



Stefano Gariazzo



IFIC, Valencia (ES)
CSIC – Universitat de Valencia



European
Commission

Horizon 2020
European Union funding
for Research & Innovation

gariazzo@ific.uv.es

<http://ific.uv.es/~gariazzo/>

Autostati di massa dei neutrini e il loro ordine: un approccio Bayesiano

Basato su JCAP 03 (2018) 011

05/04/2018 - Incontri Fisica Alte Energie - Milano (IT)

1 *Elementi di statistica Bayesiana*

- Il teorema di Bayes
- Comparare modelli in statistica Bayesiana

2 *Applicazioni all'ordine delle masse dei neutrini*

- Il problema
- Parametrizzazioni e ordine
- Comparazione di modelli

3 *Conclusioni*

1 *Elementi di statistica Bayesiana*

- Il teorema di Bayes
- Comparare modelli in statistica Bayesiana

2 *Applicazioni all'ordine delle masse dei neutrini*

- Il problema
- Parametrizzazioni e ordine
- Comparazione di modelli

3 *Conclusioni*

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera):

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera):
 $\pi(\theta)$

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:

cosa sapevamo prima

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera):

$p(\theta)$

Probabilità
a posteriori:

cosa sapremo
dopo

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:

cosa sapevamo prima

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera):

$p(\theta)$

Probabilità
a posteriori:

cosa sapremo
dopo

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:

cosa sapevamo prima

Likelihood: $\mathcal{L}(\theta)$

fondata sui dati,
assumendo H vera

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera):

$\pi(\theta)$

$p(\theta)$

Probabilità
a posteriori:

cosa sapremo
dopo

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:

cosa sapevamo prima

Likelihood: $\mathcal{L}(\theta)$

fondata sui dati,
assumendo H vera

Evidenza Bayesiana:

$$p(d|I) \equiv \sum_H p(d|H, I) p(H|I)$$

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera):

$\pi(\theta)$

$p(\theta)$

Probabilità
a posteriori:
cosa sapremo
dopo

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:

cosa sapevamo prima

Likelihood: $\mathcal{L}(\theta)$

fondata sui dati,
assumendo H vera

Evidenza Bayesiana:

$$p(d|I) \equiv \sum_H p(d|H, I) p(H|I)$$

Teorema di Bayes:

$$\text{p. posteriori} = \frac{\text{likelihood} \times \text{p. priori}}{\text{evidenza}}$$

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera): $\pi(\theta)$

$p(\theta)$
Probabilità
a posteriori:
cosa sapremo
dopo

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:
cosa sapevamo prima

Evidenza Bayesiana:

$$p(d|I) \equiv \sum_H p(d|H, I) p(H|I)$$

Likelihood: $\mathcal{L}(\theta)$

fondata sui dati,
assumendo H vera

inferenza dei
parametri

Teorema di Bayes:

$$\text{p. posteriori} = \frac{\text{likelihood} \times \text{p. priori}}{\text{evidenza}}$$

Il teorema di Bayes

su cosa si fonda la statistica Bayesiana?

data un'ipotesi H , i dati d , e qualche informazione I (assunta come vera): $\pi(\theta)$

$p(\theta)$
Probabilità
a posteriori:
cosa sapremo
dopo

Teorema di Bayes:

$$p(H|d, I) = \frac{p(d|H, I) p(H|I)}{p(d|I)}$$

Probabilità a priori:
cosa sapevamo prima

Evidenza Bayesiana:

$$p(d|I) \equiv \sum_H p(d|H, I) p(H|I)$$

Likelihood: $\mathcal{L}(\theta)$

fondata sui dati,
assumendo H vera

inferenza dei
parametri

Teorema di Bayes:

$$\text{p. posteriori} = \frac{\text{likelihood} \times \text{p. priori}}{\text{evidenza}}$$

paragone di modelli

“Evidenza Bayesiana”

$$p(d|\mathcal{M}) = Z = \sum_H p(d|H, I) p(H|I)$$

somma su diverse ipotesi (discrete)
(sempre assumendo I vera)

