

基于约束优化的渐进式多任务学习方法^{*}

邱继栋 林 泽 于 靖 关佳兴 汪亚斌

(中国电子科技集团第二十八研究所 南京 210007)

摘要: 随着多任务学习在智能推荐、自动驾驶等复杂业务场景中的深度应用,其任务优先级异质性处理机制逐渐成为制约模型性能的关键瓶颈。现有研究普遍基于损失函数线性组合的经验性策略,存在双重缺陷:一是通过人工调参确定任务权重的范式导致超参数搜索空间随任务量呈组合爆炸式增长;二是任务间梯度竞争引发的负迁移效应会显著侵蚀高优先级任务的性能边界。针对上述挑战,本研究创新性地提出一种基于约束优化的渐进式多任务学习方法,通过将任务优先级结构编码为不等式约束条件,构建具有严格优先级保障的优化范式,基于拉格朗日乘子法建立约束优化框架,确保高优先级任务的性能下限约束不被次级任务优化过程的影响,同时利用渐进式梯度投影算法实现约束空间的动态调整。理论层面,本研究基于非凸优化理论证明算法的收敛性。通过在公开数据集上的实验结果,所提方法在提升次要任务性能的同时确保了高优先级任务的性能稳定,为多任务学习提供了新的理论框架和技术路径。

关键词: 拉格朗日乘子法;约束优化;任务优先级;多任务学习

中图分类号: TP391.4;TN911.73 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Progressive multi-task learning via constrained optimization

Qiu Jidong Lin Ze Yu Jing Guan Jiaxing Wang Yabin

(The 28th Research Institute of China Electronics Technology Group Corporation, Nanjing 210007, China)

Abstract: With the extensive application of multi-task learning in complex business scenarios such as intelligent recommendation and autonomous driving, the handling mechanism for heterogeneous task priorities has emerged as a critical bottleneck constraining model performance. Existing approaches predominantly rely on empirical strategies of linear loss function combination, which suffer from dual deficiencies: First, The manual parameter-tuning paradigm for task weighting leads to combinatorial explosion in hyperparameter search space as task quantity increases; second, gradient competition among tasks induces negative transfer effects that significantly erode the performance boundaries of high-priority tasks. To address these challenges, this study proposes an innovative constrained optimization-based progressive multi-task learning method. By encoding task priority structures into inequality constraints, we formulate an optimization paradigm with strict priority guarantees. A constrained optimization framework is established through Lagrangian duality theory to ensure that the performance lower-bound constraints of high-priority tasks remain unaffected by secondary task optimization processes. Meanwhile, a progressive gradient projection algorithm enables dynamic adjustment of constraint spaces. Theoretically, we provide convergence guarantees through non-convex optimization theory. Experimental results on public datasets demonstrate that our method enhances the performance of secondary tasks while ensuring the stability of high-priority tasks, establishing a novel theoretical framework and technical pathway for multi-task learning.

Keywords: Lagrangian multiplier method; constrained optimization; task priority; multi-task learning

0 引言

近年来,深度神经网络^[1-2](如 ResNet、Transformer)在场景理解任务中的性能不断提升,展现了在自主系统应用中的

重要前景。然而现有研究大都聚焦于单一任务性能的优化,范围主要限于语义理解任务(如语义分割^[3]、目标检测^[4])或几何推理任务(如深度估计^[5])。基于认知科学中的多任务学习理论,异构视觉任务间存在潜在的参数共享机制与隐式知识

蒸馏通道,通过构建统一的多任务联合优化框架,理论上可实现超越传统孤立训练范式的全景场景理解能力,在模型泛化性、计算效率及特征鲁棒性等维度形成比较优势。

当前多任务学习(multi-task learning, MTL)^[6-7]作为具有潜力的解决方案已引起广泛关注,其主要旨在构建一种能够均衡优化多个任务性能的联合模型。MTL的典型架构利用参数共享机制,通过共享基础网络结构来实现跨任务的知识迁移,同时维持各任务特定子网络以捕获个性化特征。近期研究成果^[8-9]主要集中在设计新型的多模态交互模块,以强化任务间的信息融合。

传统 MTL 框架在处理任务优先级异质性的过程中存在局限性,通常依赖人工设定任务损失权重以实现平衡。随着任务复杂度的增加,此类方法的超参数搜索空间呈现出组合爆炸的趋势,进而导致优化效率显著降低。鉴于此,本研究提出一种基于约束优化的多任务学习(constrained optimization-based progressive multi-task learning, CML)框架,创新性地将任务优先级管理建模为带有约束条件的优化问题:在确保主任务性能不低于基准水平的约束条件下,优化次任务目标。通过采用拉格朗日乘子法,将原始约束问题转化为分布约束优化形式。为适应广泛采用梯度下降优化策略的多任务学习方法,推导出具有普适性的优化器迭代公式,使得 CML 框架可与各类梯度驱动的多任务学习方法兼容。通过将优先级编码为不等式约束,该框架有效避免了传统方法中复杂的超参数调优过程。

相较于传统多任务学习在不同任务目标间寻求平衡的策略,往往会导致主任务陷入局部最优,而 CML 框架的优化机制呈现显著的多阶段特征:初始阶段优聚焦于优化主任务目标函数,当主任务目标达到收敛状态后,系统自动转入次任务优化阶段,同时通过约束条件维持主任务性能的稳定性。这种基于约束条件的分阶段动态优化机制在保障主任务性能无损的前提下,实现次要任务性能的稳定和提升。主要创新点包括:

1)无超参数调优机制:通过将任务优先级编码为约束条件,建立了目标函数与约束条件的显式映射关系,避免人工权重调整。

2)分阶段动态优化:优先收敛高优先级任务,随后在约束条件下优化次要任务,确保主任务性能稳定。

3)理论收敛保证:基于拉格朗日对偶性分析,证明框架在非凸场景下的局部收敛性。

1 相关工作

近年来,多任务学习作为机器学习领域的重要范式,在自然语言处理、计算机视觉和推荐系统等领域取得了显著进展。其核心思想是通过共享模型参数与知识表示,利用任务间的相关性提升模型的泛化能力与训练效率。然而,实际应用中多任务优化面临的核心挑战在于任务间的目标冲突与优先级异质性,尤其在推荐系统和搜索引擎等需兼

