

BLike

stimare il segnale
con pochi fotoni

mario

astrofiesta

25 Giugno 2015

outline:


- il problema
- una soluzione
- la libreria
- le applicazioni

outline:

- il problema
- una soluzione
- la libreria
- le applicazioni


Background subtracted time series

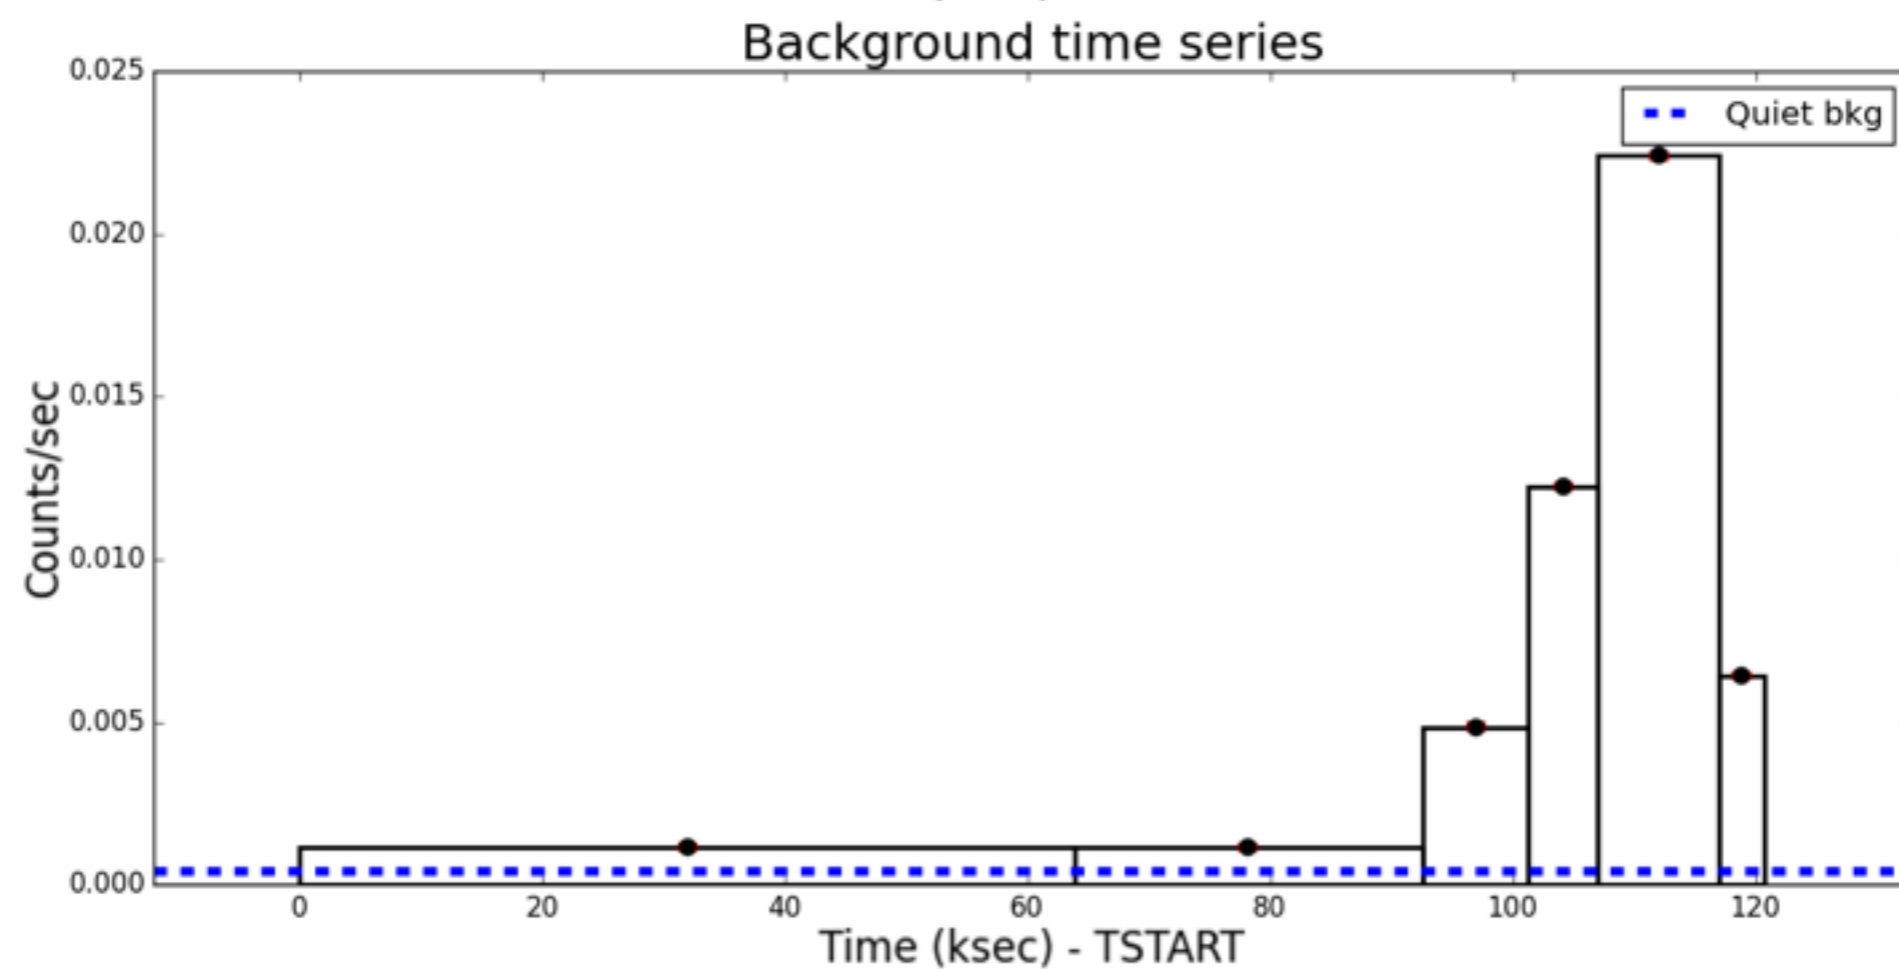
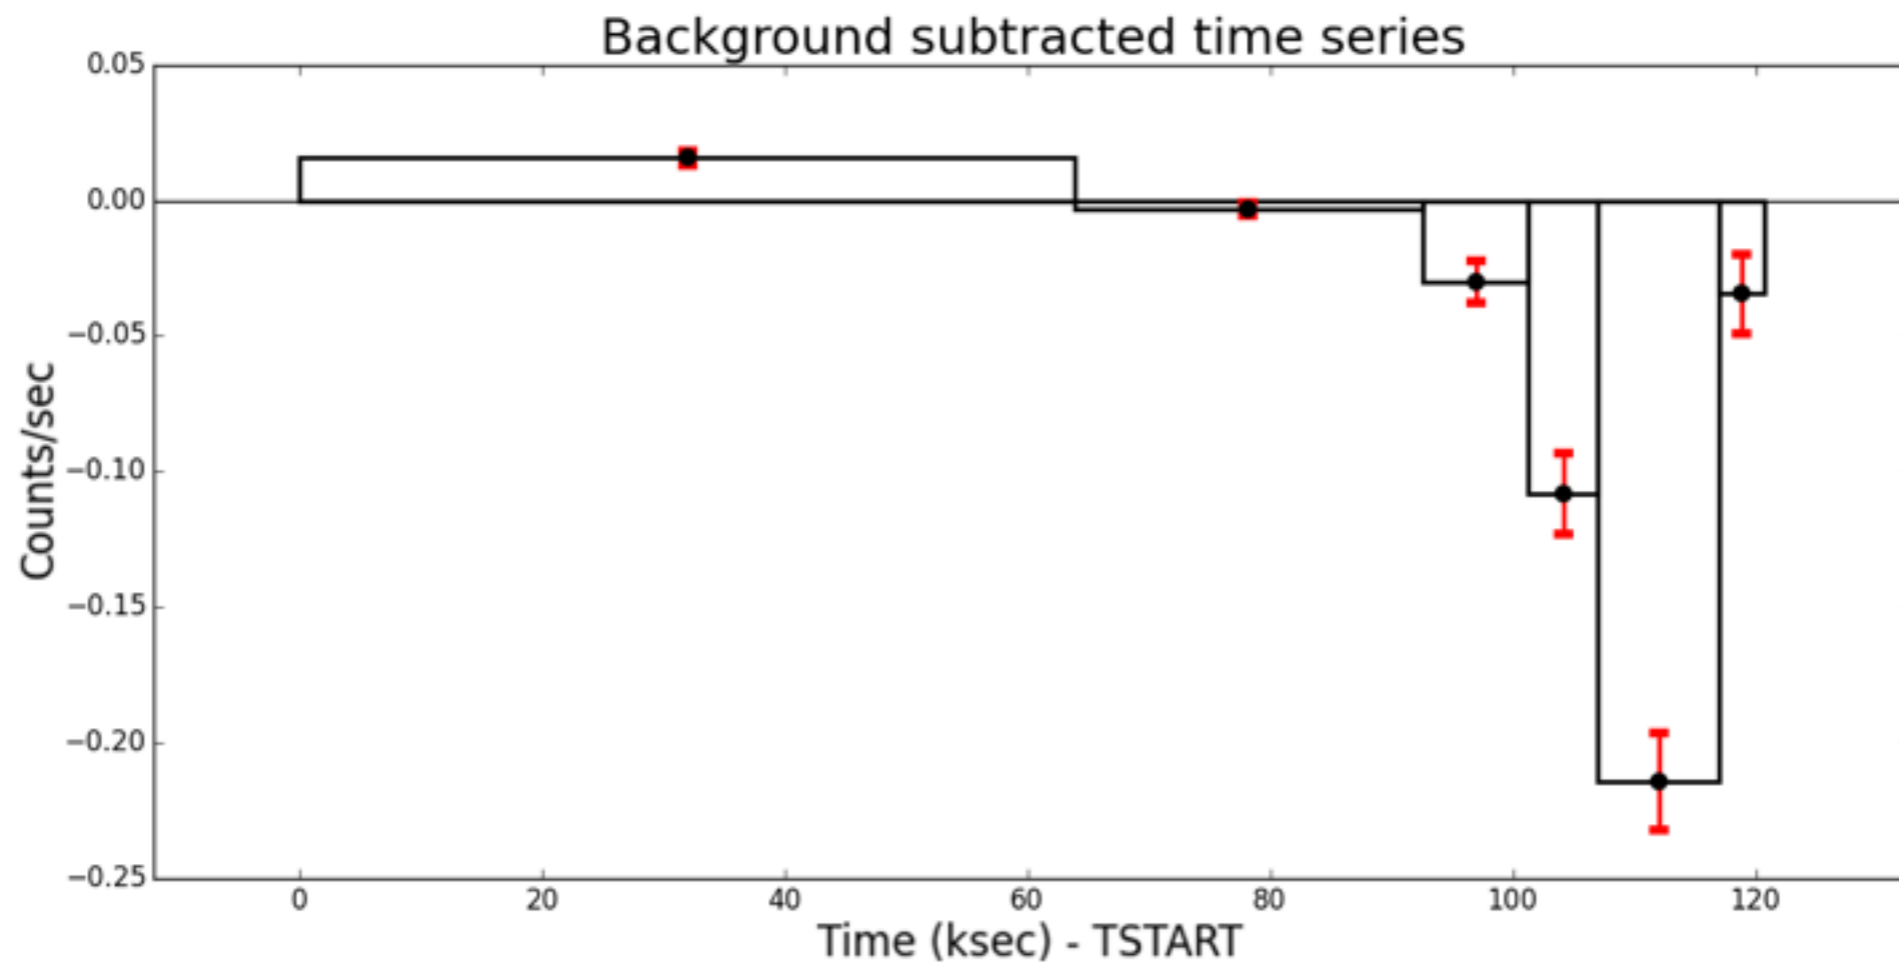
Mean Rate = -9.6011×10^{-4}



