

粗放毒未井作



非常好

概率论进阶笔记

黄盛唐, Peanut Tang

2024年6月18日

目录

1	随机矩阵	3
1.1	基本模型	3
1.2	Wigner 半圆律	5
2	中心极限定理重访	7
2.1	矩收敛定理	7
2.2	Lindeberg 替换术	8
3	统计物理	11
3.1	信息熵	11
3.2	Ising 模型	14
3.3	Curie-Weiss 模型和相变现象	17
3.4	李政道-杨政宁单位圆定理	22

1 随机矩阵

1.1 基本模型

Definition 1.1. 在概率空间 $(\Omega, \mathcal{F}, \Pr)$ 里，一个随机变量为 Borel 可测函数 $X : \Omega \rightarrow \mathbb{R}$ 。可以扩展出随机向量 $X : \Omega \rightarrow \mathbb{R}^n$ 、随机矩阵 $X : \Omega \rightarrow \mathbb{R}^{n \times n}$ 。

关心：模型、现象（半圆律）。

参考书：Tao: Topics in Random Matrix Theory. AMS, 2012.

随机矩阵的起源与研究动机。

Example 1.2 (Wishart, 1928). 背景是多元统计中的样本协方差矩阵。

一个 p 维数据 $X_i : \Omega \rightarrow \mathbb{R}^{p \times 1}$ ，我们采样若干次，取平均得到样本协方差矩阵：

$$W = \frac{1}{n} \sum_{i=1}^n X_i X_i^T = \frac{1}{n} X X^T$$

这里 $X = (X_1, X_2, \dots, X_n) \in \mathbb{R}^{p \times n}$ 。

若 $\{X_n\}$ 相互独立，且均服从 $\mathcal{N}(0, I_n)$ ，则称 W 为一个 Wishart 矩阵。

此时 X 的矩阵元联合密度函数为（自变量为矩阵）：

$$f_X(V) = \frac{1}{(2\pi)^{n/2}} \exp\left(-\frac{1}{2} \text{tr}(V V^T)\right)$$

Example 1.3 (Wigner, 1955). 背景是量子物理。

我们有 Schrödinger 方程：

$$\frac{\partial}{\partial t} \Psi(x, t) = H \Psi(x, t)$$

这里 $H = -\frac{\partial^2}{\partial x^2} + V(x)$ 。此方程变量多，相互作用复杂，没有额外假设下十分难解。

我们引入随机性，并且将无穷维的算子 H 截断，得到厄米矩阵 $H_n \in \mathbf{U}^n$ ，其中矩阵元为随机变量。研究 $n \rightarrow \infty$ 时 H_n 谱的渐进性，以此来得到 H 算子的一些性质。

下面随机矩阵的一些基本模型。

Definition 1.4 (高斯正交系综). 所谓高斯正交系综（简称 GOE, Gaussian Orthogonal Ensemble）指：

$$A_n = \frac{1}{2} (X_n + X_n^T)$$

这里 $X_n = (x_{ij})_{i,j=1}^n$ ， $\{x_{ij}\}$ i.i.d. $\mathcal{N}(0, \sigma^2)$ 。

我们记 $A_n \sim \text{GOE}(\sigma)$ 。

可以看出 A_n 上三角部分的矩阵元是相互独立的。我们可以写出每一个矩阵元的分布：

$$\begin{aligned} a_{ii} &= x_{ii} \sim \mathcal{N}(0, \sigma^2) \\ a_{ij} &= a_{ji} = \frac{1}{2}(x_{ij} + x_{ji}) \sim \mathcal{N}(0, \sigma^2/2) \quad (i < j) \end{aligned}$$

依此可写出矩阵元的联合密度函数：

$$f_{A_n}(V) = \frac{1}{2^{n/2} \cdot (\pi \sigma^2)^{n(n+1)/4}} \exp\left(-\frac{1}{2\sigma^2} \text{tr}(V^2)\right)$$

Definition 1.5 (高斯酉系综). 类似的可以定义高斯酉系综 (简称 GUE, Gaussian Unitary Ensemble):

$$A_n = \frac{1}{2} (X_n + X_n^*)$$

这里 $X_n = (x_{ij})_{i,j=1}^n$, $\{x_{ij}\}$ i.i.d. $\mathcal{N}_{\mathbb{C}}(0, \sigma^2)$ 。而 $z \sim \mathcal{N}_{\mathbb{C}}(0, \sigma^2)$ 为复高斯分布, 有概率密度函数:

$$f(z) = \frac{1}{\pi\sigma^2} \exp\left(-\frac{|z|^2}{\sigma^2}\right)$$

我们记 $A_n \sim \text{GUE}(\sigma)$ 。

可以看出 A_n 上三角部分的矩阵元是相互独立的。我们可以写出每一个矩阵元的分布:

$$a_{ii} = \text{Re}(x_{ii}) \sim \mathcal{N}(0, \sigma^2/2)$$

$$a_{ij} = a_{ji}^* = \frac{1}{2}(x_{ij} + x_{ji}^*) \sim \mathcal{N}_{\mathbb{C}}(0, \sigma^2/2) \quad (i < j)$$

依此可写出矩阵元的联合密度函数:

$$f_{A_n}(V) = \frac{2^{n(n-1)/2}}{(\pi\sigma^2)^{n^2/2}} \exp\left(-\frac{1}{2\sigma^2} \text{tr}(V^2)\right)$$

Theorem 1.6. 我们有以下结论:

- (1) GOE 具有正交变换下的不变性, 即对任意的正交矩阵 $Q \in \text{O}(n)$ 与 $A_n \sim \text{GOE}(\sigma)$, 有 QA_nQ^T 与 A_n 同分布。
- (2) 同样的, GUE 具有酉变换下的不变性, 即对任意的酉矩阵 $U \in \text{U}(n)$ 与 $A_n \sim \text{GUE}(\sigma)$, 有 UA_nU^* 与 A_n 同分布。

Proof. (1) 对于 $X \sim \text{GOE}(\sigma)$, $Q \in \text{O}(n)$, 令 $X_i = (X_{i1}, X_{i2}, \dots, X_{in})$ 为 X 的第 i 行, 可以发现 $X_i \sim \mathcal{N}(0, \sigma^2 I_n)$ 。

则由正态分布的经典结论: $X_i Q^T \sim \mathcal{N}(0Q^T, Q\sigma^2 I_n Q^T) = \mathcal{N}(0, \sigma^2)$, 与 X_i 同分布。故 XQ^T 与 X 同分布。

同理, 再左乘一个 Q 也同分布, 即 QXQ^T 与 X 同分布。故可以推出 $QXQ^T = \frac{1}{2}(QXQ^T + (QXQ^T)^T)$ 与 X 同分布。

(2) 和 GOE 一样, 我们证明 XU^* 与 X 同分布, 令 $X_i = (X_{i1}, X_{i2}, \dots, X_{in})$ 为 X 的第 i 行, 可以发现 $\text{Re}(X_i), \text{Im}(X_i) \sim \mathcal{N}\left(0, \frac{1}{2}\sigma^2 I_n\right)$ 。

故由实正态分布的经典结论: $\text{Re}(X_i U^*) \sim \mathcal{N}\left(0 \text{Re}(U^*), \text{Re}(U^*)^T \cdot \frac{1}{2}\sigma^2 I_n \cdot \text{Re}(U^*)\right) + \mathcal{N}\left(0 \text{Im}(U^*), \text{Im}(U^*)^T \cdot \frac{1}{2}\sigma^2 I_n \cdot \text{Im}(U^*)\right) = \mathcal{N}\left(0, (\text{Re}(U^*)^2 - \text{Im}(U^*)^2) \cdot \frac{1}{2}\sigma^2 I_n\right)$ 。

因为 $U \in \text{U}(n)$, 所以 $UU^* = (\text{Re}(U) + i \text{Im}(U))^2 = \text{Re}(U)^2 - \text{Im}(U)^2 = I_n$, 所以 $\text{Re}(X_i U^*) \sim \mathcal{N}\left(0, \frac{1}{2}\sigma^2 I_n\right)$ 。

同理 $\text{Im}(X_i U^*) \sim \mathcal{N}\left(0, \frac{1}{2}\sigma^2 I_n\right)$, 故 $X_i U^*$ 与 X_i 同分布, 之后同 (1)。

这实际上也证明了复高斯分布中类似的结论——酉变换不变性。 \square

1.2 Wigner 半圆律

再来介绍一个随机矩阵里的重要且基本的结果，Wigner 半圆律。

参考文献：Wigner: Annals of Math, 1955.

