

## کارگاه مدلسازی داده: Bayesian and Likelihood analysis

سید محمد صادق موحد

دانشکده فیزیک - دانشگاه شهید بهشتی

پژوهشکده فیزیک، پژوهشگاه دانشهای بنیادی (IPM)

گروه کیهان شناسی محاسباتی (GCC-SBU)

آزمایشگاه میان رشته ای ابن سینا

<http://facultymembers.sbu.ac.ir/movahed/>

کارگاه مدلسازی داده ( شماره ۱ )

۹۷/۲/۲۶

## Books:

- Data analysis: A Bayesian Tutorial, by D.S. Sivia & J. Skilling, Oxford science Publication, 2010
- Data reduction and error analysis for the physical sciences, P. R. Bevington & D. K. Robinson, McGrawHill, 2003
- Error of Observations and their Treatment, J. Topping, 1972.
- Practical Physics, G. L. Squires, 1985.
- Data analysis in cosmology, "Lecture notes in physics 665"
- Mathematical statistics with applications, J.E. Freund's, Pearson education, 2005,
- All of Statistics, L. Wasserman, Springer, 2004
- Statistics, R.J. Barlow, Wiley, 2002.
- Introduction to statistics and Data analysis for Physicist, Gerhard Bohm, Günter Zech, 2010.
- Statistics, Data Mining, and Machine Learning in Astronomy: A Practical Python Guide for the Analysis of Survey Data (Princeton Series in Modern Observational Astronomy), Željko Ivezić, Andrew J. Connolly, Jacob T. VanderPlas, and Alexander Gray, PRINCETON UNIVERSITY PRESS, 2014
- Algebraic Topology of Random Fields and Complexes, Research thesis, Omer Bobrowski, 2012
- Random Fields and Geometry, Adler, R. J., Taylor, Jonathan E., Springer 2007.
- The Geometry of Random fields, Adler, 1981.
- GEOMETRY, TOPOLOGY and Physics, M. Nakahara, 2003
- Topological Complexity of Smooth Random Functions, Robert J. Adler, Jonathan E. Taylor, Springer 2009.

## Papers and Lectures:

- Verde, Licia. "A practical guide to basic statistical techniques for data analysis in cosmology." arXiv preprint arXiv:0712.3028 (2007).
- Verde, Licia. "Statistical methods in cosmology." Lectures on Cosmology. Springer, Berlin, Heidelberg, 2010. 147-177.
- Liddle, Andrew R. "How many cosmological parameters." Monthly Notices of the Royal Astronomical Society 351.3 (2004): L49-L53.
- Heavens, Alan. "Statistical techniques in cosmology." arXiv preprint arXiv:0906.0664 (2009).
- Efron, Bradley. "Bayesians, frequentists, and physicists." PHYSTAT2003: Statistical Problems in Particle Physics, Astrophysics, and Cosmology, SLAC, Stanford CA (2003): 17-24
- arXiv:physics/0406120
- <http://facultymembers.sbu.ac.ir/movahed/>

## SHAHID BEHESHTI UNIVERSITY

Department of Physics

### MAIN MENU

- Home
- About Me
- Contact me
- Researches of Interest
- Publications
- Students
- Courses
- **Talks & Presentations**
- Useful Stuff
- Group Meetings
- My CV
- Collaborations
- Other Activities
- Photo
- Login
- پارسی (Persian)

## Seyed Mohammad Sadegh Movahed Academic Homepage

### News



My program in the Autumn semester (1396-1397 (2017-2018)) ([Download](#))



Some proposals for Master Researches in my group (عناوین تعدادی پیشنهاده پایان نامه دوره کارشناسی ارشد) ([Download](#))

Some proposals for Ph.D. Researches in my group (عناوین تعدادی پیشنهاده تز دوره دکتری) ([Download](#))

[Some proposed Books for the relation between Physics and Philosophy.](#)

## فهرست مطالب

- (۱) مقدمه
- (۲) روش بیزی و تکراری مبتنی بر مفهوم کلاسیک احتمال
- (۳) بیشینه سازی تابع درست نمایی
- (۴) بررسی میزان کیفیت مدل در مقایسه با داده ها
- (۵) تراز تطابق
- (۶) رهیافت هایی برای یافتن بیشینه مطلق تابع درست نمایی
  - MCMC -
  - HMC -
  - Gradian -
- (۷) جمع بندی