“Evidenza Bayesiana”

$$p(d|\mathcal{M}) = Z = \int_{\Omega_{\mathcal{M}}} p(d|\theta, \mathcal{M}) p(\theta|\mathcal{M}) d\theta$$

integrale sulle ipotesi (continue) = valori dei parametri nel modello \mathcal{M}
(considerando \mathcal{M} corretto)

“Evidenza Bayesiana”

$$p(d|\mathcal{M}) = Z = \int_{\Omega_{\mathcal{M}}} p(d|\theta, \mathcal{M}) p(\theta|\mathcal{M}) d\theta$$

integrale sulle ipotesi (continue) = valori dei parametri nel modello \mathcal{M}
(considerando \mathcal{M} corretto)

Cosa succede se abbiamo diversi modelli \mathcal{M}_i ?

usare Z_i per comparare i modelli

“Evidenza Bayesiana”

$$p(d|\mathcal{M}) = Z = \int_{\Omega_{\mathcal{M}}} p(d|\theta, \mathcal{M}) p(\theta|\mathcal{M}) d\theta$$

integrale sulle ipotesi (continue) = valori dei parametri nel modello \mathcal{M}
(considerando \mathcal{M} corretto)

Cosa succede se abbiamo diversi modelli \mathcal{M}_i ?

usare Z_i per comparare i modelli

P. a posteriori **del modello**:

$$p(\mathcal{M}_i|d) \propto p(\mathcal{M}_i) Z_i$$

$p(\mathcal{M}_i)$ p. a priori del modello

costante di proporzionalità dipende solo dai dati

È migliore \mathcal{M}_1 o \mathcal{M}_2 ?

$$\frac{p(\mathcal{M}_1|d)}{p(\mathcal{M}_2|d)} = B_{1,2} \frac{p(\mathcal{M}_1)}{p(\mathcal{M}_2)}$$

Fattore di Bayes:

$$B_{1,2} = \frac{Z_1}{Z_2} \Rightarrow \ln B_{1,2} = \ln Z_1 - \ln Z_2$$

Fattore di Bayes

È migliore \mathcal{M}_1 o \mathcal{M}_2 ?

$$\frac{p(\mathcal{M}_1|d)}{p(\mathcal{M}_2|d)} = B_{1,2} \frac{p(\mathcal{M}_1)}{p(\mathcal{M}_2)}$$

Fattore di Bayes:

$$B_{1,2} = \frac{Z_1}{Z_2} \Rightarrow \ln B_{1,2} = \ln Z_1 - \ln Z_2$$

se p. a priori sono uguali [$p(\mathcal{M}_1) = p(\mathcal{M}_2)$],
 $B_{1,2}$ determina il modello preferito:

$B_{1,2} > 1$ ($\ln B_{1,2} > 0$)

\mathcal{M}_1 preferito

$B_{1,2} < 1$ ($\ln B_{1,2} < 0$)

\mathcal{M}_2 preferito

Preferenza per il modello migliore:

$$|B_{1,2}| : 1$$

rilevanza del segnale secondo la scala di Jeffreys:

| $ \ln B_{1,2} $ | Preferenza | probabilità | rilevanza |
|------------------|------------------|-------------|--------------|
| < 1.0 | $\lesssim 3 : 1$ | < 0.750 | inconclusiva |
| $\in [1.0, 2.5]$ | $(3 - 12) : 1$ | < 0.923 | debole |
| $\in [2.5, 5.0]$ | $(12 - 150) : 1$ | < 0.993 | moderata |
| > 5.0 | $> 150 : 1$ | > 0.993 | forte |

Preferenza & rilevanza sempre valide

probabilità corretta solo in caso di due modelli con uguale p. a priori
(per esempio, ordine delle masse dei neutrini: normale O inverso)

Rasoio di Occam

Cosa ci insegna il paragone di modelli in statistica Bayesiana?