Lemma 1.7. 定义：

$$\rho_{\text{sc}}(x) = \frac{1}{2\pi} \sqrt{4 - x^2}, \quad x \in [-2, 2]$$

可以看出这是一个概率密度函数，我们称为 Wigner 半圆律（分布）。

对比标准正态分布 $X \sim \mathcal{N}(0, 1)$ ，有密度函数 $f(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right)$ ，并且我们可以算出各阶矩：

$$\mathbb{E}[X^k] = \begin{cases} 0 & k \text{ odd} \\ (2m - 1)!! & k = 2m \end{cases}$$

对于 $\rho_{\text{sc}}(x)$ 为密度的随机变量，我们也可以算其各阶矩：

$$\int_{-2}^2 x^k \rho_{\text{sc}}(x) dx = \begin{cases} 0 & k \text{ odd} \\ \frac{1}{m+1} \binom{2m}{m} & k = 2m \end{cases}$$

可以看到 $k = 2m$ 时对应阶矩为 Catalan 数 C_m 。

Proof. 当 k 为奇数是显然对应阶矩为 0。当 $k = 2m$ 时：

$$\begin{aligned} \int_{-2}^2 x^k \rho_{\text{sc}}(x) dx &= \frac{1}{\pi} \int_0^2 x^k \sqrt{4 - x^2} dx \\ &= \frac{2^{2m+2}}{\pi} \int_0^{\pi/2} \sin^k \theta \cos^2 \theta d\theta \quad (x = 2 \sin \theta) \\ &= \frac{2^{2m+2}}{\pi} \cdot \frac{1}{2} B\left(m + \frac{1}{2}, \frac{3}{2}\right) = \frac{2^{2m+1}}{\pi} \cdot \frac{\Gamma\left(m + \frac{1}{2}\right) \Gamma\left(\frac{3}{2}\right)}{\Gamma(m+2)} \\ &= \frac{2^{2m+1}}{\pi} \cdot \frac{(2m-1)!!}{2^m} \sqrt{\pi} \cdot \frac{1}{2} \sqrt{\pi} = \frac{1}{m+1} \binom{2m}{m} = C_m \end{aligned}$$

得证。 □

Remark. $(2m - 1)!!$ 的组合解释：1, 2, ..., 2m 两两配对不计顺序方案数。

C_m 的组合解释：1, 2, ..., 2m 不自交的两两配对方案数。

不自交：举例，当 $m = 2$ 时，将 1, 2, 3, 4 画在平面上的一条线上，配对的两个数在平面的同一边用一条线连起来。这样 (1, 2), (3, 4) 与 (1, 4), (2, 3) 是不自交的，而 (1, 3), (2, 4) 是自交的。可以用长为 $2m$ 的合法括号串来一一对应。

Definition 1.8 (Wigner 矩阵). 设 $A_n = (a_{ij}) \in \mathbf{S}^n(\mathbb{R})$ 为一实对称随机矩阵，若其矩阵元满足如下要求，则称 A_n 为 Wigner 矩阵：

- $\{a_{ij}\}_{1 \leq i \leq j \leq n}$ 相互独立。

- $\{a_{ii}\}$ 与 Y 同分布, 而 $\{a_{ij}\}_{i < j}$ 与 Z 同分布。且 Y, Z 满足: $\mathbb{E}[Y] = \mathbb{E}[Z] = 0$, $\text{Var}(Z) = 1$, $\text{Var}(Y) < \infty$, 以及 $\forall k \geq 3, \mathbb{E}[|Y|^k], \mathbb{E}[|Z|^k] < \infty$ 。

Definition 1.9 (经验分布). 给定一个实对称(随机)矩阵 $A \in \mathbf{S}^n(\mathbb{R})$ 的特征值 $\lambda_1(A), \dots, \lambda_n(A)$ 。令 $F_A(x)$ 为:

$$F_A(x) = \frac{1}{n} \#\{j \mid \lambda_j(A) \leq x\}$$

可以看出 $F_A(x)$ 是一个分布函数, 称为 A 谱的经验分布 (简称为 ESD, Empirical Spectral Distribution)。

当 A 为随机矩阵时, $F_A(x)$ 为随机 ESD (随机分布函数的具体定义按下不表)。

对于 Borel 可测函数 $g: \mathbb{R} \rightarrow \mathbb{R}$ (测试函数), 可以定义抽象积分:

$$\mathbb{E}[g(A)] = \int g dF_A = \frac{1}{n} \sum_{i=1}^n g(\lambda_i) = \frac{1}{n} \text{tr}(g(A))$$

当 A 为随机矩阵时, 上面的抽象积分本身也是一个随机变量 (两重随机性)。

当 g 为多项式函数时, 可以拆分为一个个单项式, 实际上就是在考察矩的信息。而矩的信息可以反过来确定分布函数 (特征函数)。

Theorem 1.10 (Wigner 半圆律). 对于 Wigner 矩阵 $\{A_n\}$:

$$\frac{1}{n} \mathbb{E} \left[\text{tr} \left(\left(\frac{A_n}{\sqrt{n}} \right)^k \right) \right] \rightarrow \gamma_k = \begin{cases} 0 & k \text{ odd} \\ C_m & k = 2m \end{cases}$$

由矩收敛定理知: $F_{A_n}(x)$ 弱收敛到 $\rho_{sc}(x)$ 。

Remark. 对比 CLT: $\{X_n\}$ i.i.d., $S_n = \sum_{i=1}^n X_i$, $\mathbb{E}[X_i] = 0$, $\mathbb{E}[X_i^2] = 1$, 且 X_i 各阶矩一致有界, 则:

$$\mathbb{E} \left[\left(\frac{S_n}{\sqrt{n}} \right)^k \right] \rightarrow \begin{cases} 0 & k \text{ odd} \\ (2m-1)!! & k = 2m \end{cases}$$

同样由矩收敛定理知: $\frac{S_n}{\sqrt{n}} \xrightarrow{D} \mathcal{N}(0, 1)$ 。

Proof. 有:

$$LHS = \frac{1}{n^{1+k/2}} \sum_{i_1, i_2, \dots, i_k=1}^n \mathbb{E}[a_{i_1 i_2} a_{i_2 i_3} \cdots a_{i_k i_1}]$$

和矩方法证明 CLT 时类似, 我们还是对右边的指标进行分类。

把 i_1, i_2, \dots, i_k 看成顶点, 而 $i_1 i_2, \dots, i_k i_1$ 看成边, 这实际上是一个图上的环, 从 i_1 , 走到 i_k , 最后再回到 i_1 。

只看主项, 主项里不能有一条边只出现一次 (否则根据独立性以及条件 $\mathbb{E}[Y] = \mathbb{E}[Z] = 0$, 会得出这一项为 0, 没有贡献), 故主项里每条边至少出现两次。

又因为对主项次数做限制, 所以肯定自由度越高越好, 我们让不同边的个数达到上界 $\left\lfloor \frac{k}{2} \right\rfloor$, 此时 i_1, i_2, \dots, i_k 有 $\left\lfloor \frac{k}{2} \right\rfloor + 1$ 个不同顶点。

当 k 为奇数时, $\left\lfloor \frac{k}{2} \right\rfloor + 1 < \frac{k}{2} + 1$, 所以没有主项, $n \rightarrow \infty$ 时极限为 0。

当 $k = 2m$ 时, 考虑计数合法环的个数。发现取定起点后, 我们可以和合法括号串一一对应 ($i_s \rightarrow i_t$ 边为 '(', 反向边 $i_t \rightarrow i_s$ 为 ')'), 所以合法环数量是选取 $m + 1$ 个自由元的方案数 $n(n-1)\cdots(n-m)$, 乘上 Catalan 数 C_m , $n \rightarrow \infty$ 时极限为 C_m 。□

2 中心极限定理重访

2.1 矩收敛定理

在概率论本篇和外篇中, 我们使用了若干次矩方法, 但矩何时可以决定分布函数? 下面这个反例表明, 并不是任何时候, 矩都可以决定分布函数。

Example 2.1 (反例——对数正态分布). 先有一个密度函数:

$$f_0(x) = \frac{1}{\sqrt{2\pi x}} \exp\left(-\frac{1}{2}(\ln x)^2\right) \quad (x > 0)$$

为标准对数正态分布的密度函数。再来一族分布函数:

$$f_a(x) = f_0(x)(1 + a \sin(2\pi \ln x)) \quad (a \in (-1, 1))$$

可以发现这个密度函数算出来的各阶矩和 a 是没有关系的, 所以在没有任何条件下, 矩无法决定分布函数。

下面这个定理给出了在何种条件下矩可以决定分布函数。

Lemma 2.2 (矩收敛定理). 对于一个分布函数 $F(x)$, 令 $\gamma_k = \int x^k dF$, 若:

$$\limsup_{k \rightarrow \infty} \frac{1}{2k} \gamma_{2k}^{\frac{1}{2k}} = r < \infty \quad (\text{R})$$

则 $F(x)$ 被其矩决定, 其中 (R) 被称为 Riesz 条件, 是一个充分条件。

Proof. 令 $\mu_k = \int |x|^k dF$, 则有 Cauchy-Schwarz 不等式可得:

$$\mu_{2k+1} \leq \sqrt{\mu_{2k}\mu_{2k+2}}$$

而 $\mu_{2k} = \gamma_{2k}$, 这说明偶数阶矩给定后, 绝对值的奇数阶矩也被控制, 即:

$$\limsup_{k \rightarrow \infty} \frac{1}{k} \mu_k^{\frac{1}{k}} = r \quad (1)$$

利用带 Lagrange 余项的 Taylor 展开:

$$e^{it} - \sum_{m=0}^{n-1} \frac{(it)^m}{m!} = \frac{i^n}{(n-1)!} \int_0^t (t-s)^{n-1} e^{is} ds$$

可得如下事实:

$$\left| e^{it} - \sum_{m=0}^{n-1} \frac{(it)^m}{m!} \right| \leq \frac{|t|^n}{n!}, \quad \forall t \in \mathbb{R}$$