Background time series

Mean Rate = 1.12835×10^{-3}







il problema

- la maggior parte delle sorgenti X ha pochi fotoni
- selezioni in tempo ed energia peggiorano le cose
- l'approssimazione Gaussiana non funziona piu'
- serve un metodo robusto di stima del segnale
- questo stimatore deve permettere analisi statistiche
- possiamo ridurci a considerare il problema On-Off

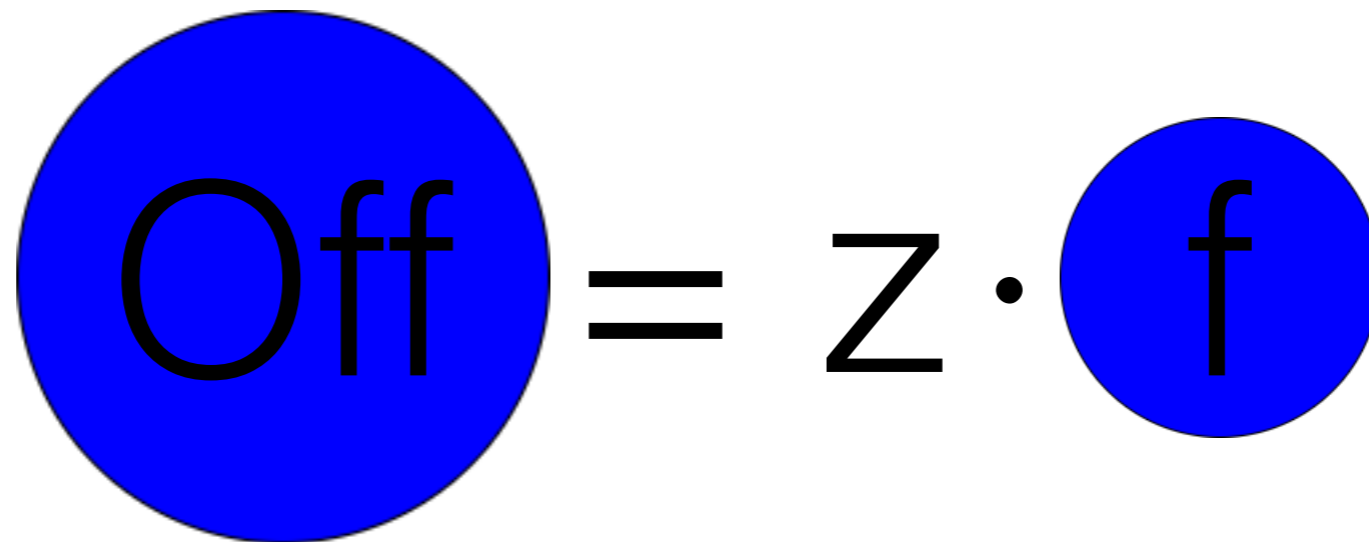
il problema On-Off

- stimo il fondo in una misura dedicata (Off)
- stimo segnale + fondo in un'altra misura (On)
- cerco di inferire il valore del segnale ripulito





$$N_{\text{On}} \sim \text{Poiss}(\mu_{\text{On}}) = \text{Poiss}(\mu_s + \mu_f)$$



$$N_{\text{Off}} \sim \text{Poiss}(\mu_{\text{Off}}) = \text{Poiss}(z \cdot \mu_f)$$

se fosse: $\mu, n \gg 0$

$$N \sim \text{Poiss}(\mu) \approx \text{Poiss}(n) \approx \text{Gauss}(n, n)$$

$$\mu_{\text{off}} \approx n_{\text{off}} \pm \sqrt{(n_{\text{off}})}$$

$$\mu_f \approx n_{\text{off}} / z \pm \sqrt{(n_{\text{off}}) / z}$$

$$\mu_{\text{on}} \approx n_{\text{on}} \pm \sqrt{(n_{\text{on}})}$$

$$\mu_s \approx (n_{\text{on}} - n_{\text{off}} / z) \pm \sqrt{(n_{\text{on}} + (n_{\text{off}} / z^2))}$$

outline:

- il problema
- una soluzione
- la libreria
- le applicazioni

c'e' un segnale?

- proviamo a misurare la sua significativita'
- partiamo dalla Null Hypothesis di solo fondo
- il problema si riduce a quello di una ripartizione binomiale [Przyborowski & Wilenski, 1940]:

$$\text{p-val} = \frac{(n_{on} + n_{off})!}{(z + 1)^{n_{on} + n_{off}}} \times \sum_{n=n_{on}}^{n_{on} + n_{off}} \frac{z^{n_{on} + n_{off} - n}}{n! \times (n_{on} + n_{off} - n)!}$$

- se p-val e' molto piccolo possiamo rigettare la NH

come lo misuriamo?

- tentiamo un approccio Bayesiano
- usiamo dei prior fisici: $\mu_s \geq 0$ e $\mu_f \geq 0$
- marginalizziamo la distribuzione di μ_s su μ_f
- ricaviamo una distribuzione a posteriori di μ_s
- estraiamo il valore medio, incertezze, limiti superiori
- usiamo il suo profilo per valutare ipotesi complesse

in pratica, che si fa?

- partiamo dai profili di verosimiglianza (likelihood)

$$\mathcal{L}(\mu_s, \mu_f | n_{on}) = e^{-(\mu_s + \mu_f)} \frac{(\mu_s + \mu_f)^{n_{on}}}{n_{on}!}$$

$$\mathcal{L}(\mu_f | n_{off}) = e^{-z \times \mu_f} \frac{(z \times \mu_f)^{n_{off}}}{n_{off}!}$$

- e marginalizziamo su una distribuzione del fondo

$$\mathcal{L}(\mu_s | n_{on}, n_{off}) = \int_0^{+\infty} \mathcal{L}(\mu_s, \mu_f | n_{on}) \times \mathcal{L}(\mu_f | n_{off}) d\mu_f$$

cosa si ottiene?

- un profilo di verosimiglianza per il segnale ($\mu_s \geq 0$):

$$\mathcal{L}(\mu_s | n_{on}, n_{off}) = \frac{e^{-\mu_s}}{K} \times \sum_{j=0}^{n_{on}} C_j(n_{on}, n_{off}) \times \mu_s^j$$

$$C_j(n_{on}, n_{off}) = \frac{(z+1)^j \times (n_{on} + n_{off} - j)!}{(n_{on} - j)! \times j!}$$

- o una distribuzione di probabilita' a posteriori se:

$$K = (z+1)^{n_{on}} \times \sum_{j=0}^{n_{on}} \frac{(n_{off} + j)!}{j! \times (z+1)^j}$$

quale prior?