Miglior modello è il bilanciamento migliore fra

Qualità del fit

Predittività

Rasoio di Occam

la teoria più semplice che spiega i dati è preferita

modello con più parametri \longrightarrow fit migliore (di solito)

\longrightarrow veramente servono tutti i parametri?

il fattore di Bayes penalizza i modelli più complessi del necessario!

Rasoio di Occam

Cosa ci insegna il paragone di modelli in statistica Bayesiana?

Miglior modello è il bilanciamento migliore fra

Qualità del fit

Predittività

Rasoio di Occam

la teoria più semplice che spiega i dati è preferita

e se usiamo gli stessi parametri ma cambiamo la loro p. a priori?

Evidenza bayesiana dipende da p. a priori!

Fattore di Bayes penalizza p. a priori più estese del necessario!

Rasoio di Occam

Cosa ci insegna il paragone di modelli in statistica Bayesiana?

Miglior modello è il bilanciamento migliore fra

Qualità del fit

Predittività

Rasoio di Occam

la teoria più semplice che spiega i dati è preferita

e se usiamo gli stessi parametri ma cambiamo la loro p. a priori?

Evidenza bayesiana dipende da p. a priori!

Fattore di Bayes penalizza p. a priori più estese del necessario!

Fattore di Bayes NON penalizza i modelli in cui ci sono parametri non vincolati dai dati

1 *Elementi di statistica Bayesiana*

- Il teorema di Bayes
- Comparare modelli in statistica Bayesiana

2 *Applicazioni all'ordine delle masse dei neutrini*

- Il problema
- Parametrizzazioni e ordine
- Comparazione di modelli

3 *Conclusioni*

Masse dei neutrini

Ordine normale (NO)


$$m_1 < m_2 < m_3$$

$$\sum m_k \gtrsim 0.06 \text{ eV}$$

 ν_e

 ν_μ


 ν_τ



Ordine inverso (IO)

$$m_3 < m_1 < m_2$$

$$\sum m_k \gtrsim 0.1 \text{ eV}$$



Masse dei neutrini

Ordine normale (NO)

$$m_1 < m_2 < m_3$$

$$\sum m_k \gtrsim 0.06 \text{ eV}$$

 ν_e

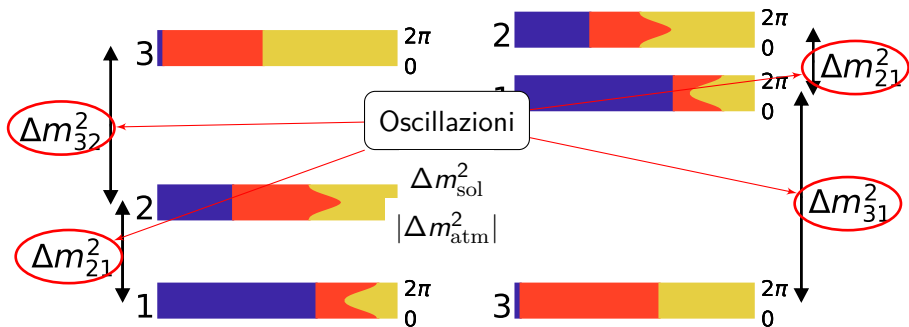
 ν_μ

 ν_τ

Ordine inverso (IO)

$$m_3 < m_1 < m_2$$

$$\sum m_k \gtrsim 0.1 \text{ eV}$$



Masse dei neutrini

Ordine normale (NO)

$$m_1 < m_2 < m_3$$

$$\sum m_k \gtrsim 0.06 \text{ eV}$$

 ν_e


 ν_μ

 ν_τ

Ordine inverso (IO)

$$m_3 < m_1 < m_2$$

$$\sum m_k \gtrsim 0.1 \text{ eV}$$



Scala assoluta delle masse non nota!