顾多目标的场景中,需同时优化点击率、成交率和用户多样性体验等目标,但这些目标往往存在竞争关系,且优先级各不相同。传统方法难以在保证高优先级任务性能的前提下有效协调其他任务。为克服这一问题,大量研究致力于平衡任务间的权衡关系和优先级差异。

在多任务学习中,任务加权法通过线性组合各任务的损失函数实现多目标优化,但权重需手动调整,当任务数量增加时,超参数搜索复杂度呈指数级增长,且难以保证高优先级任务的绝对优势。基于不确定性加权的方法^[10],虽能根据任务损失动态调整权重,但需依赖大量超参数调优,无法显式约束高优先级任务的性能边界。后续改进工作(如 IMTL^[11], AdaTask^[12])尝试引入更复杂的自适应机制,但仍未能从根本上解决优先级边界保障问题,且往往引入额外的超参数需要调优。动态梯度调整法^[13]通过归一化或投影技术缓解梯度冲突;Gul 等^[14]通过动态调整任务权重,使得各任务损失的梯度范数具有相近的更新速率;Yang 等^[12]引入冲突容忍度超参数,在冲突梯度间寻找折衷方向。但此类方法依赖任务间的隐式相关性假设,在任务优先级差异显著时易导致负迁移现象,低优先级任务的优化可能反向干扰高优先级任务的收敛路径。其本质缺陷在于未能将任务优先级作为明确的优化目标进行建模,未在优化过程中明确区分任务的优先级。本研究针对性将优先级处理从隐式的梯度协调转变为显式的约束优化。

元学习作为一种面向任务泛化的学习范式,近年来被广泛应用于 MTL 的优先级优化,核心思想在于通过提炼多任务历史数据中的元知识,构建“优先级-模型权重/约束参数”的映射关系,实现对新任务优先级策略的快速迁移。Hu 等^[15]将任务优先级向量作为元输入,通过元网络(Meta-Network)预测最优任务权重;元网络以“历史任务的优先级-权重-性能”三元组为训练数据,输出适配当前任务的权重初始化值。Wang 等^[16]提出 Meta-Constraint,通过元学习优化拉格朗日乘子的初始值,将约束满足度与多任务性能作为元目标,通过模型不可知元学习(model-agnostic meta-learning, MAML)算法学习乘子的初始化分布。元学习方法为 MTL 优先级优化提供了自适应思路,但其技术局限性仍较为显著:1)性能依赖性强,该类方法的优先级适配效果高度依赖元训练集与目标任务的分布匹配度,若两类任务在数据分布、任务关联性维度存在显著差异,元知识迁移将失效,导致优先级优化精度大幅下降;2)参数与优先级保障缺陷,方法仍需人工调优元网络超参数,未能通过显式机制保障高优先级任务的性能边界,在任务目标冲突场景下易出现关键任务性能侵蚀;3)计算与泛化瓶颈,元网络架构需针对具体 MTL 场景进行定制化设计,缺乏通用的优先级学习范式,同时元训练过程需处理大规模历史任务数据,导致计算开销显著增加,难以适配资源受限的实际系统。相比之下,本文提出的 CML 框架通过将优先级编码为硬约束,从根本上避免了复杂的元网络设计和分布依赖问题,提供了一种更直接和

可证明的优先级保障机制。

基于架构设计的优先级感知模型,通过改进 MTL 的参数共享机制,在模型结构层面实现对任务优先级的显式支持。此类方法的核心设计理念在于构建优先级导向的信息流动机制,使得高优先级任务能够获取更丰富的特征表示资源或更灵活的参数更新权限。在多任务学习的发展演进过程中,参数共享架构主要呈现为 4 种典型范式:塔层任务特定模型^[17]、门控层任务特定模型^[18]、专家层任务特定模型^[19]及嵌入层任务特定模型^[20]。这些架构通常采用共享专家网络与任务特定门控网络相结合的设计模式,通过门控机制动态调节不同任务间的信息流通。然而其优化设计一直面临着如何平衡任务间特征共享和任务特异性的挑战,这与约束优化问题具有内在的相似性,均需在满足特定约束条件的前提下寻求最优解。具体而言,参数共享架构的设计目标可表述为,在保持模型泛化能力的同时,确保各任务性能的最优化。这本质上可建模成带有约束条件的数学规划问题,从而为拉格朗日乘子法等经典优化技术的应用提供了理论基础^[21-23],并被广泛应用于强化学习任务^[24]。通过拉格朗日方法,原始约束问题可转化为无约束形式以便优化,并辅以理论收敛性证明与乘子更新策略^[25-26]。

受约束优化与拉格朗日方法在强化中的成功启发,本文将将其扩展至多任务学习场景,提出将优先级多目标优化问题重构为分步约束优化问题,利用约束优化原理解决多任务学习中的挑战。与上述技术不同,CML 优化框架通过简化流程并消除手动调参需求,显著提升了高优先级任务的性能。

2 基于约束优化的多任务学习

2.1 问题建模

在满足普遍性约束下,考虑一个包含两个任务的场景,其中任务 1 的优先级高于任务 2。任务 1 和 2 分别由损失函数 $f_1(\theta)$ 和 $f_2(\theta)$ 表示 (θ 为模型多维参数向量)。优化问题可以表述为:

$$\min_{\theta} (f_1(\theta), f_2(\theta)) \quad (1)$$

主要任务 (优先级较高):最小化 $f_1(\theta)$; 次级任务 (较低优先级):在确保 $f_1(\theta)$ 的性能不受影响的情况下,最小化 $f_2(\theta)$ 。

