



智慧とデータが拓くエレクトロニクス新材料開発拠点

Data Driven Materials Research Institute for Electronics

材料計算科学・データ解析に関するチュートリアルコース
2023/3/22 10:00~11:00



スペクトル解析

Smoothing

平滑化

平滑化


[tkprog_tutorial]¥spectrum¥dos.xlsx



平滑化の結果


単純移動平均

平滑化点数を11,21,31点




2次多項式平滑化

平滑化点数を11,21,31点



4次多項式平滑化

平滑化点数を11,21,31点



平滑化

着目している点 N点 のある平均を取る

- 単純移動平均

重みを均一に $1/N$ とする

- 加重移動平均

重み: 線形、三角形、指数関数、Gauss関数 など

Simple moving average (2m+1 points)

$$y_{i,smoothed} = \frac{1}{2m+1} \sum_{j=i-m}^{i+m} y_j$$

Weighted moving average (2m+1 points)

$$y_{i,smoothed} = \sum_{j=i-m}^{i+m} y_j w_j / \sum_{j=i-m}^{i+m} w_j$$

何らかの関数で近似して平滑化を行う

- Polynomial smoothing (多項式による平滑化)
- Smoothing spline (スプライン平滑化)
- Least-squares method (最小二乗法)

その他

- Fourier transformation (フーリエ変換)

多項式適合法 (Savitzky-Golay法) の重み

南茂夫, 科学計測のための波形データ処理, CQ出版社 (1986)

2次および3次多項式適合法の重み

# of points N	25	23	21	19	17	15	13	11	9	7	5
m=int(N/2)	12	11	10	9	8	7	6	5	4	3	2
-12	-253										
-11	-138	-210									
-10	-33	-105	-171								
-9	62	-10	-76	-136							
-8	147	75	9	-51	-105						
-7	222	150	84	24	-30	-78					
-6	287	215	149	89	35	-13	-55				
-5	342	270	204	144	90	42	0	-36			
-4	387	315	249	189	135	87	45	9	-21		
-3	422	350	284	224	170	122	80	44	14	-10	
-2	447	375	309	249	195	147	105	69	39	15	-3
-1	462	390	324	264	210	162	120	84	54	30	12
0	467	395	329	269	215	167	125	89	59	35	17
1	462	390	324	264	210	162	120	84	54	30	12
2	447	375	309	249	195	147	105	69	39	15	-3
3	422	350	284	224	170	122	80	44	14	-10	
4	387	315	249	189	135	87	45	9	-21		
5	342	270	204	144	90	42	0	-36			
6	287	215	149	89	35	-13	-55				
7	222	150	84	24	-30	-78					
8	147	75	9	-51	-105						
9	62	-10	-76	-136							
10	-33	-105	-171								
11	-138	-210									
12	-253										
Normalization factor	5175	4025	3059	2261	1615	1105	715	429	231	105	35

1次: 単純移動平均
2次と3次は同じ重みになる

(2m+1)点を用いた2,3次多項式適合の重み

$$w_{23}(j) = 3m(m+1) - 1 - 5j^2$$

$$W_{23} = (4m^2 - 1)(2m + 3)/3$$

$$j = -m, \dots, -1, 0, 1, \dots, m$$

高次の微分公式

3点公式

$$\begin{aligned} f'(a) &= \frac{1}{h} \left\{ \frac{1}{2} f(a+h) - \frac{1}{2} f(a-h) \right\} \\ &+ \frac{1}{6} f^{(3)}(\underline{a}) h^2 + \dots \end{aligned}$$

5点公式

$$\begin{aligned} f'(a) &= \frac{1}{h} \left\{ -\frac{1}{12} f(a+2h) + \frac{2}{3} f(a+h) - \frac{2}{3} f(a-h) + \frac{1}{12} f(a-2h) \right\} \\ &+ \frac{1}{30} f^{(5)}(\underline{a}) h^4 + \dots \end{aligned}$$

7点公式

$$\begin{aligned} f'(a) &= \frac{1}{h} \left\{ \frac{1}{60} f(a+3h) - \frac{3}{20} f(a+2h) + \frac{3}{4} f(a+h) - \frac{3}{4} f(a-h) \right. \\ &+ \left. \frac{3}{20} f(a-2h) - \frac{1}{60} f(a-3h) \right\} \\ &+ \frac{1}{140} f^{(7)}(\underline{a}) h^6 + \dots \end{aligned}$$

フィルターとコンボリューション

中央差分1次微分

コンボリューション:
データとフィルターの
行列演算

$$\frac{dy}{dx_2} = \frac{1}{2h} \begin{pmatrix} -1 & 0 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$
$$\frac{d^2y}{dx^2_2} = \frac{1}{2h^2} \begin{pmatrix} 1 & -2 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$

