

Beyond Equilibrium

在前面提到大质量粒子在低温时冻速度呈指数下降

$$N_i \approx \frac{n_i}{\Lambda} \sim \left(\frac{m_i}{\Lambda}\right)^{3/2} e^{-(\frac{m_i}{\Lambda})}$$

但我们至今能在宇宙中探测到它们的存在

在早期极高热平衡且与 Plasma 解耦 \rightarrow freeze out

\Rightarrow 核心方程: Boltzmann 方程

In Chapter 1

$$\frac{d n_i}{d t} + 3 \frac{\dot{a}}{a} n_i = 0 \quad (\text{不考虑相互作用})$$

$$\Rightarrow \frac{1}{a^3} \frac{d(n_i a^3)}{d t} = C_i [n_i] \Rightarrow \text{Boltzmann 方程}$$

考虑如下反应



$$\Rightarrow \frac{1}{a^3} \frac{d(n_1 n_2)}{d t} = -\alpha n_1 n_2 + \beta n_3 n_4$$

湮灭项 生成项

$\alpha = \langle \sigma v \rangle \rightarrow$ 湮灭的相对速度 \rightarrow 热平均散射截面

$\beta = \left(\frac{n_3 n_4}{n_1 n_2} \right)_{\text{eq}} \alpha \rightarrow$ 细致平衡

$$\Rightarrow \frac{1}{a^3} \frac{d(n_1 n_2)}{d t} = -\langle \sigma v \rangle [n_1 n_2 - \left(\frac{n_3 n_4}{n_1 n_2} \right)_{\text{eq}} n_1 n_2]$$

令 $N_i \equiv n_i / s \propto n_i a^3$

$$\Rightarrow \frac{d N_1 N_2}{d t} = -\frac{T}{H} \left[1 - \left(\frac{N_3 N_4}{N_1 N_2} \right)_{\text{eq}} \frac{N_3 N_4}{N_1 N_2} \right]$$

其中 $T \equiv m \langle \sigma v \rangle$, 称为粒子 1 的相互作用率

若 $T \gg H$, 则系统处于平衡

若 $N_i \gg N_i^{\text{eq}}, R.H.S < 0$

若 $N_i \ll N_i^{\text{eq}}, R.H.S > 0$

若 $T < H$, 则系统脱离平衡

$$R.H.S \rightarrow 0 \Rightarrow N_i \rightarrow \text{const}$$

暗物质冻结

相同 Boltzmann 方程 我们予以大

致推论 早期宇宙中 DM 的产生

① 解耦与冻结

考虑如下反应:



X 为暗物质粒子, L 为 SM 的粒子

考虑两个假设

(i) L 会保持热平衡速度 即 $n_L = n_L^{\text{eq}}$

(ii) X 与 \bar{X} 之间无不对称性, 即 $n_X = n_{\bar{X}}$

$$\Rightarrow \frac{1}{a^3} \frac{d(n_X n_{\bar{X}})}{d t} = -\langle \sigma v \rangle [n_X^2 - (n_X^{\text{eq}})^2]$$


$$\text{令 } Y_X = n_X / T$$

$$X = N_X / T, \text{ 则 } \frac{dX}{d t} = H X$$

$$\Rightarrow \frac{dY_X}{dX} = -\frac{X}{Y_X} [Y_X^2 - (Y_X^{\text{eq}})^2] \rightarrow \text{Riccati equation}$$

其中 $\lambda = \frac{T}{H}$, 我们将其称为 const

\Rightarrow 数值求解



X 较小 (T 很大) 平衡 $\rightarrow T \downarrow, Y_X$ 呈指数下降至 $X = X_f$ 时 ($H \sim \Gamma$)

\rightarrow 逐渐平衡

那么剩余的丰度就由 $Y_X^{\text{res}} \equiv Y_X(X = \infty)$ 所决定

由于 $Y_X \gg Y_X^{\text{eq}}$, 故 Riccati Equation 可写为

$$\frac{dY_X}{dX} \approx -\frac{Y_X}{X^2}$$

从 $X = X_f$ 到 $X = \infty$ 积分有

$$\frac{1}{Y_X} - \frac{1}{Y_X^{\text{res}}} = \frac{\Delta}{X_f}$$

$$\therefore Y_X^{\text{res}} \gg Y_X^{\text{eq}}$$

$$\Rightarrow \boxed{Y_X^{\text{res}} \approx \frac{X_f}{\Delta}}, \text{ 取决于 } X_f \text{ 与 } \Delta \text{ 的取值}$$