于是：

$$\left| e^{i\theta X} \left(e^{itX} - \sum_{m=0}^{n-1} \frac{(itX)^m}{m!} \right) \right| \leq \frac{|tX|^n}{n!}$$

对该式取期望就有：

$$\left| \phi(t + \theta) - \sum_{m=1}^{n-1} \frac{t^k}{m!} \phi^{(m)}(\theta) \right| \leq \frac{t^n}{n!} \mu_n$$

再利用 (1) 与事实 $\frac{n^n}{n!} \leq e^n$ ，可以得出：

$$\limsup_{n \rightarrow \infty} \mu_k^{\frac{1}{k}} = er$$

所以上面幂级数的收敛半径至少为 $\frac{1}{er}$ ，所以：

$$\phi(t + \theta) = \phi(\theta) + \sum_{m=1}^{\infty} \frac{(it)^k}{m!} \phi^{(m)}(\theta), \quad \forall \theta \in \mathbb{R}, |t| < \frac{1}{er}$$

取 $\theta = 0$ ，则 $|t| < \frac{1}{er}$ 范围内的 $\phi(t)$ 可由 $\{\gamma_n\}$ 确定。再接着取 $\theta = \pm \frac{1}{e(r+1)}, \dots$ ，就可以在整个实轴上确定特征函数 $\phi(t)$ ，进而唯一确定分布函数 $F(x)$ 。□

2.2 Lindeberg 替换术

Theorem 2.3 (Lindeberg-Feller 中心极限定理). 对于一系列相互独立的随机变量列（不一定同分布） $\{X_n\}$ ，有： $\mathbb{E}[X_k] = 0$ ， $\sigma_k^2 = \text{Var}(X_k) < \infty$ ， $\forall k \in \mathbb{N}^+$ ，记 $B_n^2 = \sum_{i=1}^n \sigma_i^2$ 。

则称其满足 Lindeberg 条件，若：

$$\forall \epsilon > 0, \lim_{n \rightarrow \infty} \frac{1}{B_n^2} \sum_{i=1}^n \mathbb{E}[X_i^2 I_{\{|X_i| \geq \epsilon B_n\}}] = 0 \quad (\text{L})$$

若一系列相互的随机变量列 $\{X_n\}$ 满足条件 (L)，则：

$$\frac{1}{B_n} \sum_{i=1}^n X_i \xrightarrow{D} \mathcal{N}(0, 1) \quad (\text{CLT})$$

且：

$$\lim_{n \rightarrow \infty} \frac{1}{B_n^2} \max_{1 \leq i \leq n} \sigma_i^2 = 0 \quad (\text{F})$$

其中 (F) 被称为 Feller 条件。

在本篇中，我们证明了 (L) \Rightarrow (F)，但我们不知道怎么证明 (L) \Rightarrow (CLT)，事实上 (L) \iff (CLT) + (F)。

对于独立同的情况，可以非常直接的使用若干相同特征函数的次幂来解决。对于相互独立但是不一定同分布的情况，同样我们也可以用特征函数来解决，但是处理必须非常小

心, 可以参见 Rick Durrett *Probability: Theory and Example* 和钟开莱《概率论教程》上的证明。

这里我们介绍另一种证明 Lindeberg-Feller CLT 的方法, 叫做 **Lindeberg 替换术**。

动机: 如果每个 X_n 都是服从某个正态分布的, 则可以直接做 (独立正态分布的可加性)。Lindeberg 替换术就是尝试将每个变量依次换成某个正态分布随机变量, 并且控制误差, 最后得到结果。

先证明引理, 这个引理给出了依分布收敛的若干等价刻画, 为我们之后证明做准备。

Lemma 2.4 (依分布收敛的等价刻画). 对于一个随机变量列 $\{X_n\}$, 与一个随机变量 X , 我们有如下几条等价:

- (1) $X_n \xrightarrow{D} X$.
- (2) 对于任何有界连续函数 $g \in C_b(\mathbb{R})$, 有 $\mathbb{E}[g(X_n)] \rightarrow \mathbb{E}[g(X)]$.
- (3) 对于任何有界一致连续函数 g , 有 $\mathbb{E}[g(X_n)] \rightarrow \mathbb{E}[g(X)]$.
- (4) 固定 $k \in \mathbb{N}$, 对于任何 $0 \sim k$ 阶导都有界连续的函数 g (即 $g^{(i)} \in C_b(\mathbb{R}), \forall i = 0, 1, \dots, k$), 有 $\mathbb{E}[g(X_n)] \rightarrow \mathbb{E}[g(X)]$.
- (5) 特征函数逐点收敛, 即: $\forall t \in \mathbb{R}, \phi_n(t) \rightarrow \phi(t)$.

Proof. 1、5 等价性可以使用 Lévy-Cramér 连续性定理来证明, 而 1、2 的等价性可以使用 Skorokhod 表示定理来证明。又可以发现 3、4 是 2 的特殊情况, 所以可以得到 $1 \Rightarrow 3, 4$ 。

又注意到: $\phi_n(t) = \mathbb{E}[\cos(tX_n)] + i \mathbb{E}[\sin(tX_n)]$, $\phi(t) = \mathbb{E}[\cos(tX)] + i \mathbb{E}[\sin(tX)]$ 。

而且 $\sin(tx), \cos(tx)$ 这两族函数都满足 3、4 中对函数的要求, 所以如果以 3、4 为前提, 就可以得出 $\forall t \in \mathbb{R}, \phi_n(t) \rightarrow \phi(t)$ 。

这样我们就可以证明 $1 \Rightarrow 3, 4 \Rightarrow 5 \Rightarrow 1$, 进而这五个都等价。 □

接下来我们证明 Lindeberg-Feller 中心极限定理:

Proof of Theorem 2.3. 取 $\{Y_k\}$ 相互独立, 且 $Y_k \sim \mathcal{N}(0, \sigma_k^2)$, 而且还有 $\{Y_k\}, \{X_k\}$ 相互独立 (这可以做到, 由高等概率论中的 Kolmogorov 扩展定理)。

固定 n , 对于任何 $0 \sim 3$ 阶导都有界连续的函数 g , 令:

$$\zeta_{nk} = \sum_{i=1}^{k-1} X_i + \sum_{i=k+1}^n Y_i$$

则有 $\zeta_{nn} + X_n = \sum_{i=1}^n X_i, \zeta_{n1} + Y_1 = \sum_{i=1}^n Y_i$, 而且 $\zeta_{nk} + X_k = \zeta_{n,k+1} + Y_{k+1}, \forall k \in [n-1]$ 。

因此, 令 $Y \sim \mathcal{N}(0, 1)$, 则 Y 与 $\frac{1}{B_n} \sum_{i=1}^n Y_i$ 同分布, 故错位相减可得:

$$\mathbb{E} \left[g \left(\frac{S_n}{B_n} \right) \right] - \mathbb{E} [g(Y)] = \sum_{k=1}^n \left(\mathbb{E} \left[g \left(\frac{\zeta_{nk} + X_k}{B_n} \right) \right] - \mathbb{E} \left[g \left(\frac{\zeta_{nk} + Y_k}{B_n} \right) \right] \right)$$

对于 $g(x)$, 在 $\frac{\zeta_{nk}}{B_n}$ 这一点做 Taylor 展开可以得到:

$$g \left(\frac{\zeta_{nk} + X_k}{B_n} \right) = g \left(\frac{\zeta_{nk}}{B_n} \right) + g' \left(\frac{\zeta_{nk}}{B_n} \right) \cdot \frac{X_k}{B_n} + \frac{1}{2} g''(\cdot) \cdot \frac{X_k^2}{B_n^2} + \frac{1}{6} g'''(\cdot) \cdot \frac{X_k^3}{B_n^3} + \dots$$

对于 Y_k 也有类似表达式。

因为对于任意 k , 都有 ζ_{nk} 与 X_k, Y_k 独立, 故先固定 ζ_{nk} , 关于 X_k, Y_k 求期望, 再配合 X_k, Y_k 一阶矩二阶矩都相同的条件可以得到:

$$\mathbb{E} \left[g' \left(\frac{\zeta_{nk}}{B_n} \right) \cdot \frac{X_k - Y_k}{B_n} \right] = \mathbb{E} \left[g'' \left(\frac{\zeta_{nk}}{B_n} \right) \cdot \frac{X_k^2 - Y_k^2}{B_n^2} \right] = 0$$

有了这个我们可以发现 Taylor 展开式中一阶二阶项都是 0。

而令 $h(t) = \sup_{x \in \mathbb{R}} \left| g(x+t) - g(x) - g'(x)t - \frac{1}{2}g''(x)t^2 \right|$, 因为 $g, g', g'', g''' \in C_b(\mathbb{R})$, 所以 \sup 里面的东西可以被放缩成一个系数全是有限常数的二次多项式, 故存在常数 $K > 0$, 使得 $h(t) \leq K \min\{t^2, |t|^3\}$ 。

进而:

$$\left| \mathbb{E} \left[g \left(\frac{S_n}{B_n} \right) \right] - \mathbb{E}[g(Y)] \right| \leq \sum_{k=1}^n \left(\mathbb{E} \left[h \left(\frac{X_k}{B_n} \right) \right] + \mathbb{E} \left[h \left(\frac{Y_k}{B_n} \right) \right] \right)$$

