

高等统计物理

陈志

Email: chenzyn@ustc.edu.cn

Web: http://staff.ustc.edu.cn/~chenzyn/Modern_statistical_physics.html

参考书:

1. 量子统计物理学, 杨展如。
2. 统计物理现代教程 (上册), **L.E. Reichl**(雷克)。
3. Equilibrium statistical physics, 3rd edition, by M. Plischke and B. Bergersen (世图有英文影印版, 中文版)
4. 统计力学 (英文第二版), 黄克孙。
5. 统计力学 (中文第三版), 帕斯里亚等。

主要讲述内容

- 概率论基础和随机过程简介，主方程（master equation），参考雷克的统计物理现代教程第五-六章。
- 杨展如的量子统计物理学第一---九章：
 1. 量子统计物理学基础：三种系综，统计算符和密度矩阵；
 2. 系综的配分函数，热力学函数的奇异性，经典和量子集团展开；
 3. 波色系统，波色-爱因斯坦凝聚，超流性；
 4. 费米系统，顺磁性和抗磁性，准粒子和元激发；
 5. 相变和临界现象的基本概念：序参量，临界指数，标度律，平均场理论，自发对称破缺；
 6. 几种典型的晶格统计模型：Ising模型，XY模型，Potts模型等；
 7. 重整化群理论（第八章和第九章部分内容）。

概率论基础和主方程

- 热力学和统计物理：

热力学：从若干**经验定律**出发，研究由大量微观粒子组成的**宏观**系统，给出物理量平均值之间的相互关系；

统计物理：从单个粒子的力学运动规律出发，加上**统计**的假设，通过大量**微观**粒子（自由度很大的系统）的集体表现来描述宏观物理量的行为，宏观量是相应**微观**物理量的统计平均值。

- 参考雷克的统计物理现代教程第五-六章。
- 讨论随机理论用于非线性系统涨落现象的动力学研究。
- 随机理论对统计物理在其它领域的应用有很重要的价值。

第一章 基本概率理论

1.1 概率

- 随机事件：在一定条件下，如果一个事件可能发生也可能不发生，这事件称为随机事件。
- 随机事件的概率（发生可能性的大小）：当观测次数 N 趋于无穷时，某一事件 A 发生的次数 N_A 与总观测次数的比值将趋于稳定的极限值—概率 $P(A)$:

$$P(A) = \lim_{N \rightarrow \infty} \frac{N_A}{N}$$

• 互斥事件概率的加法原理：

互斥事件：在一次观测中不可能同时发生的事件。

加法原理：对两互斥事件A和B，它们中任意一个出现的概率为：

$$P(A + B) = P(A) + P(B)$$


完备性：完备的互斥事件出现的总概率为1： $P(\sum_i A_i) = 1$.

• 独立概率事件的乘法原理：


独立事件：彼此没有任何关联的事件，即一事件的发生与否与别的事件的发生与否毫不相关。

乘法原理：两独立事件同时或依次发生的概率为 $P(A \cdot B) = P(A) P(B)$ 。


一般情形：集合论的描述



(a)



(b)



(c)

- (a) 阴影区为A和B的并 $P(A \cup B)$
- (b) 阴影区为A和B的交 $P(A \cap B)$
- (c) A和B互相排斥，没有重叠

- 事件A或事件B或二者同时出现的概率 $P(A \cup B)$ ：
$$P(A \cup B) = P(A) + P(B) - P(A \cap B)$$
- 互斥事件： $P(A \cup B) = P(A) + P(B)$.
- 若事件 A_1, A_2, \dots, A_m 是互斥和完备的，则 $P(\sum_i A_i) = 1$.
- 事件A和事件B二者同时出现的概率为 $P(A \cap B)$ 。
- 当且仅当 $P(A \cap B) = P(A)P(B)$ 时，事件A和B是独立的。
- 事件A和B互斥时 $P(A \cap B) = 0$ 。

条件概率 $P(B|A)$

- 条件概率 $P(B|A)$ 是在事件 B 已出现，而又出现事件 A 的概率（按雷克书中的定义，但很多书与此相反）。
- 我们有：
$$P(B|A) = \frac{P(A \cap B)}{P(A)}$$
- 由 $P(A \cap B) = P(B \cap A)$ 我们有(Bayes' theorem):
$$P(A) P(A|B) = P(B) P(B|A).$$
- 若 A 和 B 独立，则 $P(B|A)=P(B)$.

