

生成模型概述

什么是生成

- 根本问题：给定海量数据样本（如人脸图片），如何学习其背后那个极其复杂的高维概率分布 $P(\text{image})$?
- 一旦学到这个分布，我们就能评估新样本的“真实性”（密度估计），更能从中采样，创造出全新的、逼真的样本（生成）

为什么要生成模型？

➤ 生成模型

- 给定一组真实数据样本 $\{x_1, x_2, \dots, x_n\}$ ，它们被假设是从一个未知的真实数据分布 $P_{data}(x)$ 中采样得到的
- 生成模型 (Generative Model) 的任务是学习一个模型 $P_{model}(x)$ ，使其尽可能地逼近 $P_{data}(x)$

➤ 为什么要生成

- 理解数据。一个好的生成模型抓住了数据的本质结构与变化规律
- 创造数据。一旦学到了 P_{model} ，就可以从中采样，生成全新的、与真实数据风格一致的数据。
“创造力”
- 应用：图像合成、风格迁移、数据增强、超分辨率、药物发现等

➤ 传统方法的挑战

- 直接对高维数据的 $P_{data}(x)$ 进行最大似然估计 (MLE) 通常是极其困难或不可行

生成的技术路线

➤ 显式密度建模 (Explicit Density Modeling - VAE)

- 尝试构建一个带有参数 θ 的模型 $p_{\theta}(x)$ ，并直接优化它，使其逼近真实的数据分布（通常通过最大化对数似然 $\log p_{\theta}(x)$ 。但由于 $p(x)$ 形式复杂，我们转而优化其一个可计算的下界（ELBO）。

➤ 隐式密度建模 (Implicit Density Modeling - GAN)

- 放弃直接定义和优化 $p_{\theta}(x)$ 。而是构建一个“生成器”，它能直接从一个简单分布中采样并变换成目标样本。不关心 $p_{\theta}(x)$ 的具体形式，只要求它生成的样本“看起来是真的”。通过一个“判别器”进行对抗训练，间接地让生成分布逼近真实分布。

➤ 基于马尔可夫链的采样 (Markov Chain-based Sampling - Diffusion)

- 将“一步生成”分解为一系列极其简单的“小步去噪”问题。模型学习的不是直接生成，而是从纯噪声开始，通过一个逐步去噪的马尔可夫链，最终采样得到一个清晰的样本

数学基础

概率与分布

- 大写字母：随机变量

- 如，图像随机变量 X ，表示抽象图像的概念，而非某一张具体的图像

- $P(X)$ ：随机变量 X 的概率分布

- 小写字母：随机变量的一个具体实现

- 如， x 表示某一张具体图片，看作随机变量 X 的一次具体采样的结果

- $P(X = x)$ ：随机变量 X 采样得到 x 的概率数值

- 概率密度函数 $P(X)$ 代入具体数值 x 的计算结果

- $\mathcal{N}(\mu, \sigma^2)$ 表示均值为 μ ，方差为 σ^2 的高斯分布

- 请注意，不是 $\mathcal{N}(\mu, \sigma)$

概率

- 事件：一个特定的结果或一组结果
- 样本空间：所有可能结果的集合
- 概率：表示某个事件发生的可能性

$$P(A) = \frac{\text{事件 A 发生的方式数}}{\text{样本空间的总方式数}}$$

- 概率是一个数值，通常在 0 到 1 之间

概率

➤ 条件概率

➤ $P(A, B) = P(A | B)P(B) = P(B | A)P(A)$

➤ 边缘概率

$$p(B) = \int_A p(A, B) dA$$

➤ 求期望，去除无关变量的操作： $E_{p(x_1, x_2, \dots, x_T)} f(x_i) = E_{p(x_i)} f(x_i)$

$$\begin{aligned} & E_{p(x_1, x_2, \dots, x_T)} f(x_i) \\ = & \int_{x_1, x_2, \dots, x_T} p(x_1, x_2, \dots, x_T) f(x_i) dx_1 dx_2 \dots dx_T \\ \text{➤} = & \int_{x_i} \int_{x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_T} p(x_1, x_2, \dots, x_T) \underbrace{dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_T}_{\text{exclude } x_i} f(x_i) dx_i \\ = & \int_{x_i} p(x_i) f(x_i) dx_i = E_{p(x_i)} f(x_i) \end{aligned}$$

