

Lecture 14 - Simulated Annealing & AI for COP

赵尉辰

南开大学 统计与数据科学学院

目录

- 1 AI 与 AI for Science
- 2 模拟退火
- 3 基于退火的深度学习求解QUBO的方法


目录

- 1 AI 与 AI for Science
- 2 模拟退火
- 3 基于退火的深度学习求解QUBO的方法

人工智能



深度神经网络



用矩阵形式表示:

$$H_{l+1} = \sigma(H_l W_l + b_l), \quad l = 1, 2, \dots, L$$

神经网络的优化

- 梯度下降法

$$\Theta^{(k+1)} = \Theta^{(k)} - \eta_k \frac{1}{N} \sum_{i=1}^N \nabla_{\Theta^{(k)}} \mathcal{L}(f(x_i, \Theta^{(k)}), y_i)$$

- 反向传播算法

通过复合函数求导的链式法则，来计算每层参数的梯度。

- 随机梯度下降法&Mini-batch梯度下降法

$$\Theta^{(k+1)} = \Theta^{(k)} - \eta_k \nabla_{\Theta^{(k)}} \mathcal{L}(f(x_i, \Theta^{(k)}), y_i)$$

$$\Theta^{(k+1)} = \Theta^{(k)} - \eta_k \frac{1}{B} \sum_{i \in \mathcal{B}} \nabla_{\Theta^{(k)}} \mathcal{L}(f(x_i, \Theta^{(k)}), y_i)$$

其中 $\mathcal{B} \subset \{1, 2, \dots, N\}$, $B := |\mathcal{B}| < N$.

深度学习方法的优势

- 数据驱动的高效表示；
- 端到端的能力；
- 泛化能力；
- 大规模并行计算(GPU)。

AI for Science

THE NOBEL PRIZE IN CHEMISTRY 2024



David
Baker

Demis
Hassabis

John M.
Jumper

AI for Science¹

- 生命科学：蛋白质结构预测、蛋白质结合点位预测、蛋白质设计...
- 化学材料：分子表示、新材料发现、化学分子设计、分子动力学模拟...
- 物理：量子自旋系统基态表示...
- 医学：药物设计...
- 数学：偏微分方程数值解、组合优化求解...

¹Zhang X, Wang L, Helwig J, et al. Artificial intelligence for science in quantum, atomistic, and continuum systems[J]. arXiv preprint arXiv:2307.08423, 2023

AI for COP²

组合优化问题(Combinatorial Optimization Problem, COP)是非常重要的问题。传统求解方法(精确算法、近似算法、启发式算法...)存在以下局限性:

- 计算复杂度高: 组合优化问题通常是NP难的, 传统精确算法在问题规模较大时计算时间呈指数级增长, 难以实际应用。
- 算法设计依赖经验: 人工设计算法对领域知识依赖性强, 且难以泛化到不同问题实例。
- 适应性不足: 实际场景中约束条件或目标函数可能随时间变化, 传统方法需要反复重新求解, 效率低下。

²Guo T D, Li A Q, Han C Y. Machine learning method for combinatorial optimization problems (in Chinese). Sci Sin Math, 2025, 55: 1–30, doi: 10.1360/SSM-2024-0180

目录

- 1 AI 与 AI for Science
- 2 模拟退火**
- 3 基于退火的深度学习求解QUBO的方法

模拟退火算法

回顾Boltzmann分布/Gibbs测度，在一个由 N 个粒子组成的系统中，当系统处于温度 T 时，粒子在能量为 E_i 的状态下的概率 P_i 由以下公式给出：

$$P_i = \frac{e^{-\beta E_i}}{Z}$$

其中 $\beta = \frac{1}{k_B T}$, $Z \triangleq \sum_j e^{-\beta E_j}$.