- abbiamo assunto un prior piatto con fondo positivo:

$$\Pi(\mu_f) = \Theta(\mu_f) = \begin{cases} 1 & \mu_f \geq 0 \\ 0 & \mu_f < 0 \end{cases}$$

- si sarebbe potuto usare un prior esponenziale:

$$\Pi_\varepsilon(\mu_f) = \Theta(\mu_f) \times \varepsilon \times e^{-\varepsilon \times \mu_f} = \begin{cases} \varepsilon \times e^{-\varepsilon \times \mu_f} & \mu_f \geq 0 \\ 0 & \mu_f < 0 \end{cases}$$

$$\mathcal{L}_\varepsilon(\mu_s | n_{on}, n_{off}) = \int_0^{+\infty} \varepsilon \times e^{-\varepsilon \times \mu_f} \times \mathcal{L}(\mu_s, \mu_f | n_{on}) \times \mathcal{L}(\mu_f | n_{off}) d\mu_f$$

outline:

- il problema
- una soluzione
- la libreria
- le applicazioni

BLike

- sia pure tutto ok, ma e' un po' complicato...
- ho scritto un modulo Python, BLike che fa tutto
- e' veloce e comodo da inserire in script complessi
- sto lavorando ora alla documentazione (+paper)
- non l'ho ancora inserito in github, ma lo faro'

come si usa?

```
ipython
```

```
In [1]: from BLike import BLike
```

```
In [2]: L=BLike(N_on=23, N_off=20, bkg_ratio=2.)
```

```
In [3]: print 'Detection at %.2f sigma (P-value=%.2e)' % (L.Significance(), L.Significance(True))  
Detection at 2.80 sigma (P-value=5.07e-03)
```

```
In [4]: print 'Best fit %.3f +%.3f -%.3f' % (L.MostLikely(), L.ErrorBar(), L.ErrorBar(False))  
Best fit 12.770 +5.249 -5.404
```

```
In [5]: import matplotlib.pyplot as plt
```

```
In [6]: import numpy as np
```


```
In [7]: X=np.arange(0., 30., .01)
```

```
In [8]: Y=[L.Get(x) for x in X]
```

```
In [9]: A=plt.plot(X, Y)
```

```
In [10]: plt.show()
```

come si usa?



cosa puo' fare?

```
In [11]: L.Integrate(15, 25)
```

```
Out[11]: 0.3518258952415475
```

```
In [12]: L.UpperLimit()
```

```
Out[12]: 23.07889473438263
```

```
In [13]: L.GetIntegral(_)
```

```
Out[13]: 0.95450034035389952
```

```
In [14]: L.UpperLimit(coverage=.99)
```

```
Out[14]: 27.220936238765717
```

```
In [15]: L.MostLikely()
```

```
Out[15]: 12.769500732421875
```

```
In [16]: L.Integrate(_ - L.ErrorBar(up=False), _ + L.ErrorBar(up=True))
```

```
Out[16]: 0.68268948135806107
```

```
In [17]: L.MaxLike()
```

```
Out[17]: 0.075207812762068615
```

```
In [18]: L.Get(12.37)
```

```
Out[18]: 0.074989870469523739
```

```
In [19]: L.TS(12.37)
```

```
Out[19]: 5.1808044699473079
```



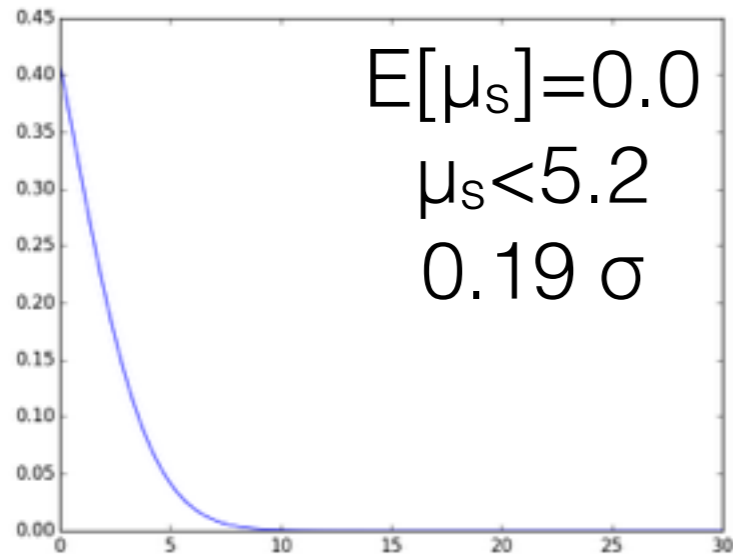
outline:

- il problema
- una soluzione
- la libreria
- le applicazioni

ma... funziona?

- 2 tipi di test: confronto con GLike e Montecarlo
- GLike usa l'approssimazione Gaussiana, troncata ai soli valori positivi di μ_s e normalizzata a 1
- GLike ha la stessa interfaccia di BLike e dovrebbe dare gli stessi risultati per $\mu_s \gg 1$
- via Montecarlo controllo le coperture dei limiti superiori e delle incertezze e la sensibilita'