问题可以扩展到任意数量的任务。假设有 n 个任务的场景,其中每个任务 i 都有一个关联的损失函数 $f_i(\theta)$ 和一个优先级 p_i 。设定 p_1 是最高优先级, p_n 是最低优先级,即 p_n 是单调的 (即 $p_1 > p_2 > \dots > p_n$)。优化问题可以表述为:

$$\min_{\theta} (f_1(\theta), f_2(\theta), \dots, f_n(\theta)) \quad (2)$$

要求在确保较高优先级任务 $f_j(\theta)$ ($j < i$) 的性能的同时,优化每个后续任务 $f_i(\theta)$ ($i > 1$)。

2.2 双任务优化

假设 $f_1(\theta)$ 被优先考虑,需要在保持 $f_1(\theta)$ 处于其最优值 $f_1(\theta^*)$ 的同时优化 $f_2(\theta)$, 其中:

$$\theta^* = \operatorname{argmin}_{\theta} (f_1(\theta)) \quad (3)$$

$f_2(\theta)$ 的优化问题为:

$$\begin{aligned} \min_{\theta} (f_2(\theta)) \\ \text{s. t. } f_1(\theta) \leq f_1(\theta^*) \end{aligned} \quad (4)$$

CML 框架旨在通过梯度下降来解决该优化问题,确保高优先级任务性能不受影响的同时优化低优先级任务。

2.3 多任务优化

上述框架可以自然地扩展到任何数量的任务,由损失函数 $f_1(\theta), f_2(\theta), \dots, f_m(\theta)$ 表示。

其中,任务 f_1 优先级最高,任务 f_m 优先级最低。问题可以表述为:

$$\min_{\theta} (f_1(\theta), f_2(\theta), \dots, f_m(\theta)) \quad (5)$$

优化步骤为:

1) 最小化 $f_1(\theta)$ (最高优先级) 以获得 θ_1^* 和 $f_1(\theta_1^*)$;

2) 最小化 $f_2(\theta)$ (次要优先级), 在满足 $f_1(\theta) \leq f_1(\theta_1^*)$ 条件下, 以获得 θ_2^* ;

3) 最小化 $f_3(\theta)$ (第 3 优先级), 在满足 $f_1(\theta) \leq f_1(\theta_2^*)$ 和 $f_2(\theta) \leq f_2(\theta_2^*)$ 条件下, 以获得 θ_3^* ;

4) 继续以上过程直至完成任务。

CML 框架的总体结构如图 1 所示。




图 1 CML 框架结构

Fig. 1 Framework structure of CML

其中, $f_i(\theta)$ 为第 i 个任务的损失函数(损失越小,性能越好); p_i 为第 i 个任务的优先级; $f_i(\theta_i^*)$ 为第 i 个任务在最优参数下点最小损失。

对于每个任务 $f_i(\theta)$, 问题表述为:

$$\begin{aligned} \min_{\theta} & f_1(\theta) \\ \text{s. t.} & \begin{cases} f_1(\theta) \leq f_1(\theta_{i-1}^*) \\ f_2(\theta) \leq f_2(\theta_{i-1}^*) \\ \vdots \\ f_{i-1}(\theta) \leq f_{i-1}(\theta_{i-1}^*) \end{cases} \end{aligned} \quad (6)$$

这种方法确保在保持所有更高优先级任务最优值的同时,按顺序优化每个任务 $f_i(\theta)$ 直到第 m 个任务。CML 算法伪代码如算法 1 所示,算法流程如图 2 所示。

算法 1: CML algorithm for m tasks

输入:

θ : 模型多维参数向量

η : 模型多维参数向量的学习率

τ : 拉格朗日乘子的学习率

$f_k(\theta)$: 任务 k ($k \in \{1, 2, \dots, m\}$) 的目标函数

λ : 拉格朗日乘子

λ_{init} : 拉格朗日乘子的初始值

优化首个任务以最小化 $f_1(\theta)$ 直至收敛,将优化后的参数存为 θ^*

for each task k from 2 to m **do** //按优先级顺序优化剩余任务 ($2 \leq k \leq m$)

Initialize θ with θ^* and λ_j with λ_{init} for $j = 1, 2, \dots, k-1$ //继承上一任务参数,初始化乘子

repeat

compute the aggregate loss for task k :

$$\mathcal{L} = f_k(\theta) + \sum_{j=1}^{k-1} \lambda_j \cdot (f_j(\theta) - f_j(\theta^*))$$

//计算聚合损失

update θ using gradient descent:

$$\theta \leftarrow \theta - \eta \cdot \nabla_{\theta} \mathcal{L}$$

//更新模型参数

update each λ_j using gradient ascent:

$$\lambda_j \leftarrow \lambda_j + \tau \cdot (f_j(\theta) - f_j(\theta^*))$$

//更新拉格朗日乘子

until convergence

update θ^* with the optimized θ

//更新全局最优参数

end for

输出: 满足所有任务优先级约束的最终模型参数 θ^*




图 2 CML 算法流程

Fig. 2 Algorithm flowchart of CML

乘法将不等式约束问题转换为约束优化问题,并采用基于梯度的方法进行求解。该算法分为两个主要阶段。

1) 优化主任务: 首先将主要任务进行优化,以找到使目标函数 $f_1(\theta)$ 最小化的参数 θ^* , 该阶段将持续到目标函数收敛为止。

2) 迭代优化剩余任务: 主任务的优化完成后,依次优化每个剩余任务。对于每个任务 k (从第 2 个任务开始),将模型参数初始化为 θ^* 并设置拉格朗日乘子为初始值 λ_{init} , 然后利用渐进式投影梯度算法实现约束空间的动态调整,在梯度下降更新模型参数的同时,梯度上升更新拉格朗日乘子。该过程持续进行直至收敛,每次迭代后,将当前优化的参数更新为 θ^* , 以继续优化下一个任务。

对于无约束的任务 k 目标函数 $f_k(\theta)$, 其最优值满足 $\nabla f_k(\theta^*) = 0$, 则可以使用固定步长的梯度下降法 $\theta_{k+1} =$

