次中的每条消息 m**执行**
      $\mathbf{z} \leftarrow E(m)$
      p值 $\leftarrow \pi_\theta(\mathbf{z})$
      $\mathbf{t}^{\text{det}} \leftarrow \lfloor \mathbf{p}\, T \rfloor$ 并贪心地分配残差
      通过式 (3) 将$\mathbf{z}$ 量化为$\mathbf{q}$
      编码：将每个q_i $1 + t_i^{\text{det}}$重复若干次
      模拟信道传输；通过多数投票解码，得到 $\hat{}\mathbf{q}$
      根据公式 (4) 反量化得到 $\hat{}\mathbf{z}$，重建消息 $\hat{}m$
      计算奖励 $R \leftarrow -D_S(m, \hat{}m) - \lambda_{\text{reg}} \sum_i t_i^{\text{det}}$
      采样松弛分配 $\mathbf{t}^{\text{relax}} \sim$ 多项分布$(T;$ **p值**$)$
      计算优势 $\hat{A} \leftarrow R - v_\phi(\mathbf{z})$
      存储（$\mathbf{z}$，$\mathbf{t}^{\text{relax}}$，$\hat{}A$，$R$）
    循环结束
    对批次内的优势进行归一化；裁剪梯度
    行动者更新：$\theta \leftarrow \theta + \gamma\, \mathbb{E}[\hat{}A \nabla_\theta \log \pi_\theta(\mathbf{t}^{\text{relax}} | \mathbf{z}) + \beta \nabla_\theta H(\pi_\theta)]$
    评论器更新：$\phi \leftarrow \phi - \alpha\, \mathbb{E}[\nabla_\phi (R - v_\phi(\mathbf{z}))^2]$
  循环结束
结束循环
返回 π_θ

证明概要。评论器更新在较快时间尺度上进行，并跟踪当前演员对应的价值函数；在评论器收敛的条件下，演员对期望正则化目标函数执行随机梯度上升。多项分布（或 Gumbel）松弛会在梯度估计中引入量级为 $O(1/T)$ 的偏差；随着 T 增大，该偏差会消失。在上述有界性和鞅差条件下，双时间尺度随机逼近可保证几乎必然收敛至（有偏）目标函数的驻点；令 $T \to \infty$即可消除偏差。

□

对于包含N条消息的小批次，令C_E、C_π和C_v分别表示嵌入器、演员和评论器的前向传递成本（每项通常为 $O(D)$）。信道模拟和解码每条消息最多需要bB位运算。因此，每批次的复杂度为

$$O\big(N\,(C_E + C_\pi + C_v + bB)\big).$$

推理时只需通过E andπ_θ 进行一次前向传播，再进行解码，即可将每条消息的复杂度降至 $O(C_E + C_\pi + bB)$，适用于低延迟边缘部署。

4. 结果与分析

本节对所提出的框架进行了全面评估。我们首先介绍实验设置和用于获得学习所得分配策略的训练方案，然后介绍评估指标和统计方法。本节其余部分按照旨在帮助读者建立直观认识的顺序分析性能：（i）训练的收敛性和稳定性；（ii）目标平衡参数α的消融实验；（iii）跨量化机制的迁移能力；（iv）与替代分配策略及不同纠错码（ECC）选择的比较；（v）信道失配下的鲁棒性；（vi）与当代语义通信系统的基准比较。

4.1. 实验设置

我们在 AG News 子集（4,000 个训练句子）[26], 上进行评估，这遵循了基于文本的语义通信研究中的常见做法 [27]。该数据集包含来自四个领域（世界、体育、商业和科学/技术）的新闻文章，句子平均长度约为 12 个词元。句子嵌入使用冻结的

all-MiniLM-L6-v2 模型（384 维） [28], 提取，随后进行 l_2 归一化。我们采用这一标准化基准，以确保与先前研究进行公平比较。

策略仅在 0 dB 信噪比下的加性高斯白噪声（AWGN）信道上进行训练[2]。训练共进行三个训练轮次，每个训练轮次包含 128 个回合。演员-评论家网络包含两个隐藏层，每层 128 个单元，使用 Adam（$\eta = 5 \times 10^{-4}$）进行优化，并采用梯度裁剪（$\|\nabla\|_2 \le 1.0$）和熵正则化系数 $\beta = 0.01$。奖励由复合语义失真 D_S 与正则化项 λ_{reg} 共同构成，后者用于惩罚过度使用冗余。冗余预算固定为 ecc_码率 = 0.02，相当于在 384 维嵌入中额外重复约 7–8 次；该预算旨在反映严格的边缘带宽约束 [29]。训练期间，我们从策略的 Softmax 输出中进行多项式采样；评估期间，则切换为确定性分配（整除取下限，并采用贪心方式分配余数）。

默认量化采用 8位均匀量化；消融实验考察 4 位、12 位和 16 位变体（包括确定性和随机性变体）。主要的纠错原语是逐维重复编码。我们在一系列广泛的信道模型上评估泛化能力（瑞利衰落、莱斯衰落（$K = 1$）、中上野衰落（m，其中$m = 1$，这相当于瑞利衰落）、突发错误，以及交叉概率为$p \in [0.05, 0.10]$的二进制对称信道）。我们还将该方法与经典分组码（里德-所罗门码和低密度奇偶校验码）进行比较，以研究其与传统纠错码设计的相互作用。