GLike

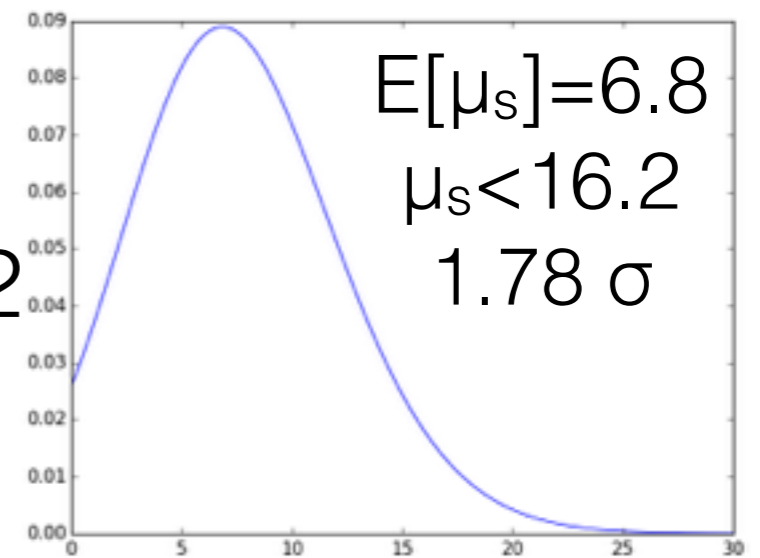




$n_{\text{On}}=7$ $n_{\text{Off}}=20$ $z=2$

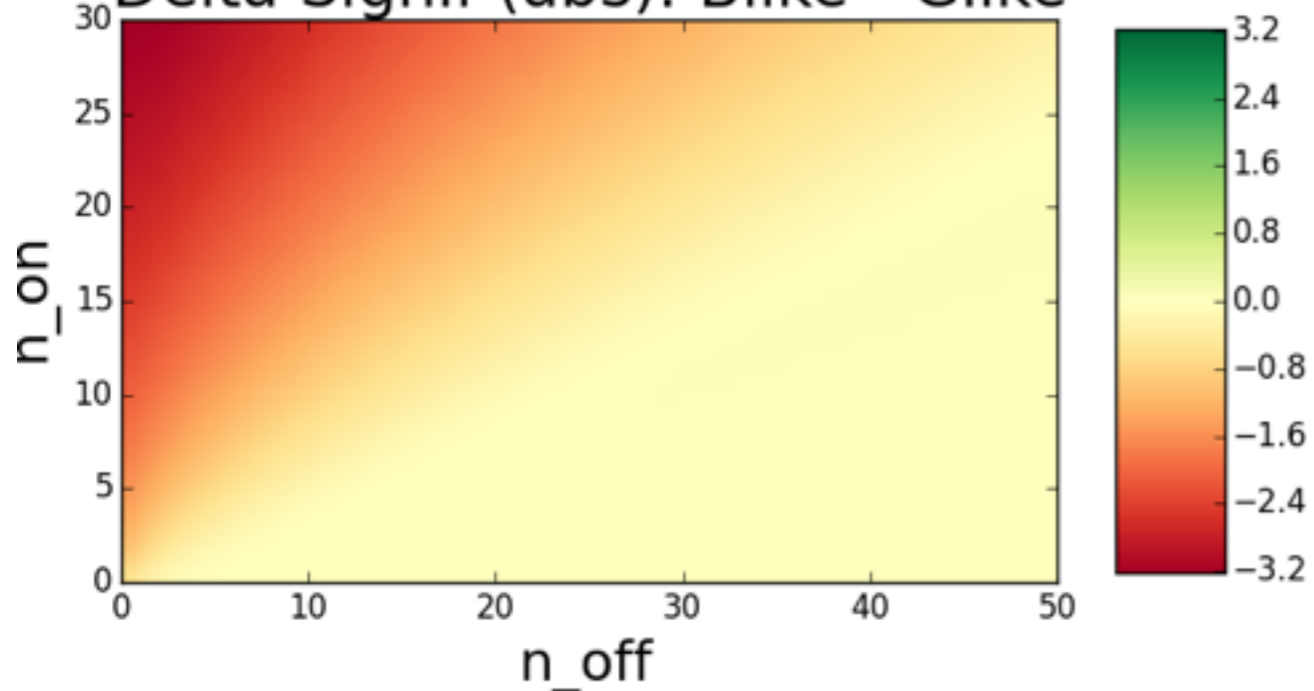
$n_{\text{On}}=13$ $n_{\text{Off}}=20$ $z=2$

