生成建模流匹配：中英双语方法深读

Flow Matching for Generative Modeling — an original bilingual methods companion

Yaron Lipman · Ricky T. Q. Chen · Heli Ben-Hamu · Maximilian Nickel · Matt Le

底本 arXiv:2210.02747v2（2023-02-08）· 英文原版 28 页
https://arxiv.org/pdf/2210.02747v2
编制日期：2026-11-25

> 原创中英双语方法深读版。覆盖摘要主旨、全部正文核心章节、关键证明与实验数据；英文段落为原创解读，中文为对应讲解。底本 arXiv 许可为非独占分发许可，未将其视为全文翻译授权。本册不冒充逐段全文译本。

阅读路线

摘要导读：把昂贵的轨迹训练改成局部速度监督
第 1 节：为什么终点正确仍然不够
第 2 节：CNF 的三个对象——密度、速度场、流映射
第 3 节：理想 FM 目标为何不可直接算
第 3.1 节：边缘速度是后验加权平均
第 3.2 节：CFM 梯度等价与不可消去的条件方差
第 4 节：高斯条件路径的速度推导
第 4.1 节：扩散路径是可选实例，不是必须的起点
第 4.1 节：条件 OT 路径与“直线”的适用层级
第 5 节：与扩散、CNF 正则化和同期工作的关系
第 6.1 节：密度、FID 与 NFE 的完整核心对照
第 6.1–6.2 节：训练更快、采样更省，分别怎样验证
第 6.3 节：超分辨率的感知质量与像素保真并不一致
附录 A–D：证明、密度评估与数值记号检查
第 7 节与局限性：方法完成了什么，留下了什么
面向 lerobot-flow-matching 与 EEPTV 的联动批注
附录 E：训练预算、去量化与复现实验的口径

摘要导读：把昂贵的轨迹训练改成局部速度监督

英文原文 PDF 第 1 页 · Abstract

这篇论文的关键，是把生成建模写成“先规定概率分布怎样随时间演化，再学习实现这种演化的速度场”。传统 CNF 的最大似然训练需要在每次更新中求解 ODE；流匹配则从预先规定的路径上随机抽取一个时间与位置，用局部速度作为监督，从而把训练主体改成普通回归。真正让它可计算的不是一句“匹配速度”，而是条件构造：每个数据样本对应一条易采样、易求导的路径，所有条件路径的混合能够给出目标边缘路径。

论文还进一步区分“训练目标的选择”与“路径几何的选择”。保留扩散路径、只改用 FM，已经能检验速度回归本身的效果；再改成条件 OT 路径，才能单独观察路径形状的作用。文中的速度与效率结论来自图像实验，不能直接当作机器人 20 ms 控制闭环的实测证据。

第 1 节：为什么终点正确仍然不够

英文原文 PDF 第 1–2 页 · §1 Introduction

只要求最终生成分布接近数据，并没有规定到达终点的道路。两种 ODE 可以有相同的终点分布，却具有完全不同的弯曲程度、速度分配和求解成本。最大似然训练从终点密度出发，通常要把动力学求解嵌入优化；FM 则先选中间分布，把道路直接变成监督信号。

这种改变并不等于把所有 ODE 计算删掉：训练时不必求解模型 ODE，推理时仍要沿学习到的场积分；若要评估密度，还要累计散度。把 simulation-free 译为“无模拟训练”比笼统的“无需求解”更准确。路径设计、网络容量和求解器共同决定最终速度，不能仅从损失函数的形式推算硬件延迟。

第 2 节：CNF 的三个对象——密度、速度场、流映射

英文原文 PDF 第 2 页 · §2, Eqs. (1)–(4)

阅读公式时要始终分清三个对象。$p_t(x)$ 是随时间变化的概率密度；$v_t(x)$ 是位置 x 在时刻 t 的速度；$\phi_t(x_0)$ 是从初始粒子 x_0 积分得到的位置。只有最后一个对象是粒子轨迹。流映射把先验分布推进成中间分布，这就是 push-forward（推前）。