先看 Y_k 部分, 有:

$$\begin{aligned} \sum_{k=1}^n \mathbb{E} \left[h \left(\frac{Y_k}{B_n} \right) \right] &\leq K \sum_{k=1}^n \mathbb{E} \left[\frac{|Y_k|^3}{B_n^3} \right] \quad (h(t) \leq K|t|^3) \\ &= K \sum_{k=1}^n \frac{\sigma_k^3}{B_n^3} \mathbb{E}[|Y|^3] \quad (\mathbb{E}[|Y_k|^3] = \sigma_k^3 \mathbb{E}[|Y|^3]) \\ &\leq \frac{K}{B_n} \max_{1 \leq k \leq n} \sigma_k \cdot \sum_{k=1}^n \frac{\sigma_k^2}{B_n^2} \mathbb{E}[|Y|^3] \quad (\text{选一个最大的 } \sigma_k^2) \\ &= K \sqrt{\frac{1}{B_n^2} \max_{1 \leq k \leq n} \sigma_k^2} \cdot \mathbb{E}[|Y|^3] \quad \left(B_n^2 = \sum_{k=1}^n \sigma_k^2 \right) \end{aligned}$$

可以看到最后一行根号里面的就是 Feller 条件的表达式, 而 $Y \sim \mathcal{N}(0, 1)$, 故 $\mathbb{E}[|Y|^3], K$ 都是正常数, 所以令 $n \rightarrow \infty$ 取极限就有:

$$\sum_{k=1}^n \mathbb{E} \left[h \left(\frac{Y_k}{B_n} \right) \right] \rightarrow 0 \quad (n \rightarrow \infty)$$

再来看 X_k 部分, 有:

$$\begin{aligned} \sum_{k=1}^n \mathbb{E} \left[h \left(\frac{X_k}{B_n} \right) \right] &= \sum_{k=1}^n \mathbb{E} \left[h \left(\frac{X_k}{B_n} \right) I_{\{|X_k| < \epsilon B_n\}} \right] + \sum_{k=1}^n \mathbb{E} \left[h \left(\frac{X_k}{B_n} \right) I_{\{|X_k| \geq \epsilon B_n\}} \right] \\ &\leq \sum_{k=1}^n K \mathbb{E} \left[\frac{|X_k|^3}{B_n^3} I_{\{|X_k| < \epsilon B_n\}} \right] + \sum_{k=1}^n K \mathbb{E} \left[\frac{X_k^2}{B_n^2} I_{\{|X_k| \geq \epsilon B_n\}} \right] \quad (h(t) \leq K \min\{t^2, |t|^3\}) \\ &\leq \sum_{k=1}^n \frac{K\epsilon}{B_n^2} \mathbb{E}[X_k^2] + \sum_{k=1}^n \frac{K}{B_n^2} \mathbb{E} \left[X_k^2 I_{\{|X_k| \geq \epsilon B_n\}} \right] \quad (\text{提出一个 } X_k \text{ 放缩成 } \epsilon B_n) \\ &= K\epsilon + \frac{K}{B_n^2} \sum_{k=1}^n \mathbb{E} \left[X_k^2 I_{\{|X_k| \geq \epsilon B_n\}} \right] \quad \left(B_n^2 = \sum_{k=1}^n \mathbb{E}[X_k^2] \right) \end{aligned}$$

先令 $n \rightarrow \infty$ 取上极限, 发现最后一行右边项就是 Lindeberg 条件表达式, 趋于 0。再令 $\epsilon \rightarrow 0$ 得到左边项也趋于 0, 故:

$$\sum_{k=1}^n \mathbb{E} \left[h \left(\frac{X_k}{B_n} \right) \right] \rightarrow 0 \quad (n \rightarrow \infty)$$

将 X_k, Y_k 两个和式拼在一起即可得到:

$$\mathbb{E} \left[g \left(\frac{S_n}{B_n} \right) \right] \rightarrow \mathbb{E} [g(Y)] \quad (n \rightarrow \infty)$$

故由 **Lemma 2.4**, 可得 $\frac{S_n}{B_n} \xrightarrow{D} Y \sim \mathcal{N}(0, 1)$ 。 □

3 统计物理

3.1 信息熵

Example 3.1 (投骰子). 在赌场中连续投三个骰子, 我们看如下两个事件:

- 出现三个六, 概率为 $\frac{1}{6^3}$ 。
- 三个骰子点数之和为偶数, 概率为 $\frac{1}{2}$ 。

相较于第二个事件, 第一个事件发生概率小很多。如果第一个事件发生, 人们脸上的表情会比发生第二个事件时惊讶很多。

我们想找到一个有关于概率 p 的函数 $S(p)$, 可以刻画一个事件的惊奇程度。

Definition 3.2 (信息熵). 称一个函数 $S : [0, 1] \rightarrow \mathbb{R}$ 是一个信息熵函数, 若其满足如下性质:

- (1) $S(1) = 0$, 这表示一个必然事件并不惊奇。
- (2) 当 $p_1 < p_2$ 时, $S(p_1) > S(p_2)$, 表示约不可能发生的事件, 其惊奇程度越高, 蕴含的信息越多。
- (3) $S(p)$ 为关于 p 的连续函数。
- (4) $S(pq) = S(p) + S(q)$ 。这表明若两个事件 A, B 独立, 且 $\Pr(A) = p, \Pr(B) = q$, 则 $A \cap B$ 的惊奇程度为 $S(pq)$ 。若先有 A 发生, 再有 B 发生, 那增量 $S(pq) - S(p)$ 应该与 A 无关, 对 B 也同理。

实际上满足这几条的函数是唯一的。

Theorem 3.3 (信息熵函数的唯一性). 信息熵函数 $S(p)$ 必然为:

$$S(p) = -c \ln p$$

其中 $c > 0$ 为一常数。

Proof. 由 4 知:

$$S(p^{m/n}) = \frac{m}{n}S(p)$$

再由 3 可知:

$$S(p^x) = xS(p), \forall x > 0$$

令 $x = -\ln p$ 就有:

$$S(p) = -S(1/e) \ln p$$

令 $c = S(1/e)$ 即得证。 □

我们再给出关于随机变量定义的熵——Shannon 熵。

Definition 3.4 (Shannon 熵). 对于一个离散型随机变量 X 。我们定义其 Shannon 熵为:

$$H(X) = -\sum_i p_i \ln p_i$$

对于两个离散随机变量 X, Y , 我们还有联合熵:

$$H(X, Y) = -\sum_{i,j} p(x_i, y_j) \ln p(x_i, y_j)$$

与 X 关于 Y 的相对熵:

$$H_Y(X) = \sum_j H_{Y=y_j}(X) p_Y(y_j)$$

其中:

$$H_{Y=y_j}(X) = -\sum_i p(x_i | y_j) \ln p(x_i | y_j)$$

这里省略了对分布列的说明。

参考文献: 1948, Shannon, "A Mathematical Theory of Communications".

对于 Shannon 熵, 我们有如下两个重要事实: 联合熵等于相对熵与原熵的加和, 以及相对熵不超过原熵。证明较为简单, 我们略去。

Lemma 3.5. 我们有如下两个事实:

- $H(X, Y) = H_Y(X) + H(Y)$ 。
- $H_Y(X) \leq H(X)$, 且等号成立当且仅当 X 与 Y 独立。

Remark. 当随机变量 X 可取有限个值 $\Pr(X = x_i) = p_i, \forall i \in [n]$, 则易知当且仅当 $p_i = \frac{1}{n}, \forall i \in [n]$ 时, $H(X)$ 取到最大值 $\ln n$ 。

而 $\ln n > \ln(n-1)$, 依此我们可以发现: 不确定性程度越大, 熵越大, 熵是刻画混乱程度的量。

Definition 3.6 (连续型随机变量的 Shannon 熵). 设连续型随机变量 X 有密度函数 $f(x)$, 则有 Shannon 熵:

$$H(X) = - \int_{\mathbb{R}} f(x) \ln f(x) dx$$

而对于两个连续型随机变量 X, Y , 也有联合熵:

$$H(X, Y) = - \iint_{\mathbb{R}^2} f(x, y) \ln f(x, y) dx dy$$

为了找出连续型随机变量熵的性质, 我们先给出如下不等式。利用事实 $\ln \leq x - 1$, 可以非常容易验证该不等式, 这里略去不证。

Lemma 3.7 (Gibbs 不等式). 我们有:

$$u - u \ln u \leq v - u \ln v, \quad \forall u, v \in \mathbb{R}^+$$

我们取 $u = f(x), v = g(x)$, 再积分就有:

$$H(x) = - \int_{\mathbb{R}} f(x) \ln f(x) dx \leq - \int_{\mathbb{R}} f(x) \ln g(x) dx$$

借助信息熵, 我们可以从另一个侧面, 看正态分布在连续型分布中的特殊地位。

Theorem 3.8 (正态分布熵最大). 记 $D_f = \{x \in \mathbb{R} \mid f(x) > 0\}$. 对于一个连续型随机变量 X , 其有密度函数 $f(x)$, 则:

- 若 $D_f = \mathbb{R}$, 且 $\mathbb{E}[X] = 0, \text{Var}(X) = 1$. 那么 $H(X) \leq \ln \sqrt{2\pi e}$, 且等号成立当且仅当 $X \sim \mathcal{N}(0, 1)$.
- 若 $D_f = (0, +\infty)$, 且 $\mathbb{E}[X] = \frac{1}{\lambda}$ ($\lambda > 0$), 则 $H(X) \leq \ln \left(\frac{e}{\lambda}\right)$, 且等号成立当且仅当 $X \sim \text{Exp}(\lambda)$.
- 若 $D_f = (0, a)$, 则 $H(X) \leq \ln a$, 且等号成立当且仅当 $X \sim U(0, a)$.