中央差分2次微分

単純移動平均 (3点)

$$y_{2,s} = \frac{1}{3} \begin{pmatrix} 1 & 1 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$

加重移動平均 (3点片三角重み)

$$y_{2,s} = \frac{1}{3} \begin{pmatrix} 0 & 2 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$

加重移動平均 (3点両三角重み)

$$y_{2,s} = \frac{1}{6} \begin{pmatrix} 1 & 2 & 1 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \end{pmatrix}$$

2次および3次多項式適合化平均 (2m+1 点)

$$y_{3,s} = \frac{1}{35} \begin{pmatrix} -3 & 12 & 17 & 12 & -3 \end{pmatrix} \begin{pmatrix} y_1 \\ y_2 \\ y_3 \\ y_4 \\ y_5 \end{pmatrix}$$

微分、平滑化、コンボリューションは、
フィルターを変えるだけで
同じコンボリューションプログラムを流用できる

任意関数のコンボリューション

南茂夫 編著、科学計測のための波形データ処理、CQ出版 (1986年)

$$f^*(x_i) = \int_{-\infty}^{\infty} f(x')g(x_i - x')dx' = N^{-1} \sum_{j=1}^N f(x_j)g(x_i - x_j)$$

$$\begin{pmatrix} f_1^* \\ f_2^* \\ f_3^* \\ \vdots \\ f_{N-1}^* \\ f_N^* \end{pmatrix} = \begin{pmatrix} g_0 & g_{-1} & \cdots & g_{-(N-3)} & g_{-(N-2)} & g_{-(N-1)} \\ g_1 & g_0 & \cdots & g_{-(N-4)} & g_{-(N-3)} & g_{-(N-2)} \\ g_2 & g_1 & \ddots & \vdots & g_{-(N-4)} & g_{-(N-3)} \\ \vdots & \vdots & \cdots & g_0 & g_{-1} & \vdots \\ g_{N-2} & g_{N-3} & \cdots & g_1 & g_0 & g_{-1} \\ g_{N-1} & g_{N-2} & \cdots & g_2 & g_1 & g_0 \end{pmatrix} \begin{pmatrix} f_1 \\ f_2 \\ f_3 \\ \vdots \\ f_{N-1} \\ f_N \end{pmatrix}$$

$g(x_i - x_j)$

$f^*(x)$

$f(x)$

pythonライブラリによる平滑化

Smoothing.py

単純移動平均

1/N の重みのフィルターを作る

```
w = np.ones(nsmooth) / nsmooth
```

コンボリューション

```
ys = np.convolve(y, w, mode = 'same')
```

多項式適合化平滑化: **Savitzky-Golay**フィルター

```
ys = scipy.signal.savgol_filter(y, nsmooth, norder, deriv = 0)
```

nsmooth: 平滑化点数

norder: 多項式の次数

deriv: 微分次数

注意: savgol_filter() では deriv = 1 とすると1次微分を取ってくれるが、
x軸のデータを与えていないので、絶対値は異なる。

絶対値が必要な場合、平滑化した後、 h^{deriv} で割ること

注: savgol_diff_test.py で限定的に確認した範囲です

多次元フィルター、コンボリューションと画像解析

フィルター: $\begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$

$$y'_{22} = \sum_{i,j=1,2,3} a_{ij} y_{ij}$$

データ $\begin{pmatrix} y_{11} & y_{12} & y_{13} \\ y_{21} & y_{22} & y_{23} \\ y_{31} & y_{32} & y_{33} \end{pmatrix}$ と

フィルタ $\begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$ の

各要素の積の和を
 y_{22} のコンボリューションにとる

X軸微分フィルター (エッジ検出)

$$\frac{1}{2h} \begin{pmatrix} 0 & 0 & 0 \\ -1 & 0 & 1 \\ 0 & 0 & 0 \end{pmatrix}$$

Y軸微分フィルター (エッジ検出)

$$\frac{1}{2h} \begin{pmatrix} 0 & -1 & 0 \\ 0 & 0 & 0 \\ 0 & 1 & 0 \end{pmatrix}$$

斜め微分フィルター (エッジ検出)

$$\frac{1}{2h} \begin{pmatrix} 0 & 1 & 0 \\ -1 & 0 & 1 \\ 0 & -1 & 0 \end{pmatrix}$$

平滑化フィルター (ぼかし)

⇔ デコンボリューションにより sharpening ができる

$$\frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

Convolutud Neural Network (畳み込みニューラルネットワーク)