# مقدمه



مدل کردن داده های حاصل از اندازه گیری

Data modeling

از داده ها چه چیزهایی یاد می گیریم؟

(۱) منشاء و ماهیت

(۲) چگونگی تحول

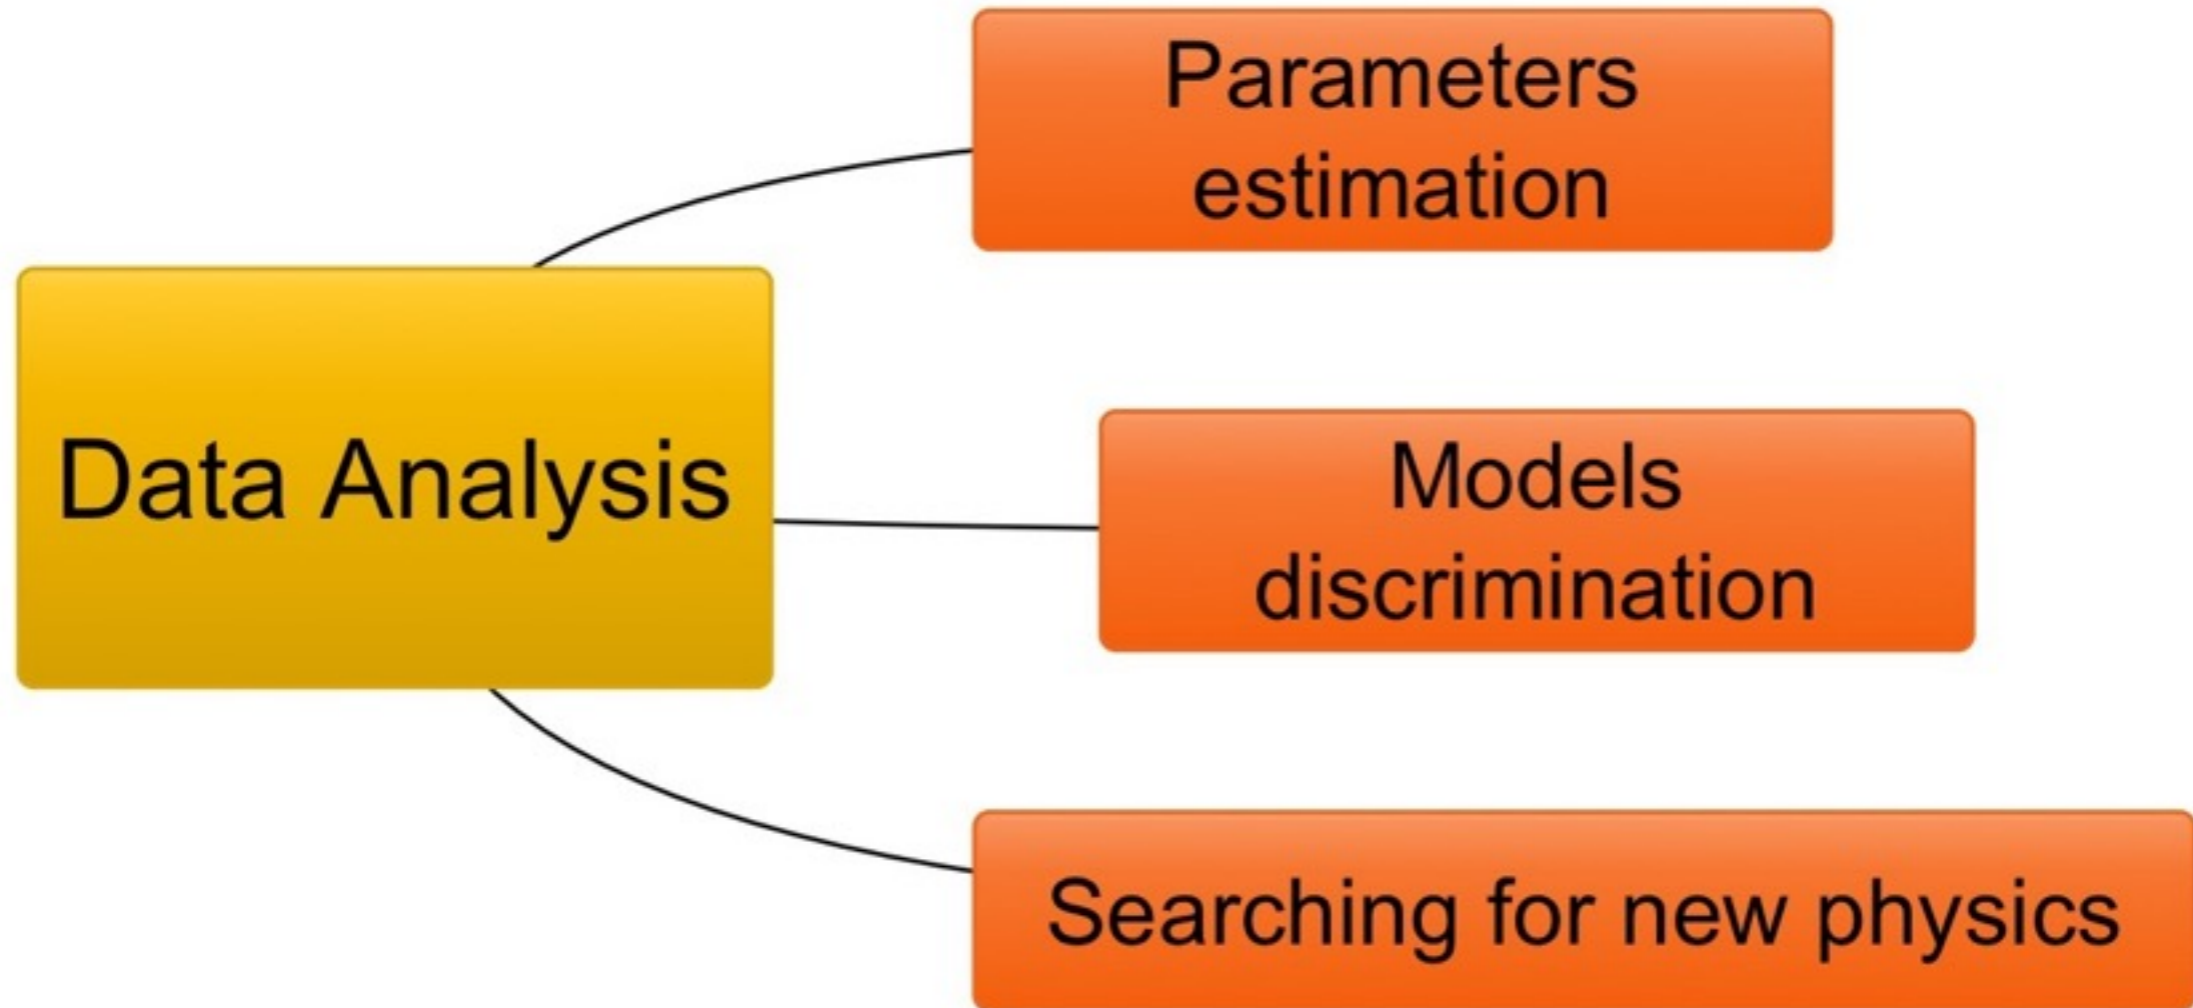
(۳) احتمالاً پیش بینی

.

.

# مدل کردن داده های حاصل از اندازه گیری

## Data modeling





## مراحل مدل کردن داده ها

- ۱) اندازه گیری ( مستقیم یا شبیه سازی ) ( Measurement )
- ۲) برآورد خطا و ارزیابی انتشار خطا بر روی کمیت های ثانویه ( Error estimation and error propagation )
- ۳) تدوین مدل با توجه به تابع مناسب ( Merit function ) ( model selection )
- ۴) انتخاب بینش تعیین مقادیر آزاد مدل ( Bayesian or Frequentist )
- ۵) استفاده از روشهای تعیین مقادیر کمیت های آزاد مدل و البته حوزه اعتبار آنها ( Parameter estimation and confidence interval )
- ۶) تعیین خوبی مدل Goodness of fit



# تعیین مقدار برای کمیت‌های آزاد

رهیافت Frequentist

(۱) در این روش داده‌ها و نتایج ریزحالت یک پیکربندی به حساب می‌آیند و داده‌ها تکرار پذیرند

(۲) کمیت‌های مدل مجهول ولی ثابت هستند

(۳) هیچ‌گونه اطلاعاتی از مدل مورد استفاده نیست

(۴) سازوکاری برای رهایی از کمیت‌های اضافی (Nuisance) ندارد

رهیافت Bayesian

(۱) در این روش داده‌ها و نتایج بخشی از یک آنسامبل هستند

(۲) کمیت‌های آزاد مدل مجهول هستند که ما تنها به صورت احتمالی می‌توانیم مقدار آنها را تعیین کنیم

(۳) هر گونه اطلاعات اولیه در این رویکرد قابل استفاده هستند

(۴) سازوکاری برای رهایی از کمیت‌های اضافی (Nuisance) دارد

## منطق قیاسی

### Deductive logic: Frequentist

مشاهده مبتنی بر واقعیت های شناخته شده  
که در کنار هم قرار می گیرند و نهایتاً به  
نتیجه می رسند. انسانها فانی هستند سقراط  
انسان است لذا سقراط فانی است


## منطق استقرایی

### Inductive logic: Bayesian

مشاهده رفتار تک تک اجزا منجر  
به قانون کلی می شود. تمام  
انسانهای مشاهده شده فانی  
بودند در نتیجه انسان فانی است

مقدار ثابت  
برای مدل


مشاهدات




مقادیر ممکن  
برای پارامترهای



مشاهدات

مدل





بر اساس نگرش frequentist  
 برای مثال ۹۰ درصد  
 مشاهدات به مقدار ثابت  $x$   
 منجر شده است



بر اساس نگرش Bayesian با  
 احتمال ۹۰ درصد مقدار دقیق  
 کمیت  $x$  در این بازه قرار می گیرد




# A history about Bayesian strategy

- By Thomas Bayes (1702–1761)
- Pierre Simon Laplace (1812)
- Fisher, Neyman, Wald,...
- Gelfand and Smith (1990)
- Now

هرچند که این ایده بسیار قدیمی است اما استفاده کاربردی از آن در دو دهه اخیر آغاز شده است چرا؟

با توجه به روشها می توان دریافت در روش Bayesian میزان و حجم محاسبات به مراتب بیشتر است بنابراین تا گسترش سخت افزارها این ایده به تعویق افتاد



# Bayesian approach

مشاهدات: داده ها

$$D : \{x_i, y_i\} \quad i = 1, \dots, N$$

برای مثال  
یک مدل

$$\Theta : \{\theta_j\} \quad j = 1, \dots, M \quad \rightarrow \quad Y(x, \Theta) = \sum_{j=1}^M \theta_j f_j(x)$$

$p(\Theta | D)$  احتمال یافتن مدل به شرطی که داده ها به دست آمده باشند. با چه احتمالی مشاهدات به مدل منجر میشود Posterior

$p(D | \Theta)$  احتمال به دست آمدن مشاهدات به شرطی که مدل مشخص باشد. مدل مشخص با چه احتمالی مشاهدات را به دست می دهد. Likelihood

$p(\Theta)$  هر گونه اطلاعات اولیه در مورد مقادیر کمیتهای مدل در این تابع توزیع وجود دارد. Prior

$$p(\Theta | D) = \frac{p(\Theta, D)}{p(D)} = \frac{p(D, \Theta)}{p(D)} = \frac{p(D | \Theta)p(\Theta)}{p(D)}$$

$$p(D) = \int d\Theta p(D, \Theta) = \int d\Theta p(D | \Theta)p(\Theta)$$

$$p(\Theta | D) = \frac{p(D | \Theta)p(\Theta)}{\int d\Theta p(D | \Theta)p(\Theta)}$$

در حالتی که اطلاعات اولیه ای برای کمیت های مدل نداشته باشیم

**Posterior=Likelihood**



# ویژگی های رهیافت بیزی

مثال: فرض کنید که برای یک دسته مشاهده داده شده، دو مدل داریم. کدامیک بامثال احتمال بیشتری انتخاب می شوند؟