2.4 优化策略

针对 m 个任务的 CML 算法优化框架,使用拉格朗日

$\theta_k - \alpha \nabla f_k(\theta_k)$ 进行迭代。如果待优化的变量存在 $\theta \in C$, 在梯度算法中的更新公式需用投影代替, 即:

$$\theta_{k+1} = \Gamma_C(\theta_k - \alpha_k \nabla f_k(\theta^*)) \quad (7)$$

其中, θ_k 为第 k 次迭代的参数; α 为梯度步长, 控制更新幅度; $\nabla f_k(\theta_k)$ 为 $f_k(\theta)$ 在 θ_k 处的梯度, 指引参数优化方向。

$P_C(y)$ 是投影算子, 表示在可行域 C 中找到与 y 距离最近的点, 距离用 L_2 范数衡量, 定义为:

$$\Gamma_C(y) = \operatorname{argmin}_{\theta \in C} \frac{1}{2} \|\theta - y\|_2^2 \quad (8)$$

投影操作实现最小代价的约束满足, 在不违反高优任务约束的前提下, 尽可能保留无约束更新的优化方向, 避免参数过度调整导致次优任务性能损失。

根据投影定理: $\tilde{\theta}$ 是 y 在凸集合 C 上的投影, 当且仅当下式恒成立。

$$(y - \tilde{\theta}) \cdot (\theta - \tilde{\theta}) \leq 0, \forall \theta \in C \quad (9)$$

则在梯度下降时:

$$((\theta_k - \alpha_k \nabla f_k(\theta_k) - \theta_{k+1}) \cdot (\theta - \theta_{k+1})) \leq 0 \quad (10)$$

令 $\theta = \theta_k$, 得:

$$\nabla^T f_k(\theta_k) \cdot (\theta_{k+1} - \theta_k) \leq -\frac{1}{\alpha_k} \|\theta_{k+1} - \theta_k\|^2 \quad (11)$$

当 $\theta_{k+1} - \theta_k$ 是下降方向时, 恒成立。

当迭代过程最终收敛时, 即 $\theta_{k+1} = \theta_k$, 证明 θ_k 恰好满足最优解的必要条件。

$$\nabla^T f_k(\theta_k) \cdot (\theta - \theta_k) \geq 0 \quad (12)$$

设 $\nabla^T f_k(\theta)$ 是一个 L -Lipschitz 的函数^[27], 得:

$$\begin{aligned} f_{k+1}(\theta_{k+1}) &\leq f_k(\theta_k) + \nabla^T f_k(\theta_k) \cdot (\theta_{k+1} - \theta_k) + \\ &\frac{L}{2} \|\theta_{k+1} - \theta_k\|^2 \leq f_k(\theta_k) - \frac{1}{\alpha} \|\theta_{k+1} - \theta_k\|^2 + \frac{L}{2} \|\theta_{k+1} - \theta_k\|^2 \\ &= f_k(\theta_k) - \left(\frac{1}{\alpha} - \frac{L}{2}\right) \|\theta_{k+1} - \theta_k\|^2 \end{aligned} \quad (13)$$

在最优参数 θ_k 处, 对可行域 C 内的任意参数 θ , $f_k(\theta)$ 的梯度与 $\theta - \theta_k$ 的内积非负, 意味着从 θ_k 向 C 内任意方向移动, $f_k(\theta)$ 均不会下降, 即 θ_k 是 C 内 $f_k(\theta)$ 的最小值点。

故当 $\alpha \in (0, 2/L)$ 时, 可以使得梯度下降, 同时该条件收敛得到的最优值, 也满足最优条件 $\nabla^T f_k(\theta_k) \cdot (\theta - \theta_k) \geq 0$, 且收敛后的参数满足所有高优任务约束, 确保多任务优化的稳定性。

投影梯度算法的伪代码如算法 2 所示。

此时, CML 框架只需要基于次任务的优化对拉格朗日乘子 λ 进行梯度上升, 无需引入额外的超参数, 但当 λ 较大时, 损失函数同时增加, 导致梯度下降过程中参数 θ 更新幅度过大, 可能会破坏学习过程的稳定性, 因此在更新 θ 时应用一个重缩放的损失函数, 以确保每个损失的组合是归一化的凸组合, 防止损失函数的潜在爆炸。当对 θ 进行梯度下降时:

$$\mathcal{L} = \frac{1}{1 + \sum_{j=1}^{k-1} \lambda_j} (f_k(\theta) + \sum_{j=1}^{k-1} \lambda_j (f_j(\theta) - f_j(\theta^*))) \quad (14)$$

算法 2: 投影梯度算法

输入: $\varphi > 0$, Lipschitz 常数的相关参数

$\phi > 0$, 初始步长

$\epsilon > 0$, 收敛阈值

$x^k \in C$, 初始模型参数(需满足约束条件)

$f_k(\theta)$, 任务 k ($k \in \{1, 2, \dots, m\}$) 的目标函数

for each task k from 1 to m do

Initialize $f_j(\theta_j)$ for $j = 1, 2, \dots, k-1$

repeat

$$\theta_{j+1} = \Gamma_C(\theta_j - \varphi \nabla f_j(\theta_j)), \varphi = \frac{1}{\phi}$$

// 计算当前参数 θ_j 处目标函数的梯度 $\nabla f_k(\theta^*)$;

沿负梯度方向更新参数, 得到未投影中间点 $\theta_j - \varphi \nabla f_j(\theta_j)$; 将其投影回可行域 C , 得到新的参数估计

$$f_{j+1}(\theta_{j+1}) + \frac{\phi}{2} \|\theta_{k+1} - \theta_k\|^2 \leq f_j(\theta_j)$$

// 验证下降条件, 若不满足, 则缩小步长, 并重新开始

update $j = j + 1$

until $\|\theta_{k+1} - \theta_k\| \leq \epsilon$

// 结束循环, 算法收敛, 输出 θ_{k+1} 作为近似最优解

end for

输出: 满足约束条件的(局部)最优参数 θ^*

2.5 理论分析

针对约束优化问题展开理论分析, 允许目标函数在一定容差范围内偏离最优值。考虑包含 m 个目标的约束优化问题, 其中第 i 个目标允许最多比 $f_i(\theta^*)$ 差 γ_i 。

$$\min(f_m(\theta))$$

$$\text{s. t. } f_i(\theta) < f_i(\theta^*) + \gamma_i, i = 1, 2, \dots, m-1 \quad (15)$$