Si può determinare l'ordine delle masse ponendo limiti su $\sum m_k$?

Limiti sulla scala assoluta delle masse dei neutrini

Effetti dei neutrini sullo spettro del decadimento β

Mainz/Troitsk: $m_{\nu_e} \lesssim 2 \text{ eV}$

Katrin (atteso): $m_{\nu_e} \lesssim 0.2 \text{ eV}$

$$m_{\nu_e}^2 = \sum_k |U_{ek}|^2 m_k^2$$

U_{ek} matrice PMNS

Limiti sulla scala assoluta delle masse dei neutrini

Effetti dei neutrini sullo spettro del decadimento β

Mainz/Troitsk: $m_{\nu_e} \lesssim 2 \text{ eV}$

Katrin (atteso): $m_{\nu_e} \lesssim 0.2 \text{ eV}$

$$m_{\nu_e}^2 = \sum_k |U_{ek}|^2 m_k^2$$

U_{ek} matrice PMNS

(se il neutrino è particella di Majorana)

Limiti dal doppio decadimento β senza neutrini

Misura $T_{1/2}^{0\nu}$, converti in $m_{\beta\beta}$ usando $m_e/m_{\beta\beta} = \mathcal{M}'^{\nu} \sqrt{G_{0\nu} T_{1/2}^{0\nu}}$

$$\text{e infine } m_{\beta\beta} = \left| \sum_k e^{i\alpha_k} U_{ek}^2 m_k \right|$$

α_k fasi di Majorana

m_e massa elettrone,
 $G_{0\nu}$ spazio fasi,
 \mathcal{M}'^{ν} elemento di matrice

Limiti sulla scala assoluta delle masse dei neutrini

Effetti dei neutrini sullo spettro del decadimento β

Mainz/Troitsk: $m_{\nu_e} \lesssim 2 \text{ eV}$

Katrin (atteso): $m_{\nu_e} \lesssim 0.2 \text{ eV}$

$$m_{\nu_e}^2 = \sum_k |U_{ek}|^2 m_k^2$$

U_{ek} matrice PMNS

(se il neutrino è particella di Majorana)

Limiti dal doppio decadimento β senza neutrini

Misura $T_{1/2}^{0\nu}$, converti in $m_{\beta\beta}$ usando $m_e/m_{\beta\beta} = \mathcal{M}'^{\nu} \sqrt{G_{0\nu} T_{1/2}^{0\nu}}$

$$\text{e infine } m_{\beta\beta} = \left| \sum_k e^{i\alpha_k} U_{ek}^2 m_k \right|$$

α_k fasi di Majorana

m_e massa elettrone,
 $G_{0\nu}$ spazio fasi,
 \mathcal{M}'^{ν} elemento di matrice

Limiti cosmologici attraverso l'effetto delle masse dei neutrini

\Rightarrow radiazione cosmica di fondo (CMB) ed espansione dell'universo

Al momento $\sum_k m_k \lesssim 0.1X \text{ eV}$, misure di singole m_k in futuro?

Cosa possiamo ricavare dai dati odierni?

- 1 [Hannestad, Schwetz, 2016]: preferenza estremamente debole (2:1, 3:2) per NO (cosmologia + fit di oscillazioni [Bergstrom et al., 2015])
approccio bayesiano;
- 2 [Gerbino et al, 2016]: preferenza estremamente debole (up to 3:2) per NO (solo cosmologia), approccio bayesiano;
- 3 [Simpson et al., 2017]: forte preferenza per NO (limiti cosmologici su $\sum m_\nu$ + misure di Δm_{21}^2 e $|\Delta m_{31}^2|$)
approccio bayesiano;
- 4 [Schwetz et al., 2017], “Comment on [Simpson et al., 2017]”: effetto di p. a priori?
- 5 [Capozzi et al., 2017]: preferenza a 2σ per NO (cosmologia + fit di oscillazioni [Capozzi et al., 2016, aggiornamento 2017])
approccio frequentista;
- 6 [Caldwell et al., 2017] indicazione molto debole per NO (cosmologia + $\beta\beta 0\nu$ + fit di oscillazioni [Esteban et al., 2016] riadattato)
approccio bayesiano;
- 7 [Wang, Xia, 2017]: Fattore di Bayes NO vs IO non informativo (solo cosmologia).