结果取 400 条留出消息的平均值，95% 置信区间通过自助法（200 次重采样）获得。对于假设检验，我们使用 Wilcoxon符号秩检验 [30] 检验余弦相似度（$p_{\cos}$）和语义失真（p_{D_S}），报告 Cohen's d作为效应量，并在进行多重比较时采用 Bonferroni校正。

4.2. 评估指标

我们使用一套全面的评估指标来评估通信可靠性和语义保真度。主要指标是综合语义失真 D_S，它将嵌入层面的余弦相似度与实体保留项相结合；数值越低，表示语义准确性越高。为进一步量化表征保真度，我们采用余弦相似度，

该指标用于衡量原始嵌入与重建嵌入之间的几何对齐程度，取值范围为 0 到 1。

文本重建质量通过 chrF 分数 [31], 进行评估。chrF 是一种字符级n元语法F分数，以其在噪声下的鲁棒性以及与人工评估结果的高度相关性而著称。事实一致性则通过实体保留比例来衡量，该比例定义为传输后正确保留的关键实体（例如专有名词、日期、数值表达和地点）所占的比例。

从通信的角度来看，我们报告比特错误率（BER），这是衡量接收错误比特所占比例的标准指标。此外，整体自然语言生成质量通过成熟的自然语言生成指标进行评估，包括 BLEU-1 和 BLEU-4 [32], ROUGE-L [33], METEOR [34], 以及 BERTScore [35]。这些指标共同从多个维度刻画语义完整性、语言质量和传输鲁棒性。

所有报告的指标均为 400 次评估的平均值，并附有 95% 自助法置信区间。在进行假设检验时，我们采用置换检验并进行 Bonferroni校正。

4.3. 训练收敛与稳定性

在分析下游性能之前，我们先验证训练收敛情况以及对随机种子的鲁棒性。表1报告了10个随机种子在0 dB 信噪比下的收敛统计数据。学习得到的策略在第一个训练轮次就达到了均匀分配所带来改进的≥ 99.9%，且在第3轮次之后几乎没有变化（Δ语义失真 $_S \le 5 \times 10^{-4}$，相对变化为 < 0.06%）。跨随机种子方差很小（$\sigma_{D_S} \le 0.0010$），表明训练过程能产生稳定且可重复的策略。确认稳定性后，我们接下来考察目标平衡参数 α 对关键低信噪比区间性能的影响。

表 1：0 分贝信噪比下的训练收敛分析（10 个随机种子）。性能增益相对于第 3 轮训练的参考值报告。

训练轮次	均值D_S (0–3 分贝)	σ (随机种子)	增益（%）
1	0.9000	0.0005	99.9
2	0.9001	0.0010	99.9
3	0.9003	0.0006	100.0
5	0.9004	0.0008	100.0
10	0.8999	0.0009	99.9

[2]在信噪比为 0 分贝时进行训练，能为不等保护策略提供最强的学习信号，并展现出对更高信噪比条件的稳健泛化能力；反之则不然。

4.4. 消融实验：失真平衡（α）

表2和图2展示了在匹配的加性高斯白噪声条件下，采用重复编码和确定性8位量化（评估信噪比为0–3 dB）时，对$\alpha \in \{0.00、0.25、0.50、0.75、1.00\}$进行的系统性消融实验。平衡目标（$\alpha = 0.5$）在关键的1–2 dB 范围内始终优于仅考虑实体（$\alpha = 0$）和仅考虑嵌入（$\alpha = 1$）的目标：在1 dB时，其 chrF 和实体保留比例最高（相较于均匀分配，分别提升6.8%和9.3%）。值得注意的是，余弦相似度很早便趋于饱和（2 dB时中位数为$p_{\cos}$ =0.648，且结果不显著），但 chrF 、实体比例和语义失真 $_S$ 的提升仍高度显著。这表明，仅凭余弦相似度不足以作为低信噪比区间语义保留的目标。到3 dB时，所有配置均收敛；而在0 dB时，性能接近随机水平，因此我们在后续实验中将$\alpha = 0.5$设为目标平衡参数。

4.5. 跨量化方案的迁移能力

固定 $\alpha = 0.5$ 后，我们接下来评估仅使用 8 位量化训练的强化学习策略，在测试时能否泛化到不同的量化分辨率。这旨在考察学到的逐维重要性权重是否捕捉了内在语义结构，而非量化特有的伪影。表 3 和表 4 分别报告了确定性量化和随机量化下的语义失真 D_S；在这些实验中，同一个使用 8 位量化训练的策略分别在 4、8、12 和 16 位下进行评估（加性高斯白噪声、重复编码、2%纠错码开销、训练信噪比 $= 0$ 分贝）。