# ویژگی های رهیافت بیزی (۱)

مثال: فرض کنید که برای یک دسته مشاهده داده شده، دو مدل داریم. کدامیک بامثال احتمال بیشتری انتخاب می شوند؟

$$D : \{x_i, y_i\}$$

$$\Theta_1 \quad \Theta_2$$

$$p(\Theta_1 | D) = \frac{p(D | \Theta_1)p(\Theta_1)}{\int d\Theta p(D | \Theta)p(\Theta)}$$

$$p(\Theta_2 | D) = \frac{p(D | \Theta_2)p(\Theta_2)}{\int d\Theta p(D | \Theta)p(\Theta)}$$

$$\frac{p(\Theta_1 | D)}{p(\Theta_2 | D)} = \frac{\frac{p(D | \Theta_1)p(\Theta_1)}{\int d\Theta p(D | \Theta)p(\Theta)}}{\frac{p(D | \Theta_2)p(\Theta_2)}{\int d\Theta p(D | \Theta)p(\Theta)}} = \frac{p(D | \Theta_1)p(\Theta_1)}{p(D | \Theta_2)p(\Theta_2)}$$

$$\text{if } p(\Theta_1) = p(\Theta_2)$$

مدلی که درست نمایی بزرگتری داشته باشد با احتمال بیشتری توسط داده ها انتخاب می شود

# ویژگی های رهیافت بیزی (II)

بهبود توزیع احتمال پارامترهای مدل

$$D_1 : \{x_i, y_i\}$$

$$\Theta : \{\theta_j\}$$

$$p(\Theta | D_1) = \frac{p(D_1 | \Theta)p(\Theta)}{\int d\Theta p(D_1 | \Theta)p(\Theta)}$$

به عنوان تابع اطلاعات اولیه در تحلیل جدید به حساب می آید

$$p(\Theta D_1 | D_2) = \frac{p(D_2 | \Theta D_1)p(\Theta | D_1)}{p(D_2 | D_1)}$$

$$p(D_2 | \Theta D_1) = \frac{p(D_2, D_1 | \Theta)}{p(D_1 | \Theta)}$$

$$p(\Theta D_1 | D_2) = \frac{p(D_2, D_1 | \Theta)}{p(D_1 | \Theta)} \times \frac{p(D_1 | \Theta)p(\Theta)}{p(D_1)} \times \frac{1}{p(D_2 | D_1)}$$

$$= \frac{p(D_2, D_1 | \Theta)p(\Theta)}{p(D_1, D_2)}$$

یعنی مشاهدات جدید را برای نتایج به دست آمده با مشاهدات قدیمی به کار برده تا نهایتاً مقادیر کمیت ها به دست آیند

# بیسکویت و شکلات

فرض کنید دو کاسه کاملاً شبیه به هم داریم. کاسه A دارای ۱۰ شکلات و ۳۰ بیسکویت است و کاسه B شامل ۲۰ عدد از هر کدام است. سوال: با چه احتمالی بیسکویت از کاسه A انتخاب می شود؟

$$P(\theta_A | x) = \frac{P(x | \theta_A)P(\theta_A)}{p(x)} = \frac{P(x | \theta_A)P(\theta_A)}{p(x | \theta_A)p(\theta_A) + p(x | \theta_B)p(\theta_B)}$$

$p(\theta_A) = p(\theta_B) = 1/2$  چون دو کاسه (مدل) شبیه به هم هستند

$$p(x | \theta_A) = \frac{30}{40}$$

$$p(x | \theta_B) = \frac{20}{40}$$

$$P(\theta_A | x) = 0.6$$

$$P(\theta_B | x) = 0.4$$

احتمال مشاهده شدن بیسکویت از کاسه A بیشتر است



کاسه B زیباتر از A است پس مشاهده گر بیشتر گرایش به انتخاب کاسه B دارد پس:

$$P(\theta_A | x) = \frac{P(x | \theta_A)P(\theta_A)}{p(x)} = \frac{P(x | \theta_A)P(\theta_A)}{p(x | \theta_A)p(\theta_A) + p(x | \theta_B)p(\theta_B)}$$

$$p(\theta_A) = \frac{1}{4}$$

$$p(\theta_B) = \frac{3}{4}$$

$$p(x | \theta_A) = \frac{30}{40}$$

$$p(x | \theta_B) = \frac{20}{40}$$

$$P(\theta_A | x) = 0.34$$

$$P(\theta_B | x) = 0.66$$

احتمال مشاهده شدن بیسکویت از کاسه B بیشتر است

اکنون به دنبال این هستیم که

**Posterior**

را بیشینه کنیم

این رهیافت دقیقاً معادل یافتن

**Best value for free parameters**

# بیشینه سازی تابع Posterior

$$D : \{x_i, y_i\} \quad i = 1, \dots, N$$

$$\Theta : \{\theta_j\} \quad Y(x; \{\Theta\}) = \sum_{k=1}^M \theta_k f_k(x)$$

$$p(\Theta | D) = \frac{p(D | \Theta)p(\Theta)}{\int d\Theta p(D | \Theta)p(\Theta)}$$

در صورتی که تابع prior وجود نداشته باشد در نتیجه تحلیل posterior به تحلیل Likelihood تبدیل می شود

$$p(\Theta | D) : p(D | \Theta)$$

$$p(D | \Theta) \equiv \prod_{i=1}^N P_i = \prod_{i=1}^N \frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left(-\frac{[y_i - Y(x_i; \{\Theta\})]^2}{2\sigma_i^2}\right)$$

(۱) با فرض اینکه اندازه گیری ها از یکدیگر مستقل باشند

$$\chi^2(\{\Theta\}) \equiv \sum_{i=1}^N \frac{[y_i - Y(x_i; \{\Theta\})]^2}{\sigma_i^2} = \sum_{i=1}^N \frac{\left[y_i - \sum_{k=1}^M \theta_k f_k(x_i)\right]^2}{\sigma_i^2}$$

(۲) با توجه به قضیه حد مرکزی می توان در نظر گرفت که هر نقطه اندازه گیری حول مقدار بهینه اش به صورت گوسی توزیع شده است

$$p(D | \Theta) : e^{-\frac{\chi^2(\{\Theta\})}{2}}$$

بیشینه شدن Likelihood معادل با کمینه شدن  $\chi^2$  است

$$\chi^2(\{\Theta\}) \equiv \sum_{i=1}^N \frac{\left[ y_i - \sum_{k=1}^M \theta_k f_k(x_i) \right]^2}{\sigma_i^2}$$

$$b_i \equiv \frac{y_i}{\sigma_i}$$

$$A_{ik} \equiv \frac{f_k(x_i)}{\sigma_i}$$

$$\text{Min} \|b - A\Theta\| \rightarrow \Theta_{\text{Best}}$$

**Normal Equations**  
**Singular Value Decomposition(SVD)**



# کمینه کردن $\chi^2$

$$\chi^2(\{\Theta\}) = \sum_{i=1}^N \frac{\left[ y_i - \sum_{k=1}^M \theta_k f_k(x_i) \right]^2}{\sigma_i^2} \quad \rightarrow \quad \chi^2(\{\Theta\} = \{\Theta\}_{Best}) = \chi_{min}^2$$


$$\left. \frac{\partial \chi^2(\{\Theta\})}{\partial \theta_j} \right|_{\{\Theta\} = \{\Theta_{Best}\}} = 0$$

$$= \sum_{i=1}^N \left[ y_i - \sum_{k=1}^M \theta_k f_k(x_i) \right] \times \frac{f_j(x_i)}{\sigma_i^2}$$

$$\sum_{i=1}^N \frac{y_i f_j(x_i)}{\sigma_i^2} = \sum_{i=1}^N \sum_{k=1}^M \frac{\theta_k f_k(x_i) f_j(x_i)}{\sigma_i^2}$$