连续性方程描述的是概率质量守恒，不是流体力学中的动量方程。它说明密度如何被速度场搬运，却一般不唯一确定速度场：还可以加入不改变密度演化的环流分量。这样的分量可能让采样绕路。因此，“建模相同的分布路径”并不保证“使用相同的粒子轨迹”。

$$\frac{d}{dt}\phi_t(x_0) = v_t(\phi_t(x_0)), \qquad \phi_0(x_0) = x_0, \qquad p_t = (\phi_t)_{\#}p_0.$$

$$\partial_t p_t + \nabla \cdot (p_t v_t) = 0.$$

第 3 节：理想 FM 目标为何不可直接算

英文原文 PDF 第 2–3 页 · §3, Eq. (5)

理想 FM 目标用边缘路径上的样本，把网络 v_θ 回归到目标边缘速度 u_t。若在整条路径上达到零误差，学到的场就能够产生该路径。但这时训练数据只有来自未知分布 q 的终点样本，既没有边缘密度 p_t 的闭式，也没有 u_t 的闭式。这个目标定义了“要学什么”，尚未说明“怎样抽取训练对”。

CFM 正是为了生成可计算的监督样本而引入，不应把它误解成常见的“给网络多喂一个条件标签”。本论文的 conditional 首先是数学分解：给定终点数据 x_1 的条件路径；网络最终回归的仍然是没有显式 x_1 输入的边缘速度。机器人任务中额外的观测条件 c 是另一层条件变量。

$$\mathcal{L}_{\mathrm{FM}}(\theta) = \mathbb{E}_{t\sim U[0,1],\, x\sim p_t} \|v_\theta(t,x) - u_t(x)\|_2^2.$$

第 3.1 节：边缘速度是后验加权平均

英文原文 PDF 第 3 页 · §3.1, Eqs. (6)–(8), Theorem 1; Appendix A p.14

先对所有终点数据 x_1 混合条件密度，得到边缘密度 $p_t(x)$。边缘速度也要混合，但权重不是均匀的数据权重，而是在当前 x, t 下终点的后验 $p_t(x_1 \mid x)$。当前位置更可能由哪个终点路径产生，那个终点对应的速度就占更大权重。

证明中最有用的一步，是先看概率通量 $p_t u_t$：后验权重中的分母 p_t 被抵消，得到条件通量的直接混合。每条条件路径都满足质量守恒，将其积分后仍然守恒，所以混合场确实产生混合密度。交换求导和积分需要适当正则性；这不是单靠示意图就成立的结论。

$$p_t(x) = \int p_t(x \mid x_1) q(x_1)\, dx_1,$$

$$u_t(x) = \int u_t(x \mid x_1) \frac{p_t(x \mid x_1) q(x_1)}{p_t(x)}\, dx_1 = \mathbb{E}[u_t(x \mid x_1) \mid x_t = x].$$

第 3.2 节：CFM 梯度等价与不可消去的条件方差

英文原文 PDF 第 4 页 · §3.2, Eq. (9), Theorem 2; Appendix A p.14

CFM 的监督目标是每次抽取到的条件速度，而网络只能看到 t, x。平方误差的最优解因此是条件速度在这些可见变量上的条件期望，恰好就是上一节的边缘速度。将条件目标拆成“边缘均值 + 零均值残差”，交叉项在期望下为零，便得到损失分解。

这一步解释了两个常见困惑。第一，CFM 训练损失不一定能降到零，因为同一 x, t 可能来自不同终点路径，目标速度仍有条件方差；这不自动说明边缘场没有学好。第二，两种目标的期望梯度相同，不代表每个 minibatch 梯度、方差和数值条件都相同。实验中的稳定性仍然需要通过实际曲线观察。

$$\mathcal{L}_{\mathrm{CFM}} = \mathbb{E}_{t,x_1,x|x_1}\|v_\theta(t,x) - u_t(x \mid x_1)\|^2,$$

$$\mathcal{L}_{\mathrm{CFM}} = \mathcal{L}_{\mathrm{FM}} + \mathbb{E}\|u_t(x \mid x_1) - u_t(x)\|^2, \qquad \nabla_\theta \mathcal{L}_{\mathrm{CFM}} = \nabla_\theta \mathcal{L}_{\mathrm{FM}}.$$