考察 $T \rightarrow \infty$ 时，对于每个状态 $i \in \mathcal{S}$,

$$e^{-\beta E_i} = e^0 = 1$$

所以高温状态下，所有可能出现的状态是等概率的

$$\lim_{T \rightarrow \infty} P_i = \frac{1}{|\mathcal{S}|}$$

模拟退火算法

考察退火过程, $T \rightarrow 0$ 时,

$$\begin{aligned}
 \lim_{T \rightarrow 0} P_i &= \lim_{T \rightarrow 0} \frac{1}{Z} \exp \left(-\frac{E_i}{kT} \right) \\
 &= \lim_{T \rightarrow 0} \frac{\exp \left(-\frac{E_i - E_{\min}}{kT} \right)}{\sum_{i \in \mathcal{S}} \exp \left(-\frac{E_i - E_{\min}}{kT} \right)} \\
 &= \lim_{T \rightarrow 0} \frac{\exp \left(-\frac{E_i - E_{\min}}{kT} \right)}{\sum_{i \in \mathcal{S}_{\min}} \exp \left(-\frac{E_i - E_{\min}}{kT} \right) + \sum_{i \notin \mathcal{S}_{\min}} \exp \left(-\frac{E_i - E_{\min}}{kT} \right)} \\
 &= \begin{cases} \frac{1}{|\mathcal{S}_{\min}|}, & i \in \mathcal{S}_{\min} \\ 0, & i \notin \mathcal{S}_{\min} \end{cases}
 \end{aligned}$$

其中 $E_{\min} = \min_{i \in \mathcal{S}} E_i$, $\mathcal{S}_{\min} = \{i : E_i = E_{\min}\}$. 这表明, 随着温度降低, 粒子会倾向于能量最低的状态中去。

模拟退火算法

模拟退火(Simulated Annealing)是一种优化算法，它的基本想法是：把优化的目标函数 f 当作是物理中的能量函数，然后通过退火，即 $T \rightarrow 0$ ，求得 f 的全局最小值。

那么优化问题转化成了：如何采样Boltzmann分布

模拟退火算法能保证收敛到全局最小值³。

模拟退火算法可以求解组合优化问题。

³Holley R A, Kusuoka S, Stroock D W. Asymptotics of the spectral gap with applications to the theory of simulated annealing[J]. J. Funct. Anal, 1989, 83(2):333-347.

目录

- 1 AI 与 AI for Science
- 2 模拟退火
- 3 基于退火的深度学习求解QUBO的方法**

Quadratic Unconstrained Binary Optimization (QUBO)

定义 1 (Quadratic Unconstrained Binary Optimization)

QUBO 问题定义为

$$\begin{aligned} \min x^T Q x \\ s.t. \quad x \in S \end{aligned}$$

其中 S 是一个二元(binary)离散空间 $\{0, 1\}^n$ 或者 $\{-1, 1\}^n$, $Q \in \mathbb{R}^{n \times n}$ 为一个 n 维方阵。

QUBO是一类非常广泛的问题，能够涵盖很多优化问题⁴：二次指派问题、背包问题、最大团问题、最大独立集问题、最大割问题、图染色问题、集合划分问题、约束满足问题、.....

⁴Kochenberger G, Hao J K, Glover F, et al. The unconstrained binary quadratic programming problem: a survey[J]. Journal of combinatorial optimization, 2014, 28: 58-81.

QUBO 与 Ising 模型⁵

设有 n 个粒子，每个粒子的自旋(spin) $\sigma_i = -1$ 或者 1 ，那么 n 个粒子的自旋组成一种构型/状态(configuration) $\sigma = (\sigma_i)$ ，记构型空间 $S := \{+1, -1\}^n$ 。

定义 2 (Ising模型)

构型空间 S 上定义如下的能量函数/哈密顿量(*energy function/Hamiltonian*):

$$E(\sigma) = - \sum_{ij \text{ 相邻}} J_{ij} \sigma_i \sigma_j - h \sum_i \sigma_i$$

称为Ising模型，其中 J_{ij} 是相互作用强度， h 是外场强度， $-\sum_{ij \text{ 相邻}} J_{ij} \sigma_i \sigma_j$ 表示相邻格点对上自旋相互作用对能量的贡献， $-h \sum_i \sigma_i$ 表示外场带来的势能。

Ising 模型的能量函数 $E(\sigma)$ 和 QUBO 的优化目标 $f(x) = x^T Q x$ 是一致的。

⁵Lucas A. Ising formulations of many NP problems[J]. Frontiers in physics, 2014, 2: 5.