$$\beta_j \equiv \sum_{i=1}^N \frac{y_i f_j(x_i)}{\sigma_i^2}$$

$$\alpha_{jk} \equiv \sum_{i=1}^N \frac{f_j(x_i) f_k(x_i)}{\sigma_i^2}$$



$$\beta_j = \sum_{k=1}^M \alpha_{jk} \theta_k$$

$$[\Theta] = [\alpha]^{-1} [\beta]$$

اکنون سوال این است که حوزه اعتبار کمیت  $\Theta$  چقدر است؟

$$\beta_j \equiv \sum_{i=1}^N \frac{y_i f_j(x_i)}{\sigma_i^2}$$

$$\alpha_{jk} \equiv \sum_{i=1}^N \frac{f_j(x_i) f_k(x_i)}{\sigma_i^2}$$

$$[\Theta] = [\alpha]^{-1} [\beta]$$

$$\sigma^2(\theta_i) = \sum_{j=1}^N \sigma_j^2 \left( \frac{\partial \theta_i}{\partial y_j} \right)^2 + \sum_{j=1}^N \sum_{l \neq j}^N \left( \frac{\partial \theta_i}{\partial y_j} \right) \left( \frac{\partial \theta_i}{\partial y_l} \right) \text{Cov}(y_j y_l) \quad \rightarrow \quad \left( \frac{\partial \theta_i}{\partial y_j} \right) = \sum_{k=1}^M [\alpha_{ik}]^{-1} \frac{\partial \beta_k}{\partial y_j}$$

$$\left( \frac{\partial \theta_i}{\partial y_j} \right)^2 = \sum_{l=1}^M \sum_{k=1}^M [\alpha_{ik}]^{-1} [\alpha_{il}]^{-1} \frac{\partial \beta_k}{\partial y_j} \frac{\partial \beta_l}{\partial y_j}$$

$$\sigma^2(\theta_i) = \sum_{l=1}^M \sum_{k=1}^M [\alpha_{ik}]^{-1} [\alpha_{il}]^{-1} \sum_{j=1}^N \sigma_j^2 \frac{\partial \beta_k}{\partial y_j} \frac{\partial \beta_l}{\partial y_j} \quad \rightarrow \quad \sigma^2(\theta_i) = \sum_{l=1}^M \sum_{k=1}^M [\alpha_{ik}]^{-1} [\alpha_{il}]^{-1} [\alpha_{kl}]$$

$$\rightarrow \sum_{k=1}^M [\alpha_{il}]^{-1} [\alpha_{kl}] = \delta_{ik}$$

$$\sigma^2(\theta_i) = [\alpha_{ii}]^{-1}$$

## polynomial function

$$D : \{x_i, y_i\} \rightarrow i = 1, \dots, N$$

$$\Theta : \{\theta_k\} \rightarrow k = 1, \dots, M \rightarrow Y(x; \Theta) = \theta_1 + \theta_2 x^1 + \dots + \theta_M x^{M-1}$$

$$P(D | \Theta) = \prod_{i=1}^N P(D_i | \Theta) = \prod_{i=1}^N \left( \frac{1}{\sigma_i \sqrt{2\pi}} \right) \exp \left( -\frac{1}{2} \sum_{i=1}^N \frac{\left[ y_i - \sum_{k=1}^M \theta_k x_i^{k-1} \right]^2}{\sigma_i^2} \right)$$

$$\text{for } M = 3 \quad \chi^2(\theta_1, \theta_2, \theta_3) = \sum_{i=1}^N \frac{\left[ y_i - \sum_{k=1}^3 \theta_k x_i^{k-1} \right]^2}{\sigma_i^2}$$

$$0 = \frac{\partial \chi^2(\theta_1, \theta_2, \theta_3)}{\partial \theta_1} = -2 \sum_{i=1}^N \frac{\left[ y_i - \sum_{k=1}^3 \theta_k x_i^{k-1} \right]}{\sigma_i^2}$$

$$0 = \frac{\partial \chi^2(\theta_1, \theta_2, \theta_3)}{\partial \theta_2} = -2 \sum_{i=1}^N x_i \frac{\left[ y_i - \sum_{k=1}^3 \theta_k x_i^{k-1} \right]}{\sigma_i^2}$$

$$0 = \frac{\partial \chi^2(\theta_1, \theta_2, \theta_3)}{\partial \theta_3} = -2 \sum_{i=1}^N x_i^2 \frac{\left[ y_i - \sum_{k=1}^3 \theta_k x_i^{k-1} \right]}{\sigma_i^2}$$

$$\theta_1 = \frac{1}{\Delta} \begin{vmatrix} \sum_{i=1}^N \frac{y_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \\ \sum_{i=1}^N y_i \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} \\ \sum_{i=1}^N y_i \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^4}{\sigma_i^2} \end{vmatrix}$$

$$\theta_2 = \frac{1}{\Delta} \begin{vmatrix} \sum_{i=1}^N \frac{1}{\sigma_i^2} & \sum_{i=1}^N \frac{y_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N y_i \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N y_i \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^4}{\sigma_i^2} \end{vmatrix}$$

$$\theta_3 = \frac{1}{\Delta} \begin{vmatrix} \sum_{i=1}^N \frac{1}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{y_i}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N y_i \frac{x_i}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} & \sum_{i=1}^N y_i \frac{x_i^2}{\sigma_i^2} \end{vmatrix}$$


$$\Delta = \begin{vmatrix} \sum_{i=1}^N \frac{1}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} \\ \sum_{i=1}^N \frac{x_i^2}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^3}{\sigma_i^2} & \sum_{i=1}^N \frac{x_i^4}{\sigma_i^2} \end{vmatrix}$$



# Goodness of fit

## کیفیت برازش

یک سوال مهم: برای مقدار مشخص به دست آمده برای  $\chi^2$  احتمال اینکه مشاهده ای داشته باشیم که به تطابق بدتر منجر شود چقدر است؟



(۱) در تحلیل‌ها یک مقدار برای احتمال بدتر بودن در نظر گرفته می‌شود. بعد اگر داشته باشیم:  $\chi_{obs}^2 \approx \chi_{\alpha}^2$

در آن صورت ادعا می‌شود که با احتمال  $\alpha \times 100$  اندازه‌گیری‌هایی خواهیم داشت که با این مدل به  $\chi^2$  ای بیشتر منجر می‌شود. به بیانی دیگر این مدل با احتمال  $(1 - \alpha) \times 100$  مشاهده و اندازه‌گیری‌ها را توصیف نمی‌کند.

(۲) اگر داشته باشیم  $\chi_{obs}^2 > \chi_{\alpha}^2$  در آن صورت مدل به خوبی مشاهدات را توصیف کرده است. یعنی تفاوت مدل و مشاهدات معنا دار نیست.

(۳) اگر داشته باشیم  $\chi_{obs}^2 \ll \chi_{\alpha}^2$  در آن صورت یا خطاهای مشاهدات خیلی بزرگتر از مقدار واقعی‌اش محاسبه شده‌اند یا که داده‌سازی شده است


برای رهایی از حالت ۳ بهتر است رهیافت دیگری را مد نظر بگیریم

وقتی بخواهیم که یک مدلی را تا احتمال ۹۵ درصد تایید کنیم یعنی اینکه با احتمال ۹۵ درصد با همین مدل به  $\chi^2$  بزرگتر برسیم

وقتی بخواهیم که یک مدلی را تا احتمال ۹۵ درصد کنیم یعنی اینکه با احتمال ۵ درصد باید با همین مدل به  $\chi^2$  بزرگتر برسیم



در نظر می گیریم که وضعیت بهینه موقعی است که در صورتی اندازه گیری را دوباره تکرار کنیم به مقدار  $\chi^2$  محتمل برسیم بنابراین علاقه مندیم که احتمال برابر با ۵۰ درصد باشد بنابراین نه احتمال کم نه احتمال زیاد (معادل داده سازی یا غلط بودن واریانسها)




یک قاعده سرانگشتی برای بررسی میزان تطابق مدل با اندازه گیری


$$P(\chi^2; \nu) = \frac{(\chi^2)^{-\frac{(\nu-2)}{2}} \exp(-\chi^2 / 2)}{2^{\nu/2} \Gamma(\nu / 2)}$$

for  $\nu \gg 1$

$$P(\chi^2; \nu) \rightarrow P_{Gaussian} : \exp\left(\frac{[\chi^2 - \nu]^2}{2(2\nu)}\right)$$

$$\chi^2 = \nu \pm \sqrt{2\nu} \rightarrow \chi^2_{\nu} \equiv \frac{\chi^2}{\nu} = 1 \pm \sqrt{\frac{2}{\nu}}$$





محدویت توضیحات قبلی وقتی خواهد بود که تابع توزیع هر اندازه گیری گوسی نباشد بنابراین با تابع توزیع  $\chi^2$  مواجه نیستیم. نه اینکه نمی توانیم از  $\chi^2$  استفاده کنیم بلکه بحث در خصوص تابع توزیع است بنابراین باید ابتدا با کمک تبدیل تابع توزیع شکل تابع توزیع مانده را بدست آوریم و بعد مانند قبل به محاسبه پردازیم



# تراز تطابق (Confidence interval)

(۱) دیدیم که اگر مشاهدات مستقل و حول مقدار بهینه کمیت های مدل به صورت گوسی توزیع شده باشند نهایتاً به کمیت  $\chi^2$  می رسیم. با کمینه کردن این کمیت تابع Likelihood بیشینه می شود.