Neural network の中段にフィルターによる畳み込み層を入れて、
フィルターの要素の値を学習させる


学習したフィルターを見ることで、どのような処理が必要か理解できることもある

数学のデコンボリューションとは異なるので注意

Peak search

[tkProg]¥tkprog_tutorial¥spectrum¥peak_search.py

ピーク判定の条件 南茂夫 編著、科学計測のための波形データ処理、CQ出版 (1986年)



フーリエ変換


異なる定義があるので注意

$$\left\{ \begin{array}{ll} \text{FT (フーリエ変換)} & F(\omega) = \int_{-\infty}^{\infty} f(t) \exp(i\omega t) dt \\ \text{IFT (逆フーリエ変換)} & f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) \exp(-i\omega t) d\omega \end{array} \right.$$
$$\left\{ \begin{array}{ll} \text{FT} & F(\omega) = \int_{-\infty}^{\infty} f(t) \exp(i2\pi ft) dt \\ \text{IFT} & f(t) = \int_{-\infty}^{\infty} F(\omega) \exp(-i2\pi ft) d\omega \end{array} \right.$$

フーリエ変換の特徴

- ・ 時間依存データを周波数依存データに変換
- ・ 位置依存データを波数依存データに変換
- ・ 元データの原点は逆空間全体に広がる
- ・ 元データの全体は逆空間の原点に収束する
- ・ フーリエ変換したデータ (FT) を逆変換 (IFT) すると元のデータに戻る

フーリエ変換による平滑化





FTデータの高周波成分を除去: 平滑化

ローパスフィルター

低周波成分を除去: ドリフト成分を除去

ハイパスフィルター

例: $[k_{\text{cut}0}, k_{\text{cut}1}]$ 外部のデータを除去して
逆フーリエ変換



Program: smoothing-fft.py

[tkprog_tutorial]¥spectrum¥xrd.xlsx

The image shows the Launcher2023 application window and the FFT: configure dialog box. The Launcher window has a menu bar with 'ファイル' (File) and 'ツール' (Tools). The '設定' (Settings) menu is open, showing options like '設定ファイル編集' (Edit settings file), 'ja' (Japanese), and '終了' (Exit). The 'ランチャ' (Launcher) tab is selected, showing a list of external programs. The 'スベクトル解析' (Spectral analysis) option is highlighted. The 'FFT/Smoothing' option is also highlighted in the list. The 'FFT: configure' dialog box is open, showing configuration options for the FFT program. The 'python3' field is set to 'C:¥Anaconda3¥python.exe'. The 'script' field is set to 'D:¥tkProg¥tkProg¥tkprog_tutorial¥spectrum'. The 'input path' field is set to 'D:/tkProg/tkProg/tkprog_tutorial/spectrum/x'. The 'x[0]' field is set to '2Theta' and the 'x[1]' field is set to 'I'. The 'xmin' field is set to '-1e+100' and the 'xmax' field is set to '1e+100'. The 'kcut_low' field is set to '0' and the 'kcut_high' field is set to '3'. The 'FFT smoothing' button is highlighted. The 'OK' button is highlighted.

Launcher2023 - tutorial2022 - Launcher_tkami.ini

ファイル ツール

設定 設定ファイル編集 ja 終了

ランチャ 開発者用 ビュー

外部プログラム

----- Help -----

ヘルプ

インストールマニュアル等

----- Data analysis -----

ベイズ最適化(PHYSBO)

フィッティング

スベクトル解析

2023/1/31チュートリアル (回帰)

2023/2/17チュートリアル (回帰・機械学習)

2023/3/6チュートリアル (非線形最適化)

2023/3/22チュートリアル (スベクトル解析)

----- Links -----

リンク

cmd.exe

PowerShell

Explore

エディタ

スクリプト

スクリプトリスト

リソース編集

ファイル: 選択 app

引数:

デコンボリューション	?	入力ファイル例	×
コンボリューション	?	入力ファイル例	×
平滑化	?	入力ファイル例	×
FFT/Smoothing	?	入力ファイル例	×
FFT(func)	?	Laplace trans.(func)	?
	×		×
	×		×

cmd(org): \$(start) \$(file_path)

cmd(conv): start D:¥tkProg¥tkProg¥tkprog_tutorial¥r

FFT: configure

python3: C:¥Anaconda3¥python.exe 選択 app

script: D:¥tkProg¥tkProg¥tkprog_tutorial¥spectrum 選択 app

input path: D:/tkProg/tkProg/tkprog_tutorial/spectrum/x app

データを選擇:

