

بسمه تعالی

امتحان پایانی - مدل های مولد

نام و نام خانوادگی:

شماره دانشجویی:

صحیح و غلط (با ذکر دلیل دقیق) (۲۰ نمره)

۱. با توجه به اینکه در مدل normalizing flow به شکل دقیق مقدار MLE محاسبه می شود، با کیفیت ترین تصاویر در میان مدل های مولد را می تواند تولید کند.
۲. زمان لازم برای تولید نمونه در مدل EBM از سایر مدل های مولد بهینه تر است.
۳. در انتخاب سطوح نویز متفاوت در Annealed Langevin dynamics، باید واریانس نویزها به اندازه کافی نزدیک باشند تا توزیع های مختلف همپوشانی کافی داشته باشند.

پاسخ تشریحی (۴۰ نمره)

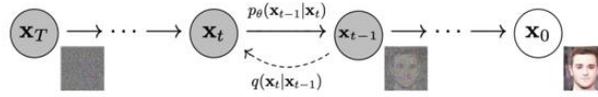
۴. چرا در صورت یادگیری به کمک الگوریتم های score matching و نمونه گیری به کمک Langevin dynamic همچنان نمی توان به تصاویر با کیفیتی رسید (۳ دلیل بیاورید)؟ چه راه حلی پیشنهاد می کنید؟
۵. در شبیه سازی پیوسته مدل های score based به کمک معادلات دیفرانسیل تصادفی می توان از روش های عددی برای حل معادله برای مثال به شکل زیر استفاده کرد:
$$\mathbf{x} \leftarrow \mathbf{x} - \sigma(t)^2 \mathbf{s}_\theta(\mathbf{x}, t) \Delta t + \sigma(t) \mathbf{z} \quad (\mathbf{z} \sim \mathcal{N}(\mathbf{0}, |\Delta t| \mathbf{I}))$$
$$t \leftarrow t + \Delta t$$
 - آیا این رویکرد برای رسیدن به فرآیند generation مناسب کافی است؟
 - الگوریتم predictor-corrector چگونه در فرآیند حل معادله بالا کمک می کند و ارتباط آن با Annealed Langevin Dynamic چیست؟
۶. در الگوریتم Denoising score matching تابع score برای فضای نمونه های نویزی با کمینه کردن fisher divergence تخمین زده می شود. همانطور که می دانید این معیار در این روش برابر است با:

$$\frac{1}{2} E_{\tilde{\mathbf{x}} \sim p_{\text{data}}} [\|\mathbf{s}_\theta(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \log q_\sigma(\tilde{\mathbf{x}})\|_2^2]$$
$$= \frac{1}{2} E_{\mathbf{x} \sim p_{\text{data}}(\mathbf{x}), \tilde{\mathbf{x}} \sim q_\sigma(\tilde{\mathbf{x}}|\mathbf{x})} [\|\mathbf{s}_\theta(\tilde{\mathbf{x}}) - \nabla_{\tilde{\mathbf{x}}} \log q_\sigma(\tilde{\mathbf{x}}|\mathbf{x})\|_2^2] + \text{const.}$$

نشان دهید در صورت در نظر گرفتن نویز نرمال، شبکه تعلیم دیده در این روش در عمل نویز اضافه شده به هر نمونه را تخمین می زند.

۷. برای آموزش یک مدل EBM تابع هزینه KL-divergence را میان توزیع مدل و توزیع داده نوشته و به گونه ای با ذکر محاسبات آن را بازنویسی کنید که به کمک آن و sampling از شبکه بتوان مدل را آموزش داد. در رابطه با sampling از این مدل نیز در حین training توضیح دهید.

۸. مدل diffusion یک مدل با چند لایه نهان محسوب می‌شود که در آن توزیع پیشین روی مقدار متغیر نهان نهایی، توزیع نرمال و توزیع شرطی هر لایه نسبت به لایه قبل نیز یک توزیع نرمال است.



The forward process: $q_t(\mathbf{x}_t|\mathbf{x}_{t-1}) = \mathcal{N}(\mathbf{x}_t; \sqrt{1 - \beta_t}\mathbf{x}_{t-1}, \beta_t I)$.