Cosa possiamo ricavare dai dati odierni?

- 1 [Hannestad, Schwetz, 2016]: preferenza **estremamente debole** (2:1, 3:2) per NO (cosmologia + fit di oscillazioni [Bergstrom et al., 2015])
approccio bayesiano;
- 2 [Gerbino et al, 2016]: preferenza **estremamente debole** (up to 3:2) per NO (solo cosmologia), approccio bayesiano;
- 3 [Simpson et al., 2017]: **forte** preferenza per NO (limiti cosmologici su $\sum m_\nu$ + misure di Δm_{21}^2 e $|\Delta m_{31}^2|$)
approccio bayesiano;
- 4 [Schwetz et al., 2017], “Comment on [Simpson et al., 2017]”: effetto di p. a priori?
- 5 [Capozzi et al., 2017]: **preferenza a 2σ** per NO (cosmologia + fit di oscillazioni [Capozzi et al., 2016, aggiornamento 2017])
approccio frequentista;
- 6 [Caldwell et al., 2017] indicazione **molto debole** per NO (cosmologia + $\beta\beta 0\nu$ + fit di oscillazioni [Esteban et al., 2016] riadattato)
approccio bayesiano;
- 7 [Wang, Xia, 2017]: Fattore di Bayes NO vs IO **non informativo** (solo cosmologia).

Oscillazioni di neutrini

$$\chi^2 = -2 \log \mathcal{L}_{\text{osc}}$$

dal fit globale

[de Salas et al, 2017]

Oscillazioni

| Parametro | p. a priori |
|----------------------|-------------|
| $\sin^2 \theta_{12}$ | 0.1 – 0.6 |
| $\sin^2 \theta_{13}$ | 0.00 – 0.06 |
| $\sin^2 \theta_{23}$ | 0.25 – 0.75 |

Masse: vedi oltre!

Dati $\beta\beta 0\nu$

Likelihood approssimate come in [Caldwell et al, 2017], usando [Gerda, 2017] (Ge), [KamLAND-Zen, 2016], [EXO-200, 2014] (Xe)

Oscillazioni di neutrini

$\chi^2 = -2 \log \mathcal{L}_{\text{osc}}$
dal fit globale
[de Salas et al, 2017]

| $\beta\beta 0\nu$ | | Oscillazioni | |
|---------------------------|---------------|----------------------|---------------|
| Parametro | p. a priori | Parametro | p. a priori |
| α_2 | $0 - 2\pi$ | $\sin^2 \theta_{12}$ | $0.1 - 0.6$ |
| α_3 | $0 - 2\pi$ | $\sin^2 \theta_{13}$ | $0.00 - 0.06$ |
| $M_{76\text{Ge}}^{0\nu}$ | $4.07 - 4.87$ | $\sin^2 \theta_{23}$ | $0.25 - 0.75$ |
| $M_{136\text{Xe}}^{0\nu}$ | $2.74 - 3.45$ | | |

Masse: vedi oltre!