Proof. 我们只证明第一条, 剩下几条证明类似。

我们取 $g(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right)$, 则由 Gibbs 不等式:

$$H(X) \leq - \int_{\mathbb{R}} f(x) \left(-\frac{1}{2}x^2 - \ln \sqrt{2\pi}\right) = \frac{1}{2} + \ln \sqrt{2\pi}$$

而当且仅当并不好说明, 我们略去。 □

我们还有离散情形的 Gibbs 不等式:

Lemma 3.9. 若 $\forall i \in [n], p_i, q_i \geq 0$, 且:

$$\sum_{i=1}^n p_i = \sum_{i=1}^n q_i,$$

则:

$$- \sum_{i=1}^n p_i \ln p_i \leq - \sum_{i=1}^n p_i \ln q_i$$

且等号成立当且仅当 $\forall i \in [n], p_i = q_i$.

由离散情形的 Gibbs 不等式，我们可以引出另一种熵——Boltzmann 熵：

Problem 3.10 (Boltzmann 熵). 对于一个离散型随机变量 X ，是一个代表能级的物理量。其有分布列： $\Pr(X = E_i) = p_i, \forall i \in [n]$ 。

给定平均能量 $\mathbb{E}[X] = \sum_{i=1}^n p_i E_i = U$ ，问 $\{p_i\}$ 取何值时其熵 $H(X)$ 最大。

Solution. 取 $q_i = \frac{1}{Z} e^{-\beta E_i}$ ，其中 $Z = \sum_{i=1}^n e^{-\beta E_i}$ ， $\beta > 0$ 。

由离散情形的 Gibbs 不等式：

$$H(X) \leq - \sum_{i=1}^n p_i (-\beta E_i - \ln Z) = \beta U + \ln Z$$

在物理上 β 可由 $\{E_i\}$ 和 U 决定。注意对比只给定 n ，不给定 U 的情况。 \triangle

由此可以给出物理上的 Boltzmann 熵：

Definition 3.11 (Boltzmann 熵). $S = k_B \ln \Omega$ ，其中 Ω 为微观粒子状态数， k_B 为 Boltzmann 常数。

3.2 Ising 模型

Example 3.12 (格点气体). 设 $\Lambda \subset \mathbb{Z}^d$ 且 $N = |\Lambda| < \infty$ ，是 d 维格点的有限子集，而样本空间为 $\Omega_\Lambda = \{+1, -1\}^\Lambda$ 。

引入 Hamilton 量：

$$H(\omega) = - \sum_{i,j \in \Lambda} J_{ij} \omega_i \omega_j, \forall \omega \in \Omega_\Lambda$$

其中 $\{J_{ij}\}$ 给定，表示粒子各个分量相互作用的强度。由此我们可以定义 Ω_Λ 上的概率测度：

$$\mu_{\Lambda\beta} = \frac{1}{Z_{\Lambda\beta}} e^{-\beta H(\omega)}$$

其中 $Z_{\Lambda\beta}$ 是一个规范化常数。这个是统计物理里的格点气体模型。

更一般的，我们可以根据统计力学的基本假设，以及最大熵原理，引入 Gibbs 测度：

Definition 3.13 ((正则) Gibbs 分布). 我们有统计力学的基本假设：

- (1) 微观状态空间 Ω_Λ ，记 $N = |\Lambda| < \infty$ 为微观粒子状态数；
- (2) 相互作用的 Hamilton 量 $H : \Omega_\Lambda \rightarrow \mathbb{R}$ 。

则我们可以定义 Gibbs 测度：

$$\mu_{\Lambda\beta N}(\omega) = \frac{1}{Z_{\Lambda\beta N}} e^{-\beta H(\omega)}, \forall \omega \in \Omega_\Lambda$$

这里 $\beta \geq 0$ 为逆温度 $\frac{1}{k_B T}$ ， ω 的 Boltzmann 权重为 $e^{-\beta H(\omega)}$ ，而配分函数：

$$Z_{\Lambda\beta N} = \sum_{\omega \in \Omega_\Lambda} e^{-\beta H(\omega)}$$

对于这一统计力学模型，我们关心如下问题：

- (1) 热力学极限， $N \rightarrow \infty$ 。
- (2) 相变现象。
- (3) 简单逼近复杂。

接下来我们引入 Ising 模型。

在 1895 年，Pierre Curie 发现，加热一个磁铁，到达一定临界温度，磁铁的磁性会消失。这一临界温度被称为 Curie 温度。

1920 年 Heinrich Lenz 和 1925 年 Ernst Ising 提出如下模型来解释这一现象。

Definition 3.14 (Ising 模型). $\Lambda \subset \mathbb{Z}^d$ 为有限格点集合，构形空间 $\Omega_\Lambda = \{+1, -1\}^d$ 。

定义相邻点对集合：

$$\varepsilon_\Lambda = \{(i, j) \in \Lambda^2 \mid \|i - j\|_1 = 1\}$$

$$\varepsilon_{\Lambda_L} = \{(i, j) \in \Lambda_L^2 \mid \|i - j\|_1 \equiv 1 \pmod{L}\}$$

这里 $\Lambda_L = [L]^d$ ，在第二个集合里 $1, L$ 也是相邻的。

对于一个粒子 $\sigma \in \Omega_\Lambda$ ，记 $\sigma = (\sigma_1, \sigma_2, \dots, \sigma_N)$ 。那么有 Ising 模型：

- (1) 自由边界：

$$H(\sigma) = -J \sum_{(i,j) \in \varepsilon_\Lambda} \sigma_i \sigma_j - h \sum_{i \in \Lambda} \sigma_i$$

- (2) 周期边界：

$$H(\sigma) = -J \sum_{(i,j) \in \varepsilon_{\Lambda_L}} \sigma_i \sigma_j - h \sum_{i \in \Lambda} \sigma_i$$

J 表示相互作用强度，而 h 表示外场强度。两种情况都可以定义对应的 Gibbs 测度。

我们关心磁化强度 $M_\Lambda(\sigma) = \sum_{i \in \Lambda} \sigma_i$ ，在平均下的极限行为 $\frac{M_\Lambda(\sigma)}{N} \in [-1, 1]$ ， $N \rightarrow \infty$ ；以及在温度 T 变化（ β 相应变化）时 $M_\Lambda(\sigma)$ 的涨落行为（比如当 $T = \infty, \beta = 0$ 时，Boltzmann 权重都是 1，就是一个古典概型；而当 $T \rightarrow 0, \beta \rightarrow +\infty$ ， $H(\sigma)$ 非常小，能量与熵相互竞争，相变可能出现）。

以 $d = 1$ 周期边界这一情况来阐述 Ising 模型（ $d \geq 3$ 时非常困难），我们可以写出 Hamilton 量和配分函数：

$$H(\sigma) = -J \sum_{i=1}^N \sigma_i \sigma_{i+1} - h \sum_{i=1}^N \sigma_i$$

$$Z_{\Lambda\beta h} = \sum_{\sigma_1, \dots, \sigma_N = \pm 1} \exp\left(\beta J \sum_{i=1}^N \sigma_i \sigma_{i+1} + \beta h \sum_{i=1}^N \sigma_i\right)$$

约定 $\sigma_{N+1} = \sigma_1$ 。

Definition 3.15 (转移矩阵). 我们引入转移矩阵 P ：

$$\langle \sigma | P | \sigma' \rangle = \exp\left(\beta J \sigma \sigma' + \frac{1}{2} \beta h (\sigma + \sigma')\right)$$

其中 Dirac 记号 $\langle \sigma | P | \sigma' \rangle$ 表示矩阵 P 在 (σ, σ') 处元素。具体展开写有：

$$P = \begin{array}{c} + \\ - \end{array} \begin{array}{cc} + & - \\ \left(\begin{array}{cc} e^{\beta J + \beta h} & e^{-\beta J} \\ e^{-\beta J} & e^{\beta J - \beta h} \end{array} \right) \end{array}$$

这样配分函数可以写为：

$$Z_{\Lambda\beta h} = \text{tr}(P^N) = e^{N\beta J} (A_+^N(h) + A_-^N(h))$$

其中：

$$A_{\pm}(h) = \cosh(\beta h) \pm \sqrt{\sinh^2(\beta h) + e^{-4\beta J}}$$

并且 $\lambda_{\pm} = e^{\beta J} A_{\pm}(h)$ 为 P 的两个特征值。

进而：

$$\begin{aligned} \mathbb{E} \left[\frac{M_N(\sigma)}{N} \right] &= \frac{1}{\beta N} \frac{\partial}{\partial h} \ln Z_{\Lambda\beta h} = \frac{1}{\beta N} \frac{\partial}{\partial h} \ln (A_+^N(h) + A_-^N(h)) \\ &\rightarrow \frac{1}{\beta} \frac{\partial}{\partial h} \ln A_+(h) = \frac{\sinh(\beta h)}{\sqrt{\sinh^2(\beta h) + e^{-4\beta J}}} \end{aligned}$$