(۲) بیشینه شدن تابع درست نمایی معادل یافتن بهترین مقادیر برای پارامترهای آزاد مدل خواهد بود.

$$P(D | \Theta) : \exp\left(-\frac{\chi^2}{2}\right)$$

(۳) حال سوال این است که در منطق بیزی ناحیه ای که با احتمال مشخص مثلاً ۶۸ درصد می توان بهترین مقادیر را برای پارامترهای آزاد به دست آورد؟

(۴) اکنون کمیت جدیدی تعریف می کنیم به نام Relative Likelihood:

$$\Gamma(D | \Theta) \equiv \frac{P(D | \Theta)}{P_{Max}(D | \Theta_*)} = \exp\left(-\frac{[\chi^2(\Theta) - \chi_{min}^2]}{2}\right)$$

(۵) از سویی دیگر از آنجا که به ازای مقدار بهینه کمیت های آزاد در مدل تابع Likelihood بیشینه می شود میتوان این تابع را بسط داد:

$$\begin{aligned} \log(P(D | \Theta)) &= \log(P(D | \Theta = \Theta_{Best})) + \sum_{k=1}^M (\theta_k - \theta_k^{Best}) \frac{\partial \log(P(D | \Theta))}{\partial \theta_k} \\ &+ \frac{1}{2} \sum_{k,l}^M \frac{\partial^2 \log(P(D | \Theta))}{\partial \theta_k \partial \theta_l} (\theta_k - \theta_k^{Best})(\theta_l - \theta_l^{Best}) + O(\delta\Theta^3) + \dots \end{aligned}$$

(۶) جمله دوم سمت راست معادله بالا صفر است با صرف نظر کردن از جملات مرتبه بالاتر داریم:

$$\Gamma(D | \Theta) = \exp\left(-\frac{[\chi^2(\Theta) - \chi_{\min}^2]}{2}\right) = \sqrt{\frac{\det[F]}{(2\pi)^M}} \exp\left(-\frac{\delta\Theta^T \cdot [F] \cdot \delta\Theta}{2}\right)$$

$$\Theta : \{\theta_k\} \quad k = 1, \dots, M$$

$$\delta\Theta \equiv \Theta - \Theta_{Best}$$

$$\chi_{\min}^2 = \chi^2(\Theta = \Theta_{Best})$$

$$\Gamma(D | \Theta) : \exp\left(-\frac{\delta\Theta^T \cdot [F] \cdot \delta\Theta}{2}\right)$$

## تعیین تراز تطابق با کمک تغییرات $\chi^2$ به صورت عددی

دیدیم که می توان نوشت:

$$\Gamma(D | \Theta) = \exp\left(-\frac{[\chi^2(\Theta) - \chi_{\min}^2]}{2}\right) = \sqrt{\frac{\det[F]}{(2\pi)^M}} \exp\left(-\frac{\delta\Theta^T \cdot [F] \cdot \delta\Theta}{2}\right)$$

$$\Gamma(D | \theta_1) = \int d\theta_2 \dots d\theta_M \Gamma(D | \Theta) : \exp\left(-\frac{(\theta - \theta_{Best})^2}{2\sigma_\theta^2}\right)$$

$$\Delta\chi^2 = \chi^2(\Theta) - \chi_{\min}^2 = \frac{(\theta - \theta_{Best})^2}{\sigma_\theta^2}$$

$$n(\theta - \theta_{Best}) \leq n\sigma_\theta \quad \rightarrow \quad \Delta\chi^2 \leq n^2$$

$$\Gamma(D | \theta_1) = \exp\left(-\frac{n^2}{2}\right) \rightarrow \begin{cases} n = 1 \rightarrow \Gamma(D | \theta_1) = 0.606 \\ n = 2 \rightarrow \Gamma(D | \theta_1) = 0.135 \end{cases}$$

بنابراین اگر  $\chi^2$  مربوط به Marginalized Posterior از مقدار کمینه اش به اندازه  $n$  تغییر کند ناحیه احتمال  $n\sigma$  برای کمیت مورد نظر به دست می آید

# تراز تطابق در فضای M بُعدی

برای اینکار سوال میکنیم که تابع توزیع مربوط به  $\chi^2$  چگونه است؟ باز هم از تبدیل بین تابع توزیع ها استفاده می کنیم

$$\Gamma(D | \Theta) = \exp\left(-\frac{[\chi^2(\Theta) - \chi_{\min}^2]}{2}\right) = \sqrt{\frac{\det[F]}{(2\pi)^M}} \exp\left(-\frac{\delta\Theta^T \cdot [F] \cdot \delta\Theta}{2}\right)$$

$$: \exp\left(-\frac{1}{2} \sum_{i=1}^N \left(\frac{\left[y_i - \sum_{k=1}^M f(\{\theta_k\}, x_i)\right]^2}{\sigma_i^2}\right)\right)$$

$$D : \{x_i, y_i\} \rightarrow i = 1, \dots, N$$

$$\Theta : \{\theta_M\} \quad k = 1, \dots, M$$

$$\text{if } i = 1 \rightarrow \Delta y = \left[ y - \sum_{k=1}^M f(\{\theta_k\}, x) \right] \rightarrow \chi^2 = \Delta y^2$$

$$P(\Delta y)d\Delta y = P(\chi^2)d\chi^2 \rightarrow P(\chi^2) = \frac{(\chi^2)^{-1/2} \exp(-\chi^2 / 2)}{\sqrt{2\pi}}$$

$$68.3\% = \int_{\sigma^-}^{\sigma^+} P(\theta)d\theta = \int_{\chi_{\min}^2}^{\chi^2} P(\chi^2)d\chi^2 \rightarrow \Delta\chi^2 = 1$$

مانند قبل است

$$\Gamma(D | \Theta) = \exp\left(-\frac{[\chi^2(\Theta) - \chi_{\min}^2]}{2}\right) = \sqrt{\frac{\det[F]}{(2\pi)^M}} \exp\left(-\frac{\delta\Theta^T \cdot [F] \cdot \delta\Theta}{2}\right)$$


$$: \exp\left(-\frac{1}{2} \sum_{i=1}^N \left(\frac{\left[y_i - \sum_{k=1}^M f(\{\theta_k\}, x_i)\right]^2}{\sigma_i^2}\right)\right)$$

$$D : \{x_i, y_i\} \rightarrow i = 1, \dots, N$$

$$\Theta : \{\theta_M\} \quad k = 1, \dots, M$$

$$P(\Delta y) d\Delta y = P(\chi^2) d\chi^2 \rightarrow P(\chi^2; \nu) = \frac{(\chi^2)^{\frac{(\nu-2)}{2}} \exp(-\chi^2/2)}{2^{\nu/2} \Gamma(\nu/2)}$$