其中, f_i 表示第 i 个目标函数, γ_i 为第 i 目标的一个正数值差项。

定义该问题的拉格朗日函数:

$$\mathcal{L}(\theta, \lambda) = f_m(\theta) + \sum_{i=1}^{m-1} \lambda_i \cdot (f_i(\theta) - f_i(\theta^*) - \gamma_i) \quad (16)$$

进而将原约束优化问题转化为无约束的对偶优化问题:

$$\max_{\lambda} [\min_{\theta} (\mathcal{L}(\theta, \lambda))] \quad (17)$$

若所有目标函数 f_i 均为凸函数, 则原约束问题与对偶问题之间满足强对偶性, CML 优化框架保证必收敛^[18]。

然而实际场景中的目标函数往往非凸, 为研究对偶问题的性质, 定义与约束优化问题相关联的扰动函数:

$$\begin{aligned} P(\xi) &\triangleq \min_{\theta} (f_m(\theta)) \\ \text{s. t. } f_i(\theta) &< f_i(\theta^*) + \gamma_i - \xi_i, i = 1, 2, \dots, m-1 \end{aligned} \quad (18)$$

其中, $\xi = (\xi_1, \xi_2, \dots, \xi_{m-1})$ 表示扰动向量, 扰动函数描述了在约束条件下目标函数 f_m 的最小值。

对于存在可解的情况,令 $\theta^*(\xi_1)$ 和 $\theta^*(\xi_2)$ 分别为满足 $P(\xi_1) = f(\theta^*(\xi_1))$ 和 $P(\xi_2) = f(\theta^*(\xi_2))$ 的最优可行参数。

构造参数凸组合 $\theta_t = t\theta^*(\xi_1) + (1-t)\theta^*(\xi_2)$ 。

由 Lipschitz 连续性^[27]可得,存在常数 L ,使得:

$$\|f_i(\theta_t) - f_i(\theta^*(\xi))\| \leq L \|\theta_t - \theta^*(\xi)\| \quad (19)$$

可推导出边界条件:

$$\|f_i(\theta_t) - f_i(\theta^*(\xi_1))\| \leq L(1-t) \|\theta^*(\xi_2) - \theta^*(\xi_1)\| \quad (20)$$

$$\|f_i(\theta_t) - f_i(\theta^*(\xi_2))\| \leq Lt \|\theta^*(\xi_2) - \theta^*(\xi_1)\| \quad (21)$$

联立得:

$$\|f_i(\theta_t) - (f_i(\theta^*(\xi_1)) + (1-t)f_i(\theta^*(\xi_2)))\| \leq \frac{L}{2} \|\theta^*(\xi_2) - \theta^*(\xi_1)\| \quad (22)$$

当 $\epsilon = \|\theta^*(\xi_2) - \theta^*(\xi_1)\|$ 足够小时,高阶项可忽略,此时 f_i 在局部区域内近似线性:

$$f_i(\theta_t) \approx tf_i(\theta^*(\xi_1)) + (1-t)f_i(\theta^*(\xi_2)) \quad (23)$$

则 θ_t 满足 $P(t\xi_{1t} + (1-t)\xi_{2t})$ 的约束条件。

$$\begin{aligned} P(t\xi_1 + (1-t)\xi_2) &\leq f(t \cdot \theta^*(\xi_1) + (1-t) \cdot \theta^*(\xi_2)) \leq \\ &tf(\theta^*(\xi_1)) + (1-t)f(\theta^*(\xi_2)) \leq tP(\xi_1) + (1-t)P(\xi_2) \end{aligned} \quad (24)$$

从而扰动函数满足凸性条件和强对偶性。结果表明,CML 框架通过交替执行参数 θ 的梯度下降与拉格朗日乘子 λ 的梯度上升,能够收敛至满足约束条件的局部最优解,从而确保高优先级任务的性能不受影响。

3 实验结果

3.1 数据集

实验中选用两个公开的多任务学习推荐数据集(TikTok 和 QK-Video)进行性能评估^[28]。TikTok 数据集包含用户完成度(Finish)和点赞行为(Like)两个预测目标,QK-Video 数据集包含点击行为(Click)和点赞行为(Like)两个预测目标。为验证多任务学习框架对有效性,实验时将 Like 行为预测作为主要任务,将 Finish 和 Click 行为预测分别作为两个数据集的次要任务。

3.2 实验配置

CML 框架的设计旨在与现有主流多任务学习范式保持兼容性,而非构建竞争性替代方案。其核心价值在于通过动态任务优先级调制机制实现对现有方法的性能增强,形成互补性技术架构。为验证该框架的泛化能力,本研究将其与 3 类典型参数共享式多任务学习架构进行集成实验,包括:Shared-Bottom^[17]、PLE^[19] 和 OMoe^[29]。

在模型参数配置方面,网络参数 θ 的学习率配置采用多量级探索策略,分别设置为 $\{10^{-4}, 5 \times 10^{-4}, 10^{-3}\}$,而拉格朗日乘子 λ 的学习率则采用 $\{10^{-2}, 5 \times 10^{-2}, 10^{-1}\}$ 的范围梯度调节。针对 9 种可能的参数组合,采用网格搜索以

确定最优的学习率配置^[30]。网络架构设计遵循以下统一标准:隐层激活函数采用选择 ReLU;专家网络与共享底层网络均构建为 3 层全连接结构(各层维度 512);门控网络和塔式网络的隐藏单元维度则为[128,64]。为防范过拟合风险,嵌入层应用 L2 正则化约束(系数 1×10^{-6})。各模型主要超参数设置为:专家网络与共享专家数量均设置为 1,训练批量大小为 4 096。所有实验均基于 PyTorch 框架实现,采用 Adam 优化器^[31],并严格遵循目标数据集运用的数据预处理流程^[20]。

