

元学习方法在机器翻译中的研究进展

希润高娃

内蒙古师范大学, 内蒙古 呼和浩特 010022

DOI: 10.61369/RTED.2026050012

摘 要： 元学习通过“学习如何学习”的范式，使模型能够从多任务训练中获得快速适应新任务的能力，为机器翻译在低资源语言、跨领域迁移和多语言零样本等数据稀缺场景下的性能提升提供了新的理论框架与实践路径。本文系统梳理了元学习方法在神经机器翻译领域的研究进展，首先介绍元学习的基本概念与核心范式，继而聚焦于模型无关元学习、元参数分离、课程元学习和联邦元学习等关键技术的创新与应用，进而从低资源机器翻译、无监督领域自适应、零样本跨语言迁移和多语言联邦学习四个维度分析元学习方法的具体成效，最后讨论当前面临的任务设计、数据隐私与泛化理论等挑战，并对元学习与大语言模型深度融合的未来方向进行展望。

关 键 词： 元学习方法；机器翻译；低资源翻译；研究进展

Research Progress of Meta-Learning Methods in Machine Translation

Xi Rungaowa

Inner Mongolia Normal University, Hohhot, Inner Mongolia 010022

Abstract： With the paradigm of "learning to learn", meta-learning enables models to rapidly adapt to new tasks through multi-task training. It provides a novel theoretical framework and practical path for improving the performance of machine translation in data-scarce scenarios, such as low-resource languages, cross-domain transfer and multilingual zero-shot translation. This paper systematically reviews the research progress of meta-learning in the field of neural machine translation. It first introduces the basic concepts and core paradigms of meta-learning, and focuses on the innovation and application of key technologies including model-agnostic meta-learning, meta-parameter separation, curriculum meta-learning and federated meta-learning. Furthermore, it analyzes the specific effects of meta-learning methods from four dimensions: low-resource machine translation, unsupervised domain adaptation, zero-shot cross-lingual transfer and multilingual federated learning. Finally, it discusses current challenges in task design, data privacy and generalization theory, and prospects the future development direction of the in-depth integration between meta-learning and large language models.

Keywords： meta-learning methods; machine translation; low-resource translation; research progress

引言

神经机器翻译（Neural Machine Translation, NMT）自 Transformer 架构问世以来，在高资源语言对上取得了接近人工水准的翻译质量，重塑了全球跨语言交流模式。然而，这一成就的背后是庞大的平行语料支撑——模型需要海量的标注数据才能习得稳定的映射关系^[1]。全球现存超过7000种语言，其中仅一小部分属于高资源语言，绝大多数语言缺乏足够的数字化语料用于训练，这构成了机器翻译走向普遍可及性的根本障碍。不仅如此，即便是高资源语言之间的翻译任务，当面对特定专业领域时，模型性能同样因数据匮乏而大幅下滑。领域差异导致语义漂移、术语误译和风格失调等问题成为 NMT 实际部署中的常见瓶颈。元学习（Meta-Learning）从根本上改变了这一问题的求解思路，其将目标提升为让模型学会如何快速适应新任务^[2]。这一范式与人类语言学习具有深刻的相似性，将元学习引入机器翻译，意味着模型不再是针对某个语言或某个领域的专用工具，而是获得了在不同语言和领域间灵活迁移的通用能力。

一、元学习的基本概念与核心范式

（一）元学习的定义与核心理念

“元学习”的字面意思即“学会如何学习”，即一种基于积

累不同任务的学习经验来提升模型对新任务的适应性的机器学习方法。相比传统机器学习只针对单一任务找到最佳参数配置的方法而言，元学习是面向整个任务分布空间的优化过程，为了快速将少量样本泛化至新任务上。这样的想法可以在机器翻译中应

用，比如面对新的语言或者新的领域时，我们不需要收集大量的平行文本，而只需依靠以前翻译任务所获得的语言知识——如句法信息、词项映射及语义对齐策略等等。元学习的本质就是将学习过程本身作为一个变量来对待，即除了会翻译之外，还能够进行不同翻译任务之间的切换^[3]。

（二）元学习的三大核心范式

我们将元学习方法分为三大类：以最小化目标为主的元学习算法；基于无模型元学习的方法；以及基于模型元学习的方法。其中以最小化为目标的元学习代表是无模型元学习，它的思想是在面对任务转换时可以迅速收敛到最优解的一系列最稳定初始化参数点。第二种是基于度量的元学习方法，这类算法采用一个通用的距离度量方程进行新样本的归类和变换，典型的有原型网络和匹配网络；第三种是基于模型的方法，该方法将记忆模块和神经网络相结合，让模型能在推断过程中灵活保存并且提取过去的任务背景资料^[4]。这三者在机器翻译领域中各自有所偏好：由于MAML（Model-Agnostic Meta-Learning，模型无关元学习）类的技巧与其主流NMT优化体系相吻合，所以它的适用范围是最广泛的；然而，度量学习和基于模型的技术更常用于跨语言搜索和处理低资源环境下的情况。