QUBO 与 Ising 模型

回顾退火方法，当统计物理系统处于平衡时，粒子分布服从Boltzmann-Gibbs分布

$$p(\sigma, \beta) = \frac{e^{-\beta E(\sigma)}}{Z}$$

而系统平衡时会倾向于处于能量最低的状态，所以我们从中采样构型 σ ，大概率会使得能量函数 $E(\sigma)$ 处于最小值，那么根据 QUBO 与 Ising 模型的关系，此时的 σ 大概率为 QUBO 问题的解。

直接从

$$p(x) = \lim_{\beta \rightarrow \infty} p(x, \beta) = \lim_{\beta \rightarrow \infty} \frac{e^{-\beta f(x)}}{Z} = \lim_{\beta \rightarrow \infty} \frac{e^{-\beta x^T Q x}}{Z}$$

离散采样得到 x 即可求解QUBO问题。⁶

⁶Sun H, Goshvadi K, Nova A, et al. Revisiting sampling for combinatorial optimization[C]//International Conference on Machine Learning. PMLR, 2023: 32859-32874.

基于退火求解QUBO

基于退火方法求解 QUBO 已经转化为从 $p(x, \beta) = \frac{e^{-\beta x^T Q x}}{Z}$ 中采样的问题。按是否使用深度学习可以分成两类方法：

- 经典方法直接采样，例如MCMC (online method)⁷；
- 首先训练一个深度学习模型 $q_\theta(x, \beta)$ 来近似 $p(x, \beta)$ ，然后用模型 $q_\theta(x, \beta)$ 输出样本 (offline training + online inference)

我们接下来关注第二类方法。

⁷Sun H, Goshvadi K, Nova A, et al. Revisiting sampling for combinatorial optimization[C]//International Conference on Machine Learning. PMLR, 2023: 32859-32874.

基于退火求解QUBO的深度学习方法

训练 $q_\theta(x, \beta)$ 近似 $p(x, \beta)$ 有两个关键问题:

- 如何构建损失函数?

在机器学习中一个常见的度量两个分布之间距离的损失函数是KL散度

$$D_{KL}(p(x, \beta) || q_\theta(x, \beta)) \triangleq \int p(x, \beta) \log \frac{p(x, \beta)}{q_\theta(x, \beta)} dx \approx \frac{1}{N} \sum_{n=1}^N \log \frac{p(X_n, \beta)}{q_\theta(X_n, \beta)}$$

其中 $X_n \sim p(x, \beta)$ ，但是我们要处理的是采样问题，没有 $p(x, \beta)$ 的样本。

- 如何建模 $q_\theta(x, \beta)$?

这对应了不同的模型。

损失函数

Inverse KL 散度

$$\begin{aligned}
 D_{KL}(q_{\theta}(x, \beta) || p(x, \beta)) &\triangleq \int q_{\theta}(x, \beta) \log \frac{q_{\theta}(x, \beta)}{p(x, \beta)} dx \\
 &= \int q_{\theta}(x, \beta) (\log q_{\theta}(x, \beta) + \beta f(x) + \log Z) dx \\
 &:= \beta(F_q(\theta, \beta) - F)
 \end{aligned}$$

其中

$$F_q(\theta, \beta) = \frac{1}{\beta} \int q_{\theta}(x, \beta) (\log q_{\theta}(x, \beta) + \beta f(x)), \quad F = -\frac{1}{\beta} \log Z.$$

那么我们的优化目标转化为

$$\min_{\theta} D_{KL}(q_{\theta}(x, \beta) || p(x, \beta)) \Leftrightarrow \min_{\theta} F_q(\theta, \beta).$$

平均场近似⁸

建模 $q_{\theta}(x, \beta)$ 的一个平凡的方法是用平均场近似(Mean-Field Approximation):

$$q_{\theta}(x, \beta) = \prod_i q_{\theta}(x_i, \beta)$$

其中 x_i 是高维向量 x 的第 i 个分量，独立地优化 $q_{\theta}(x_i, \beta)$ 即可。

这种建模方法比较简单，难以近似复杂的分布 $p(x, \beta)$ 。

⁸Shen Z S, Pan F, Wang Y, et al. Free-energy machine for combinatorial optimization[J]. Nature Computational Science, 2025: 1-11.