② 暗物质冻速

由于 freeze-out 后, $N_X \propto a^{-3}$

$$\Rightarrow n_{X,0} = N_{X,1} \left(\frac{a_1}{a_0} \right)^3 = Y_X^{\text{res}} T_0^3 \left(\frac{a_1 T_0}{a_0 T_0} \right)^3$$

a_1 为任意一个足够使 X 到达剩余丰度的时刻 t_1 时的尺度因子

上一步推导得到, $g_{X,S}(aT)^3 = \text{const}$

$$\Rightarrow n_{X,0} = Y_X^{\text{res}} T_0^3$$

∴ ∴ ∴

$$\Omega_X = \frac{\rho_{X,0}}{\rho_{\text{crit},0}} \sim 0.1 \frac{Y_X^{\text{res}}}{\sqrt{g_X(M_X)}} \frac{10^{-8}}{\langle \sigma v \rangle} \text{ GeV}^{-2}$$

\Rightarrow 主要由散射截面决定

$$\text{双值: } \sqrt{\langle \sigma v \rangle} \sim 10^{-4} \text{ GeV}^{-1}$$

\Rightarrow 与弱相互作用粒子计算出时间一个数量级

\rightarrow MWIMP miracle

暗物质

现今的宇宙

暗能量: 68.3%

暗物质: 26.8%

原子: 4.9%

①来源: 星系旋转曲线

$$m = \begin{cases} M \frac{r^2}{R^2} & r < R \\ M & r > R \end{cases}$$

$$\Rightarrow v = \begin{cases} \sqrt{\frac{GM}{R^3} r^3} & r < R \\ \sqrt{\frac{GM}{r}} & r > R \end{cases}$$



⇒ 利用 DM 来填补两者之间的缺陷

其他观测证据: 宇宙大尺度结构与模拟

用暗物质模型去做模拟 P31

G1

⇒ 目前的观测强烈支持 CDM!

② 暗物质的密度分布

银河系常用的模型:

VFW: $\rho_{FW}(r) = \rho_0 N \left[\frac{r}{r_s} \left(1 + \frac{r}{r_s} \right) \right]^{-1}$, $r_s = 20$, $\rho_0 = 0.3136 \text{ GeV/cm}^3$

纳纳斯托: $\rho(r) = \rho_0 E \exp\left[-\frac{\alpha}{2} \left(\frac{r}{r_s}\right)^\alpha\right]$, $\alpha = 0.17$, $\rho_0 E = 9.428 \times 10^5 \text{ GeV/cm}^3$

③ 暗物质候选者 (P42)

基本性质: 1) 无强和电磁相互作用

2) 在宇宙尺度上稳定

时间

3) 重子物质不能占过大的比例

4) 不存在于 SM

主要候选者: WIMP { 中微子, 中性强子, 轴子

—— 原初超-哥特斯通 bosons, 由派斯-李因 U(1)

对称性破缺而产生的一种假想粒子, 且在早期宇宙中可以从 GCD 相交中非热产生

超 WIMP (湮灭截面远小于弱相互作用反应截面)

暗物质引力卡普扎
轴子-瓦普因粒子

大型天文物体 (基本不行)

{ 大尺度致密物体
BH and PBH

④ 暗物质探测

贝叶斯统计与引力波天文学

① Why introduce Bayesian inference

BBH (GW150914) - 15 parameters

$m_1, m_2, \chi, S_1, S_2, \theta_1, \theta_2, \psi_1, \psi_2 (\varphi_1, \varphi_2), D_L, z_c, \psi, h_0, \phi_0, \tau_A, \text{dec}$