Parametrizzazioni, p. a priori e dati

[SG et al., JCAP 03 (2018) 011]

Dati cosmologici

Dati completi CMB (temperatura, polarizzazione) di [Planck, 2015], con modello Λ CDM come base

Dati $\beta\beta 0\nu$

Likelihood approssimate come in [Caldwell et al, 2017], usando [Gerda, 2017] (Ge), [KamLAND-Zen, 2016], [EXO-200, 2014] (Xe)

Oscillazioni di neutrini

$\chi^2 = -2 \log \mathcal{L}_{\text{osc}}$
dal fit globale
[de Salas et al, 2017]

| Cosmologia | | $\beta\beta 0\nu$ | | Oscillazioni | |
|---------------------|---------------|--|-------------|----------------------|-------------|
| Parametro | p. a priori | Parametro | p. a priori | Parametro | p. a priori |
| ω_b | 0.019 – 0.025 | α_2 | 0 – 2π | $\sin^2 \theta_{12}$ | 0.1 – 0.6 |
| ω_c | 0.095 – 0.145 | α_3 | 0 – 2π | $\sin^2 \theta_{13}$ | 0.00 – 0.06 |
| Θ_s | 1.03 – 1.05 | $\mathcal{M}_{76}^{0\nu}_{\text{Ge}}$ | 4.07 – 4.87 | $\sin^2 \theta_{23}$ | 0.25 – 0.75 |
| τ | 0.01 – 0.4 | $\mathcal{M}_{136}^{0\nu}_{\text{Xe}}$ | 2.74 – 3.45 | | |
| n_s | 0.885 – 1.04 | | | | |
| $\log(10^{10} A_s)$ | 2.5 – 3.7 | | | | |

Masse: vedi oltre!

[Simpson et al, 2017]

usando m_1, m_2, m_3 (A)

[Caldwell et al, 2017]

usando $m_{\text{lightest}}, \Delta m_{21}^2, |\Delta m_{31}^2|$ (B)

intuizione dice: (B) è più vicino a osservabili! Meglio di (A)?

P. a priori deve essere lineare o logaritmica in m_k (m_{lightest})?

I dati possono dire chi è meglio, (A) o (B), lineare o log?

[Simpson et al, 2017]

[Caldwell et al, 2017]

 usando m_1, m_2, m_3 (A)

 usando $m_{\text{lightest}}, \Delta m_{21}^2, |\Delta m_{31}^2|$ (B)


intuizione dice: (B) è più vicino a osservabili! Meglio di (A)?

 P. a priori deve essere lineare o logaritmica in m_k (m_{lightest})?

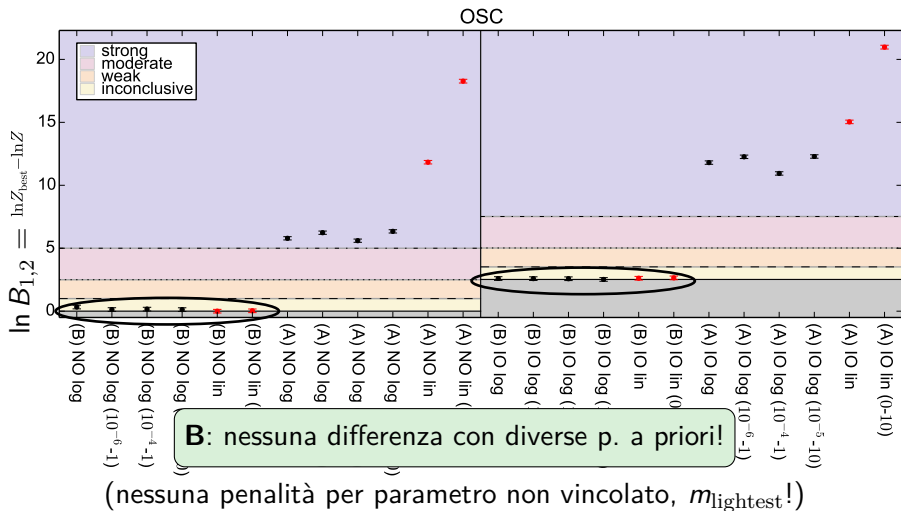
 I dati possono dire chi è meglio, (A) o (B), **lineare** o **log**?