这个是在期望意义下磁化强度的极限行为。实际上我们对于 Ising 模型也有 LLN 和 CLT。

Theorem 3.16 (Ising 模型的 LLN 与 CLT). 取 Ising 模型中 $d = 1$, $h = 0$, 且周期边界, 则：

$$\frac{M_N(\sigma)}{N} \xrightarrow{P} 0, \quad \frac{M_N(\sigma)}{B\sqrt{N}} \xrightarrow{D} \mathcal{N}(0, 1) \quad (N \rightarrow \infty)$$

这里 $B = \sqrt{\frac{1 + e^{2\beta J}}{1 + e^{-2\beta J}}}$ 。

Proof. 我们考虑 $\frac{M_N(\sigma)}{N^\delta}$ 的矩母函数：

$$M(t) = \mathbb{E} \left[\exp \left(t \frac{M_N(\sigma)}{N^\delta} \right) \right] = \frac{Z_{\Lambda\beta h}}{Z_{\Lambda\beta 0}}, \quad h = \frac{t}{\beta N^\delta}, \quad \forall t \in \mathbb{R}$$

而：

$$\ln \left(\frac{Z_{\Lambda\beta h}}{Z_{\Lambda\beta 0}} \right) = \ln \left(\frac{A_+^N(h) + A_-^N(h)}{A_+^N(0) + A_-^N(0)} \right)$$

我们将 $A_{\pm}(h)$ 在 0 处 Taylor 展开：

$$A_{\pm}(h) = 1 \pm e^{-2\beta J} + \frac{1}{2}(1 \pm e^{2\beta J})(\beta h)^2 + O((\beta h)^4)$$

所以：

$$\begin{aligned} \ln \left(\frac{Z_{\Lambda\beta h}}{Z_{\Lambda\beta 0}} \right) &= \ln \left(\frac{A_+^N(h) + A_-^N(h)}{A_+^N(0) + A_-^N(0)} \right) \\ &= N \ln \left(1 + \frac{1}{2} \frac{1 + e^{2\beta J}}{1 + e^{-2\beta J}} (\beta h)^2 + O((\beta h)^4) \right) \end{aligned}$$

$$= N(\beta h)^2 \frac{1 + e^{2\beta J}}{2(1 + e^{-2\beta J})} + O(N(\beta h)^4)$$

当 $\delta = 1$ 时, 极限为 0; 当 $\delta = \frac{1}{2}$ 时, 极限为 $\frac{B^2}{2}t^2$ 。这两个取一个 \exp 分别对应零分布和 $\mathcal{N}(0, B^2)$ 的矩母函数, 故得证。 \square

这样在 $d = 1$ 周期边界条件下的事情已经明了了。当 $d = 2$ 时, LLN 显得稍微有点不同:

$$\mathbb{E} \left(\left| \frac{M_N(\sigma)}{N} \right| \right) \rightarrow \begin{cases} 0 & T > T_c \\ (1 - \sinh^{-4}(2\beta J))^{1/8} & T \leq T_c \end{cases}$$

可以看到在温度小于 Cuire 温度 T_c 时, 收敛到的值不一样, 这个是相变现象一种概率诠释。

3.3 Cuire-Weiss 模型和相变现象

接下来我们介绍 Cuire-Weiss 模型, 一定程度上可以说是 Ising 模型的平均场近似。在这一模型下, 我们可以研究相变现象。

Definition 3.17 (Cuire-Weiss 模型). 一定程度上可以说是 Ising 模型的平均场近似, 我们有:

$$\sum_{j:j\sim i} \sigma_i \sigma_j = 2d\sigma_i \frac{1}{2d} \sum_{j:j\sim i} \sigma_j \rightarrow \frac{2d\sigma_i}{N} \sum_{j=1}^N \sigma_j$$

我们使用整体平均, 近似 Hamilton 量为:

$$H(\sigma) = -\frac{dJ}{N} \left(\sum_{i=1}^N \sigma_i \right)^2 - h \sum_{i=1}^N \sigma_i$$

这时候也定义相应的 Gibbs 测度为:

$$\mu_{N\beta h}(\sigma) = \frac{1}{Z_{N\beta h}} e^{-\beta H(\sigma)}$$

Theorem 3.18 (Cuire-Weiss 模型的相变现象). 令 $J = 1, h = 0, \beta_c = \frac{1}{2d}$, 则:

- (1) 当 $0 < \beta \leq \beta_c$ 时, 对于任何的 $\epsilon > 0$, 存在依赖于 β, ϵ 的常数 $c = c(\beta, \epsilon) > 0$, 使得对充分大的 N , 有:

$$\mu_{N\beta h} \left(\frac{M_N(\sigma)}{N} \notin (-\epsilon, \epsilon) \right) \leq 2e^{-cN}$$

- (2) 当 $\beta > \beta_c$ 时, 存在某一依赖于 β 的常数 (自发磁化强度) $m^* = m^*(\beta) > 0$, 使得对于任意充分小的 $\epsilon > 0$, 存在一个依赖于 β, ϵ 的常数 $b = b(\beta, \epsilon) > 0$, 当 N 充分大时有:

$$\mu_{N\beta_0} \left(\frac{M_N(\sigma)}{N} - m^* \notin (-\epsilon, \epsilon) \text{ and } \frac{M_N(\sigma)}{N} + m^* \notin (-\epsilon, \epsilon) \right) \leq 2e^{-bN}$$

为了证明这一定理, 我们需要如下引理:

Lemma 3.19. 令自由能 $f_\beta(m) = -\beta dm^2 - S(m)$ ($m \in [-1, 1]$), 这里 $S(m)$ 为熵:

$$S(m) = -\frac{1-m}{2} \ln \left(\frac{1-m}{2} \right) - \frac{1+m}{2} \ln \left(\frac{1+m}{2} \right)$$

则:

$$\lim_{N \rightarrow \infty} \frac{1}{N} \ln Z_{N\beta 0} = - \min_{m \in [-1, 1]} f_\beta(m)$$

更一般的, 对 $K \subset [-1, 1]$, 有:

$$\lim_{N \rightarrow \infty} \frac{1}{N} \ln \mu_{N\beta 0} \left(\frac{M_N(\sigma)}{N} \in K \right) = - \min_{m \in K} I_\beta(m)$$

这里 $I_\beta(m) = f_\beta(m) - \min_{m' \in [-1, 1]} f_\beta(m')$, 为速率函数, 在大偏差理论中很有用。

Proof. 记 $A_N = \left\{ -1 + \frac{2k}{N} \mid k = 0, 1, \dots, N \right\}$, 则由二项式的组合意义知:

$$\begin{aligned} \mu_{N\beta h} \left(\frac{M_N(\sigma)}{N} \in K \right) &= \sum_{m \in K \cap A_N} \mu_{N\beta 0} \left(\frac{M_N(\sigma)}{N} = m \right) \\ &= \frac{1}{Z_{N\beta h}} \sum_{m \in K \cap A_N} \binom{N}{(1+m)N/2} e^{\beta dm^2 N + \beta hmN} \end{aligned}$$

类似的, 有:

$$Z_{N\beta h} = \sum_{m \in A_N} \binom{N}{(1+m)N/2} e^{\beta dm^2 N + \beta hmN} \quad (2)$$

我们只证 $h = 0$ 情况的 (2), 剩下部分证明类似。做一个粗放缩:

$$\Delta = \max_{m \in A_N} \binom{N}{(1+m)N/2} e^{\beta dm^2 N}, \quad \Delta \leq Z_{N\beta 0} \leq (N+1)\Delta$$

再来, 利用事实: 存在常数 $c_1, c_2 > 0$, 使得:

$$\frac{c_1}{\sqrt{N}} e^{NS(m)} \leq \binom{N}{(1+m)N/2} \leq c_2 \sqrt{N} e^{NS(m)}$$

我们可以对 $Z_{N\beta 0}$ 做上下界估计。

先做上界估计:

$$\begin{aligned} Z_{N\beta 0} &\leq c_2 \sqrt{N} (N+1) \exp \left(N \max_{m \in A_N} \{ \beta dm^2 + S(m) \} \right) \\ &\leq c_2 \sqrt{N} (N+1) \exp \left(-N \min_{m \in [-1, 1]} f_\beta(m) \right) \end{aligned}$$

故:

$$\limsup_{N \rightarrow \infty} \frac{1}{N} \ln Z_{N\beta 0} \leq - \min_{m \in [-1, 1]} f_\beta(m)$$

再做下界估计: 由 $f_\beta(m)$ 连续性知, 存在 $m' \in [-1, 1]$, 使得 $f_\beta(m') = \min_{m \in [-1, 1]} f_\beta(m)$ 。

则对于任意 $\delta > 0$, 可取充分大的 N , 使得存在 $m \in A_N$, 满足:

$$|f_\beta(m) - f_\beta(m')| \leq \delta$$

因此:

$$Z_{N\beta_0} \geq \frac{c_1}{\sqrt{N}} \exp(-N(f_\beta(m') + \delta))$$

进而:

$$\liminf_{N \rightarrow \infty} \frac{1}{N} \ln Z_{N\beta_0} \geq -f_\beta(m') - \delta$$