→ Bayesian inference

② Likelihood, priors and postposterior

核心定理 $P(\theta|d) = \frac{L(\theta|d)P(\theta)}{Z} [P(\theta|d, M)]$

Primary aim: $P(\theta|d) \rightarrow$ posteriors
 参数 \rightarrow data

$P(\theta) \rightarrow$ priors

$L(\theta|d) = P(d|\theta) \rightarrow$ Likelihood

$Z = \int P(\theta) L(\theta|d) d\theta \rightarrow$ evidence

归一化: $\int d\theta P(\theta|d) = 1$

常见 Likelihood:

$$L(\theta|d) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(d - \mu(\theta))^2}{2\sigma^2}\right]$$

其越大, 表明在给定 d 下, 观测到 d 的可能性越大, 即表明 θ 的取值越合理。

priors: $P(\theta)$, 表明在我们拿到 data 前, 对参数取值的预期 (belief), 例 1: $Z_S = \int d\theta L(d|\theta) \pi(\theta)$ 有信号

常见: 均匀分布: $X \sim U(a, b)$

对数均匀分布: $Y = \log X$

如 GW150914: $m_1 \sim U(5, 100)$

evidence: 评判模型的优劣, 其越大表明模型解释数据能力越强

边缘化: 在多个参数下, 若我们对一个特定的参数感兴趣, 我们就可以采取边缘化的技巧

$$P(\theta_i|d) = \int \left(\prod_{k \neq i} d\theta_k \right) P(\theta|d) = \frac{L(\theta_i|d) P(\theta_i)}{Z} \text{ (消除其他参数的不确定性)}$$

但是, 若 a 与 b 有相关性, 即 $\text{Cov}(a, b) \neq 0$

如我们边缘化 a , 就会使 $P(b|d)$ 比 $P(b|d, a)$ 更宽 \rightarrow 条件后验分布 (给定 a 的其均值)

人话: $P(\text{下雨} | \text{data})$ 比 $P(\text{下雨} | \text{data}, \text{湿度}=80\%)$ 更宽

③ Models, evidence and odds

Bayesian evidence: $Z = \int d\theta L(\theta|d) P(\theta)$
 $Z = \int d\theta L(\theta|d) P(\theta)$

其可以用于模型选择, 由 Bayes factor 所衡量

$$BF_{12} = \frac{Z_1}{Z_2}$$

更采用其对数形式: $\log BF_{12} = \log Z_1 - \log Z_2$

通常以 $|\log BF| = 8$ 为基准衡量

例子 比较不同的信号模型

$$Z_A = \int d\theta L(\theta|d) P(\theta)$$

$$Z_B = \int d\nu L(\nu|d) P(\nu)$$

A: GR

B: ~~GR~~ modified gravity

$$Z_N = L(d|0) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{h^2}{\sigma^2}\right) \text{ 无信号}$$

例 2: 比较不同的 priors

Z_{spin}

$Z_{\text{no spin}}$

但通常更加 formal 是比值 odds ratio

$$O_A \equiv \frac{Z_A P_A}{Z_B P_B} = \frac{P_A(\theta|d)}{P_B(\theta|d)}$$

只不过实际运用中我们通常会令先验比为 1
(即采用相同的先验分布)

Bayesian evidence 的另一个信息告诉我们
其边缘化效应告诉我们采取拟合时参数空间的大小, 通常较小的参数空间有更好的拟合结果 (best fit possible and minimum prior volume)
这就是所谓的 Occam 剃刀原理 — 如无必要, 勿增实体,
贝叶斯推断更倾向于选择更简单的模型

如 $n=200$, $x=115$ 次正面

M_1 : 正面 $P=0.5$

M_2 : $\theta \text{ 正面} \in (0,1)$, 且 $\Pr(\theta|M_2) = U[0,1]$

频率学派 $\rightarrow M_2$, 且得出 $\theta = \frac{115}{200}$

Bayes 学派 $\rightarrow O_{M_1}^{M_2} \approx 1.2 \rightarrow$ 倾向于 M_1

但注意, 这并不意味着更为复杂的模型是错的, 我们只能对其作出更为严格的限制

频率学派: 参数是固定的, 概率是个固定的值, 数据由概率产生, 由大量独立实验的频率逼近概率

~~置信区间 (confidence intervals) 95% 置信区间为 [2,5]~~

Bayes 学派: 概率是随机的变量, 参数存在分布, 这些分布可以由更新自己的认知被改变