条件概率

➤ $p(z | x)$

➤ 函数映射

➤ 给定 x ，得到的 z 概率 $p(z | x)$

➤ 推断/推理（本质/原因 x ，推断现象/结果 z ）

➤ 先验概率 $p(x)$

➤ 根据观察现象/结果 z ，推断本质/原因 x 。后验概率 $p(x | z)$

➤ 类条件概率函数

➤ 类别 c 的特征 x 的概率密度函数， $p(x | c)$

➤ 编码

➤ 给定 x ，得到编码 z 的概率 $p(z | x)$

➤ 解码/生成

➤ 给定编码 z ，解码得到 x 的概率 $p(x | z)$

期望和采样

期望

- 概率密度函数 $p(x)$, x 的期望

$$\mathbb{E}[x] = \int xp(x)dx$$

- (近似) 数值计算时, 选若干代表性的点 $x_0 < x_1 < x_2 < \dots < x_n$, 得

$$\mathbb{E}[x] \approx \sum_{i=1}^n x_i p(x_i)(x_i - x_{i-1})$$

- 如果根据 $p(x)$ 采样若干个点的 x_1, x_2, \dots, x_n , 那么

$$\mathbb{E}[x] \approx \frac{1}{n} \sum_{i=1}^n x_i, \quad x_i \sim p(x)$$

- 记号

- 假设有一个连续型随机变量 x , 其概率密度表示为 $p(x)$ 。此时, 函数 $f(x)$ 的期望值可以表示为

$$\mathbb{E}_{p(x)}[f(x)] = \int f(x)p(x)dx$$

- 这种表示方法清晰地表明它是关于 $p(x)$ 的期望值
- 以此类推, 关于概率分布 $q(x)$ 的期望值表示为

$$\mathbb{E}_{q(x)}[f(x)] = \int f(x)q(x)dx$$

期望 - 蒙特卡洛模拟

➤ 计算方式的主要区别

➤ 其一包含了概率的计算

➤ 另一个仅有 x 的计算

➤ x_i 从 $p(x)$ 中依概率采样而来，概率大的 x_i 出现的次数也多，采样的结果已经包含了 $p(x)$ 信息

$$\mathbb{E}_{x \sim p(x)}[f(x)] = \int f(x)p(x)dx \approx \frac{1}{n} \sum_{i=1}^n f(x_i), \quad x_i \sim p(x)$$

KL 散度

- 衡量两个概率分布之间差异的一种方法是 KL 散度。当给定两个概率分布 $p(x)$ 和 $q(x)$ 时,当 x 为连续型随机变量时,KL 散度

$$D_{\text{KL}}(p \parallel q) = \int p(x) \log \frac{p(x)}{q(x)} dx$$

- 当 x 为离散型随机变量时, 数学式如下所示。

$$D_{\text{KL}}(p \parallel q) = \sum_x p(x) \log \frac{p(x)}{q(x)}$$

- KL 散度具有以下特性:

- 两个概率分布的差异越大, KL 散度的值就越大;
- KL 散度的值大于或等于 0 ,且仅当两个概率分布相同时,其值才为 0 ;
- KL 散度是非对称的衡量指标,因此 $D_{\text{KL}}(p \parallel q)$ 和 $D_{\text{KL}}(q \parallel p)$ 的值不同。

“最大似然估计” (Maximum Likelihood Estimation)

- 假设有一个概率分布,其形状由参数 θ 决定。当参数为 θ 时,获得数据 x 的概率密度为 $p(x; \theta)$ 。
- 对于正态分布,可以将参数视为 $\theta = \{\mu, \sigma\}$ 。