x[0]: 2Theta

x[1]: I

計算対象の x 範囲:

xmin: -1e+100 初期値 ? x下限

xmax: 1e+100 初期値 ? x上限

平滑化条件:

kcut_low: 0 初期値 ? 平滑化: ローパス周波数

kcut_high: 3 初期値 ? 平滑化: ハイパス周波数

実行する場合は以下のボタンを押してください


FFT smoothing FFT Inverse FFT

OKを押すとプログラムを実行せずにLauncher画面に戻ります

OK Cancel

Program: smoothing-fft.py


kcut0: 0, kcut1: 3



FFTの注意


Numpy fft module: $F = \text{np.fft.fft}(y)$ FFT

フーリエ変換したデータは
逆座標 k の中点 ($i_x = n_x/2$) に対して鏡面对称
(フーリエ像の周期性と、実部が対称、
虚部が反対称関数であることによる).



平滑化のためには

$i_x = [0, i_{xHF}], [i_{xHF}, n_x/2]$ 、 $[n_x-1, n_x-1-i_{xHF}]$,
 $n_x/2+1, n_x-1-i_{xHF} i_{xHF}]$ の領域のデータを
ゼロにしてから逆変換を行う





畳み込み (Convolution)

$$(f * g)(x) = f^*(x) = \int_{-\infty}^{\infty} f(x')g(x - x')dx'$$

試料本来のデータは線幅ゼロ
(δ 関数) でも、
測定値は**装置関数** $g(x)$ の広がりを持つ

試料本来のデータは $f(x)$ でも、
測定されるのは
装置関数 $g(x)$ の畳み込みをした $f^*(x)$



Convolution: Matrix representation (行列表示)

南茂夫 編著、科学計測のための波形データ処理、CQ出版 (1986年)

$$f^*(x_i) = \int_{-\infty}^{\infty} f(x')g(x_i - x')dx' = N^{-1} \sum_{j=1}^N f(x_j)g(x_i - x_j)$$

$$\begin{pmatrix} f_1^* \\ f_2^* \\ f_3^* \\ \vdots \\ f_{N-1}^* \\ f_N^* \end{pmatrix} = \begin{pmatrix} g_0 & g_{-1} & \cdots & g_{-(N-3)} & g_{-(N-2)} & g_{-(N-1)} \\ g_1 & g_0 & \cdots & g_{-(N-4)} & g_{-(N-3)} & g_{-(N-2)} \\ g_2 & g_1 & \ddots & \vdots & g_{-(N-4)} & g_{-(N-3)} \\ \vdots & \vdots & \cdots & g_0 & g_{-1} & \vdots \\ g_{N-2} & g_{N-3} & \cdots & g_1 & g_0 & g_{-1} \\ g_{N-1} & g_{N-2} & \cdots & g_2 & g_1 & g_0 \end{pmatrix} \begin{pmatrix} f_1 \\ f_2 \\ f_3 \\ \vdots \\ f_{N-1} \\ f_N \end{pmatrix}$$

$f^*(x)$
 Observed signal

$g(x_i - x_j)$
 Apparatus function


$f(x)$
 Intrinsic signal

Very often, matrix g_{ij} is band matrix with maxima at diagonal

(行列 g_{ij} は対角要素に最大値を持つ帯行列になることが多い)

Program: convolution.py

[tkprog_tutorial]¥spectrum¥dos.xlsx




畳み込みによる平滑化 (ぼかし: smearing)

密度汎関数計算で得たa-InGaZnO₄の状態密度

問題: スパイキーな構造があり、読み取りにくい

それぞれのデータに幅 0.3 eV の Gauss関数の広がりを加える: 畳み込み


$$G(E) = \exp(-[(E - E_0)/w]^2) \quad (w = 0.2 \text{ eV})$$




注意: バンドエッジは窓関数の広がり分、裾を引く。
正確なバンドエッジは求められない

畳み込みによる平滑化

$w=0.05$




$w=0.2$



コンボリューション: 装置関数と実測スペクトル

$$(f * g)(x) = f^*(x) = \int_{-\infty}^{\infty} f(x')g(x - x')dx'$$

例: Au のフェルミ端の紫外光電子スペクトル



試料固有のスペクトル

$$S(E)$$

装置関数 (窓関数)