1.2 随机变量

- 随机变量：如果一个变量 x 以一定的概率在其样品空间 S 里取各种可能值，则 x 称为随机变量。随机变量分为离散型和连续型两种。
- 我们通常以 x 表示随机变量，以 x_i 和 $f(x_i)$ 表示离散型随机变量的可能取值和相应值的概率（分布函数）；以 x 和 $f_X(x)$ 表示连续型随机变量的可能取值和相应值的概率密度。
- 对离散型随机变量，我们有： $f(x_i) \geq 0$ 和 $\sum_i f(x_i) = 1$.
- 对连续型随机变量，我们有： $f_X(x) \geq 0$ 和 $\int f_X(x)dx = 1$.
- 随机变量的 n 阶矩(moments): $\langle X^n \rangle = \sum_i x_i^n f(x_i)$ 或 $\langle X^n \rangle = \int dx x^n f_X(x)$.
- $\langle X \rangle$ 为平均值，二阶矩与方差(variance)有关： $\text{Var}(x) = \langle X^2 \rangle - \langle X \rangle^2$.
- 矩给出了分布函数的范围和形状信息。
- 对连续型随机变量，若所有的矩 $\langle X^n \rangle$ 都知道，则概率密度函数被完全确定。特殊地，高斯分布被一阶和二阶矩完全确定（反之也成立）。

为什么?

1.3 特征函数

特征函数 $\phi_X(k)$: 概率密度函数 $f_X(x)$ 的傅立叶变换。

$$\phi_X(k) = \langle e^{ik \cdot x} \rangle = \int dx e^{ikx} f_X(x) = \sum_{n=0}^{\infty} \frac{(ik)^n \langle X^n \rangle}{n!}.$$

- 在上面的积分里对 k （多次）求导再取 $k=0$ ，很容易就可得到最后的级数表达式。注意级数展开只当高阶矩足够小时才有意义。
- 由上式可见，特征函数和概率密度函数都由各级矩完全确定。
- 另一个相关的量：累积量(cumulants)---其中 $C_n(X)$ 是第 n 级累积量

$$\phi_X(k) = \exp \left[\sum_{n=1}^{\infty} \frac{(ik)^n}{n!} C_n(X) \right].$$

我们有 $C_1(X) = \langle X \rangle$, $C_2(X) = \langle X^2 \rangle - \langle X \rangle^2$, $C_3(X) = \langle X^3 \rangle - 3\langle X^2 \rangle \langle X \rangle + 2\langle X \rangle^3$, 等等。
 $C_2(X)$ 是方差， $C_3(X)$ 可用于判断分布的对称性， $C_4(X)$ 常用于判断分布与高斯分布的偏离。

引入特征函数有何好处？

- 可以很容易计算任意两个独立随机变量和 $X=X_1+X_2$ 的密度函数：

x空间：

$$f(x) = \int_{-\infty}^{\infty} dx_1 f_1(x_1) f_2(x - x_1)$$

k空间：

$$\phi(k) = \phi_1(k) \phi_2(k)$$

避免了积分！

- 把对概率密度函数的求导转为乘积（可应用于主方程的求解），大大简化计算！

$$\begin{aligned} \phi(k) &= \int e^{ikx} f(x) dx = \iint e^{ikx} f_1(x_1) f_2(x - x_1) dx_1 dx \\ &= \int f_1(x_1) dx_1 e^{ikx_1} \int e^{ik(x-x_1)} f_2(x - x_1) d(x - x_1) \\ &= \phi_1(k) \phi_2(k). \end{aligned}$$

