

Nelineární metoda nejmenších čtverců – fit píku


peak.py

1. V Pythonu proveďte fit píku v souboru peak.txt Gaussiánem

modelová funkce:

$$y = \frac{I}{\sqrt{2\pi}\sigma} \exp \left[-\frac{(x - x_0)^2}{2\sigma^2} \right] + \text{bcb}$$

intenzita poloha píku
↑
standardní odchylka ↑
pozadí



```
from scipy.optimize import curve_fit
def peak(x,x0,sigma,I,bcb):
    return I/(np.sqrt(2*np.pi)*sigma)*np.exp(-(x-x0)**2/(2*sigma**2))+bcb
```

nelineární fit metodou nejmenších čtverců

```
params,pcov = curve_fit(func,x,y,p0,sigma=ey)
```

↑ ↑ ↑ ↑ ↑
hodnoty kovarianční modelová závislá chyby naměřených hodnot
nafitovaných matice funkce proměnná závislé proměnné
parametrů počáteční odhad
(zde I , x_0 , σ , bcb) parametrů

Nelineární metoda nejmenších čtverců – fit píku


peak.py

1. V Pythonu proveďte fit píku v souboru `peak.txt` Gaussiánem

modelová funkce:

$$y = \frac{I}{\sqrt{2\pi}\sigma} \exp \left[-\frac{(x - x_0)^2}{2\sigma^2} \right] + b_{cg}$$

intenzita poloha píku
↑
standardní odchylka ↑
pozadí



χ^2 test kvality fitu

```
from scipy.stats import chi2
chi2_exp=np.sum(((y-yfit)/ey)**2)
print("P = ",1-chi2.cdf(chi2_exp,nu))
```

↑
 P - hodnota

↑
distribuční funkce
 χ^2 rozdělení

↑
experimentální hodnota χ^2
vážený součet rozdílů kvadrátů mezi
experimentálními hodnotami a
modelovou funkcí

počet stupňů volnosti
počet naměřených hodnot mínus počet
fitovaných parametrů


Nelineární metoda nejmenších čtverců – fit píku

peak.opj

Fit píku Gaussiánem v Originu

Model	Gaussian
Equation	$y = y_0 + A/(w \cdot \sqrt{\pi/(4 \cdot \ln(2))}) \cdot \exp(-4 \cdot \ln(2) \cdot (x - x_c)^2 / w^2)$
Plot	y
y0	74.73812 ± 1.39744
xc	7.42521 ± 7.21092E-4
A	141.2053 ± 1.46542
w	0.16172 ± 0.00155
Reduced Chi-Sqr	1.07379
R-Square (COD)	0.99249
Adj. R-Square	0.9922


hodnota χ^2 na počet stupňů volnosti



2. Ověřte, že vážený součet kvadrátů rozdílů mezi N naměřenými hodnotami náhodné proměnné s normálním rozdělením a modelové funkce s m parametry má χ^2 rozdělení s počtem stupňů volnosti $\nu = N - m$ v případě, že modelová funkce popisuje experimentální data správně

kvadratická závislost ($N = 100$ hodnot)

fit parabolou $\lambda(x|\theta) = \theta_0 + \theta_1 x + \theta_2 x^2$



χ^2 test kvality fitu



chi2sim.py

2. Ověřte, že vážený součet kvadrátů rozdílů mezi N naměřenými hodnotami náhodné proměnné s normálním rozdělením a modelové funkce s m parametry má χ^2 rozdělení s počtem stupňů volnosti $\nu = N - m$ v případě, že modelová funkce popisuje experimentální data správně

kvadratická závislost ($N = 100$ hodnot)

fit parabolou $\lambda(x|\theta) = \theta_0 + \theta_1 x + \theta_2 x^2$

1000 opakování



$$\chi^2 = \sum_{i=1}^N \frac{(y_i - \lambda(x_i|\theta))^2}{\sigma_i^2}$$



2. Ověřte, že vážený součet kvadrátů rozdílů mezi N naměřenými hodnotami náhodné proměnné s normálním rozdělením a modelové funkce s m parametry má χ^2 rozdělení s počtem stupňů volnosti $\nu = N - m$ v případě, že modelová funkce popisuje experimentální data správně

kvadratická závislost ($N = 100$ hodnot)

fit parabolou $\lambda(x|\theta) = \theta_0 + \theta_1 x + \theta_2 x^2$

1000 opakování

rezidua $r_i = \frac{y_i - \lambda(x_i|\theta)}{\sigma_i}$



χ^2 test kvality fitu



chi2sim.py

2. Ověřte, že vážený součet kvadrátů rozdílů mezi N naměřenými hodnotami náhodné proměnné s normálním rozdělením a modelové funkce s m parametry má χ^2 rozdělení s počtem stupňů volnosti $\nu = N - m$ v případě, že modelová funkce popisuje experimentální data správně

kvadratická závislost ($N = 100$ hodnot)

fit přímkou $\lambda(x|\theta) = \theta_0 + \theta_1 x$

1000 opakování (nesprávná modelová funkce)




$$\chi^2 = \sum_{i=1}^N \frac{(y_i - \lambda(x_i|\theta))^2}{\sigma_i^2}$$

2. Ověřte, že vážený součet kvadrátů rozdílů mezi N naměřenými hodnotami náhodné proměnné s normálním rozdělením a modelové funkce s m parametry má χ^2 rozdělení s počtem stupňů volnosti $\nu = N - m$ v případě, že modelová funkce popisuje experimentální data správně

kvadratická závislost ($N = 100$ hodnot)

fit přímkou $\lambda(x|\theta) = \theta_0 + \theta_1 x$

1000 opakování (nesprávná modelová funkce)



rezidua $r_i = \frac{y_i - \lambda(x_i|\theta)}{\sigma_i}$