自回归建模⁹

自回归建模 (Autoregressive Modelling) 方法:

$$q_{\theta}(x, \beta) = \prod_i q_{\theta}(x_i | x_1, \dots, x_{i-1}; \beta)$$

运用策略梯度 (policy gradient) 方法训练

$$\beta \nabla_{\theta} F_q(\theta, \beta) = \mathbb{E}_{x \sim q_{\theta}(x, \beta)} (\nabla \log q_{\theta}(x, \beta) (\log q_{\theta}(x, \beta) + \beta f(x)))$$

这种建模方法一旦解的前几个分量 $x_1, x_2, \dots$ 有错误, 便只能将错就错下去。

⁹Sanokowski S, Berghammer W, Hochreiter S, et al. Variational annealing on graphs for combinatorial optimization[J]. Advances in Neural Information Processing Systems, 2023, 36: 63907-63930.

扩散模型建模¹⁰

关于KL散度，一个基本的观察是：

$$D_{KL}(q_{\theta}(x) \| p(x)) \leq D_{KL}(q_{\theta}(x, z) \| p(x, z))$$

其中

$$q_{\theta}(x, z) = q_{\theta}(x | z)q(z), \quad p(x, z) = p(x | z)q(z)$$

我们可以通过优化上界来优化 $D_{KL}(q_{\theta}(x) \| p(x))$

扩散模型中加噪的过程可以对应到这里的 z ，这启发我们用扩散模型来建模 $q_{\theta}(x, z)$


¹⁰Sanowski S, Hochreiter S, Lehner S. A diffusion model framework for unsupervised neural combinatorial optimization[C]//Proceedings of the 41st International Conference on Machine Learning. 2024: 43346-43367.

Denoising Diffusion Probabilistic Models, DDPM¹¹

Forward/Diffusion Process



Reverse/Denoise Process



¹¹Denoising diffusion probabilistic models. Advances in Neural Information Processing Systems, 33, 2020

Forward Diffusion Process

- 一步加噪过程

$$q(\mathbf{x}_t | \mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{\alpha_t} \mathbf{x}_{t-1}, (1 - \alpha_t) \mathbf{I})$$

$$\mathbf{x}_t = \sqrt{\alpha_t} \mathbf{x}_{t-1} + \sqrt{(1 - \alpha_t)} \boldsymbol{\epsilon}_{t-1}, \quad \text{where } \boldsymbol{\epsilon}_{t-1} \sim \mathcal{N}(0, \mathbf{I}).$$

- t 步加噪过程

命题 1

条件分布 $q(\mathbf{x}_t | \mathbf{x}_0)$ 为

$$q(\mathbf{x}_t | \mathbf{x}_0) = \mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t} \mathbf{x}_0, (1 - \bar{\alpha}_t) \mathbf{I}),$$

其中 $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$. 即 $\mathbf{x}_t = \sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \boldsymbol{\epsilon}_0$.

能够计算 $q(\mathbf{x}_t | \mathbf{x}_0)$ 的好处在于给定 $\mathbf{x}_0$, 给一个 t , 可以直接得到 $\mathbf{x}_t$.

Proof

$$\begin{aligned}
 \mathbf{x}_t &= \sqrt{\alpha_t} \mathbf{x}_{t-1} + \sqrt{1 - \alpha_t} \epsilon_{t-1} \\
 &= \sqrt{\alpha_t} (\sqrt{\alpha_{t-1}} \mathbf{x}_{t-2} + \sqrt{1 - \alpha_{t-1}} \epsilon_{t-2}) + \sqrt{1 - \alpha_t} \epsilon_{t-1} \\
 &= \sqrt{\alpha_t \alpha_{t-1}} \mathbf{x}_{t-2} + \underbrace{\sqrt{\alpha_t} \sqrt{1 - \alpha_{t-1}} \epsilon_{t-2} + \sqrt{1 - \alpha_t} \epsilon_{t-1}}_{\mathbf{w}_1}.
 \end{aligned}$$

由于 ϵ_{t-2} 和 ϵ_{t-1} 都是标准高斯的， $\mathbf{w}_1$ 是均值为0的高斯，我们下面计算协方差

$$\begin{aligned}
 \mathbb{E}[\mathbf{w}_1 \mathbf{w}_1^T] &= [(\sqrt{\alpha_t} \sqrt{1 - \alpha_{t-1}})^2 + (\sqrt{1 - \alpha_t})^2] \mathbf{I} \\
 &= [\alpha_t (1 - \alpha_{t-1}) + 1 - \alpha_t] \mathbf{I} = [1 - \alpha_t \alpha_{t-1}] \mathbf{I}.
 \end{aligned}$$