1.4 高维情形

- 联合概率密度:

对两随机变量 X 和 Y , 其联合概率密度 $f(x,y)$ 有:

$$f(x, y) \geq 0, \iint dx dy f(x, y) = 1.$$

- X 和 Y 的协方差定义为:

$$\text{cov}(X, Y) = \iint dx dy (x - \langle X \rangle)(y - \langle Y \rangle) f(x, y) = \langle XY \rangle - \langle X \rangle \times \langle Y \rangle.$$

- 若 X 和 Y 独立, 我们有:

$$f(x, y) = f_X(x) f_Y(y) \text{ 和}$$

$$\langle XY \rangle = \langle X \rangle \times \langle Y \rangle \text{ 及 } \text{cov}(X, Y) = 0.$$

其中最后两式的逆命题不一定成立。

1.5 几种常见分布

- 二项式分布：设每次试验有两种结果1和-1，概率分别为p和q。则N次独立试验后， n_1 次结果为1的概率为：

$$P_N(n_1) \equiv \frac{N!}{n_1!n_2!} p^{n_1} q^{n_2}.$$

- 高斯(Gaussian)分布：在大N和大pN极限下，二项式分布趋于高斯分布：

$$P_N(n_1) = \frac{1}{\sigma_N \sqrt{2\pi}} \exp \left\{ -\frac{1}{2} \frac{(n_1 - \langle n_1 \rangle)^2}{\sigma_N^2} \right\}.$$

其中 $\sigma_N = \sqrt{Npq}$ 。

- 泊松(Poisson)分布：在大N和小p极限下，如 $Np = a$, a 是一个常数，二项分布趋于泊松分布：

$$P_N(n_1) = \frac{a^{n_1} e^{-a}}{n_1!}.$$

- Lorentz或Cauchy分布（有时也叫Breit-Wigner分布）：所有的矩都发散。

$$P(x) = \frac{1}{\pi} \frac{\gamma}{(x - a)^2 + \gamma^2}, \quad -\infty < x < \infty.$$

其中Gaussian分布和Cauchy分布是稳定分布。

Levy稳定随机变量和稳定分布

这里我们考察N个iid（independent and identically distributed）随机变量 X_i 的和的分布：

$$S_N = X_1 + X_2 + \cdots + X_N.$$

若 S_N 的分布与单个随机变量 X_i 的线性函数的分布相同，即 $P_{S_N} = P_{c_N X + d_N}$ ，则称这个分布是稳定（stable）的。特别地，若 $d_N = 0$ 则分布是严格稳定的（strictly stable）。上面提到的 Gaussian分布和Cauchy分布就是稳定分布的例子。

稳定分布的重要性：不论初始随机变量 X_i 的分布是什么，当N趋于无穷大时， X_i 的和或平均值满足的分布一般将趋近于稳定分布，而后者正是我们在统计物理的研究中经常观测的量。

对稳定分布，我们有： $c_N = N^{1/\alpha}$ ， $0 < \alpha \leq 2$ 。

- 对任意满足 $\alpha \neq 1$ 的稳定分布 $P(x)$ ，我们总能找到一个常数 μ 使得 $P(x-\mu)$ 是严格稳定的；
- 当 $\alpha=2$ 我们发现分布为Gaussian分布（对Cauchy分布我们有 $\alpha=1$ ），若 $\alpha < 2$ 则方差和更高阶的矩发散（若 $\alpha < 1$ 平均值也发散）！Gaussian分布是唯一有有限方差的稳定分布。

这部分解释了为什么在自然界里我们发现很多（平均值）的分布是Gaussian分布。

稳定分布的特征函数一般可以写为:

$$\chi(t) = \langle e^{itX} \rangle = \exp(it a - |bt|^\alpha [1 - i\beta \operatorname{sgn}(t) u_\alpha(t)]), \quad t \in R, \quad \text{where } u_\alpha(t) = \begin{cases} \tan\left(\frac{\pi\alpha}{2}\right), & \alpha \neq 1 \\ -\frac{2}{\pi} \ln(|t|), & \alpha = 1 \end{cases}$$

这里shift parameter a 可以是任意实数, $b \in (0, \infty)$, $\alpha \in (0, 2]$, $\beta \in [-1, 1]$.
 b 是scale parameter, β 是skewness parameter.