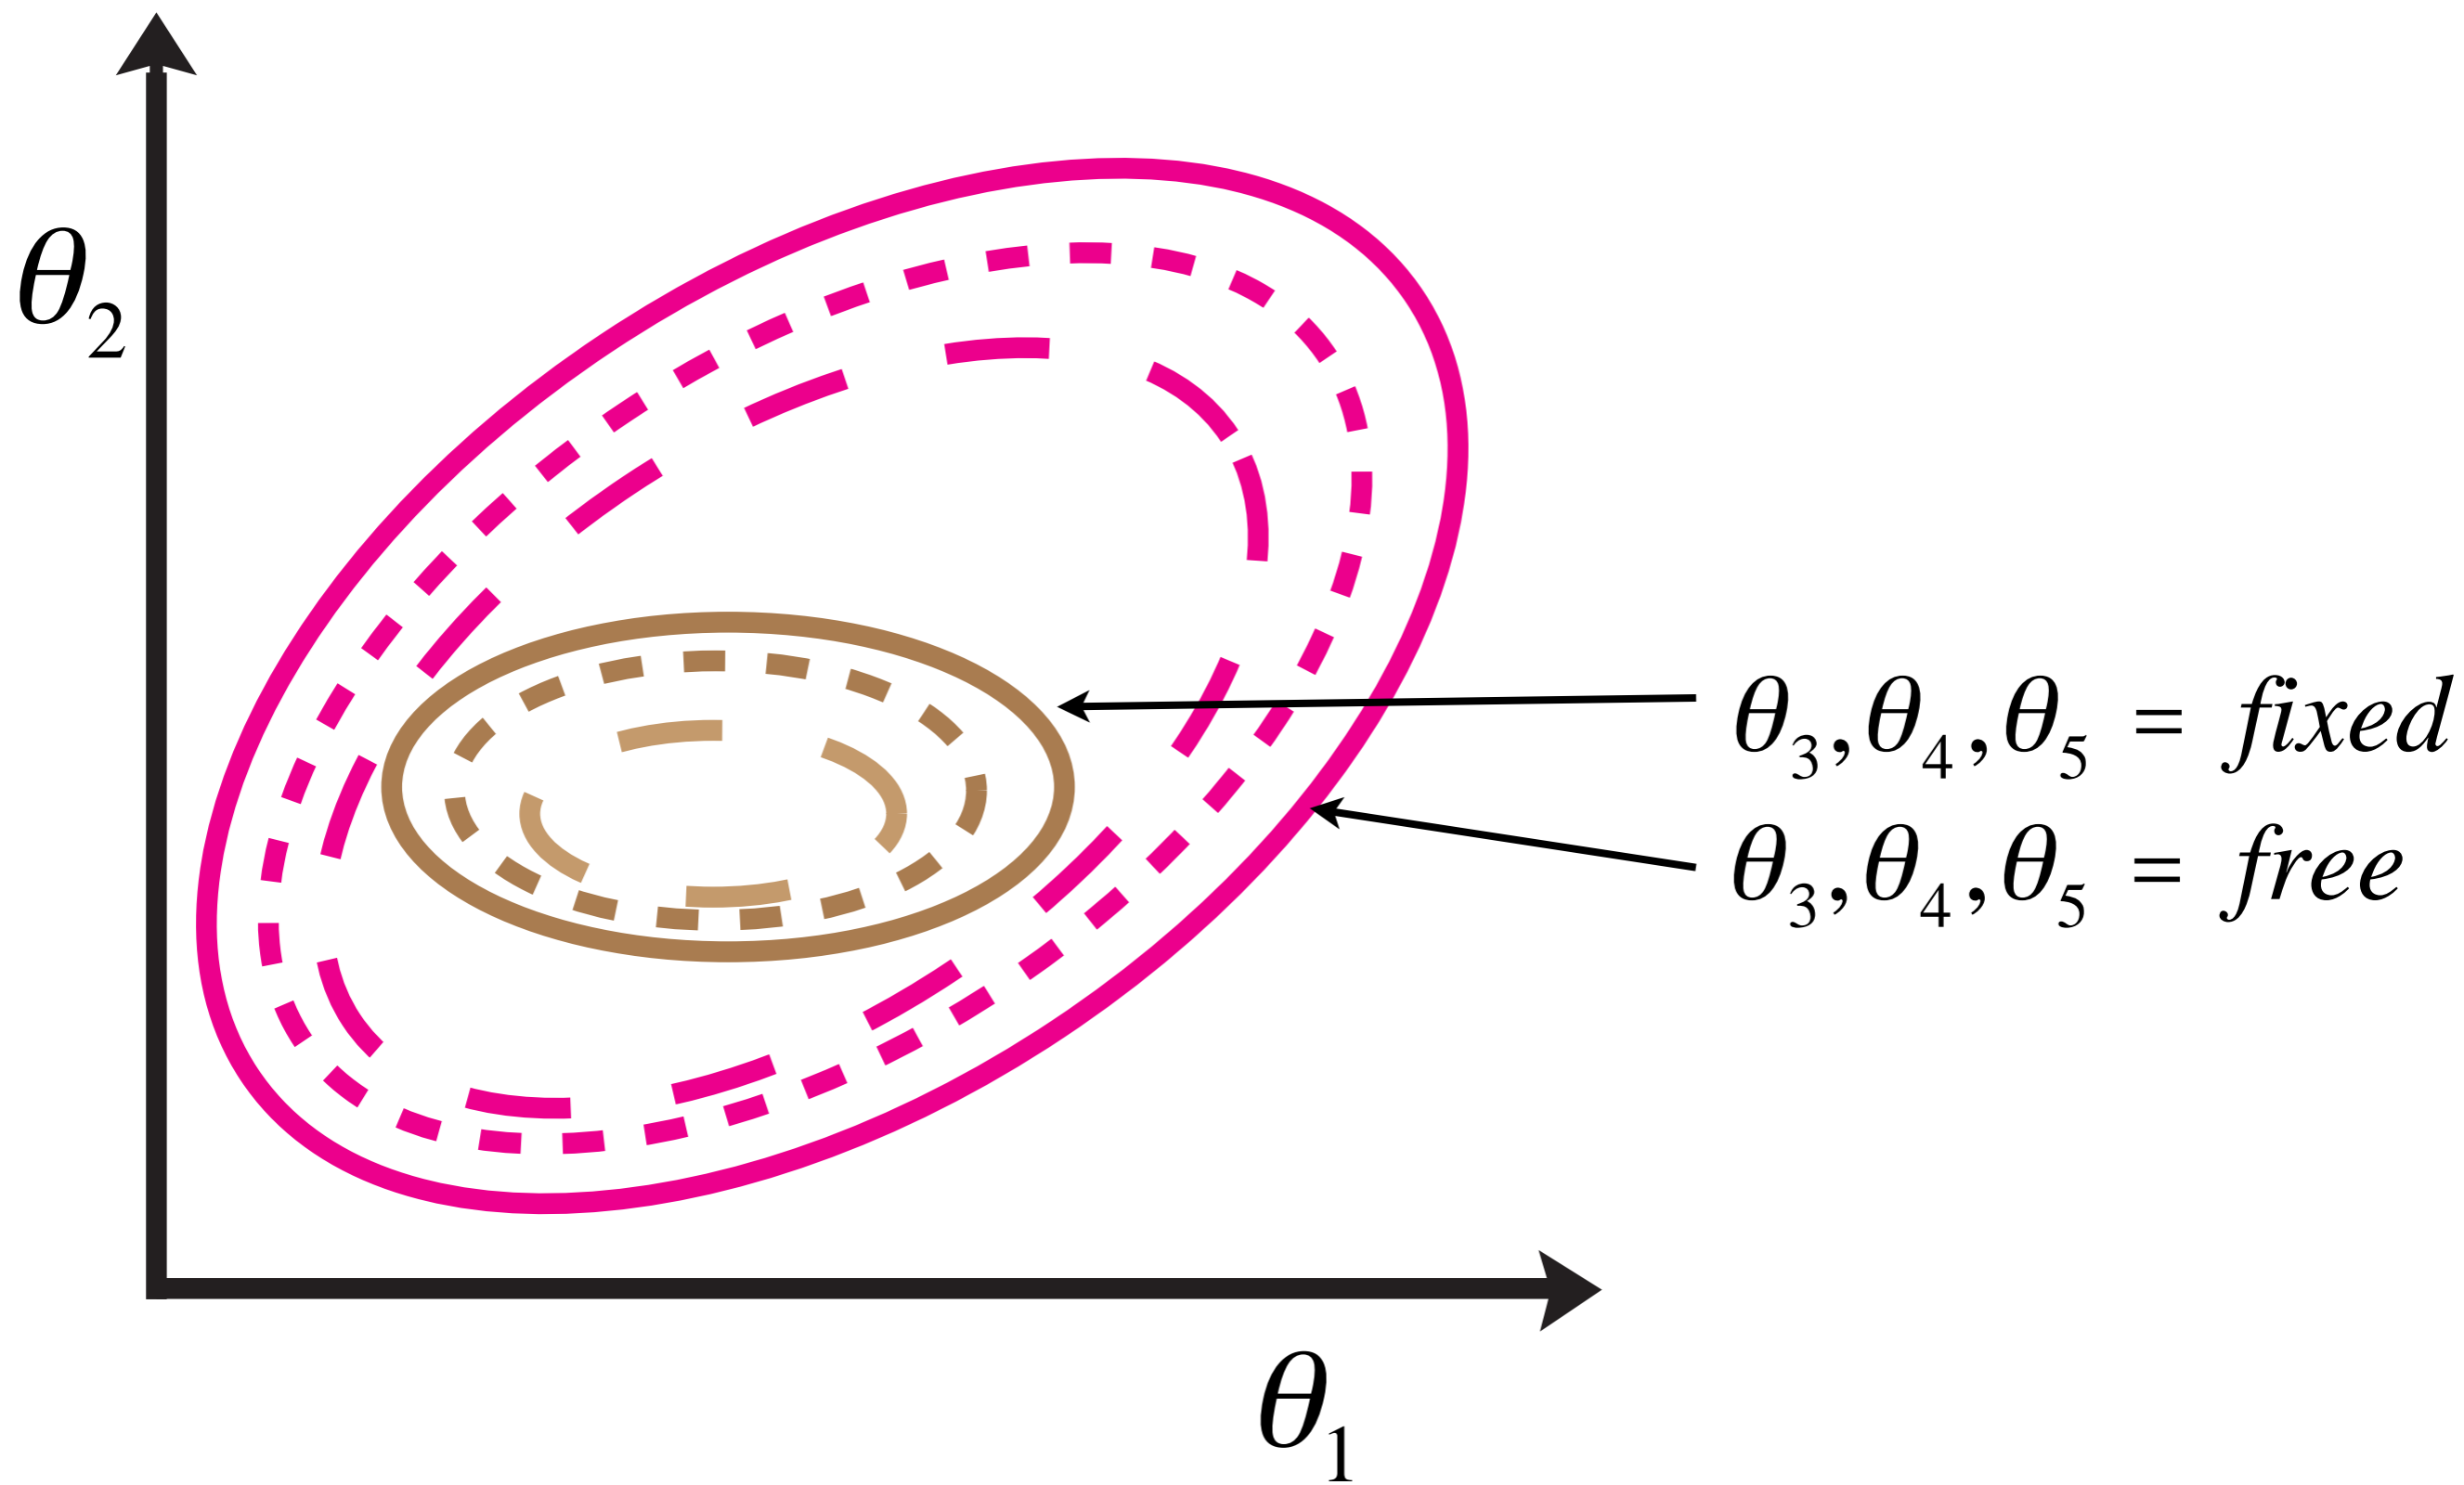
$$68.3\% = \int_{\sigma_1^-}^{\sigma_1^+} \int_{\sigma_2^-}^{\sigma_2^+} P(\theta_1, \theta_2) d\theta_1 d\theta_2 = \int_{\chi_{\min}^2}^{\chi^2} P(\chi^2; 2) d\chi^2 \rightarrow \Delta\chi^2 = 2.3$$