二、元学习在机器翻译中的关键技术方法

（一）基于优化的元学习方法与MAML在NMT中的应用

目前，基于模型无关元学习的框架是主流方法，因为其能够很好地嵌入任意可微NMT模型中。该元学习过程包含两个循环去获得元知识：内部循环，在单个任务上进行少量梯度下降更新从而获得一个单独的参数；外部循环，优化元初始化的参数，这样就可以很好地降低内层循环的难度，在NMT中已经证明MAML能够大幅提升模型对新的语言以及对未知场景下的泛化性能，为更好地提升这一性能，采取的策略是将T5模型引入到MAML并构建了跨语种翻译任务^[5]。这个策略可以在有限的数据集上迅速适应。MAML的主要发现是：一个优秀的初始化条件自身就包含了跨语言翻译所需要的通用的知识，只需稍作调整就能从一种语言或领域转移至另一种。

（二）元参数分离与MetaMT方法

为了克服多元翻译中由于数据不平衡及参数的影响而产生的弊端，MetaMT提出将模型参数划分为两部分：“任务参数”和“元参数”。任务参数用来专门负责具体的翻译模型，建模单语种源语言至目标语言的专属语义映射，适配细分翻译任务；元参数负责全局特征空间变换，赋予模型跨领域、跨语种泛化能力。训练阶段，MetaMT交替更新任务参数与元参数，模拟跨领域自适应过程，最终得到兼顾全局通用语义、可快速微调适配全新领域的翻译模型。

（三）课程元学习与零样本跨语言迁移

元学习在应用上涉及元学习框架和元学习策略两方面，用于处理严重的语言不平衡造成的零样本迁移困难。其中关键的是设计生成式任务，使用交叉验证评估并微调元梯度对元学习率敏感

程度实现平衡高资源和低资源的语言间不平衡差值的目标。其次，在此基础上Meta-XNLG进一步引入了语言分类方法，将根据语言属性的语言分类工作结合到元学习过程中来：首先利用语言属性信息对所有语言划分成不同的类别，并从中选出典型语言，然后以该类别的典型语言为背景训练元学习器，最后在零样本条件下评估剩余语言^[6]。

（四）联邦元学习与多语言翻译

考虑到联邦学习保护个人信息的优点以及元学习灵活性的特点，联邦元学习为我们提供了从一个新的角度去研究多语言NMT的可能性，在这个框架下每个参与者分别在自己所拥有的数据集中进行翻译模型的学习，并将这些模型信息汇总到中心服务器上，得到全局元模型。该元模型包含所有源语言的重要语义结构表达。随后使用Reptile和光滑优化器Optuna对该全局元模型进行微调以适应目标语言，而它未必是源语言之一，对于那些缺乏大量平行文本的数据非常有利。这种方法已经在基隆迪语（Kirundi）等少数语言的低资源翻译任务中得到证实：无论是由联邦学习生成的微型模型（4.8M个参数）还是NLLB-600M模型都能在圣经语料库和FLORES-200标准测试中取得优异成绩。联邦元学习的意义不仅在于技术模型的组合，在于其可以作为一种在数据主权和知识共享之间取得平衡的方法：即多语言翻译系统可以在不需要集中地保存敏感信息的前提下完成跨语言协作式学习。

三、元学习在机器翻译中的应用成效

（一）低资源语言机器翻译

利用元学习缓解低资源语种翻译数据稀缺问题，是具备落地价值的主流研究方向。针对这一挑战，学界提出多款快速自适应元学习NMT策略，结合回译半监督技术进一步扩充低资源语种训练数据，有效提升小语种翻译质量。大量监督实验表明，元学习方案可稳定提升低资源任务BLEU指标，这也验证了元学习在低资源场景下的适配优势^[7]。类似的MetaMT也是为了提升低资源场景下的翻译性能并使用多领域数据来模拟翻译器对新领域的适应性，从而实现基于少量数据同时更新模型参数以及元参数的目标。实验结果表明该方法可以有效改善各领域的低资源机器翻译性能。元学习能够取得低资源翻译中这样好的效果是因为其独特的思想即不完全依靠大数据来建立高维映射的能力，但依靠元知识将对数据的要求缩小到模型能够快速推理的程度。

（二）无监督神经机器翻译的领域自适应

虽然UNMT利用不平行的一对一的数据进行训练，在一定程度上降低了对平行数据的需求；但是由于其性能仍然受制于一对一数据的数据量少。因此有研究者提出一种针对低资源领域的无监督NMT的元学习方法。他们认为，关键在于理解如何运用来自丰富资源区域所学到的知识去处理那些匮乏的数据区域，并以此作为基础构建出一种元学习方案。这种方式相较于传统的转移学习技术能够提高至少两个BLEU评分，同时也在迅速适应和保持一致性的能力上超越了其他的基准模型。另一项工作从meta-learning