练习: 验证两个稳定分布的和的分布仍是稳定分布, 并有:

$$\begin{aligned} a &= a_1 + a_2, \\ |b| &= (|b_1|^\alpha + |b_2|^\alpha)^{1/\alpha} \\ \beta &= \frac{\beta_1 |b_1|^\alpha + \beta_2 |b_2|^\alpha}{|b|^\alpha} \end{aligned}$$

熵和相对熵

- 对任一个密度函数为 ρ_X 的随机变量 \mathbf{x} 我们可以定义其熵为:

$$S[\rho_X] = -k \int dx \rho_X(x) \ln \left(\frac{\rho_X(x)}{\rho_0} \right).$$

这里我们引入参数 ρ_0 使得 $S \geq 0$ 能够成立。以后可以看到这里定义的熵和物理中的熵密切相关。

- 对任两个密度函数 p 和 q 我们可以引入相对熵的概念:

$$S[p||q] = -k \int dx p(x) \ln \left(\frac{p(x)}{q(x)} \right).$$

利用不等式: $\ln z \leq z - 1$ 可以很容易证明 (作为练习): $S[p||q] \leq 0$.

- 熵的广延性 (练习):

对任两个随机变量 \mathbf{x}_1 和 \mathbf{x}_2 , 设它们的密度函数分别为 $\rho_{X_1}(x)$ 和 $\rho_{X_2}(x)$, 两个随机变量的联合概率密度函数为 $\rho_{X_1, X_2}(x_1, x_2)$, 利用相对熵 $S[\rho_{X_1, X_2} || \rho_{X_1} \rho_{X_2}]$ 可以证明: $S_{12} \leq S_1 + S_2$. 等号当且仅当随机变量 \mathbf{x}_1 和 \mathbf{x}_2 独立时成立。

- 最大熵原理:

如果密度函数 $\rho(\mathbf{x})$ 有最大熵, 且满足额外的限制条件:

$$\langle g_i(X) \rangle \equiv \int dx g_i(x) \rho(x) = \eta_i, \quad i = 1, \dots, n.$$

这里 $g_i(x), \eta_i$ 均已知, 那么 $\rho(\mathbf{x})$ 的形式必为:
$$\rho(x) = \frac{1}{A} \exp \left[- \sum_{i=1}^n \lambda_i g_i(x) \right],$$

这个性质可利用相对熵加以证明, 具体证明作为练习。

统计物理中的对应: 平衡态时系统的熵最大, 如正则系综, 巨正则系综等。

熵的定义是唯一的吗? ---- 不是的

通常定义的熵对任两个独立随机变量 \mathbf{A} 和 \mathbf{B} 具有广延性(见前页), 但我们也可以定义不具有广延性的熵。比如Tsallis最近定义的熵(当 $q = 1$ 时即回到前面的定义):

$$S_q = \frac{1 - \int d\Omega [p(x)]^q}{q - 1}, \quad \text{where } \int p(x) d\Omega = 1, \text{ and very often } 0 \leq q \leq 2.$$

这里 $d\Omega$ 是体积元。可以发现对这个熵有: $S_q(A + B) = S_q(A) + S_q(B) + (1 - q)S_q(A)S_q(B)$.