第 4 节：高斯条件路径的速度推导

英文原文 PDF 第 4–5 页 · §4, Eqs. (10)–(15), Theorem 3; Appendix A pp.14–15

令高斯条件路径的均值为 $\mu_t(x_1)$，标量标准差为 $\sigma_t(x_1) > 0$。最自然的流映射是把标准高斯样本 x_0 做仿射变换。对时间求导时，必须固定初始样本 x_0，得到拉格朗日速度 $\dot{\sigma}_t x_0 + \dot{\mu}_t$；再代入 $x_0 = (x - \mu_t)/\sigma_t$，才得到任意当前位置上的欧拉速度场。

这里的“唯一”针对已选定的仿射流映射，不是说同一高斯密度路径只能由一个场产生。实现时直接监督 $\dot{\sigma}_t x_0 + \dot{\mu}_t$ 往往更方便，不必每次把带小分母的闭式场算一遍。终点若取严格零方差，需要另外处理端点奇性；原文保留 $\sigma_{\min} > 0$。

$$x_t = \psi_t(x_0) = \sigma_t(x_1)x_0 + \mu_t(x_1), \qquad x_0 \sim \mathcal{N}(0, I),$$

$$u_t(x \mid x_1) = \frac{\dot{\sigma}_t(x_1)}{\sigma_t(x_1)}\big(x - \mu_t(x_1)\big) + \dot{\mu}_t(x_1).$$

第 4.1 节：扩散路径是可选实例，不是必须的起点

英文原文 PDF 第 5; 17–19 页 · §4.1 Example I; Appendix D–E.1

本论文将时间设为 $t = 0$ 噪声、$t = 1$ 数据，恰好与通常前向扩散的时间方向相反。把 VP 或 VE 的反向均值、方差代入通用高斯速度公式，就能恢复条件概率流 ODE 的速度。因此，同一分布路径既可由随机扩散推导，也可直接从密度演化构造。

以 VP 为例，设前向时间为 $s = 1 - t$，则 $\alpha_s = \exp[-\frac{1}{2}\int_0^s \beta(r)dr]$，反向路径取均值 $\alpha_{1-t}x_1$、标准差 $\sqrt{1-\alpha_{1-t}^2}$。切换时间方向时速度要变号。原文还指出，标准有限时间扩散通常只近似到纯噪声；直接规定路径则能显式控制初始分布。这个端点差异和训练参数化是两个不同问题。

$$p_t(x \mid x_1) = \mathcal{N}\big(\alpha_{1-t}x_1, (1-\alpha_{1-t}^2)I\big)\,, \qquad \alpha_s = \exp\left[-\frac{1}{2}\int_0^s \beta(r)\,dr\right].$$

第 4.1 节：条件 OT 路径与“直线”的适用层级

英文原文 PDF 第 5–6 页 · §4.1 Example II, Eqs. (20)–(24)

条件 OT 选择让均值与标准差都随时间线性变化。对于固定的 x_0, x_1，路径是直线，速度是常数；当终点标准差为 $\sigma_{\min}$ 时，最终样本是 $x_1 + \sigma_{\min}x_0$，不是严格的数据点 x_1。这种写法给出了可控的有限时间端点，也使回归目标特别简单。

“OT”在这里首先指每个数据终点对应的两个高斯分布之间的位移插值。把这些条件路径混合，并不意味着边缘噪声分布到整个数据分布之间的全局最优传输已被求出。边缘场是后验平均，可能随位置与时间改变方向；学习到的边缘轨迹也可能弯曲。将条件直线直接等同于一步精确生成，是越过了论文明确保留的层级区别。

$$a_t = 1 - (1-\sigma_{\min})t, \qquad x_t = a_t x_0 + t x_1,$$

$$\dot{x}_t = x_1 - (1-\sigma_{\min})x_0, \qquad u_t(x \mid x_1) = \frac{x_1 - (1-\sigma_{\min})x}{a_t}.$$

$$\mathcal{L}_{\mathrm{OT-CFM}} = \mathbb{E}\left\|v_\theta(t, a_t x_0 + t x_1) - \left[x_1 - (1-\sigma_{\min})x_0\right]\right\|^2.$$