| Caso A | | | Caso B | | |
|-----------|-----------------------|------------------------|--------------------------|-----------------------|---|
| Parameter | P. priori | Intervallo | Parametro | P. priori | Intervallo |
| m_1/eV | lineare log | 0 – 1 $10^{-5} - 1$ | m_{lightest}/eV | lineare log | 0 – 1 $10^{-5} - 1$ |
| m_2/eV | lineare log | 0 – 1 $10^{-5} - 1$ | $\Delta m_{21}^2/eV^2$ | lineare | $5 \times 10^{-5} - 10^{-4}$ |
| m_3/eV | lineare log | 0 – 1 $10^{-5} - 1$ | $ \Delta m_{31}^2 /eV^2$ | lineare | $1.5 \times 10^{-3} - 3.5 \times 10^{-3}$ |

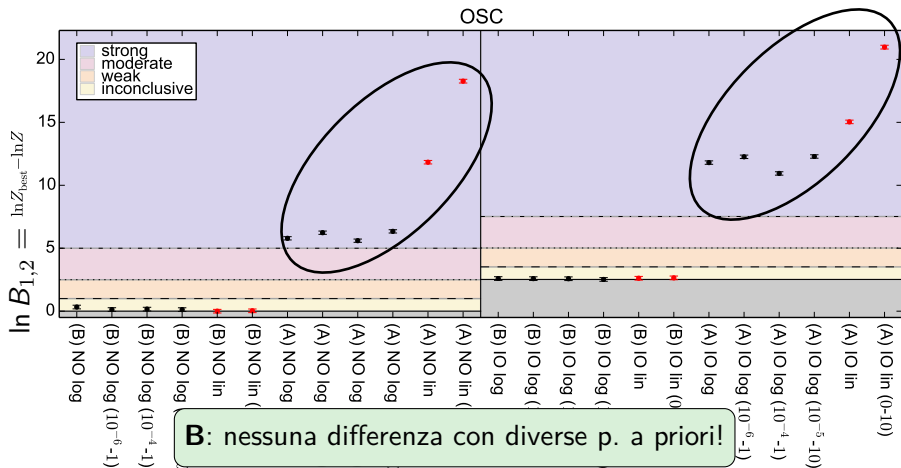
Paragoni fra parametrizzazioni e p. a priori



Paragoni fra parametrizzazioni e p. a priori



Paragoni fra parametrizzazioni e p. a priori




(nessuna penalità per parametro non vincolato, m_{lightest} !)

A: sempre fortemente sfavorito!


(molto spazio parametri "sprecato", no parametri non vincolati!)

Paragoni fra parametrizzazioni e p. a priori



compariamo **lineare** vs **logaritmico**

Paragoni fra parametrizzazioni e p. a priori




compariamo **lineare** vs **logaritmico**

log è

debolmente/moderatamente più efficiente

Paragoni fra parametrizzazioni e p. a priori





compariamo **lineare** vs **logaritmico**


log è

debolmente/moderatamente più efficiente

per riassumere: caso B, log è meglio!







1 *Elementi di statistica Bayesiana*

- Il teorema di Bayes
- Comparare modelli in statistica Bayesiana

2 *Applicazioni all'ordine delle masse dei neutrini*

- Il problema
- Parametrizzazioni e ordine
- Comparazione di modelli

3 *Conclusioni*

1

Comparazione bayesiana di modelli
attraverso evidenza bayesiana/fattore di Bayes
per **test robusti di parametrizzazioni**
usando i dati

2

Attenzione alle scelte di p. a priori
(o di **altre scelte soggettive**)
che possono influenzare i risultati

3

i dati preferiscono **moderatamente** l'ordine
normale vs inverso per le masse dei neutrini

1

Comparazione bayesiana di modelli
attraverso evidenza bayesiana/fattore di Bayes
per **test robusti di parametrizzazioni**
usando i dati

2

Attenzione alle scelte di p. a priori
(o di **altre scelte soggettive**)
che possono influenzare i risultati

3

i dati preferiscono **moderatamente** l'ordine
normale vs inverso per le masse dei neutrini

Grazie per l'attenzione!