由 δ 的任意性, 令 $\delta \rightarrow 0+$ 即得证 (实际上这时候 N 也跟着一起趋向于 ∞)。 \square

接下来我们证明原定理:

Proof of Theorem 3.18. 我们讨论 $I_\beta(m) = f_\beta(m) - \min_{m' \in [-1,1]} f_\beta(m')$ 在 $[-1, 1]$ 的最小值点 (最小值为 0), 实际上看的是 $f_\beta(m)$ 的拐点。

对 $f(m) = f_\beta(m)$ 求一阶和二阶导:

$$f'(m) = -2\beta dm + \frac{1}{2} \ln \left(\frac{1+m}{1-m} \right)$$

$$f''(m) = -2\beta d + \frac{1}{1-m^2}$$

我们分两种情况讨论:

- (1) 当 $2\beta d \leq 1$ 时, 则 $f''(m) \geq 0$ 恒成立, 而 $f'(m) = 0$ 当且仅当 $m = 0$, 这也是 $I_\beta(m)$ 的唯一最小值点。

我们取 $K = [-1, -\epsilon] \cup [\epsilon, 1]$, 则在 K 上, $I_\beta(m)$ 的最小值是一个和 ϵ, β 有关的常数, 记为 $c = c(\beta, \epsilon) > 0$ 。故由 **Lemma 3.19**:

$$\lim_{N \rightarrow \infty} \frac{1}{N} \ln \mu_{N\beta_0} \left(\frac{M_N(\sigma)}{N} \in K \ (\notin (-\epsilon, \epsilon)) \right) = -c$$

故:

$$\mu_{N\beta_0} \left(\frac{M_N(\sigma)}{N} \notin (-\epsilon, \epsilon) \right) \leq 2e^{-cN}$$

其中右边乘 2 是为了包括取极限带来的误差。

- (2) 当 $2\beta d > 1$ 时, $f''(m) = 0$ 有两根 $m = \pm \sqrt{1 - \frac{1}{2\beta d}} \triangleq \pm m^*$, 这也是 $I_\beta(m)$ 在 $[-1, 1]$ 上的两个最小值点。

我们取 $K = [-1, 1] \setminus ((m^* - \epsilon, m^* + \epsilon) \cup (-m^* - \epsilon, -m^* + \epsilon))$, 之后和上一个情况完全类似。

综上所述得证。 \square

Remark. 通过 **Theorem 3.18**, 我们可以得到一个有着相变现象的“LLN”:

$$\frac{M_N(\sigma)}{N} \xrightarrow{P} \begin{cases} 0 & \beta \leq \beta_c \\ \frac{1}{2}(\delta(m^*) + \delta(-m^*)) & \beta > \beta_c \end{cases}$$

其中 $\delta(x)$ 为 Dirac 函数, $\frac{1}{2}(\delta(m^*) + \delta(-m^*))$ 表示以概率 $\frac{1}{2}$ 取到 $\pm m^*$ 的随机变量的密度函数。

有了“LLN”, 我们自然还关心“CLT”, 即 $\frac{M_N(\sigma)}{N^\delta}$ 的极限行为。我们还是看矩母函数:

$$M(t) = \mathbb{E} \left[\exp \left(t \frac{M_N(\sigma)}{N^\delta} \right) \right] = \frac{Z_{N\beta h}}{Z_{N\beta 0}}, \quad h = \frac{t}{\beta N^\delta}$$

对于 $Z_{N\beta h}$, 有:

$$Z_{N\beta h} = \sum_{\{\sigma\}} \exp \left(\frac{\beta d}{N} \left(\sum_{i=1}^N \sigma_i \right)^2 + \beta h \sum_{i=1}^N \sigma_i \right)$$

我们不喜欢那个关于和式的二次方项。为此, 我们使用技巧 **Hubbard-Stratonovich 变换**:

$$e^{\alpha x^2} = \frac{1}{\sqrt{\pi\alpha}} \int_{\mathbb{R}} dy \exp \left(-\frac{y^2}{\alpha} + 2xy \right), \quad \alpha > 0$$

可得:

$$\begin{aligned} Z_{N\beta h} &= \sum_{\{\sigma\}} \exp \left(\frac{\beta d}{N} \left(\sum_{i=1}^N \sigma_i \right)^2 + \beta h \sum_{i=1}^N \sigma_i \right) \\ &= \sqrt{\frac{N}{\pi\beta d}} \int_{\mathbb{R}} dy \sum_{\{\sigma\}} \exp \left(-\frac{N}{\beta d} y^2 + (2y + \beta h) \sum_{i=1}^N \sigma_i \right) \\ &= \sqrt{\frac{N}{\pi\beta d}} \int_{\mathbb{R}} dy \exp \left(-\frac{N}{\beta d} y^2 \right) (e^{2y+\beta h} + e^{-2y-\beta h})^N \\ &= \sqrt{\frac{N}{4\pi\beta d}} \int_{\mathbb{R}} dy \exp \left(-\frac{\beta h^2 N}{4d} + \frac{hN}{2d} y - Ng(y) \right) \quad (\text{做代换 } y \leftarrow (y - \beta h)/2) \end{aligned}$$

其中 $g(y) = \frac{1}{4\beta d} y^2 - \ln(e^y + e^{-y})$ 。代回去得到:

$$M(t) = \exp \left(-\frac{t^2}{4\beta d N^{2\delta-1}} \right) \cdot \frac{\int_{\mathbb{R}} \exp \left(\frac{ty}{2\beta d N^{\delta-1}} - Ng(y) \right) dy}{\int_{\mathbb{R}} e^{-Ng(y)} dy}$$

我们需要找到一种方法去处理分子分母里的积分, 为此我们引入:

Example 3.20 (Laplace 方法). 我们有欧拉积分:

$$\Gamma(s+1) = \int_0^{+\infty} x^s e^{-x} dx = s^{s+1} \int_0^{+\infty} e^{-sg(x)} dx$$

其中最后一步做替换 $x \leftarrow sx$, 而 $g(x) = x - \ln x$ 。

我们换一种方式来证明 Stirling 公式, 大致上的想法就是, 在 $s \rightarrow +\infty$ 时, 上面的积分式里只有 $g(x)$ 的极小值点部分产生的贡献是主要的。

$g(x)$ 在 $x = 1$ 处取到极小值 1，我们在 $x = 1$ 这一点 Taylor 展开，配合 $g'(1) = 0$ 有：

$$g(x) - g(1) = \frac{g''(1)}{2}(x-1)^2 + O((x-1)^3)$$

O 里面的小项，在 \exp 作用会变得“更小”，所以我们只需要看二阶导对应的主项：

$$\begin{aligned} & e^{-sg(1)} \int_0^{+\infty} e^{-s(g(x)-g(1))} dx \\ & \sim e^{-s} \int_{1-\delta}^{1+\delta} \exp\left(-\frac{g''(1)}{2}(x-1)^2\right) dx \\ & \sim \frac{e^{-s}}{\sqrt{s}} \int_{-\sqrt{s}\delta}^{\sqrt{s}\delta} \exp\left(-\frac{x^2}{2}\right) dx \sim \sqrt{\frac{2\pi}{s}} e^{-s} \end{aligned}$$

其中最后一个 \sim 是因为当 $s \rightarrow +\infty$ 时，那个积分会变成高斯积分。发现这时候再乘 s^{s+1} 就得到 Stirling 公式。

这种方法实际上叫 Laplace 方法，上面说的并不严谨，更多可以参见：[Wikipedia: Laplace Method](#)。

回到原问题，我们对 $g(y)$ 求一阶和二阶导：

$$g'(y) = \frac{y}{2\beta d} - \frac{e^y - e^{-y}}{e^y + e^{-y}}$$

$$g''(y) = \frac{1}{2\beta d} - \frac{4e^{2y}}{(1 + e^{2y})^2}$$

当 $\beta \leq \beta_c$ 时， $g(y)$ 有唯一的最小值点 $y_0 = 0$ 。

还是根据 β 分类讨论：

(1) 当 $\beta < \beta_c$ 时，有 $g''(y_0) > 0$ 。

将 $g(y)$ 在 y_0 这一点 Taylor 展开：

$$g(y) - g(y_0) = \frac{1}{2} \left(\frac{1}{2\beta d} - 1 \right) y^2 + O(y^4)$$