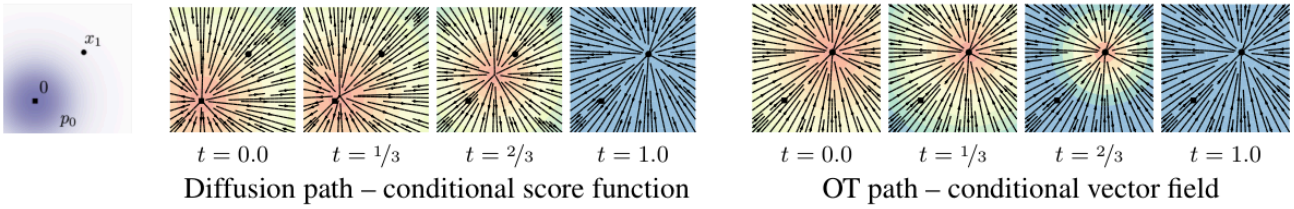

图 2：扩散条件得分与 OT 条件速度场。读图先分清左侧回归对象是 score，右侧是 velocity；颜色表示向量幅度，不是概率质量。沿同一条 OT 条件轨迹，速度不随时间改变。

来源：Lipman et al., arXiv:2210.02747v2, p.6, Figure 2；中文解释为本导读原创。

第 5 节：与扩散、CNF 正则化和同期工作的关系

英文原文 PDF 第 6–7 页 · §5 Related Work

相关工作中有两条轴线：一条是仍按最大似然训练 CNF，只用正则项、增广或结构约束让 ODE 更易求解；另一条是直接指定可采样的路径，用回归绕开训练中的轨迹求解。FM 属于后者。它与去噪得分匹配共享“条件目标替代边缘目标”的统计结构，但回归对象从 score 推广为生成分布路径的速度。

论文也明确列出同期的 Rectified Flow 与随机插值相关工作。比较这几条线索时，应看它们对条件路径、端点耦合、理论目标与推理加速分别做了什么，而不是简单争论“谁先把噪声和数据连成直线”。本册与下一册连读时，CFM 的梯度等价和 RF 的耦合重整分别是最值得保留的理论贡献。

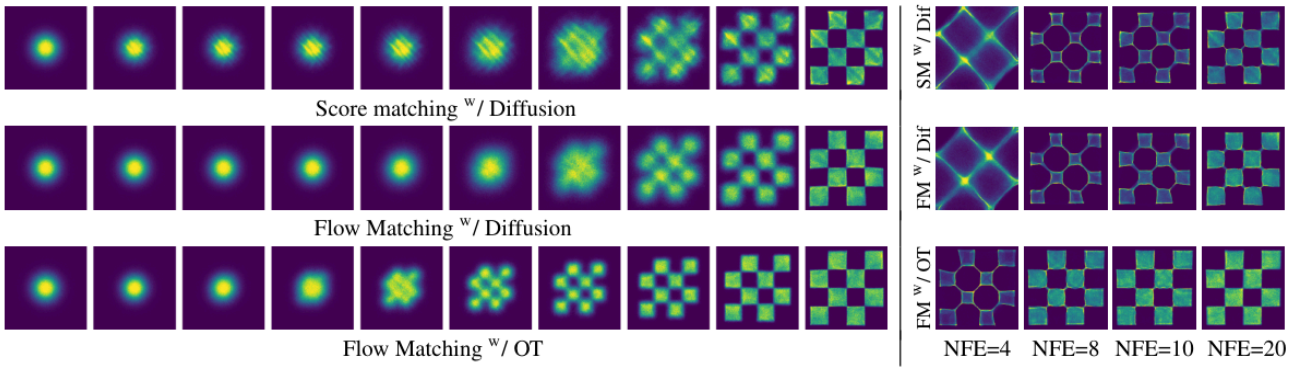

图 4：二维棋盘分布与低 NFE 采样。左组用于观察概率质量何时形成棋盘结构，右组比较同一 midpoint 求解器在不同 NFE 预算下的采样形状；图中少步可见结构不等于任意任务一步精确。
来源：Lipman et al., arXiv:2210.02747v2, p.7, Figure 4；中文解释为本导读原创。

第 6.1 节：密度、FID 与 NFE 的完整核心对照

英文原文 PDF 第 7–8 页 · §6–6.1; Table 1; Appendix E pp.19–21

核心消融采用基本相同的 U-Net 架构，分别训练 DDPM、Score Matching、ScoreFlow、扩散路径 FM 与 OT 路径 FM。NLL 表示概率建模质量，FID 表示生成图像分布的特征距离，NFE 表示自适应求解器达到给定容差所需的网络调用次数；三者不能相互替代。标准评估采用 dopri5，相对与绝对容差均为 10^{-5}，采样指标基于 50k 样本。