当 $q \neq 1$ 时广延性消失。这个熵当系统有长程相互作用时比较有用。

1.6 中心极限定理和大数定律

- 考虑随机变量 X 的 N 次独立测量平均的随机变量 Y ，其概率密度函数为 $f_Y(y_N - \langle X \rangle)$ 。 $f_Y(y_N - \langle X \rangle)$ 可由 X 的密度函数获得但表达式很复杂，为简单记我们考虑其特征函数：

$$\begin{aligned}\Phi(k) &= \int e^{ik(y_N - \langle X \rangle)} f_Y(y_N - \langle X \rangle) dy_N \\ &= \int \left[e^{i(k/N)((x_1 - \langle X \rangle) + (x_2 - \langle X \rangle) + \dots + (x_N - \langle X \rangle))} f_{X - \langle X \rangle}(x_1 - \langle X \rangle) \right. \\ &\quad \left. \times f_{X - \langle X \rangle}(x_2 - \langle X \rangle) \cdots f_{X - \langle X \rangle}(x_N - \langle X \rangle) dx_1 dx_2 \cdots dx_N \right] = [\phi(k/N)]^N.\end{aligned}$$

- 记 $\sigma^2 = \langle X^2 \rangle - \langle X \rangle^2$ ，则

$$\begin{aligned}\phi\left(\frac{k}{N}\right) &= \int e^{i(k/N)(x_1 - \langle X \rangle)} f_{X - \langle X \rangle}(x_1 - \langle X \rangle) dx_1 \\ &= 1 - \frac{1}{2} \frac{k^2}{N^2} \sigma^2 + \dots\end{aligned}$$

若当 $x_1 \rightarrow \infty$ 时函数 $f_X(x_1)$ 向零趋近得够快，则矩是有限的，并有：

$$\Phi(k) = \left[1 - \frac{1}{2} \frac{k^2}{N^2} \sigma^2 + o\left(\frac{k^3}{N^3}\right) \right]^N \xrightarrow{N \rightarrow \infty} e^{-k^2 \sigma^2 / (2N)}.$$

于是概率密度 $f_Y(y_N - \langle X \rangle)$ 变为：

$$\begin{aligned} f_Y(y_N - \langle X \rangle) &= \frac{1}{2\pi} \int_{-\infty}^{\infty} dk e^{-ik(y_N - \langle X \rangle)} \Phi(k) = \frac{1}{2\pi} \int_{-\infty}^{\infty} dk e^{-ik(y_N - \langle X \rangle)} e^{-k^2 \sigma^2 / (2N)} \\ &= \sqrt{\frac{N}{2\pi}} \frac{1}{\sigma} e^{-N(y_N - \langle X \rangle)^2 / (2\sigma^2)}. \end{aligned}$$

因此，不管 $f_X(x)$ 的形式如何，只要它有有限的矩， x 的大量独立测量的平均值的分布是中心在 $\langle X \rangle$ 的高斯分布，其方差是 x 的概率密度的方差的 $1/N$ 。这就是中心极限定理。

大数定律

大数定律： 当 $N \rightarrow \infty$ 时， y_N 偏离 $\langle X \rangle$ 的概率趋于零。

我们利用Chebyshev's inequality: $P(|x - \langle X \rangle| \geq \varepsilon) \leq \frac{\sigma_X^2}{\varepsilon^2}$.

(由 $\sigma_X^2 = \int_{-\infty}^{\infty} dx (x - \langle X \rangle)^2 f_X(x) \geq \left[\int_{-\infty}^{\langle X \rangle - \varepsilon} + \int_{\langle X \rangle + \varepsilon}^{\infty} \right] dx (x - \langle X \rangle)^2 f_X(x)$ 易得)

及 y_N 和 X 的方差的关系及 $\langle Y_N \rangle = \langle X \rangle$ 很容易发现：

$$P(|y_N - \langle X \rangle| \geq \varepsilon) \leq \frac{\sigma_{Y_N}^2}{\varepsilon^2} = \frac{\sigma_X^2}{N\varepsilon^2}.$$

故当 $N \rightarrow \infty$ 时，若 σ_X^2 有限，则

$$\lim_{N \rightarrow \infty} P(|y_N - \langle X \rangle| \geq \varepsilon) \rightarrow 0.$$