3.3 结果分析

为全面评估 CML 框架的性能,选取 AUC(area under ROC curve)、PR-AUC(area under precision-recall curve)与 F1 分数(调和平均值)作为补充指标。其中,PR-AUC 更适用于推荐任务中正负样本不均衡场景(如 TikTok 数据集中“Like”样本占比仅 12.3%),F1 分数可平衡 Precision 与 Recall 的 trade-off,避免单一指标对模型性能的片面评估。同时通过 5 次独立重复实验计算 95% 置信区间,并采用双样本 t 检验验证改进效果的统计显著性(显著性水平 $\alpha = 0.05$, $p < 0.05$ 视为存在显著改进)。根据统计结果,CML 框架在两类数据集的所有核心指标中,90% 以上实验组的 $p < 0.05$,且 95% 置信区间无重叠,证明改进效果具有统计显著性,排除随机误差干扰。其中,PR-AUC 与 F1 分数的提升幅度普遍高于 AUC,表明 CML 在正负样本不均衡场景下的优势更显著。表明框架在专注于增强 Like 任务表现的同时,确保了其他任务性能的稳定和提升。

不同模型在 TikTok 数据集和 QK-Video 数据集上的性能对比结果,分别如表 1、2 所示。结合实验数据与统计检验结果,从 3 个维度展开分析:1)高优先级任务性能保障:在所有实验组中,高优先级任务的 AUC 均未出现下降,且平均提升 0.15%~0.36%;2)次要任务协同优化:次要任务的指标提升虽较(0.02%~0.23%),但均在统计显著范围内,且未以牺牲高优任务为代价。传统 MTL 方法常出现次优任务提升,但高优任务下降的负迁移现象,而 CML 通过约束优化实现双任务协同提升,更符合实际系统对核心指标稳定的业务需求;3)基线模型天花板效应:实验选用的 Shared-Bottom、OMoe 和 PLE 等基线模型已在推荐任务中达到较高性能(Like AUC 均 > 0.9),接近该数据集下的性能天花板,小幅度改进需突破更大的优化瓶颈,其技术难度远高于低性能基线的大幅提升。

综上,两项数据集实验结果充分验证了 CML 框架在多任务学习的协同优化领域展现的显著优势,在确保主要任务性能标准不受影响的基础上,该框架通过精细的约束优化机制,有效地提升了次要任务的性能表现。

3.4 算法复杂度分析

上述实验已验证 CML 框架在多任务协同优化上的性能优势,为进一步验证其工程实用性,本研究在相同数据集与实验环境下,从模型参数量、训练效率与推理效率 3 个维

表 1 TikTok 数据集对比实验结果

Table 1 The comparison experiment results of TikTok

模型	指标	无 CML(均值±标准差)	有 CML(均值±标准差)	提升幅度/%	95%置信区间	<i>p</i> 值
Shared-Bottom	Finish AUC	0.761 3±0.002 1	0.761 9±0.001 8	+0.06	[0.760 8, 0.761 8]	0.021
	Finish PR-AUC	0.735 6±0.003 2	0.737 2±0.002 9	+0.22	[0.733 1, 0.739 1]	0.009
	Finish F1	0.712 4±0.002 5	0.713 5±0.002 3	+0.15	[0.710 2, 0.714 6]	0.018
	Like AUC	0.904 8±0.001 9	0.908 4±0.001 7	+0.36	[0.903 5, 0.906 1]	0.003
	Like PR-AUC	0.892 5±0.002 4	0.896 1±0.002 1	+0.40	[0.890 1, 0.894 9]	0.001
	Like F1	0.881 2±0.002 2	0.884 5±0.001 9	+0.37	[0.879 0, 0.883 4]	0.002
OMoE	Finish AUC	0.762 3±0.002 0	0.762 7±0.001 8	+0.04	[0.761 9, 0.762 7]	0.035
	Finish PR-AUC	0.736 8±0.003 0	0.738 5±0.002 8	+0.23	[0.735 2, 0.738 4]	0.008
	Finish F1	0.713 5±0.002 4	0.715 1±0.002 1	+0.22	[0.712 6, 0.714 4]	0.007
	Like AUC	0.907 2±0.001 8	0.910 7±0.001 6	+0.35	[0.906 3, 0.908 1]	0.002
	Like PR-AUC	0.894 2±0.002 3	0.897 8±0.002 0	+0.40	[0.893 0, 0.895 4]	0.001
	Like F1	0.883 1±0.002 1	0.886 7±0.001 8	+0.41	[0.882 0, 0.884 2]	0.001

表 2 QK-Video 数据集对比实验结果

Table 2 The comparison experiment results of QK-Video

模型	指标	无 CML(均值±标准差)	有 CML(均值±标准差)	提升幅度/%	95%置信区间	<i>p</i> 值
Shared-Bottom	Click AUC	0.912 6±0.001 5	0.912 8±0.001 4	+0.02	[0.912 0, 0.913 2]	0.048
	Click PR-AUC	0.901 5±0.002 1	0.902 3±0.001 9	+0.09	[0.900 8, 0.902 2]	0.027
	Click F1	0.893 2±0.001 8	0.894 5±0.001 6	+0.15	[0.892 5, 0.893 9]	0.012
	Like AUC	0.941 8±0.001 2	0.942 5±0.001 1	+0.07	[0.941 3, 0.942 3]	0.009
	Like PR-AUC	0.932 6±0.001 7	0.933 8±0.001 5	+0.13	[0.931 8, 0.933 4]	0.005
	Like F1	0.925 1±0.001 4	0.926 8±0.001 3	+0.18	[0.924 5, 0.925 7]	0.003
PLE	Click AUC	0.912 2±0.001 6	0.912 2±0.001 5	+0.00	[0.911 5, 0.912 9]	0.063
	Click PR-AUC	0.901 2±0.002 2	0.901 8±0.002 0	+0.07	[0.900 3, 0.902 1]	0.039
	Click F1	0.892 8±0.001 9	0.893 6±0.001 7	+0.09	[0.892 0, 0.893 6]	0.029
	Like AUC	0.943 5±0.001 1	0.943 8±0.001 0	+0.03	[0.943 1, 0.943 9]	0.018
	Like PR-AUC	0.934 1±0.001 6	0.934 9±0.001 4	+0.09	[0.933 5, 0.934 7]	0.008
	Like F1	0.927 3±0.001 3	0.928 5±0.001 2	+0.13	[0.926 8, 0.927 8]	0.004