该策略表现出明显的非对称迁移：在 4 位下测试可显著降低 D_S （改善 30–48%），同时将带宽减半，且所有改善均具有统计显著性（$p < 0.001$）。相反，在 12/16 位下评估会增加失真（16 位、3 分贝时最高增加 +167%）。我们认为，这种非对称性源于该策略在信道噪声严重时只着重保护语义上最关键的维度。粗量化实际上会消除边缘可接受级别，并放大保护关键维度的收益；而精细量化会产生许多易受影响的级别，而该策略并未对其加以保护。确定性量化与随机量化结果之间的相似性进一步表明，该策略对量化噪声的类型具有鲁棒性。

这种非对称但可预测的可迁移性支持一种实用的部署范式：只需在中等分辨率（8位）下训练一次，便可在恶劣信道中以极低比特率部署，无需重新训练即可实现出色的性能并节省带宽。

4.6. 与替代分配策略的比较

接下来，我们在匹配的加性高斯白噪声条件下，采用重复编码，将学习得到的分配策略与几种基线方法进行了比较（表5）。基线方法包括随机分配、基于逐维方差的启发式重要性分配、将所有冗余集中于最关键维度的 No_不等错误保护策略，以及均匀分配。

学习得到的策略始终优于基线方法，尤其是在保护分配至关重要的 1–2 dB 范围内。例如，在 2 分贝时，强化学习策略的 chrF 比均匀分配高出 2.7%，而重要性启发式方法仅高出 1.5%。这表明，强化学习智能体能够捕捉复杂的、依赖上下文的重要性模式，超越简单的基于方差的启发式方法。

4.7. 与纠错编码的交互

接下来，我们研究了分配策略与不同纠错码选择之间的交互（表 6）。尽管学习得到的策略与逐维重复编码结合使用时能带来显著收益，但采用里德-所罗门码或低密度奇偶校验码等传统分组码时，这些优势便不复存在。这是因为分组码在符号块级别施加均匀保护，阻碍了智能体利用细粒度的逐维重要性。

这一结果阐明了一个方法论要点：学习得到的逐维不等差错保护能够有效补充简单的重复编码，但无法被强制实行均匀保护的块级纠错码有效利用。因此，选择重复作为纠错码原语，是实现学习所得分配带来的增益不可或缺的一环。

4.8. 信道失配下的鲁棒性

尽管策略仅在 0 分贝的加性高斯白噪声条件下进行训练，但表7显示，它们能够很好地泛化到多种信道模型。在许多失配场景中，相对于均匀分配的相对增益有所提高，尤其是在衰落信道（瑞利、莱斯和中上野衰落）中。观察到的最显著改进出现在采用里德–所罗门编码的中上野衰落信道中，此时该策略在 chrF 指标上实现了 338% 的相对提升。这些结果表明，所学习的重要性分布捕捉到了在很大程度上独立于特定信道统计特性的语义结构。

表2：在匹配的加性高斯白噪声信道下，采用重复编码和确定性8位量化时，对失真平衡参数 α 的消融实验（评估信噪比为0–3分贝）。平衡复合目标（$\alpha = 0.5$）在关键的1–2分贝区间内始终优于仅实体（$\alpha = 0$）和仅余弦相似度（$\alpha = 1$）目标。粗体表示每个信噪比下的最优RL配置。*表示在所有 λ_{reg} 个值下，相较于均匀基线的中位数置换检验$p < 0.05$。

评估信噪比	α	chrF（95%置信区间）	实体比例	中位数 p值$_{\cos}$ 与均匀分布相比	注释
0 dB	0.00	0.0774（0.0740–0.0808）	0.0026	1.000	
0 dB	0.25	0.0773（0.0738–0.0809）	0.0026	0.594	
0 dB	0.50	0.0751（0.0737–0.0765）	<0.0001	0.935	
0 dB	0.75	0.0773（0.0738–0.0808）	0.0026	0.346	
0 dB	1.00	0.0821（0.0752–0.0912）	0.0076	0.032	*
0 dB	均匀	0.0774（0.0740–0.0825）	0.0026	–	
1 dB	0.00	0.2923（0.2547–0.3418）	0.2374	0.498	
1 dB	0.25	0.2950（0.2566–0.3344）	0.2390	0.882	
1 dB	0.50	**0.3123（0.2710–0.3498）**	**0.2595**	0.032	*（最佳）
1 dB	0.75	0.3087（0.2691–0.3475）	0.2548	0.132	
1 dB	1.00	0.3055（0.2660–0.3442）	0.2502	0.245	
1 dB	均匀	0.2923（0.2547–0.3418）	0.2374	–	
2 dB	0.00	0.8672（0.8375–0.8958）	0.8684	0.474	
2 dB	0.25	0.8904（0.8604–0.9159）	0.8941	0.838	*
2 dB	0.50	**0.8904（0.8604–0.9159）**	**0.8941**	0.648	*（最佳）
2 dB	0.75	0.8889（0.8588–0.9144）	0.8920	0.133	
2 dB	1.00	0.8856（0.8555–0.9131）	0.8888	0.955	
2 dB	均匀	0.8672（0.8375–0.8958）	0.8684	–	
3 dB	全部 α	0.9845–0.9867	0.993–0.9996	>0.14	所有方法均收敛
3 dB	均匀	0.9867（0.9858–0.9875）	0.9996	–	