下表逐行复录核心三数据集对照。FM-OT 在每一列组内都取得最低 NLL、FID 与 NFE。以 ImageNet-64 为例，DDPM 的 NFE 为 264，FM-OT 为 138，调用数减少约 47.7%；这还不是端到端延迟同比降低 47.7%，因为单次网络成本、批量和求解器开销也要计入。ImageNet-128 的 FM-OT 另报 NLL 2.90、FID 20.9，不与这里的低分辨率行横向拼接。

方法	CIFAR-10 NLL / FID / NFE	ImageNet-32 NLL / FID / NFE	ImageNet-64 NLL / FID / NFE
DDPM	3.12 / 7.48 / 274	3.54 / 6.99 / 262	3.32 / 17.36 / 264
Score Matching	3.16 / 19.94 / 242	3.56 / 5.68 / 178	3.40 / 19.74 / 441
ScoreFlow	3.09 / 20.78 / 428	3.55 / 14.14 / 195	3.36 / 24.95 / 601
FM + Diffusion	3.10 / 8.06 / 183	3.54 / 6.37 / 193	3.33 / 16.88 / 187
FM + OT	2.99 / 6.35 / 142	3.53 / 5.02 / 122	3.31 / 14.45 / 138

	CIFAR-10			ImageNet 32×32			ImageNet 64×64		
Model	NLL↓	FID↓	NFE↓	NLL↓	FID↓	NFE↓	NLL↓	FID↓	NFE↓
Ablations									
DDPM	3.12	7.48	274	3.54	6.99	262	3.32	17.36	264
Score Matching	3.16	19.94	242	3.56	5.68	178	3.40	19.74	441
ScoreFlow	3.09	20.78	428	3.55	14.14	195	3.36	24.95	601
Ours									
FM ^{w}/ Diffusion	3.10	8.06	183	3.54	6.37	193	3.33	16.88	187
FM ^{w}/ OT	**2.99**	**6.35**	**142**	**3.53**	**5.02**	**122**	**3.31**	**14.45**	**138**

	ImageNet 128×128	
Model	NLL↓	FID↓
MGAN (Hoang et al., 2018)	–	58.9
PacGAN2 (Lin et al., 2018)	–	57.5
Logo-GAN-AE (Sage et al., 2018)	–	50.9
Self-cond. GAN (Lučić et al., 2019)	–	41.7
Uncond. BigGAN (Lučić et al., 2019)	–	25.3
PGMGAN (Armandpour et al., 2021)	–	21.7
FM ^{w}/ OT	**2.90**	**20.9**

表 1 原表裁图：NLL 的单位为 bits/dim；FID、NLL、NFE 均越小越好。下方中文表复录左表的完整三数据集系列，避免把不同分辨率混在同一比较中。

来源：Lipman et al., arXiv:2210.02747v2, p.8, Table 1；中文解释为本导读原创。

第 6.1–6.2 节：训练更快、采样更省，分别怎样验证

英文原文 PDF 第 8–9 页 · §6.1 faster training; §6.2; Figures 5–7

论文的训练曲线支持 FM-OT 在所用设置下更快降低 FID，但“训练迭代更少”不能独立等价为“总训练成本同比更少”。ImageNet-128 的比较中，FM 使用约大 25% 的模型、500k 次更新、batch 约 1.5k；对照为 4.36m 次、batch 256。原文因此额外讨论图像吞吐量，而不是只比更新次数。

低成本采样实验也分两层：一层固定随机种子，用低 NFE 结果与 1000 NFE 参考结果计算逐像素 MSE；另一层看大量样本的 FID。前者检验数值近似，后者检验生成效果。原文在 ImageNet-32 的比较中发现，FM-OT 达到相同数值误差约需扩散模型 60% 的 NFE。这个量是特定容差与实验下的经验结果，不是对所有模型的固定常数。