还是仿照 Laplace 方法，只看主项，就有：

$$\begin{aligned} M(t) & \sim \exp\left(-\frac{t^2}{4\beta d}\right) \frac{\int_{-\epsilon}^{\epsilon} \exp\left(\frac{t}{2\beta d} \sqrt{N} y - \frac{N}{2} \left(\frac{1}{2\beta d} - 1\right) y^2\right) dy}{\int_{-\epsilon}^{\epsilon} \exp\left(-\frac{N}{2} \left(\frac{1}{2\beta d} - 1\right) y^2\right) dy} \\ & \sim \exp\left(-\frac{t^2}{4\beta d} + \frac{t^2}{4\beta d(2\beta d - 1)}\right) \frac{\int_{-\sqrt{N}\epsilon}^{\sqrt{N}\epsilon} \exp\left(\left(\frac{t}{\sqrt{4\beta d(2\beta d - 1)}} - \sqrt{\frac{1 - \beta d}{4\beta d}} u\right)^2\right) du}{\int_{-\sqrt{N}\epsilon}^{\sqrt{N}\epsilon} \exp\left(-\frac{1}{2} \left(\frac{1}{2\beta d} - 1\right) u^2\right) du} \\ & \sim \exp\left(\frac{t^2}{2(1 - 2\beta d)}\right) \frac{\int_{\mathbb{R}} \exp\left(-\frac{N}{2} \left(\frac{1}{2\beta d} - 1\right) u'^2\right) du'}{\int_{\mathbb{R}} \exp\left(-\frac{N}{2} \left(\frac{1}{2\beta d} - 1\right) u^2\right) du} \sim \exp\left(\frac{t^2}{2(1 - 2\beta d)}\right) \end{aligned}$$

其中第一行到第二行使用换元 $u = \sqrt{N}y$, 并且将分子进行配方。第二行到第三行, 先利用当 $N \rightarrow \infty$ 时, 积分区域可以扩展到 \mathbb{R} , 再进一步利用分子积分的平移不变性。

可以看到这时候 $M(t)$ 极限 $\mathcal{N}(0, B^2)$ 的矩母函数, 其中 $B = \frac{1}{\sqrt{1-2\beta d}}$ 。

(2) 当 $\beta = \beta_c$ 时, $g''(y_0) = 0$, 这时候 Taylor 展开只看二次项不够了, 要看四次项:

$$g(y) - g(y_0) = \frac{1}{12}y^4 + O(y^6)$$

那么令 $\delta = \frac{3}{4}$, 我们有:

$$M(t) \sim \exp\left(-\frac{t^2}{4\beta d\sqrt{N}}\right) \frac{\int_{-\epsilon}^{\epsilon} \exp\left(\frac{N^{1/4}t}{2\beta d}y - \frac{1}{12}y^4\right) dy}{\int_{-\epsilon}^{\epsilon} \exp\left(-\frac{1}{12}y^4\right) dy} \sim \frac{\int_{\mathbb{R}} \exp\left(tx - \frac{1}{12}x^4\right) dx}{\int_{\mathbb{R}} \exp\left(-\frac{1}{12}x^4\right) dx}$$

其中最后一步同前面类似: 做了换元 $x \leftarrow N^{1/4}y$; 然后再用: 当 $N \rightarrow \infty$ 时, 积分区域可以扩展到 \mathbb{R} ; 并且还用了: 分式外的 $\exp(\cdot/\sqrt{N})$ 项, 当 $N \rightarrow \infty$ 时会趋向于 1。

可以看到这时候 $M(t)$ 极限是一个密度函数为 $\frac{1}{c} \exp\left(-\frac{1}{12}x^4\right)$ 的随机变量, 其中

$c = \int_{\mathbb{R}} \exp\left(-\frac{1}{12}x^4\right) dx$ 是一规范化常数。

综上所述, 我们有结论:

Theorem 3.21 (Cuire-Weiss 模型的更多极限行为). 令 $J = 1, h = 0, \beta_c = \frac{1}{2d}$, 则:

(1) 当 $\beta < \beta_c$ 时:

$$\frac{M_N(\sigma)}{B\sqrt{N}} \xrightarrow{D} \mathcal{N}(0, 1), \quad B = \frac{1}{\sqrt{1-2\beta d}}$$

(2) 当 $\beta = \beta_c$ 时:

$$\frac{M_N(\sigma)}{N^{3/4}} \xrightarrow{D} \text{Some distribution with density } \frac{1}{c} \exp\left(-\frac{1}{12}x^4\right)$$

3.4 李政道-杨政宁单位圆定理

我们重写 Ising 模型的配分函数 $Z_{N\beta h}$, 把 $\sigma_i\sigma_j, \sigma_i$ 中为 1 的那些抛去不看:

$$Z_{N\beta h} = \exp\left(\beta h N + \beta \sum_{i<j} J_{ij}\right) \sum_{\{\sigma\}} \exp\left(\beta h \sum_{i=1}^N (\sigma_i - 1) + \beta \sum_{i<j} J_{ij} (\sigma_i \sigma_j - 1)\right)$$

令 $z = e^{-2\beta h}$, $a_{ij} = e^{-2\beta J_{ij}}$, $X(\{\sigma\}) = \{i \in [N] \mid \sigma_i = -1\}$, 则有:

$$Z_{N\beta h} = \exp\left(\beta h N + \beta \sum_{i<j} J_{ij}\right) \sum_{X \subset [N]} z^{|X|} \prod_{i \in X, j \notin X} a_{ij}$$

我们进行一个推广, 定义一个关于 N 个复变元 z_1, z_2, \dots, z_N 的多项式:

$$P(z_1, \dots, z_N) = \sum_{X \subset [N]} z^X \prod_{i \in X, j \notin X} a_{ij}$$

其中 $z^X = \prod_{i \in X} z_i$ 。

关于这个多项式，我们可以刻画其零点的性质，这就是李政道-杨政宁单位圆定理。

Theorem 3.22 (李政道-杨政宁单位圆定理). 若对于任何 i, j 有 $a_{ij} \in [-1, 1]$ ，则当 $|z_i| < 1, \dots, |z_N| < 1$ 时， $P(z_1, \dots, z_N) \neq 0$ 。

特别的对于 $|z| < 1$ ，有 $P(z, \dots, z) \neq 0$ 。进而，当 $|z| > 1$ 时，我们有 $P(1/z, \dots, 1/z) = z^{-N} P(z, \dots, z) \neq 0$ 。也就是说， $P(z, \dots, z)$ 的零点只能在 $|z| = 1$ 这样一个单位圆上。

Proof. 考试不考，摆烂。 □

Remark. 在 $\mu_{N\beta 0}$ 下看 $Y = \beta \sum_{i=1}^N \sigma_i$ 其矩母函数：

$$M_Y(t) = \mathbb{E}[e^{tY}] = \frac{Z_{N\beta t}}{Z_{N\beta 0}} = 2^{-N/2} \frac{P_N(z)}{P_N(1)}$$

若 $h = it$ ，则 Y 的特征函数 $\phi_Y(t)$ ，只有有实零点（即使 t 取遍整个复数域 \mathbb{C} ）。

再来，配分函数可能有实零点后，取对数就会有奇点。奇点和相变现象很有关系，没有奇点就没有相变，有奇点就有相变。

依此我们可以定义一类随机变量：

Definition 3.23 (李-杨类随机变量). 称一个随机变量 X 是李-杨类随机变量，若：

- (1) X 是对成的，即 X 与 $-X$ 同分布。
- (2) $\mathbb{E}[e^{bX^2}] < \infty$ ，对于某个 $b > 0$ 。
- (3) 特征函数 $\phi(t)$ 只有实零点。

还有一个定理：

Theorem 3.24. 若一系列随机变量 $\{X_n\}_{n=1}^{\infty}$ 都是李-杨类随机变量，且 $X_n \xrightarrow{D} X$ ，则 X 也是李-杨类随机变量。

参考文献： Charles M. Newman, Wei Wu. *Lee-Yang Property and Gaussian Multiplicative Chaos*. Communications In Mathematical Physics, 2019.

利用这一定理，我们先发现磁化强度 $M_N(\sigma) = \sum_{i=1}^N \sigma_i$ 是李-杨类随机变量。于是根据前面的定理，我们可以得到 $\mathcal{N}(0, 1)$ 和 $\frac{1}{c} \exp\left(-\frac{1}{12}x^4\right) dx$ 都是李-杨类随机变量，后者在量子场论中很有用（ ϕ^4 模型）。

李政道-杨政宁单位圆定理与 Riemann 猜想有一定联系。我们有 Riemann Zeta 函数：

$$\zeta(s) = \sum_{n=1}^{\infty} \frac{1}{n^s}, \quad \text{Re}(s) > 1$$

令 $\xi(z) = \frac{1}{2}s(s-1)\Gamma\left(\frac{s}{2}\right)\zeta(s) = \frac{1}{2}s(s-1)\Gamma\left(\frac{1-s}{2}\right)\zeta(1-s)$ 。则 $\xi(s) = \xi(-s)$ ，且为整函数。

利用 Fourier 变换, 可得:

$$\xi(s) = \int_{\mathbb{R}} e^{isu} \Phi(u) du, \quad \Phi(u) = \sum_{n=1}^{\infty} (4\pi^2 n^4 e^{9u/2} - 6\pi n^2 e^{5u/2}) \exp(-\pi n^2 e^{2u})$$

可以看到有 $\Phi(u) = \Phi(-u) \geq 0$, 且 $\Phi(u)$ 在 \mathbb{R} 上可积。于是 $\Phi(u)$ 是某种密度函数 (差一个常数)。

Conjecture 3.25 (Riemann 猜想). $\xi(s)$ 只有实零点。

可能的一种证明方法是, 研究特征函数只有实零点的随机变量。如果可以证明 $\Phi(u)$ 为密度函数的随机变量, 是李-杨类随机变量。那么根据之前的讨论, Riemann 猜想就证完了。

结语

路漫漫其修远兮, 吾将上下而求索。——离骚