延用记号 ϵ_t

$$\begin{aligned}
 \mathbf{x}_t &= \sqrt{\alpha_t \alpha_{t-1}} \mathbf{x}_{t-2} + \sqrt{1 - \alpha_t \alpha_{t-1}} \epsilon_{t-2} \\
 &= \sqrt{\alpha_t \alpha_{t-1} \alpha_{t-2}} \mathbf{x}_{t-3} + \sqrt{1 - \alpha_t \alpha_{t-1} \alpha_{t-2}} \epsilon_{t-3} \\
 &= \cdots = \sqrt{\prod_{i=1}^t \alpha_i} \mathbf{x}_0 + \sqrt{1 - \prod_{i=1}^t \alpha_i} \epsilon_0.
 \end{aligned}$$

Reverse Denoising Process

我们希望用一个神经网络实现降噪过程，即

$$p_{\theta}(\mathbf{x}_{t-1}|\mathbf{x}_t) \approx q(\mathbf{x}_{t-1}|\mathbf{x}_t)$$

由Markov性，

$$q(\mathbf{x}_t|\mathbf{x}_{t-1}) = \frac{q(\mathbf{x}_{t-1}|\mathbf{x}_t)q(\mathbf{x}_t)}{q(\mathbf{x}_{t-1})} \xrightarrow{\text{condition on } \mathbf{x}_0} q(\mathbf{x}_t|\mathbf{x}_{t-1}, \mathbf{x}_0) = \frac{q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0)q(\mathbf{x}_t|\mathbf{x}_0)}{q(\mathbf{x}_{t-1}|\mathbf{x}_0)}$$

在优化神经网络的过程中转化为¹²¹³

$$p_{\theta}(\mathbf{x}_{t-1}|\mathbf{x}_t) \approx q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0)$$

¹²Luo C. Understanding diffusion models: A unified perspective[J]. arXiv preprint arXiv:2208.11970, 2022.

¹³Chan S H. Tutorial on Diffusion Models for Imaging and Vision[J]. arXiv preprint arXiv:2403.18103, 2024.

Reverse Denoising Process

命题 2

条件分布 $q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0)$ 为一个高斯分布 $\mathcal{N}(\mathbf{x}_{t-1}; \boldsymbol{\mu}_q(\mathbf{x}_t, \mathbf{x}_0), \boldsymbol{\Sigma}_q(t))$, 其中

$$\boldsymbol{\mu}_q(\mathbf{x}_t, \mathbf{x}_0) = \frac{(1 - \bar{\alpha}_{t-1})\sqrt{\alpha_t}}{1 - \bar{\alpha}_t} \mathbf{x}_t + \frac{(1 - \alpha_t)\sqrt{\bar{\alpha}_{t-1}}}{1 - \bar{\alpha}_t} \mathbf{x}_0$$

$$\boldsymbol{\Sigma}_q(t) = \frac{(1 - \alpha_t)(1 - \sqrt{\bar{\alpha}_{t-1}})}{1 - \bar{\alpha}_t} \mathbf{I}$$

$$\begin{aligned} q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0) &= \frac{q(\mathbf{x}_t|\mathbf{x}_{t-1}, \mathbf{x}_0)q(\mathbf{x}_{t-1}|\mathbf{x}_0)}{q(\mathbf{x}_t|\mathbf{x}_0)} \\ &= \frac{\mathcal{N}(\mathbf{x}_t; \sqrt{\alpha_t}\mathbf{x}_{t-1}, (1 - \alpha_t)\mathbf{I})\mathcal{N}(\mathbf{x}_{t-1}; \sqrt{\bar{\alpha}_{t-1}}\mathbf{x}_0, (1 - \bar{\alpha}_{t-1})\mathbf{I})}{\mathcal{N}(\mathbf{x}_t; \sqrt{\bar{\alpha}_t}\mathbf{x}_0, (1 - \bar{\alpha}_t)\mathbf{I})} \\ &\propto \exp \left\{ - \left[\frac{(\mathbf{x}_t - \sqrt{\alpha_t}\mathbf{x}_{t-1})^2}{2(1 - \alpha_t)} + \frac{(\mathbf{x}_{t-1} - \sqrt{\bar{\alpha}_{t-1}}\mathbf{x}_0)^2}{2(1 - \bar{\alpha}_{t-1})} - \frac{(\mathbf{x}_t - \sqrt{\bar{\alpha}_t}\mathbf{x}_0)^2}{2(1 - \bar{\alpha}_t)} \right] \right\} \end{aligned}$$