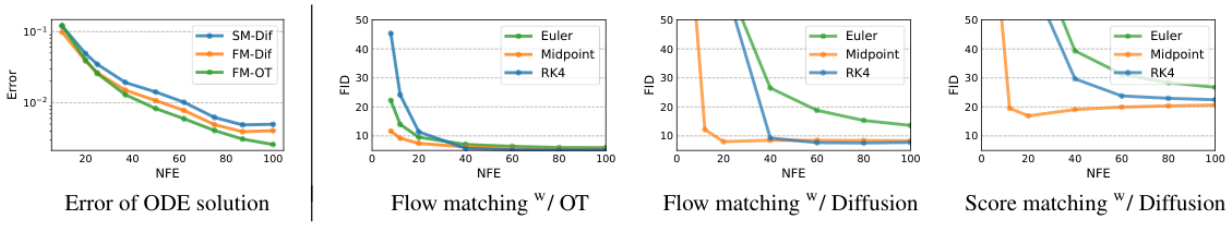

图 7：在同一 ImageNet-32 实验中区分数值误差与样本质量。左图以高 NFE 结果为数值参考，右侧三图比较不同求解器的 FID—NFE 曲线；两种纵轴不应相互替代。

来源：Lipman et al., arXiv:2210.02747v2, p.9, Figure 7；中文解释为本导读原创。

第 6.3 节：超分辨率的感知质量与像素保真并不一致

英文原文 PDF 第 9 页 · §6.3; Table 2; Appendix Figures 14–15

条件生成实验将 64×64 图像提升到 256×256。FM-OT 的 FID 与 IS 优于 SR3，但 PSNR、SSIM 更低。把“像素指标相近”译成“所有指标都更好”会掩盖实际取舍：生成模型可以给出更像自然图像的纹理，却未必逐像素更接近参考。

这对 EEPTV 等定量测量尤其重要。若下游依赖粒子质心、亮度或速度梯度，感知上更逼真的细节也可能改变物理量。不能以 FID 的改善替代测量误差验证。若把 FM 用作超分或去噪前端，应另行报告位置偏差、轨迹误差、速度与不确定度。

方法	FID ↓	IS ↑	PSNR ↑	SSIM ↑
Reference	1.9	240.8	—	—
Regression	15.2	121.1	27.9	0.801
SR3	5.2	180.1	26.4	0.762
FM + OT	3.4	200.8	24.7	0.747

附录 A–D：证明、密度评估与数值记号检查

英文原文 PDF 第 14–18 页 · Appendices A–D, Eqs. (25)–(41)

附录 A 给出三个理论结果的证明，B 把连续性方程作为生成路径的判据，C 说明如何计算 CNF 密度，D 则核对 VE/VP 与概率流 ODE 的一致性。密度评估沿轨迹累计负散度；如果给定的是测试数据点，就需从终点反向积分增广系统，恢复先验点和对数密度修正。

高维散度可用 Hutchinson 估计：对满足 $\mathbb{E}[zz^\top] = I$ 的随机向量，$z^\top J_v z$ 的期望为 Jacobian 的迹。原文小标题有时写“概率的无偏估计”，但推导与式 (35) 实际得到的是对数密度估计；把它取指数后一般不保持无偏。本导读按公式的统计含义表述。公式中的 Jacobian 修正还必须包括数据缩放，例如从像素单位到归一化区间的变换。

$$\frac{d}{dt}\log p_t(\phi_t(x_0)) = -\nabla\cdot v_t(\phi_t(x_0)),$$

$$\operatorname{tr} J_v = \mathbb{E}_z[z^\top J_v z], \qquad \mathbb{E}[zz^\top] = I.$$

第 7 节与局限性：方法完成了什么，留下了什么

英文原文 PDF 第 9; 19–28 页 · §7 Conclusion; Appendix E–F

论文完成的是一种可扩展的连续流训练方式：在可构造条件路径的前提下，直接回归局部速度。其边界也应与贡献一起阅读。条件 OT 不保证全局边缘 OT；有限网络只能近似目标场；$\sigma_{\min} > 0$ 引入终点平滑；推理的数值积分还有离散化误差。降低其中一项，不会自动消去其他项。

这篇论文没有单独设置一个完整的局限性章节。本节将方法假设、实验口径及正文明确保留的区别集中整理。附录的实现参数和样本图库支持复现图像实验，但没有机器人闭环、事件相机或工业测速的实测。因此跨领域应用应继承目标函数与路径设计，而不是继承未经验证的延迟和物理精度结论。