“最大似然估计” (Maximum Likelihood Estimation)

- 样本 $\mathcal{D} = \{x^{(1)}, x^{(2)}, \dots, x^{(N)}\}$ 每个数据都是基于概率分布 $p(x; \theta)$ 独立生成的。此时, 获得样本 \mathcal{D} 的概率密度

$$p(\mathcal{D}; \theta) = p(x^{(1)}; \theta)p(x^{(2)}; \theta) \cdots p(x^{(N)}; \theta) = \prod_{n=1}^N p(x^{(n)}; \theta)$$

- 由于假定每个数据是独立生成的, 因此获得 N 个数据的概率密度等于每个数据的概率密度的乘积。
- $p(\mathcal{D}; \theta)$ 表示当参数为 θ 时获得样本 \mathcal{D} 的概率密度。这个 $p(\mathcal{D}; \theta)$ 也可以被看作以 θ 为参数的函数, 其定义式如下所示。

$$L(\theta) = p(\mathcal{D}; \theta)$$

“最大似然估计” (Maximum Likelihood Estimation)

- $L(\theta) = p(\mathcal{D}; \theta) = p(x^{(1)}; \theta)p(x^{(2)}; \theta) \cdots p(x^{(N)}; \theta) = \prod_{n=1}^N p(x^{(n)}; \theta)$
 - $L(\theta)$ 称为似然 (likelihood) 或似然函数 (likelihood function)
 - 以参数 θ 为参数的函数, 表示在给定参数 θ 的情况下, 样本 \mathcal{D} 出现的概率密度。
- 最大似然估计, 找到使似然 $p(\mathcal{D}; \theta)$ 最大的参数 θ
 - 如果使似然最大的参数是 $\hat{\theta}$, 那么当参数为 $\hat{\theta}$ 时, 观测到样本的概率最大
 - 也就是说, 当参数为 $\hat{\theta}$ 时, 模型最拟合样本。
- 其实最大似然估计进行的不是似然 $p(\mathcal{D}; \theta)$ 的最大化, 而是对数似然 $\log p(\mathcal{D}; \theta)$ 的最大化

$$\hat{\theta} = \operatorname{argmax}_{\theta} \sum_{n=1}^N \log p_{\theta}(x^{(n)})$$

模型表达

模型编码或者解码的表示

- 函数
 - 直接对应关系
- 概率
 - 输入 x ，生成 z 的概率 $p(z \mid x)$
- 神经网络，拟合
 - 函数
 - 概率中的参数

函数

➤ $z = f(x)$

➤ 直接对应关系，根据输入得到确定的输出

➤ 缺点

➤ 对已经有的数据的总结

➤ 没有考虑数据之间的关联，所以并不能生成新的数据

➤ 如果希望生成新的数据，那么模型需要考虑样本推断相邻区域的能力，因此，对应不能只是一个点，应该是一片

➤ 因此，映射机制发展成概率和采样的生成机制

概率生成模型 - 条件概率 $p(z | x)$

- $p(z | x)$: 由 x 得到 z 的概率。 x 参数, z 为随机变量
- $p(z | x)$ 为 x 到各个 z (没有唯一对应的 z) 映射的概率 (频率或者可能性)
 - $p(z | x)$ 值越大, z 和 x 的相关性越高
 - 和映射 $z = f(x)$ 形式对照

$$z_{max} = \arg \max_z p(z|x)$$

- 按照概率 $p(z | x)$ 采样 z , 记号: $z \sim p(z|x)$
 - 采样得到 z : 先采样一个 x , 再依据概率 $p(z | x)$ 采样得到 z
 - 一个策略: 采样1000次, 得到1000个 z_i , 这些 z_i 符合概率 $p(z_i | x)$ 分布, 如果只要一个样本, 随机挑选一个
- 如果 $p(z | x)$ 形式为高斯分布。给定 x ,
 - z 的一个采样 = (高斯函数的均值) + (随机生成一个标准正态噪声) * 方差