$n_{\text{On}}=17$ $n_{\text{Off}}=20$ $z=2$


BLike



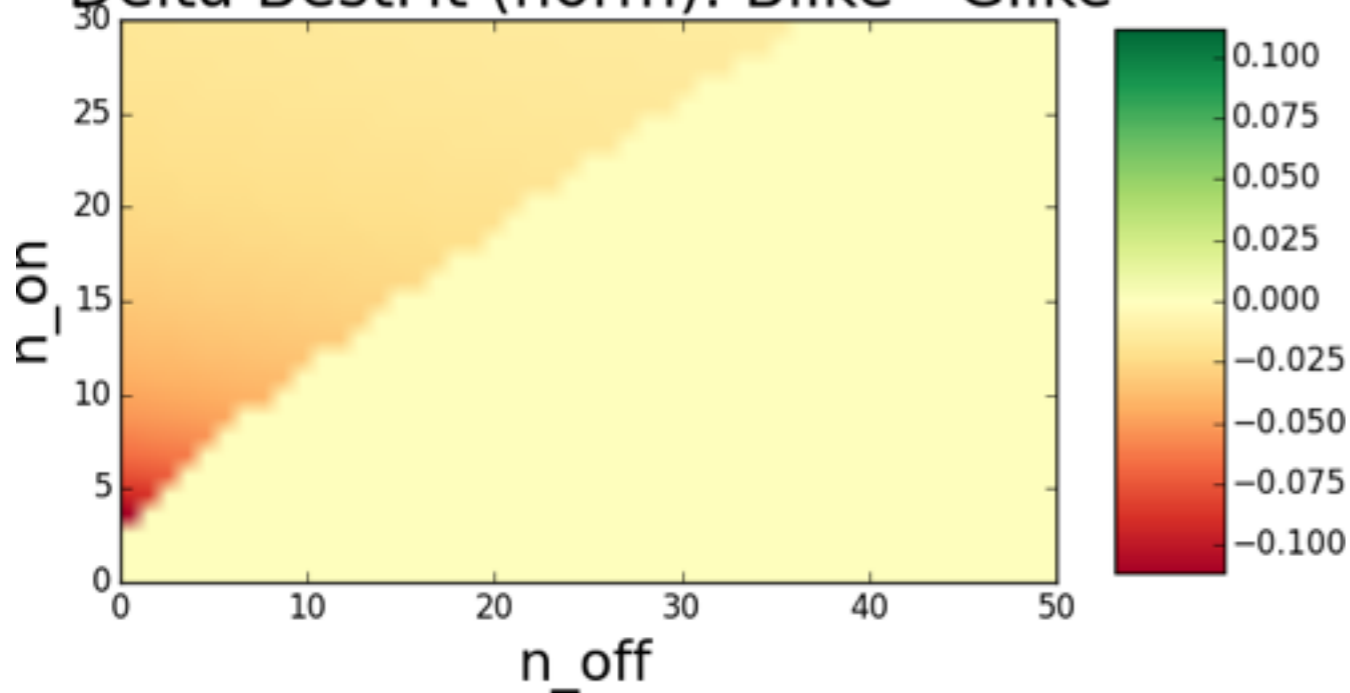
Delta Signif (abs): Blike - Glike



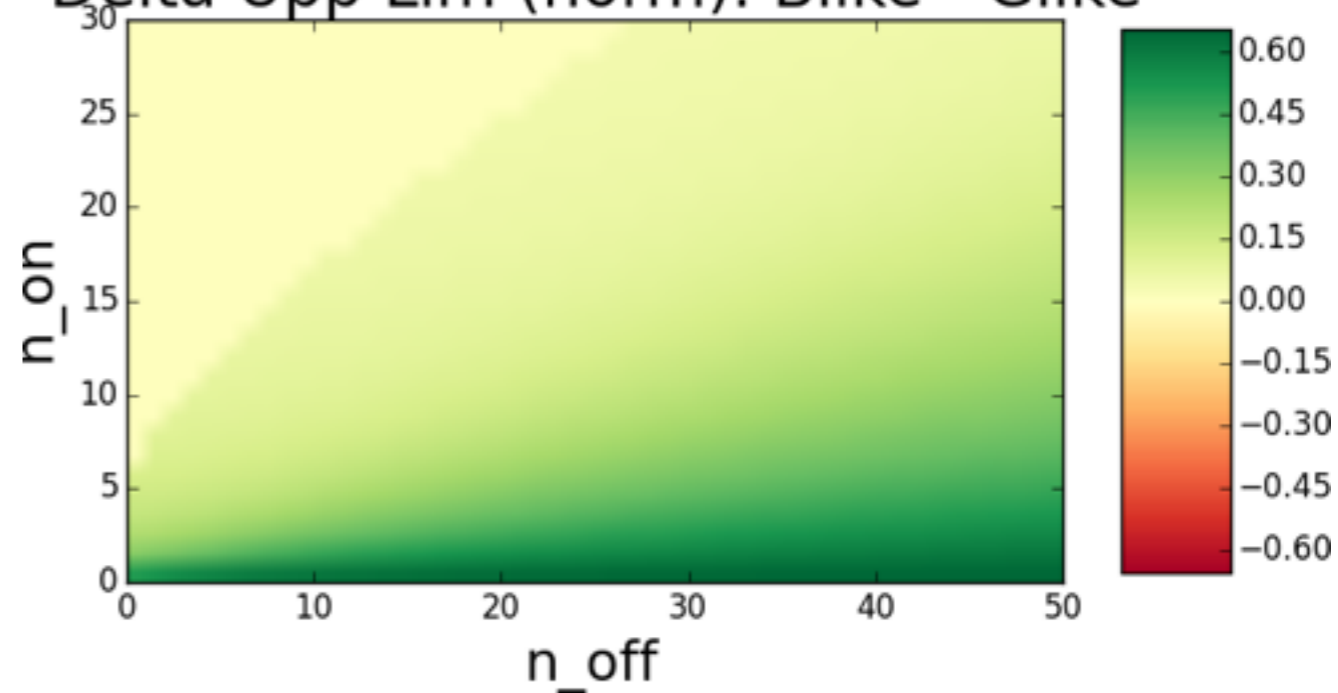
Delta Signif (norm): Blike - Glike



Delta BestFit (norm): Blike - Glike




Delta Upp Lim (norm): Blike - Glike



che me ne faccio?


- devo avere dei problemi riconducibili a questo: conteggi, fondo da sottrarre, piccole statistiche
- puo' essere usato per curve di luce, spettri, studio di sorgenti estese o un mix di queste
- se faccio bin abbastanza piccoli le statistiche diminuiscono, se no ricado in GLike (approssimato)
- la misura Off puo' venire anche da modelli molto piu' complessi (come in EXTraS, con BLike2)

ha sistemato il problema?




CO=-2.4594E-03, WV= 163.5 , N= 124.0


cosa avevamo davvero osservato?



questa e' la stima in approssimazione Gaussiana




riscaliamo, sottraiamo, propaghiamo gli errori




controlliamo se la sorgente si vede


```
Like = [BLike(N_on=N_on[i], N_off=N_off[i], bkg_ratio=zeta[i]) for i in range(N_points)]  
for i in range(N_points):  
    print (time[i] - time[0])/1000., Like[i].Significance()
```