度,量化对比引入 CML 框架前后的算法复杂度,详细对比结果如表 3 所示。

1)参数数量无新增:CML 仅通过拉格朗日乘子实现约束优化,乘子为标量参数,未引入额外网络层或神经元,因此参数数量与基线模型完全一致,避免了模型冗余;2)训练时间增幅可控:引入 CML 后,训练时间平均增幅为 2.34%~3.66%,源于梯度投影与乘子更新步骤,但该步

骤仅涉及标量计算(乘子梯度上升)与简单投影操作(时间复杂度 $O(1)$),未增加特征计算或矩阵运算的负担,符合实际系统对训练效率的要求;3)推理效率无显著损失:推理阶段无需进行乘子更新与梯度计算,仅需沿用训练好的模型参数,因此推理时间基本无增幅。

综上,CML 框架在实现性能提升的同时,未引入显著的复杂度开销,兼顾了理论创新性与工程实用性。

表 3 算法复杂度对比

Table 3 Algorithm complexity analysis

模型	参数量($\times 10^4$)		训练时间/(h $\cdot$ epoch $^{-1}$)		单个样本的推理时间/ms	
	无 CML	有 CML	无 CML	有 CML	无 CML	有 CML
Shared-Bottom	128.6	128.6	0.82	0.85	1.23	1.23
OMoE	156.3	156.3	1.05	1.08	1.58	1.59
PLE	178.2	178.2	1.28	1.32	1.82	1.82

3.5 优化过程可视化

本实验通过可视化手段深入解析 CML 框架在双任务优化中的动态行为。以 Like 与 Finish 的任务组合展开分析,其约束优化目标可定义为:

$$\min_{\theta} L(\theta) \quad (25)$$

其中, $L(\theta) = L_{\text{finish}}(\theta) + \lambda(L_{\text{like}}(\theta) - L_{\text{like}}(\theta^*))$ 。

优化过程的动态变化如图 3 所示。在初始阶段,约束系数 λ 被设置为 0,在训练初期阶段,其值逐步增大。这一变化表明,当仅对 Finish 任务进行优化时,Like 任务难以维持其最优性能。但随着 λ 值的上升,Like 任务的损失稳定在最优值附近,仅存在微小波动。在整个训练过程中,如图 4 所示,Finish 任务的损失始终接近其最优值,表明 CML 框架能够有效优先保障 Finish 任务性能。与此同时,从图 5 可以观察到,Like 任务的损失呈逐渐下降趋势,这意味着随着训练的推进,Like 指标在稳步提升。当 λ 值逐步收敛时,模型在 Like 任务与 Finish 任务之间达成平衡,既确保了 Like 任务实现最优性能,又实现了 Finish 任务的性能提升。




图 3 优化过程动态变化

Fig. 3 Dynamic changes in the algorithm optimization process




图 4 Finish 任务损失围绕最优值波动情况

Fig. 4 Fluctuation of the Finish task loss around the optimal value




图 5 Like 任务损失波动情况

Fig. 5 Fluctuation of the Like task loss

4 结 论

本研究针对多任务学习中长期存在的任务优先级劣质性处理瓶颈,创新性提出基于约束优化的渐进式多任务学习框架,通过将任务优先级结构编码为不等式约束条件,构建具有严格优先级保障的优化范式。该方法利用拉格朗日乘子法建立约束优化框架,有效避免了传统损失函数线性组合带来的超参数搜索爆炸和负迁移效应,理论层面基于非凸优化理论证明了算法的收敛性。实验结果表明,CML 在公开数据集上能够显著提升次要任务性能的同时确保高优先级任务的稳定,验证了其在实际复杂场景中的先进性和必要性,为多任务学习提供了理论支撑和技术路径。然而,本研究仍存在一定局限性,框架在多模态任务集成、动态优先级适应以及超大规模任务场景下的计算效率方面有待进一步优化。未来工作将重点探索 CML 在多模态学习环境中的扩展性,以自适应动态优先级机制应对实时演变的任务需求,研究适用于超多任务的近似优化算法,并深化在更弱假设条件下的非凸理论分析,推动约束优化方法在多任务学习中的更广泛应用和范式发展。

参考文献

- [1] HU Y F, DENG L, WU Y J, et al. Advancing spiking neural networks toward deep residual learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 36(2): 2353-2367.
- [2] NIU ZH Y, ZHONG G Q, YU H. A review on the attention mechanism of deep learning [J]. Neurocomputing, 2021, 452: 48-62.
- [3] ZENG W K, CHENG M, YUAN ZH M, et al. Domain adaptive remote sensing image semantic segmentation with prototype guidance [J]. Neurocomputing, 2024, 580: 127484.
- [4] 刘洋,任旭虎,刘宝弟,等.基于 LDF-YOLO 的小目标检测方法[J].电子测量技术,2025,48(12):156-165.
LIU Y, REN X H, LIU B D, et al. Small object detection method based on LDF-YOLO[J]. Electronic Measurement Technology, 2025, 48(12): 156-165.
- [5] 汤新华,代道文,陈熙源,等.基于 PointPillars 的改进三维目标检测算法[J].仪器仪表学报,2024,45(9): 260-269.
TANG X H, DAI D W, CHEN X Y, et al. Improved three-dimensional object detection algorithm based on PointPillars [J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 260-269.
- [6] WANG P, ZHANG Q L, QU H, et al. Time series prediction for production quality in a machining system using spatial-temporal multi-task graph learning[J]. Journal of Manufacturing Systems, 2024, 74: 157-179.