*在大多数运行中，α对应的 λ_{reg} 配置的置换检验中位数 p 值为 <0.05。

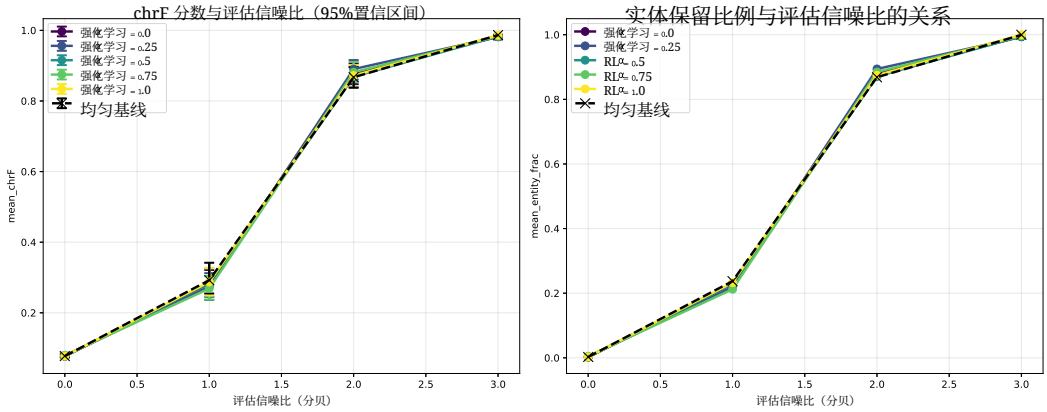

图2：在匹配的加性高斯白噪声条件下，不同 α 值的性能比较。在关键的 1–2 分贝信噪比区间内，平衡目标函数（$\alpha = 0.5$，青色）的性能始终优于仅实体（$\alpha = 0.0$，紫色）和仅嵌入（$\alpha = 1.0$，黄色）目标函数。

4.9. 与最先进方法进行基准比较

最后，表 8 将我们的方法与当代语义通信系统进行了基准比较。尽管相比更简单的组件（单信噪比训练和纯重复编码），我们的方法取得了显著

表 3：迁移能力条件（不重叠 （仅在 8位下训练的强化学习策略）在确定性量化下的迁移能力。粗体：最佳性能；*** $p < 0.001$，与 8位训练相比的 95 % CI + 威尔科克森检验）。

测试-time bits	Rate（比特/维度）	D_S (0 分贝)	D_S (1 分贝)	D_S (2 分贝)	D_S (3 分贝)
4	4.08	**0.430** ***(0.427–0.432)	**0.226** ***(0.223–0.229)	**0.153** *** (0.150–0.156)	**0.104** ***(0.101–0.107)
8#	8.16	0.821 (0.818–0.824)	0.642 (0.639–0.644)	0.266 (0.264–0.269)	0.149 (0.147–0.152)
12	12.24	0.880 ***(0.877–0.883)	0.828 *** (0.825–0.831)	0.642 *** (0.639–0.645)	0.222 *** (0.219–0.225)
16	16.32	0.917 *** (0.915–0.920)	0.873 *** (0.870–0.876)	0.806 ***(0.803–0.808)	0.397 *** (0.395–0.400)

#训练

表 4：随机量化下的可迁移性（与表 3 使用相同的强化学习策略）。

测试-time bits	Rate (比特/维度)	D_S (0 分贝)	D_S (1 分贝)	D_S (2 分贝)	D_S (3 分贝)
4	4.08	**0.434** ***(0.431–0.438)	**0.243** ***(0.240–0.247)	**0.155** *** (0.152–0.157)	**0.106** ***(0.103–0.109)
8#	8.16	0.825 (0.822–0.828)	0.661 (0.658–0.664)	0.280 (0.277–0.283)	0.153 (0.150–0.156)
12	12.24	0.881 ***(0.878–0.884)	0.828 *** (0.825–0.831)	0.647 *** (0.644–0.650)	0.221 ***(0.218–0.223)
16	16.32	0.919 *** (0.916–0.922)	0.874 ***(0.871–0.878)	0.807 ***(0.803–0.810)	0.410 ***(0.407–0.413)

#训练

表5：在匹配的加性高斯白噪声条件下采用重复编码时，与替代分配策略的比较。

SNR	方法	chrF（95%置信区间）	实体比例	显著性
0 dB	强化学习（最佳）	0.0821（0.075–0.091）	0.0076	*
	随机	0.0819（0.074–0.089）	0.0076	n.s.
	重要性	0.0805（0.073–0.088）	0.0060	n.s.
	无不等错误保护_	0.0797（0.072–0.087）	0.0051	n.s.
	均匀	0.0774（0.074–0.083）	0.0026	–
1 dB	强化学习（最佳）	**0.3123（0.271–0.350）**	**0.2595**	***
	随机	0.3026（0.262–0.343）	0.2494	**
	重要性	0.2804（0.241–0.320）	0.2253	*
	无不等错误保护_	0.2963（0.256–0.337）	0.2426	*
	均匀	0.2923（0.255–0.342）	0.2374	–
2 dB	强化学习（最佳）	**0.8904（0.860–0.916）**	**0.8941**	***
	随机	0.8846（0.855–0.913）	0.8872	**
	重要性	0.8801（0.850–0.909）	0.8832	*
	均匀	0.8672（0.837–0.896）	0.8684	–