的角度出发，将 unsupervised domain adaptation translation 视为寻找一个好译者的起点的优化过程，并提出了 MT-GAN 方法，在 Meta-training 阶段积累的跨域翻译经验能够有效地进行各种域问题的自适应。

（三）零样本跨语言知识迁移

在无对齐平行语料的条件下，将高资源语种习得的语言表征知识迁移至低资源、新兴小语种。元学习提供完整技术体系解决该场景的数据缺失难题，已有工作验证元学习在零样本跨语言推理任务的有效性，可有效缓解高、低资源语种间的表征偏见。而 Meta-XNLG 则在该方向上取得了新的突破，即对 30 余类语种使用这一方法进行零样本评估，在不同的自然语言生成（NLG）任务中其性能都显著超过了基线^[8]。依托分层语言聚类的框架设计，该方法可有效抑制多语言生成中的语种混淆（意外翻译）问题，具备更强的鲁棒性，保障零样本翻译落地可行性。除此之外，分离式词元元学习为未知语种零样本翻译提供全新思路，该方案将词元学习与跨语言语义映射解耦，在无监督翻译场景下取得可观实验效果。

（四）多语言与跨领域翻译的泛化能力

针对模型的泛化能力以及多样性的任务需求，对多语言或多领域翻译场景提出了更高的要求。就多语言而言，基于元学习的类别化语言技术强调了多样化语言的学习可共享其结构属性，进而有利于形成更具平衡性意义的跨语言迁移框架；而就跨领域而言，采用元学习和语义转换技术的跨学科神经网络翻译架构，借

助任务级的元学习策略和比较学习以优化语义的一致性，使得该模型在三个主要评估标准（BLEU、TER 和 CHRF）上的得分超过其他八种流行方案，其中 BLEU 值平均提高了 1.1 到 2.3 个单位^[9]。当引入了段落标记和噪声干扰机制后，模型可以在长文档、包含专有名词集合的文章中、风格转换的情境下具有较高的鲁棒性；大语言模型的出现为元学习应用于机器翻译领域带来了新的契机，以 Trans-Zero 这类自对弈为基础的方法仅凭单语数据及大语言模型内含的多语信息便可达到传统方法相似水平的效果，也充分体现了元学习思想和超大规模模型技术结合的巨大潜力^[10]。

四、结语

元学习方法在神经机器翻译领域的研究已经走过了从理论探索到实践验证的发展阶段，在低资源语言翻译、无监督领域自适应、零样本跨语言迁移等核心任务上取得了可观的成效。其核心创新在于重构模型的数据依赖逻辑——不再依靠海量标注数据拟合单一映射关系，而是通过多任务累积学习赋予模型快速适配全新任务的迁移能力。未来元学习与机器翻译的融合研究，将重点围绕元学习与大语言模型协同优化展开。大模型海量预训练语义知识库可作为元学习的底层特征底座，而元学习轻量化快速微调机制能够缓解大模型适配低资源语种、陌生领域时算力成本过高的缺陷，二者结合有潜力推动通用多语言翻译智能体的迭代升级。

参考文献

- [1] 刘婉婉. 结合无监督元学习方法的神经机器翻译 [J]. 信息技术与信息化, 2021(01): 241-243.
- [2] 马潇, 田永红, 赵伟. 基于神经网络的机器翻译研究综述 [J]. 计算机工程与应用. 2025, 61(22): 36-54.
- [3] 张晗. 基于预训练语言模型的持续学习方法 [D]. 哈尔滨工业大学, 2025.
- [4] PARISI G I, KEMKER R, PART J L, et al. Continual Lifelong Learning With Neural Networks: A Review [J]. Neural Networks, 2019, 113 (C) : 54-71.
- [5] Jiatao Gu, Yong Wang, Yun Chen, Victor O. K. Li, Kyunghyun Cho. Meta-Learning for Low-Resource Neural Machine Translation [J]. EMNLP 2018: 3622-3631.
- [6] WU T, LI X, LI Y-F, et al. Curriculum-Meta Learning For Order-Robust Continual Relation Extraction [C]// Proceedings of the AAAI Conference on Artificial Intelligence, 2021: 10363-10369.
- [7] 常鑫. 元学习框架下情景级蒙汉机器翻译系统的实现 [D]. 内蒙古大学, 2022.
- [8] Maurya K K, Desarkar M S. Meta-XNLG: A Meta-Learning Approach Based on Language Clustering for Zero-Shot Cross-Lingual Transfer and Generation [J]. arXiv preprint arXiv:2203.10250, 2022.
- [9] 王逸凡. 面向领域的机器翻译关键技术研究 [D]. 电子科技大学, 2024.
- [10] HOANG H, KHAYRALLAH H, JUNCZYS-DOWMUNT M. On-the-Fly Fusion of Large Language Models and Machine Translation [C]. ACL, 2024.