The reverse process: $p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t) = \mathcal{N}(\mathbf{x}_{t-1}|\mu_\theta(\mathbf{x}_t, t), \Sigma_\theta(\mathbf{x}_t, t))$.

Conditionals have closed form: $q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0) = \mathcal{N}(\mathbf{x}_{t-1}; \tilde{\mu}(\mathbf{x}_t, \mathbf{x}_0), \tilde{\beta}_t I)$

Where: $\tilde{\mu}(\mathbf{x}_t, \mathbf{x}_0) = \frac{\sqrt{\tilde{\alpha}_t}\beta_t}{1 - \tilde{\alpha}_t}\mathbf{x}_0 + \frac{\sqrt{\tilde{\alpha}_t}(1 - \tilde{\alpha}_{t-1})}{1 - \tilde{\alpha}_t}\mathbf{x}_t$.

And: $\alpha_t = 1 - \beta_t$, $\tilde{\alpha}_t = \prod_{s=1}^t \alpha_s$, $\tilde{\beta}_t = \frac{1 - \tilde{\alpha}_{t-1}}{1 - \tilde{\alpha}_t}\beta_t$.

$$\begin{aligned} \mathbb{E}_{\substack{\mathbf{x}_0 \sim p \\ \mathbf{x}_{1:T} \sim q}} \left[- \sum_{t>1} \log \frac{p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t)}{q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0)} \right] &= \mathbb{E}_{\substack{\mathbf{x}_0 \sim p \\ \mathbf{x}_t \sim q_t}} [D(q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0) \parallel p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t))] \\ &= \mathbb{E}_{\substack{\mathbf{x}_0 \sim p \\ \mathbf{x}_t \sim q_t}} \left[\frac{1}{2\sigma_t^2} \|\tilde{\mu}_t(\mathbf{x}_t, \mathbf{x}_0) - \mu_\theta(\mathbf{x}_t, t)\|^2 \right] + C. \end{aligned}$$

Acti

$$\begin{aligned} \mathbb{E}_{\substack{\mathbf{x}_0 \sim p \\ \mathbf{x}_{1:T} \sim q}} \left[- \sum_{t>1} \log \frac{p_\theta(\mathbf{x}_{t-1}|\mathbf{x}_t)}{q(\mathbf{x}_{t-1}|\mathbf{x}_t, \mathbf{x}_0)} \right] &= \mathbb{E}_{\substack{\mathbf{x}_0 \sim p \\ \varepsilon \sim \mathcal{N}(0, I)}} \left[\frac{1}{2\sigma_t^2} \|\tilde{\mu}_t(\mathbf{x}_t, \mathbf{x}_0) - \mu_\theta(\mathbf{x}_t, t)\|^2 \right] + C \\ &= \mathbb{E}_{\substack{\mathbf{x}_0 \sim p \\ \varepsilon \sim \mathcal{N}(0, I)}} \left[\frac{\beta_t^2}{2\sigma_t^2 \alpha_t (1 - \tilde{\alpha}_t)} \|\varepsilon - \varepsilon_\theta(x_t(\mathbf{x}_0, \varepsilon), t)\|^2 \right] + C. \end{aligned}$$

Activ

توزیع نرمال با وجود مزایای محاسباتی در عمل به دلیل ظرفیت پایین گاهی در مدل‌سازی کافی نمی‌باشد که اصطلاحاً منجر به مشکل **prior hole problem** می‌شود که در آن در مناطقی p_{data} زیاد ولی p_{model} کم و یا صفر است. یک دلیل این اتفاق این است که در مدل diffusion با معماری کنونی روابط متغیرهای نهان در لایه‌های مختلف به اندازه کافی مدل می‌شود اما روابط متغیرهای یک لایه به خوبی مدل نمی‌شوند (برای مثال پیکسل‌های یک تصویر در یک لایه نوین مشخص).
به کمک رویکرد EBM و ترکیب مدل diffusion و EBM معماری و تابع هزینه‌ای را پیشنهاد دهید که تا حدی این مشکل را بتواند برطرف کند.