显著性水平：*** p值 < 0.001，** p值 < 0.01，* p值 < 0.05，n.s. =不显著。

更高的语义保真度，尤其是在中低信噪比范围内。例如，我们报告的 BERTScore 在 3 分贝时达到 0.981，显著高于 Yang 等人报告的 0.52 BERTScore（其结果是在 4分贝时取得的），尽管他们采用了更强的纠错码和多信噪比训练。这凸显了所学习的逐维保护在语义方面的高效性 [36]

带宽受限条件下的语义保留。

总之，实验表明：(i) 在 0 分贝加性高斯白噪声训练下，强化学习智能体能够可靠地学习稳定的逐维分配策略；(ii) 平衡复合目标（$\alpha = 0.5$）对于在 1–2 分贝范围内保留语义至关重要；(iii) 学得的

表 6：匹配的加性高斯白噪声条件下，不同纠错码的性能比较。

ECC	SNR	强化学习 chrF（95%置信区间）	均匀 chrF（95% CI）	Δ_{chrF}	p 值
重复	1	0.3123（0.271–0.354）	0.2923（0.255–0.342）	+0.0200	< 0.001
重复	2	0.8904（0.860–0.916）	0.8672（0.837–0.896）	+0.0232	< 0.001
里德-所罗门码	1	0.2910（0.276–0.306）	0.2946（0.278–0.310）	-0.0036	0.42
里德-所罗门码	2	0.4776（0.463–0.491）	0.4787（0.463–0.491）	-0.0011	0.71
里德-所罗门码	3	0.6161（0.600–0.632）	0.6234（0.607–0.639）	-0.0073	0.18
LDPC	1–3	≈0.075	≈0.075	≈0	>0.9

表7：性能增 益。策略在信噪比为0分贝的加性高斯白噪声信道上训练，并在各种信道模 els.

信道	ECC	SNR	Δ_{chrF}	Δ_{entity}	相对增益（%）
瑞利	重复	1	+0.233	+0.255	159%
瑞利	RS	1	+0.217	+0.238	140%
莱斯	重复	0	+0.025	+0.028	31%
莱斯	RS	0	+0.637	+0.699	220%
中上野衰落	重复	1	+0.434	+0.477	233%
中上野衰落	RS	1	+0.487	+0.534	338%
突发	重复	0	+0.434	+0.476	79%
突发	RS	0	+0.648	+0.710	191%
BSC	重复	all	+0.274	+0.301	38%
BSC	RS	all	+0.304	+0.334	44%

表 8：与最先进的语义通信系统进行比较。

Work	训练信噪比	使用的纠错码	语义保 ric	主要特征
DeepJSCC [2]	0–20 分贝扫描	None	峰值信噪比/结构相似性指数	图像域，多需要信噪比训练
JSCC for 文本 [10]	0–10 dB 扫描	None	双语评估替补 ≈ 0.75 在 4 分贝	多信噪比训练，文本领域
语义通信 [36]	1–7 分贝多重	重复 +卷积-的	BERTScore ≈ 4 分贝时为 0.52	强纠错码，多信噪比训练
我们的方法	**单一 0 分贝**	**纯重复码**	**BERTScore 3 分贝时为 0.981**	**单信噪比 训练，简单纠错码**

策略能够有效迁移到更粗的量化（对于更精细的量化，则呈现可预测的非对称行为）；(iv) 将学得的分配策略与重复编码结合使用时，其表现显著优于简单启发式方法和随机基线，但与块级纠错码配合时则并非如此；(v) 尽管采用了更简单的训练方法和纠错码原语，该策略仍能稳健地泛化至各种信道失配情况，其表现也优于当前最先进的语义通信系统。

5. 讨论

第4节呈现的实验结果提供了广泛且一致的证据，表明学习得到的逐维不等差错保护（UEP）是在带宽和噪声约束严格的情况下实现语义通信的一种有效且实用的策略。接下来，我们将总结主要发现，结合第2节指出的研究空白展开讨论，即如何根据语义内容和信道条件动态分配保护资源，

并讨论我们的方法在实践中的意义，同时概述其主要局限性和未来研究方向。

通过实现细粒度逐维冗余分配，所提出的框架充分利用了嵌入维度之间异质的语义重要性。表5显示，学习得到的分配方案始终优于均匀分配和启发式基线（基于重要性的、No_UEP、随机），其中最显著的收益集中在1–2分贝信噪比范围内，在该范围内差异化保护的作用最为重要。这表明，逐维自适应能够捕捉到简单启发式方法所遗漏的语义结构。

其次，平衡复合失真目标D_S with $\alpha = 0.5$在实证上被验证为具有实际价值的优化目标。表2和图2中的消融实验结果表明，平衡目标函数在全局嵌入保真度与实体级正确性之间实现了更优的权衡，在统计上取得了显著增益（例如，在1分贝条件下，相较于均匀分配，chrF提高 ≈ 6.8%，实体保留提高 ≈ 9.3%）。这一发现对仅优化余弦相似度的常见做法提出了挑战，并突出了当目标是实现语义保真度时，明确纳入实体级目标的重要性。