به لحاظ محاسباتی باید پس از یافتن مقدار بهینه کمیت ها اجازه دهیم که کمیت ها از مقدار بهینه اشان تغییر کنند به طوری که  $\chi^2$  از مقدار کمینه اش به اندازه مشخص شده جابجا شود در این وضعیت بیضی گون تراز تطابق در ۲ بُعد را به دست می آوریم



7	5	4	3	2	1	$M$
$\Delta x^r$	$\Delta x^r$	$\Delta x^r$	$\Delta x^r$	$\Delta x^r$	$\Delta x^r$	$p\%$
7.04	5.19	4.72	3.53	2.30	1.00	71.3%
10.7	9.24	7.78	6.25	4.71	2.71	90%
12.10	11.30	9.70	8.02	6.17	4.00	95.4%
17.10	15.10	13.30	11.30	9.21	6.73	99%
20.10	18.20	16.30	14.20	11.10	9.00	99.73%
27.10	25.70	23.50	21.10	18.40	15.10	99.99%



# Chi<sup>2</sup> versus Median analysis

The  $\chi^2$  analysis assumes that:

- (i) The experimental results are statistically independent;
- (ii) There are no systematic errors;
- (iii) The statistical errors follow a Gaussian distribution;
- (iv) The standard deviation of the statistical errors is equal to the observational uncertainty.

The median analysis considers only following assumptions

- (i) The experimental results are statistically independent;
- (ii) There are no systematic errors;

the median statistic is not very sensitive to the presence of a few “outlier” SNIa objects.

In [9], it has been shown how the presence of one or very few “ill” data points could severely distort a  $\chi^2$  analysis, while the median results remained approximately the same.

In median statistics we search for those theoretical values for which, the half part of observed data points are located above and the rest is located below or equal theoretical prediction.

# یافتن مقادیر کمیت ها به صورت عددی

## 1) Grid search Methods

- Deterministic approach
- Markov chain Monte Carlo MCMC
- Hamiltonian Monte Carlo HMC

## 2) Gradient Method

## 3) Expansion Method

- 
- 
-

در رهیافت تعینی با حرکت در فضای پارامتری و مقایسه تا جایی جلو می‌رویم تا تابع Posterior بیشینه شود.

برای فضای پارامتری در بُعد های کم توصیه می‌شود

# MCMC

هدف یافتن دسته مقادیری که posterior را بیشینه می کنند

1)  $\Theta_0 : \{\theta_0\}$

معمولاً گوسی انتخاب می شود. هر چه که واریانس

2)  $g(\Theta_0 \rightarrow \Theta)$

آن بزرگ باشد آهنگ پذیرش کمتر می شود

3)  $\eta = \min \left[ 1, \frac{P(\Theta | D)g(\Theta_0 \rightarrow \Theta)}{P(\Theta_0 | D)g(\Theta \rightarrow \Theta_0)} \right]$

4)  $u : \text{Uniform}[0,1]$

5) *If*  $u \leq \eta \rightarrow \Theta_1 = \Theta$

*else*

$$\Theta_1 = \Theta_0$$

6) *Iterate*

(۱) ابتدا از یک سری مقادیر دلخواه برای کمیت های مدل شروع می کنیم

(۲) با توجه به ماتریس پیشنهادی جهشی به مقادیر جدید می کنیم

(۳) برای تصمیم به اینکه این جهش مورد قبول باشد یا نه آزمون مربوطه بررسی میشود

(۴) این فرایند تکرار می شود تا جواب همگرا شود



Import Data  $\{D\}$

Select  $\{\theta\}_{old}$

Compute  $\chi_{old}^2(\{\theta\}_{old})$  و  $\xi_{old} = e^{-\chi_{old}^2/2}$

loop on MCMC

Select  $\{\theta\}_{New}$  by using  $\{\theta\}_{old}$

Compute  $\chi_{New}^2(\{\theta\}_{New})$

$$\Delta\chi^2 = \chi_{New}^2(\{\theta\}_{New}) - \chi_{old}^2(\{\theta\}_{old})$$

check acceptance rate  $R = \min\{1, e^{-\Delta\chi^2/2}\}$

$\xi =$  Call Random number

if  $\xi \leq \exp(-\Delta\chi^2/2)$  then

$$\{\theta\}_{old} = \{\theta\}_{New}$$

$$\chi_{old}^2 = \chi_{New}^2$$


Endif

Write  $\{\theta\}_{old}$  و  $\chi_{old}^2$




End loop

در واقع در اینجا داریم داده هایی تولید می کنیم که دارای تابع توزیع  $\text{Chi}^2$  هستند

HMC



MCMC



# Hamiltonian MC (HMC)

در این روش با توجه به تعریف یک هامیلتونی مسیر حرکت بر روی انرژی ثابت انجام می گیرد. این امر باعث می شود آهنگ پذیرش بالا رفته و مدت زمان محاسبات به طور قابل توجهی کاهش یابد.

برای این منظور یک انرژی پتانسیل و یک انرژی جنبشی تعریف می کنیم.