possiamo visualizzare i valori piu' probabili

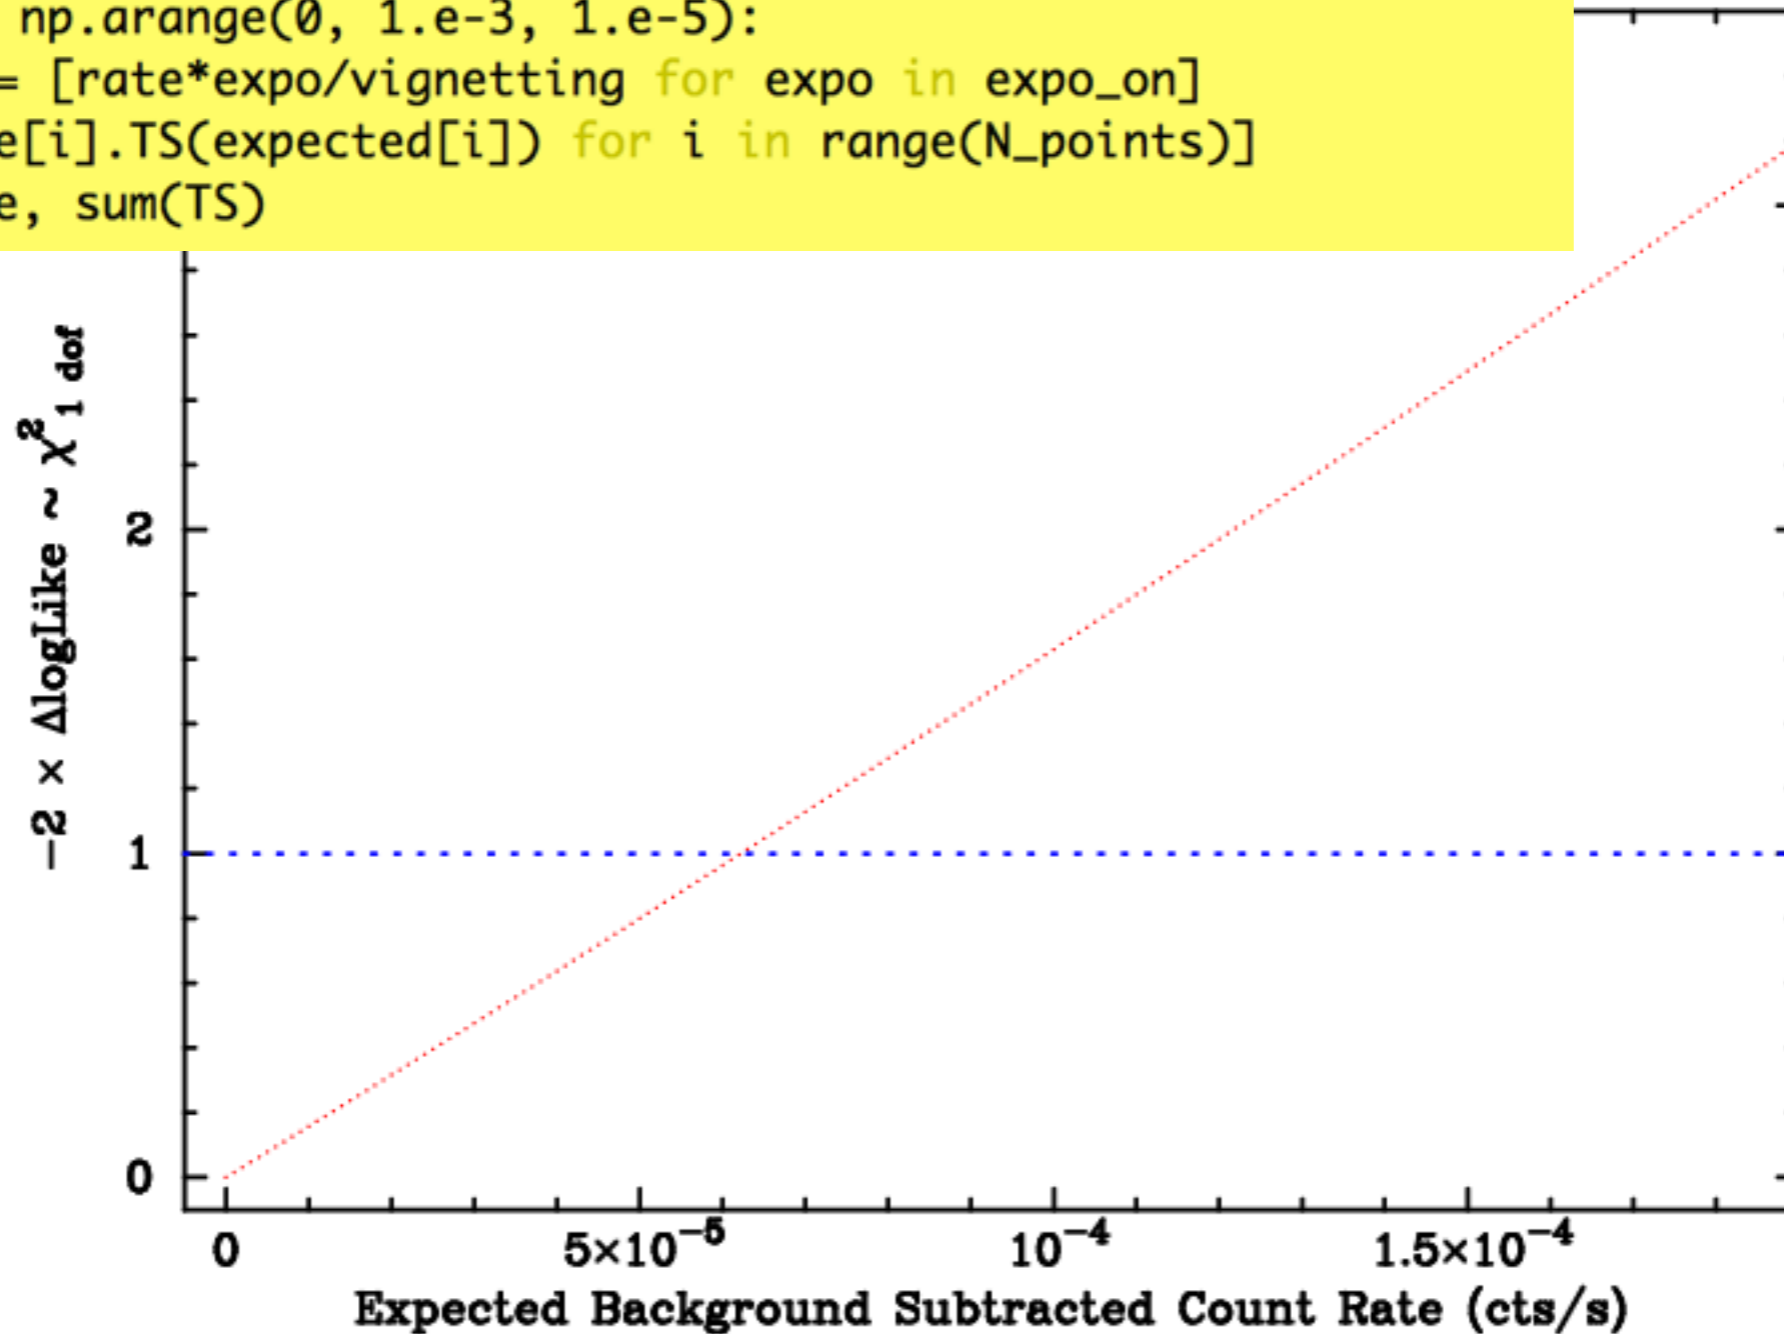


o forse meglio i limiti superiori




conserviamo i profili per fittare una costante


```
vignetting = 2.50487
for rate in np.arange(0, 1.e-3, 1.e-5):
    expected = [rate*expo/vignetting for expo in expo_on]
    TS = [Like[i].TS(expected[i]) for i in range(N_points)]
    print rate, sum(TS)
```