第三，量化迁移实验（表3和表4）揭示了一种反直觉但在实际应用中颇具价值的特性：在中等分辨率（8位）下训练的策略能够有效迁移到更粗糙的分辨率（4位）部署，并且在某些情况下表现最佳。观察到的非对称迁移（向下迁移有益，向上迁移则性能下降）表明，学到的策略会优先保护一组数量有限但信息量极高的维度。更粗糙的量化实际上会去除重要性较低的细粒度级别，从而增强对这些关键维度进行保护的效果，由此实现实用的“一次训练，部署时使用更低比特率”模式，无需重新训练即可节省带宽。

第四，分配策略与纠错码原语之间的交互揭示了一项基本的架构原则：码结构必须与语义重要性的粒度相匹配 [37]。表 6 展示了三种情形。重复编码虽然从经典意义上看频谱效率较低，却能提供必要的逐维粒度，使强化学习智能体得以利用语义异质性，并带来显著增益。里德–所罗门编码以多比特符号为单位进行运算，会在各维度间平均分配保护，从而消除逐维自适应的优势。在本文考虑的极低开销预算下，低密度奇偶校验码远低于其瀑布阈值，无法提供有意义的语义保护。

综合来看，这些结果表明，对于超低冗余语义通信，能够保留逐维可操控性的简单编码原语，可能胜过那些会掩盖细粒度重要性信号的更强分组码。

第五，仅在0分贝加性高斯白噪声下训练的策略，对多种不匹配信道（瑞利、莱斯、中上野衰落、突发错误、BSC）均表现出稳健的泛化能力，而且其相对增益往往高于信道匹配的加性高斯白噪声场景（表7）。这种稳健性表明，学到的重要性分布捕捉的是嵌入的内在语义特性，而非对特定信道统计特性的过拟合。这一结果令人鼓舞，因为在现实部署中，具体的信道模型各不相同。

最后，与当代方法的基准比较（表 8）表明，合理分配适度的保护资源，并结合有原则的语义目标，可以优于依赖更强大纠错码机制或多信噪比训练的方法。在 3 分贝下，采用单信噪比训练和纯重复码获得 0.981 的 BERTScore，体现了所学习的不等错误保护在语义保留方面的高效性。

这些结果为语义通信系统的设计者提出了若干可操作的建议。

- 当语义保真度（而非原始比特保真度）是主要目标时，应优先选择支持逐维精细控制的保护原语。
- 优化目标应同时包含嵌入级相似度和实体级正确性；在低信噪比区间内，仅依靠余弦相似度是不够的。
- 采用务实的 中等信噪比训练、粗粒度部署策略，在无需重新训练的情况下降低运行码率，尤其适用于带宽约束严格的边缘部署。
- 评估纠错码选择时，不仅要考察其比特级性能，还要考察其符号化方式如何与计划利用的语义粒度相互作用。

尽管具有这些优势，仍应承认其存在若干局限。

1. **冻结的句子嵌入器：** 所有实验均使用固定的句子嵌入器。尽管这将分配策略单独隔离出来，但可能会限制领域适配的效果。联合微调嵌入器

与分配策略，或可进一步提升针对特定领域词汇的语义鲁棒性。

2. **模态：** 本研究仅关注文本嵌入。将该框架扩展到多模态场景（语音、图像和视频）需要针对特定领域的语义线索，调整失真目标和保护原语。

3. **信道知识假设：** 我们假设训练期间信道统计特性是完美已知或名义上已知的。放宽这一假设，并开发能够适应不完美信道状态信息或机会式反馈的分配策略，是实现实际无线部署的重要后续工作。

4.**纠错码设计空间：** 尽管重复编码在此处证明了其有效性，但它并不是唯一能够保留逐维自适应能力的原语。未来研究应探索混合码和结构化码，在保留维度级可操控性的同时提高频谱效率。

5. **数据集多样性与任务特异性：** 研究结果基于 AG News 子集获得；有必要在更多样化的数据集和下游任务（例如问答、摘要生成、面向任务的对话）上进行更广泛的验证，以量化其普适性。

6. 结论

本研究提出了一种强化学习框架，旨在通信系统面临严重带宽限制时保留语义含义。该方法结合了三个组成部分：细粒度的逐维不等错误保护。该复合语义失真度量在全局相似性与实体保留之间实现平衡，并通过基于强化学习的方式分配轻量级重复编码资源。

实验评估表明，所提出的方法相较于均匀分配策略和启发式分配策略取得了可测量的提升。采用 $\alpha = 0.5$ 的复合失真目标带来了稳定的性能增益：在信噪比为 1 分贝时，chrF 相对提升 6.8%，实体保留能力提升 9.3%。在关键的 1–2 分贝范围内，学习得到的分配策略优于基线方法，表明逐维自适应具有重要价值。