面向 lerobot-flow-matching 与 EEPTV 的联动批注

英文原文 PDF 第 2–9; 14–21 页 · Reader analysis grounded in §§2–6; not source experiment

对 lerobot-flow-matching，可把终点 x_1 换成标准化后的动作块 $a_{1:H}$，把图像与状态观测记为条件 c，学习 $v_\theta(t, a_t, c)$。动作各维度应采用明确且一致的尺度，否则同一个 L2 损失会让大数值单位支配训练。生成时间 $t \in [0,1]$ 是内部积分坐标；控制周期则是墙钟时间，两者不可混同。

优先建立三个分开的基线：高精度求解器作为数值参考；相同权重的少步求解器用于量化离散化损失；实际闭环任务用于量化动作误差如何影响成功率。若目标周期为 20 ms，必须将视觉编码、网络调用、数据传输、执行器接口与调度抖动一并纳入预算。

对 EEPTV，概率流中的速度是“样本空间随生成时间演化的导数”，不是图像光流，也不是粒子在物理时间中的速度。可以研究条件轨迹分布或缺失观测补全，但最终仍需用物理时间戳、标定尺度和独立轨迹真值检查测量误差。

$$\mathcal{L} = \mathbb{E}\|v_\theta(t, a_t, c) - (a_1 - a_0)\|^2, \qquad a_t = (1-t)a_0 + t a_1 \quad (\sigma_{\min} = 0 \text{ 的实现特例}).$$

附录 E：训练预算、去量化与复现实验的口径

英文原文 PDF 第 19–21 页 · Appendix E; Tables 3–4

附录 E 明确了硬件规模与精度：CIFAR-10、ImageNet-32 使用全 32 位训练，ImageNet-64/128 使用 16 位混合精度。优化器是 Adam，参数为 $\beta_1=0.9$、$\beta_2=0.999$、weight decay=0、$\varepsilon=10^{-8}$。下表列出主要训练预算；同一数据集内的主要消融按相同架构与参数比较，跨数据集的 NFE 和训练步数则不能直接当作相同计算量。

NLL 使用均匀去量化，且会对多个去量化样本的重要性加权估计取对数，因此 K 会影响 BPD。原文表 4 的 CIFAR-10 使用 K=1/20/50，ImageNet-32 为 1/5/15，ImageNet-64 为 1/5/10。主表 1 与附表 4 的 ImageNet-32 条目存在小差异：FM-Diffusion 在主表为 3.54，而附表 K=15 为 3.56；Score Matching 对应为 3.56 与 3.57。本导读主表按表 1 保留，未擅自把这两组数合并。

数据集	有效 batch	GPU 数	更新次数	学习率
CIFAR-10	256	2	391k	5×10^{-4}
ImageNet-32	1024	4	250k	10^{-4}
ImageNet-64	2048	16	157k	10^{-4}
ImageNet-128	1536	32	500k	10^{-4}

统一术语与符号

English / Symbol	中文与含义
flow matching (FM)	流匹配；对目标速度场做局部回归
conditional flow matching (CFM)	条件流匹配；条件目标替代不可积的边缘目标
continuous normalizing flow (CNF)	连续归一化流；由 ODE 定义可逆流映射
probability path	概率分布路径，不是单条粒子轨迹
conditional / marginal vector field	条件 / 边缘速度场，二者通过后验期望连接
push-forward	推前；把输入分布经映射变成输出分布
displacement interpolation	位移插值
score	得分函数，即对数密度对状态的梯度
NFE	函数评估次数；本实验中主要是网络调用数
NLL / BPD	负对数似然 / 每维比特数
q / p_t / x_0 / x_1	数据分布 / 路径密度 / 先验样本 / 数据终点
σmin	终点条件标准差，非时间步长

来源与使用说明

原论文作者与书目信息见扉页。英文原版单独保存，出处：https://arxiv.org/abs/2210.02747 。arXiv 许可：https://arxiv.org/licenses/nonexclusive-distrib/1.0/ 。本文为原创方法导读，英文 commentary 不是论文 Original 段落；提取图表仅伴随定点学术解释，版权归原权利人。未复录全文、完整图注或完整参考文献。