Reverse Denoising Process

注意到，给定加噪schedule， $\Sigma_q(t)$ 是已知的，所以我们只需要参数化均值部分，即

$$p_{\theta}(x_{t-1}|x_t) = \mathcal{N}(x_{t-1}; \mu_{\theta}, \Sigma_q(t))$$

两个高斯分布之间的KL散度¹⁴可以容易计算：

$$D_{\text{KL}}(q(x_{t-1}|x_t, x_0) \parallel p_{\theta}(x_{t-1}|x_t)) = \frac{1}{2\Sigma_q^2(t)} \left[\|\mu_{\theta} - \mu_q\|_2^2 \right]$$

注意到

$$\begin{aligned} \mu_q(x_t, x_0) &= \frac{(1 - \bar{\alpha}_{t-1})\sqrt{\alpha_t}}{1 - \bar{\alpha}_t} x_t + \frac{(1 - \alpha_t)\sqrt{\bar{\alpha}_{t-1}}}{1 - \bar{\alpha}_t} x_0 \\ &= \frac{(1 - \bar{\alpha}_{t-1})\sqrt{\alpha_t}}{1 - \bar{\alpha}_t} x_t + \frac{(1 - \alpha_t)\sqrt{\bar{\alpha}_{t-1}}}{1 - \bar{\alpha}_t} \frac{x_t - \sqrt{1 - \bar{\alpha}_t} \epsilon_0}{\sqrt{\bar{\alpha}_t}} \\ &= \frac{1}{\sqrt{\alpha_t}} x_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t} \sqrt{\alpha_t}} \epsilon_0 \end{aligned}$$

¹⁴ $D_{\text{KL}}(p(x)||q(x)) \triangleq \int p(x) \log \frac{p(x)}{q(x)} dx$

Denoising Diffusion Probabilistic Models

考虑

$$\mu_{\theta}(\mathbf{x}_t, t) = \frac{1}{\sqrt{\alpha_t}} \mathbf{x}_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t} \sqrt{\alpha_t}} \epsilon_{\theta}(\mathbf{x}_t, t)$$

我们要学习的目标其实是一个 Denoiser $\epsilon_{\theta}(\mathbf{x}_t, t)$ 。

Algorithm 1 Training

```


1: repeat
2:    $\mathbf{x}_0 \sim q(\mathbf{x}_0)$ 
3:    $t \sim \text{Uniform}(\{1, \dots, T\})$ 
4:    $\epsilon \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 
5:   Take gradient descent step on
        $\nabla_{\theta} \|\epsilon - \epsilon_{\theta}(\sqrt{\bar{\alpha}_t} \mathbf{x}_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon, t)\|^2$ 
6: until converged
  
```

Algorithm 2 Sampling

```

1:  $\mathbf{x}_T \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$ 
2: for  $t = T, \dots, 1$  do
3:    $\mathbf{z} \sim \mathcal{N}(\mathbf{0}, \mathbf{I})$  if  $t > 1$ , else  $\mathbf{z} = \mathbf{0}$ 
4:    $\mathbf{x}_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left( \mathbf{x}_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_{\theta}(\mathbf{x}_t, t) \right) + \sigma_t \mathbf{z}$ 
5: end for
6: return  $\mathbf{x}_0$ 
  
```

扩散模型建模



$$D_{KL}(q_\theta(X_{0:T})||p(X_{0:T})) = - \sum_{t=1}^T \mathbb{E}_{X_{T:t} \sim q_\theta(X_{T:t})} [S(q_\theta(X_{t-1}|X_t))] \\ - \sum_{t=1}^T \mathbb{E}_{X_{T:t-1} \sim q_\theta(X_{T:t-1})} [\log p(X_t|X_{t-1})] \\ + \beta \mathbb{E}_{X_{T:0} \sim q_\theta(X_{T:0})} [f(X_0)] + C,$$

其中 $S(X) \triangleq - \int p(x) \log p(x) dx$ 是香农熵。