本研究的另一项重要发现涉及编码结构与语义粒度之间的关系。尽管重复编码能够实现有效的逐维自适应，但在低冗余约束下，LDPC 和里德-所罗门码等传统分组码无法取得同等程度的改进。这表明，选择码结构时必须考虑语义目标，而不能仅依据传统的比特级考量。

结果还表明，尽管仅在加性高斯白噪声信道上训练，学习得到的策略仍能很好地泛化到多种信道条件，包括衰落信道和突发差错信道。结合训练的快速收敛，这说明该框架可能适用于带宽受限的边缘场景部署。

未来工作可以包括嵌入器与保护策略的联合优化，以及将方法扩展到多模态语义通信，并探索处理不完美信道状态信息的策略。这些方向为进一步将语义目标融入通信系统设计提供了机遇。

数据可用性声明

本研究仅使用公开可用的资源。AG News 数据集可通过 https://huggingface.co/datasets/ag_news 获取。冻结的句子嵌入模型 all-MiniLM-L6-v2 可通过
h
t
t
ps://huggingface.co/sentence-transformers/all-MiniLM-L6-v2 获取。合理请求时，可向通讯作者索取代码。

写作过程中使用生成式 *AI* 和 *AI* 辅助技术的声明

在准备本研究期间，作者使用 Paperpal（一款 AI 驱动的学术写作助手）进行语言润色、语法检查、改写建议和稿件格式调整。作者审阅并编辑了所有内容，对出版物的完整性和准确性承担全部责任，并确认未使用生成式 AI 创作原创研究内容、图表或代码。

致谢

作者没有需要特别感谢的个人、机构或资助机构。本研究独立开展，未获得外部资金支持，也未直接得到他人的贡献。

参考文献

[1] C. E. Shannon, 《通信的数学理论》, 《贝尔系统技术期刊》27（1948）379–423。网址：https://ieeexplore. ieee.org/document/6773024。

[2] E. Bourtsoulatze、D. B. Kurka、D. Gündüz, 《用于无线图像传输的深度联合信源信道编码》, IEEE《认知通信与网络汇刊》5（2019年）567–579。网址：https://ieeexplore.ieee.org/document/8719300。

[3]J. Xu、T.-Y. Tung、B. Ai、W. Chen、Y. Sun、D. Gündüz, 《用于语义通信的深度联合信源信道编码》, IEEE《通信杂志》61（2022年）42–48。网址：https://ieeexplore.ieee.org/document/10014078。

[4] N. Reimers、I. Gurevych, 《Sentence-BERT：利用孪生 BERT 网络生成句子嵌入》, 载于：2019年自然语言处理经验方法会议暨第9届自然语言处理国际联合会议（EMNLP-IJCNLP）论文集，2019年，第3982–3992页。网址：https://arxiv.org/abs/1908.10084。

[5] F. Jiang、L. Dong、Y. Peng、K. Wang、K. Yang、C. Pan、X. You, 《大语言模型赋能的多模态语义通信》, 2024。网址：https://arxiv.org/abs/2309.01249。arXiv：2309.01249。

[6]H.-f. Chou, 《一种最优不等差错保护的低密度奇偶校验码编码记录系统》, 2023。网址：https://arxiv.org/abs/2310.04923。arXiv：2310.04923，arXiv：2310.04923。

[7] B. Masnick、J. K. Wolf, 《关于线性不等差错保护码》, 《IEEE 信息论汇刊》13（1967）600–607。doi：10.1109/TIT.1967.1054054。

[8]Z. Lu、R. Li、Z. Zhao、H. Zhang, 《基于强化学习的语义广播通信异构多任务优化》, 2025。网址：https://arxiv.org/abs/2504.19806。arXiv：2504.19806。

[9] Y. Zhang, B. Cheng, J. Chen, 《语义物联网服务通信——服务目标与事件路由之间的阻抗匹配》, 《国际分布式传感器网络期刊》(2024)。doi:10.1155/2024/2776723.

[10] H. Xie, Z. Qin, G. Y. Li, B.-H. Juang, 深度学习赋能的语义通信系统，IEEE 信号处理汇刊 69 (2021) 2663–2675。[11] S. Guo, Y. Wang, N. Zhang, Z. Su, T. H. Luan, Z. Tian, X. Shen, 语义通信网络综述：架构、安全与隐私，IEEE Communications Surveys & Tutorials (2024)。[12] G. Xin, P. Fan, K. B. Letaief, 语义通信：理论发展的综述，Entropy 26 (2024) 102。

[13] P. Zhang、Y. Liu、Y. Song、J. Zhang, 《语义通信的进展与挑战：系统性综述》, National Science Open 3（2024）20230029。

[14] T. Jeong, 《检索增强生成中向量嵌入的4位量化》, 载于：2024年国际机器学习与应用会议（ICMLA），IEEE，2024年，第1037–1042页。

[15] Z. Gao、C. Tan、J. Wang、Y. Huang、L. Wu、S. Z. Li, 《Foldtoken：通过向量量化及其他方法学习蛋白质语言》, 2025年。

[16] S. Liao、J. Chen、Y. Wang、Q. Qiu、B. Yuan, 《采用各向同性迭代量化的嵌入压缩》, 《AAAI人工智能会议论文集》34（2020）4795–4802。