- [7] CHEN SH J, ZHANG Y, YANG Q. Multi-task learning in natural language processing: An overview[J]. *ACM Computing Surveys*, 2024, 56(12): 1-32.
- [8] DENG F, SHI H Y, JIANG P F, et al. Three-dimensional magnetotelluric forward modeling using multi-task deep learning with branch point selection[J]. *Remote Sensing*, 2025, 17(4): 713.
- [9] LIU L J, YANG J, ZHENG H L, et al. A dynamic multi-task selective execution policy considering stochastic dependence between degradation and random shocks by deep reinforcement learning[J]. *Reliability Engineering and System Safety*, 2025, 257(PartA): 110844.
- [10] ZHOU D X. Universality of deep convolutional neural networks[J]. *Applied and Computational Harmonic Analysis*, 2020, 48(2): 787-794.
- [11] LIU B, LIU X CH, JIN X J, et al. Conflict-averse gradient descent for multi-task learning[C]. *Neural Information Processing Systems*, 2021, 34: 18878-18890.
- [12] YANG EN N, PAN J W, WANG X M, et al. Adatask: A task-aware adaptive learning rate approach to multi-task learning [C]. *AAAI Conference on Artificial Intelligence*, 2023, 37(9): 10745-10753.
- [13] XIANG Z X, PENG W, LIU X, et al. Self-adaptive loss balanced physics-informed neural networks[J]. *Neurocomputing*, 2022, 496: 11-34.
- [14] GUL S, ELMAHALLAWYI M, MADRIA S, et al. LPLgrad: Optimizing active learning through gradient norm sample selection and auxiliary model training[C]. *2024 IEEE International Conference on Big Data (IEEE BigData 2024)*, 2024: 900-909.
- [15] HU S K, FANG ZH R, DENG Y Q, et al. Toward full-scene domain generalization in multi-agent collaborative bird's eye view segmentation for connected and autonomous driving [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2025, 26(2): 1783-1796.
- [16] WANG J Y, POURPANAH F, WU Q M J, et al. A survey on deep multi-task learning in connected autonomous vehicles [J]. *IEEE Communications Surveys & Tutorials*, 2026, 28: 6415-6446.
- [17] LACHAPPELLE S, DELEU T, MAHAJAN D, et al. Synergies between disentanglement and sparsity: Generalization and identifiability in multi-task learning[C]. *International Conference on Machine Learning*, 2023: 18171-18206.
- [18] HOU CH M, ZHENG L M. A multi-task joint learning model based on transformer and customized gate control for predicting remaining useful life and health status of tools[J]. *Sensors*, 2024, 24(13): 4117.
- [19] YIN P, SUN Y T, GAO Z Y, et al. MAInt: A multi-task learning model with automatic feature interaction learning for personalized recommendations [J]. *Information Sciences*, 2024, 665: 120362.
- [20] SU L C, PAN J W, WANG X M, et al. STEM: Unleashing the power of embeddings for multi-task recommendation [J]. *ArXiv preprint arXiv: 2308.13537*, 2024.
- [21] HU ZH ZH, GONG W Y, PEDRV CZ W, et al. Deep reinforcement learning assisted co-evolutionary differential evolution for constrained optimization[J]. *Swarm and Evolutionary Computation*, 2023, 83: 101387.
- [22] 徐静萍, 王文杰, 张鑫. 改进金豺算法的多目标约束问题研究[J]. *电子测量技术*, 2025, 48(23): 108-118.
- [22] XU J P, WANG W J, ZHANG X. Improved golden jackal algorithm for multi-objective constrained problems [J]. *Electronic Measurement Technology*, 2025, 48(23): 108-118.
- [23] 胥圣洁. 几类求解线性约束凸优化问题的增广拉格朗日型乘子法[D]. 哈尔滨: 哈尔滨工业大学, 2023.
- [23] XU SH J. Some augmented Lagrangian like methods for linearly constrained convex optimization [D]. Harbin: Harbin Institute of Technology, 2023.
- [24] STOOKE A, ACHIAM J, ABBEEL P. Responsive safety in reinforcement learning by pid lagrangian methods [C]. *International Conference on Machine Learning*, 2020: 9133-9143.
- [25] TOMAR S, SINGH M, VAIRAVELU K, et al. Simplifying the variational iteration method: A new approach to obtain the Lagrange multiplier [J]. *Mathematics and Computers in Simulation*, 2023, 204: 640-644.
- [26] CALVO-FULLANA M, PATERNAIN S, CHAMON L F O, et al. State augmented constrained reinforcement learning: Overcoming the limitations of learning with rewards [J]. *IEEE Transactions on Automatic Control*, 2023, 69(7): 4275-4290.
- [27] ABBAR A, COINE C, PETITJEAN C. A pre-adjoint approach on weighted composition operators between spaces of Lipschitz functions [J]. *Results in Mathematics*, 2024, 79: 85.
- [28] YUAN G H, YUAN F J, LI Y D, et al. Tenrec: A large-scale multipurpose benchmark dataset for recommender systems [C]. *Neural Information Processing Systems 35*, 2022: 11480-11493.
- [29] YUAN R T, ABDEL-ATY M, XIANG Q J, et al. A temporal multi-gate mixture-of-experts approach for

- vehicle trajectory and driving intention prediction[J]. IEEE Transactions on Intelligent Vehicles, 2023, 9(1): 1204-1216.
- [30] 赵慎, 诸皓冉, 周超, 等. 声学探测无人机中的麦克风立体阵列优化设计[J]. 电子测量与仪器学报, 2025, 39(5): 155-165.
- ZHAO SH, ZHU H R, ZHOU CH, et al. Optimization design of microphone array for acoustic detection drones [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 155-165.
- [31] REYAD M, SARHAN A M, ARAFA M. A modified Adam algorithm for deep neural network optimization[J]. Neural Computing and Applications, 2023, 35(23):

17095-17112.

作者简介

邱继栋, 硕士研究生, 高级工程师, 主要研究方向为指挥控制信息技术。

E-mail: 381374335@qq.com

林泽(通信作者), 硕士研究生, 工程师, 主要研究方向为图像处理、指挥控制信息技术。

E-mail: 966879@qq.com

于靖, 博士研究生, 高级工程师, 主要研究方向为指挥控制信息技术。

关佳兴, 硕士研究生, 高级工程师, 主要研究方向为指挥控制信息技术。

汪亚斌, 博士研究生, 高级工程师, 主要研究方向为指挥控制体系仿真与验证技术。