in realta' questa era una sorgente sciagurata




un caso piu' sano



ma con i suoi problemi


Background subtracted time series


Mean Rate= 8.98929×10^{-3}





Background time series


Mean Rate= 5.27787×10^{-3}




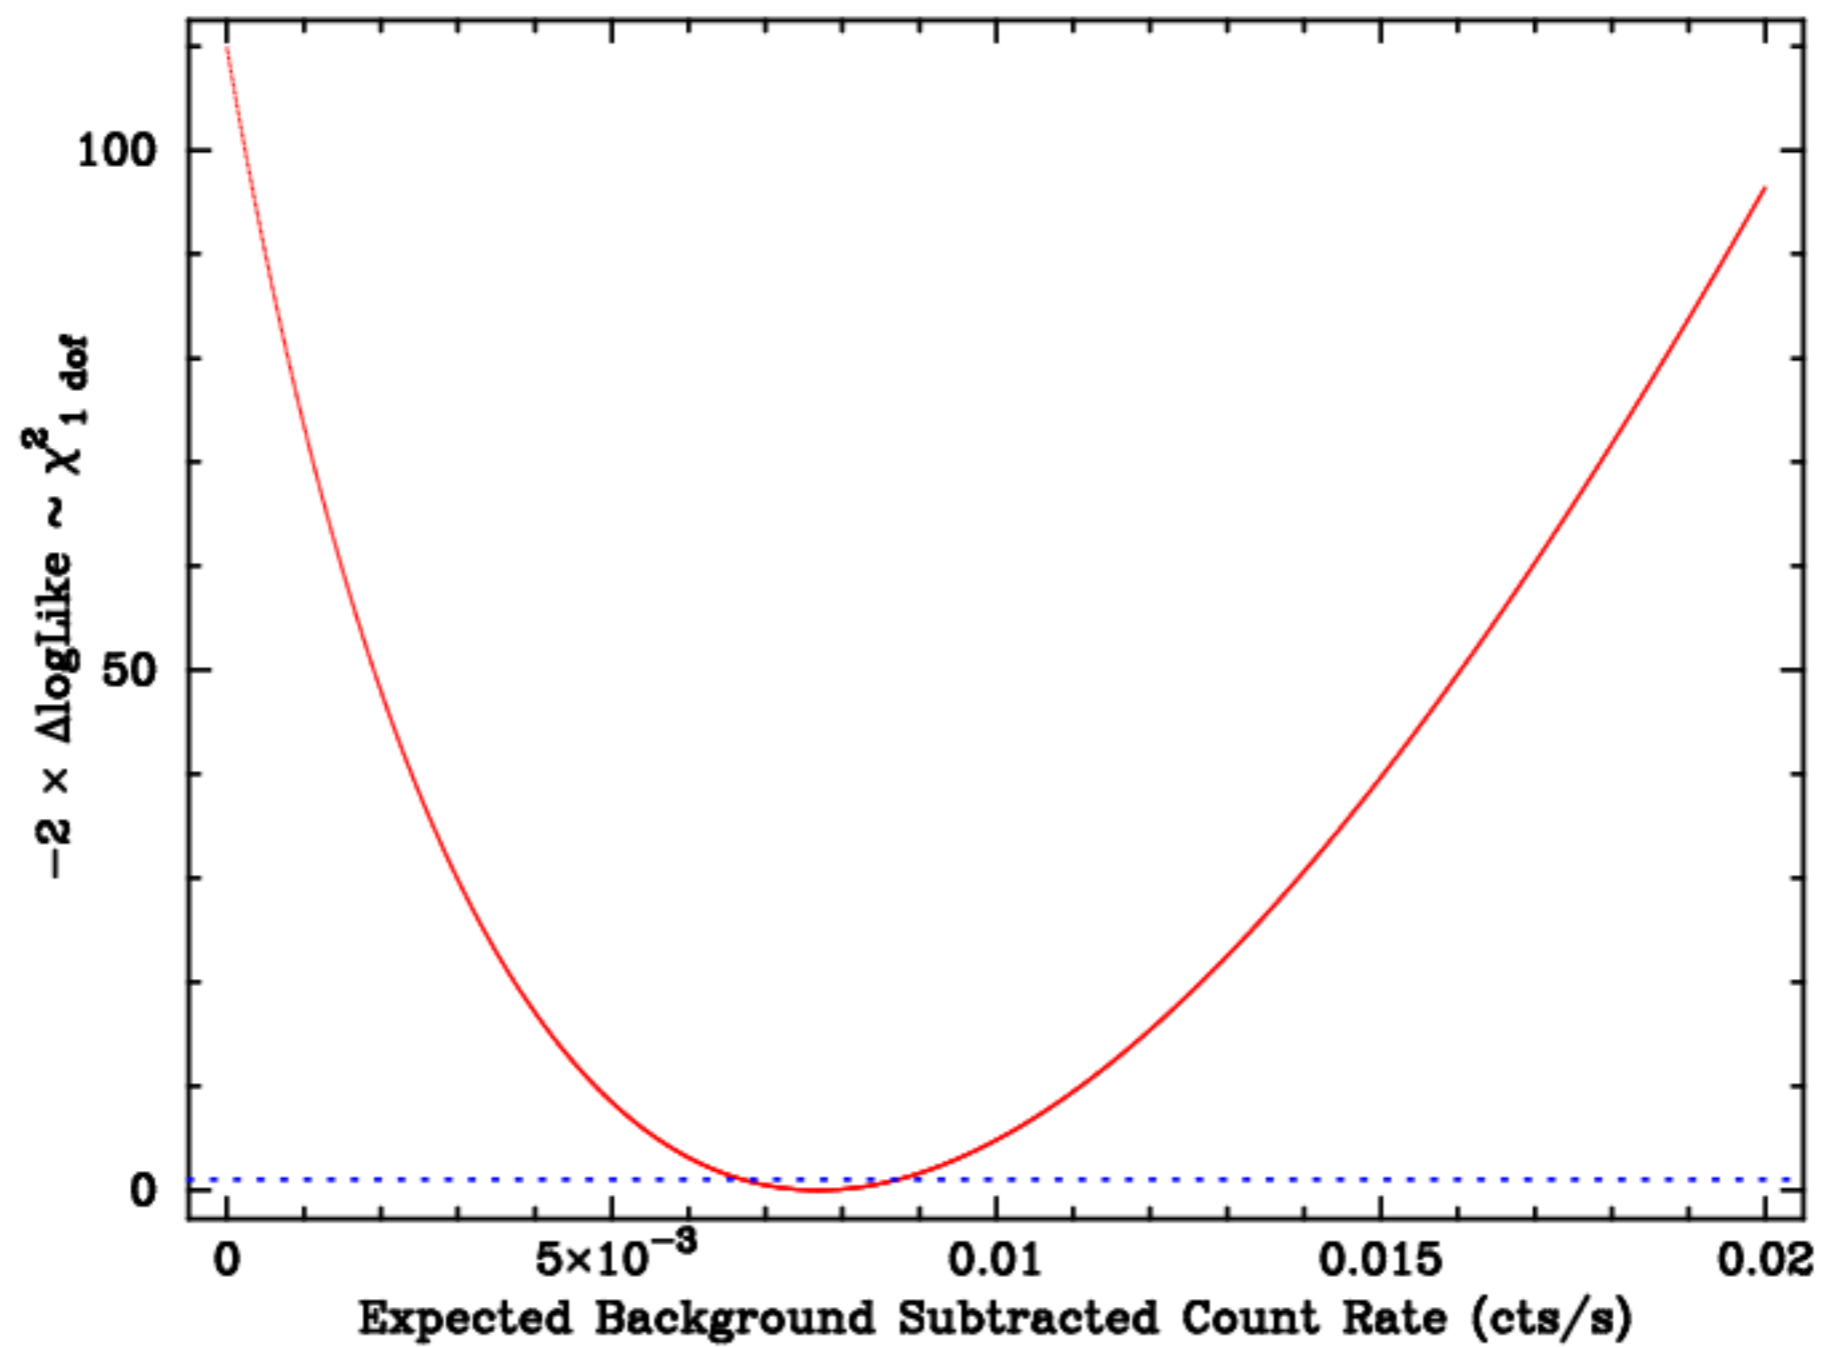













$$\rho_s = 7.68^{+1.03}_{-.97} \text{ e-3 cts/s}$$



grazie per l'attenzione

buone vacanze!