[17]S. Kim、Y. Oh、Y. Kim、N. Lee、Y.-S. Jeon, 《数字语义通信中的不等差错保护信道编码》, arXiv预印本 arXiv:2508.03381（2025年）。

[18] S. Zheng、X. Chen, 《面向联邦学习的不等差错保护传输》, IET Communications 16（2022年）1106–1118。

[19]I. S. Reed、X. Chen, 《里德–所罗门码》, 载于：Error-Control Coding for Data Networks, Springer，1999年，第233–284页。

[20] R. Gallager, 《低密度奇偶校验码》, IRE Transactions on Information Theory 8（1962年）21–28。doi:10.1109/TIT.1962.1057683。

[21] B. Hu, J. Ma, Z. Sun, J. Liu, R. Li, L. Wang, 《基于深度强化学习的智能反射面物理层语义通信资源分配》, Physical Communication 63 (2024) 102270。

[22] C. Huang, X. Chen, G. Chen, P. Xiao, G. Y. Li, W. Huang, 《面向空天地一体化网络中混合比特与生成式语义通信的深度强化学习资源分配》, IEEE通信领域精选期刊（2025）。[23] P. Dai, K. Hu, X. Wu, H. Xing, Z. Yu, 《面向MEC赋能车联网中数据驱动任务卸载的异步深度强化学习》, 载于：IEEE INFOCOM 2021-IEEE计算机通信会议，IEEE，2021年，第1–10页。[24] S. Conia, M. Li, R. Navigli, S. Potdar, X. Huang, J. Andreas，SemEval-2025任务2：实体感知机器翻译，2025年。[25]F. Aghaebe, Y. Sefidgar, S. Agarwal, H. Bull, R. Song, D. McDuff, L. A. Celi, 《大语言模型看不出年龄：评估自动系统综述综合中的人口统计偏差》，arXiv预印本（2025）。URL：https://arxiv.org/abs/2511.06000。arXiv:2511.06000，arXiv:2511.06000。[26] X. Zhang, J. Zhao, Y. LeCun, 《用于文本分类的字符级卷积网络》，载于：第29届神经信息处理系统国际会议论文集——第1卷，NIPS'15，麻省理工学院出版社，美国马萨诸塞州剑桥，2015年，第649–657页。[27]S. Salehi, M. Erol-Kantarci, D. Niyato, 《大语言模型赋能的端到端语义通信数据传输》，2025年。URL：https://arxiv. org/abs/2504.07431。arXiv:2504.07431。[28]N. Reimers, I. Gurevych，all-MiniLM-L6-v2，https://huggingface.co/sentence-transformers/ all-MiniLM-L6-v2，2021年。Sentence-Transformers模型。[29] S. Yuan, J. Li, H. Chen, Z. Han, C. Wu, Y. Zhang, JIRA：面向基于边缘的实时视频流系统的联合激励设计与资源分配，IEEE无线通信汇刊 22（2023）2901–2916。doi:10.1109/TWC.2022. 3215140。[30] F. Wilcoxon, 《基于秩方法的个体比较》，《生物统计学通报》1（1945）80–83。[31] M. Popovi´c，chrF：用于自动机器翻译评估的字符n元语法F分数，载于：论文集

第十届统计机器翻译研讨会（WMT），2015年，第392–395页。网址：https: // aclanthology.org/W15-3049.[32] K. Papineni、S. Roukos、T. Ward、W.-J. Zhu, 《BLEU：一种机器翻译自动评估方法》，载于：计算语言学协会第40届年会（ACL）论文集，2002年，第311–318页。网址：https://aclanthology.org/P02-1040.[33]C.-Y. Lin, 《ROUGE：一种摘要自动评估工具包》，载于：《文本摘要的新方向：ACL-04研讨会论文集》，2004年，第74–81页。网址：https: // aclanthology.org/W04-1013.[34] S. Banerjee、A. Lavie, 《METEOR：一种与人工判断相关性更高的机器翻译评估自动指标》，载于：ACL机器翻译和/或摘要生成内在与外在评估指标研讨会论文集，2005年，第65–72页。网址：https: // aclanthology.org/W05-0909.[35] T. Zhang、V. Kishore、F. Wu、K. Q. Weinberger、Y. Artzi, 《BERTScore：使用BERT评估文本生成》，arXiv预印本 arXiv:1904.09675（2019年）。[36] W. Yang、H. Du、Z. Q. Liew、W. Y. B. Lim、Z. Xiong、D. Niyato、X. Chi、X. S. Shen、C. Miao, 《面向未来互联网的语义通信：基础、应用与挑战》，IEEE Communications Surveys & Tutorials 25（2022年）213–250。网址：https:// ieeexplore.ieee.org/document/10014078.[37] S. L. Howard、C. Schlegel、K. Iniewski 等, 《低功耗无线传感器网络中的纠错编码：ECC何时具备能效？》，《无线通信与网络期刊》2006年（2006年）74812。网址：https://doi.org/10.1155/WCN/2006/74812。doi:10.1155/WCN/ 2006/74812。