# Hamiltonian MC (HMC)

1)  $[\Theta_0 : \{\theta_0\} ; u_0 : N(u, 0, 1)]$ ,

$$H(\Theta, u) = U(\Theta) + K(u) \quad U(\Theta) = -\ln P(\Theta | D), \quad K(u) = \frac{u^T u}{2}$$

$$\Gamma(\Theta | D; u) : \exp(-H(\Theta, u)) = P(\Theta | D) \times N(u, 0, 1)$$

2) *Make a leapfrog move*  $\{\Theta_{(j-1)}; u_{(j-1)}\} \rightarrow \{\Theta_{(j)}; u_{(j)}\}$

3)  $\{\Theta^*; u^*\} = \{\Theta(s); u(s)\}$

4)  $\eta = \min \left[ 1, e^{(H(\Theta, u) - H(\Theta^*, u^*))} \right]$


5)  $\alpha : \text{Uniform}[0, 1]$

6) *If*  $\alpha \leq \eta \rightarrow \begin{cases} \Theta_1 = \Theta^* \\ u = u^* \end{cases}$

*else*


$$\Theta_1 = \Theta_0$$

7) *Iterate*



با انتخاب  
مقدار دیگری  
دوباره u برای  
شروع می  
کنیم

عدم پذیرش



Import Data  $\{D\}$

Select  $\{\theta\}_{old}$ ,  $\{u\}_{old} \sim N(u, 0, 1)$

$$\chi_{old}^2(\{\theta\}_{old})$$

$$\mathcal{H}_{old} = \frac{\chi_{old}^2}{2} + \frac{u^T u}{2}$$

$$S_{old} = \exp(-\mathcal{H}_{old}) = \mathcal{L}(\{D\} | \{\theta\}_{old}) N(u, 0, 1)$$

loop on MC

loop on HMC

Leapfrog or  
Verlet method  $\left\{ \begin{array}{l} \{\theta\}_{old} \rightarrow \{\theta\}_{old}^{HMC} \\ \{u\}_{old} \rightarrow \{u\}_{old}^{HMC} \end{array} \right.$

End loop

$$\{\theta\}_{New} = \{\theta\}_{old}^{HMC}, \quad \{u\}_{New} = \{u\}_{old}^{HMC}$$

$$\mathcal{H}_{New} = \frac{\chi_{New}^2}{2} + \frac{u^T u}{2}$$

$$\Delta \mathcal{H} = \mathcal{H}_{New} - \mathcal{H}_{old}$$

$$S = \exp(-\Delta \mathcal{H})$$

Acceptance Rate  $R = \min\{1, S\}$

$$\{\theta\}_{old} = \{\theta_{New}\}, \quad \chi_{old}^2 = \chi_{New}^2$$

$$\{u\}_{old} \sim N(u, 0, 1)$$

Write  $\{\theta\}_{old}$ ,  $\exp(-\chi_{New}^2/2)$

End loop MC



## HMC loop

Verlet  
Algorithm

loop on HMC  $j$

$$f_{old}^{\theta_j^{j+1}} = f_{old}^{\theta_j^j} + f_{old}^u^j \epsilon + \frac{1}{2} \epsilon^2 \left( -\frac{\partial \mathcal{H}}{\partial \theta_{old}^j} \right)$$

$$f_{old}^u^{j+1} = f_{old}^u^j + \frac{1}{2} \left[ -\frac{\partial \mathcal{H}}{\partial \theta_{old}^{j+1}} - \frac{\partial \mathcal{H}}{\partial \theta_{old}^j} \right] \epsilon$$

End loop

یا الگوریتم پرش قورباغه ای به صورت زیر

loop on HMC

$$f_{old}^u^{j+\frac{1}{2}} = f_{old}^u^j - \frac{\epsilon}{2} \frac{\partial \mathcal{H}}{\partial \theta_{old}^j}$$

$$f_{old}^{\theta_j^{j+1}} = f_{old}^{\theta_j^j} + \epsilon f_{old}^u^{j+\frac{1}{2}}$$

$$f_{old}^u^{j+1} = f_{old}^u^j - \frac{\epsilon}{2} \frac{\partial \mathcal{H}}{\partial \theta_{old}^{j+1}}$$

End loop

## روش حرکت مبتنی بر گرادیان $\chi^2$

$$\nabla \chi^2 = \sum_{k=1}^M \frac{\partial \chi^2}{\partial \theta_k} \hat{\theta}_k$$

$$\left( \nabla \chi^2 \right)_k = \frac{\partial \chi^2}{\partial \theta_k} \approx \frac{\chi^2(\theta_k + \Delta \theta_k) - \chi^2(\theta_k)}{\Delta \theta_k}$$

$$b_k \equiv \frac{\theta_k}{\Delta \theta_k} \quad \text{بدون بُعد کردن}$$

$$\frac{\partial \chi^2}{\partial b_k} = \frac{\partial \chi^2}{\partial \theta_k} \Delta \theta_k$$

$$\gamma_i = \frac{\frac{\partial \chi^2}{\partial b_k}}{\sqrt{\sum_{k=1}^M \left( \frac{\partial \chi^2}{\partial b_k} \right)^2}}$$

مولفه بردار یکه گرادیان

$$\theta_k(i+1) = \theta_k(i) - \gamma_i \Delta \theta_k$$

علامت منفی تضمین می کند که در جهتی حرکت کنیم که  $\chi^2$  به سمت کمینه پیش رود

# جمع بندی

- (۱) رهیافت بیزی و تکراری
- (۲) تحلیل Likelihood
- (۳) کمینه کردن  $\chi^2$
- (۴) کیفیت برازش
- (۵) تراز تطابق و ماتریس Fisher
- (۶) یافتن مقادیر بهینه کمیت ها به صورت عددی
- (۷) رهیافت MCMC
- (۸) رهیافت HMC
- (۹) رهیافت گرادیان



**کارگاه** **مدل سازی داده**

مهلت ثبت نام **۱۶ اردیبهشت ۱۳۹۷**  
مهلت ثبت نام **۲۶ اردیبهشت ۱۳۹۷**

Workshop on  
Data Modeling

آزمایشگاه میان رشته ای ابن سینا، دانشکده فیزیک، دانشگاه شهید بهشتی  
Ibn-Sina Multidisciplinary Laboratory, Department of Physics, Shahid Beheshti University

کمیته برگزاری  
مقصود ارشدی (آزمایشگاه ابن سینا، دانشگاه شهید بهشتی)  
مرضیه فرهنگ (دانشگاه شهید بهشتی)  
سید علیرضا معنوی (آزمایشگاه ابن سینا، دانشگاه شهید بهشتی)  
سید محمدصادق موحد (دانشگاه شهید بهشتی و پژوهشگاه دانشهای بنیادی)  
علیرضا وفايي صدر (دانشگاه شهید بهشتی)

$$x = \frac{\sum_{data} x_i}{\sum_{data} \sigma_i}$$

$$P(\Upsilon|D) = \frac{\mathcal{L}(D|\Upsilon)P(\Upsilon)}{\int \mathcal{L}(D|\Upsilon)P(\Upsilon)d\Upsilon}$$

$$C.L. = \int_{-\infty}^A d\mathcal{A}' P(\mathcal{A}'|D)$$

$$\chi^2(\Upsilon) \equiv \Delta^\dagger \cdot C^{-1} \cdot \Delta$$

$$68.3\% = \int_{-\sigma_{68}(q)}^{+\sigma_{68}(q)} \mathcal{L}(\mathcal{F}_q(s)|h(q))dh(q)$$

<https://aavaat.com/dmw/>

**کارگاه آشنایی با کدهای کیهان شناسی**  
**CAMB و CosmoMC**  
۲۷ اردیبهشت ۱۳۹۷  
دانشکده فیزیک، دانشگاه شهید بهشتی

مهلت ثبت نام **۱۶ اردیبهشت ۱۳۹۷**  
آزمایشگاه میان رشته ای ابن سینا با هم کاری گروه آوات برگزار می کند

کمیته برگزاری  
مرضیه فرهنگ (دانشکده فیزیک، دانشگاه شهید بهشتی)  
حسین مصحفی (آزمایشگاه ابن سینا، دانشگاه شهید بهشتی)  
سید علیرضا معنوی (آزمایشگاه ابن سینا، دانشگاه شهید بهشتی)  
سید محمدصادق موحد (دانشکده فیزیک، دانشگاه شهید بهشتی و پژوهشگاه دانشهای بنیادی)  
علیرضا وفايي صدر (دانشکده فیزیک، دانشگاه شهید بهشتی)

<https://aavaat.com/ccw/>