$$G(E) = G_0 \exp(-[(E - E_0)/aw]^2)$$

Fermi-Dirac分布

$$f(E) = 1/(1 + \exp[(E - E_F)/k_B T]) \quad \text{eq. (1)}$$

観測されるスペクトル

$$I(x) = \int_{-\infty}^{\infty} S(E')G(E - E')f(E - E')dE'$$


Auでは E_F 付近で $S(E)$ が一定と近似する
 $G(E)$ はeq. (1)を $I(x)$ にフィッティングして
求められる

$$w = 0.12 \text{ eV}$$

$G(E)$ がわかると、他の実測スペクトルから逆畳み込みで
 $S(E)$ がわかる


Program: deconvolution.py

[tkprog_tutorial]¥spectrum¥polySnSe-100C.xlsx




デコンボリューション結果


Gauss-Seidel法を使い、繰り返し計算ごとに5点3次多項式平滑化を行う



デコンボリューションしたスペクトルは装置関数分だけ鋭くなる





計算結果の確認のため、デコンボリューションしたデータを再コンボリューションして比較している



装置関数


デコンボリューションの注意

[tkprog_tutorial]¥spectrum¥polySnSe-100C.xlsx



デコンボリューションの注意

平滑化などの操作をしないと、正負に振動するデコンボリューション結果が得られる
ノイズに対して過剰適合した結果



デコンボリューションの解法: FFT

$$(f * g)(x) = f^*(x) = \int_{-\infty}^{\infty} f(x')g(x - x')dx'$$

フーリエ変換(FT) $F^*(k) = \int_{-\infty}^{\infty} f^*(x) \exp(ikx)dx$

逆フーリエ変換 (IFT) $f(x) = \int_{-\infty}^{\infty} F(k) \exp(-ikx)dk$
 $g(x) = \int_{-\infty}^{\infty} G(k') \exp(-ik'x)dk'$

$$\begin{aligned} F^*(k) &= \int_{-\infty}^{\infty} f(x)g(x - x') \exp(ikx)dx dx' \\ &= \int_{-\infty}^{\infty} f(x) \left(\int g(x - x') \exp(ikx)dx \right) dx' \\ &= \int_{-\infty}^{\infty} f(x) \left(\int g(x) \exp(ik(x + x'))dx \right) dx' \\ &= \int_{-\infty}^{\infty} f(x)G(k) \exp(ikx')dx' \\ &= F(k)G(k) \end{aligned}$$

原理的には、 $f(x)$ はフーリエ変換で $F^*(k)$ をもめ、 $F(k) = F^*(k) / G(k)$ を
逆フーリエ変換して求められる

=> ノイズなどがあると不安定で解が発散しやすい

デコンボリューションの解法: 行列方程式

南茂夫 編著、科学計測のための波形データ処理、CQ出版 (1986年)

$$f^*(x_i) = N^{-1} \sum_{j=1}^N f(x_j) g(x_i - x_j)$$

デコンボリューション $f(x_j)$ は以下の行列式を解けば求められる

$$\begin{pmatrix} f_1^* \\ f_2^* \\ \vdots \\ f_N^* \end{pmatrix} = \begin{pmatrix} g_0 & g_{-1} & & g_{-(N-1)} \\ g_1 & g_0 & & \\ \vdots & & \ddots & \vdots \\ g_{N-1} & & \cdots & g_0 \end{pmatrix} \begin{pmatrix} f_1 \\ f_2 \\ \vdots \\ f_N \end{pmatrix}$$

しかし、フーリエ変換法と同様、ノイズなどがあると不安定で解が発散しやすい

以下の方法で改善できる:

1. デコンボリューションの前に、平滑化等でノイズを除去する
2. 繰り返し法 (Jacobi法や Gauss-Seidel法) で行列方程式を解き、その過程でノイズ削減などの処理を行う

Jacobi法 / Gauss-Seidel法

大規模行列による線形連立方程式の解:

$$\begin{pmatrix} a_{11} & a_{12} & & a_{1N} \\ a_{21} & a_{22} & & \\ \vdots & & \ddots & \vdots \\ a_{N1} & & \cdots & a_{NN} \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{pmatrix} = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_N \end{pmatrix}$$

For $(k+1)$ -th iteration, $x_i^{(k+1)}$ is estimated from $x_i^{(k)}$

(initial data may be chosen as $x_i^{(0)} = b_i$, uniform value $x_i^{(0)} = 1$, etc):

(i) Jacobi method: $x_i^{(k+1)} = (b_i - \sum_{j \neq i}^N a_{ij} x_j^{(k)}) / a_{ii}$

$$x_1^{(k+1)} = (b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1N}x_N^{(k)}) / a_{11}$$

$$x_2^{(k+1)} = (b_2 - a_{21}x_1^{(k)} - a_{23}x_3^{(k)} - \cdots - a_{2N}x_N^{(k)}) / a_{22}$$

(ii) Gauss-Seidel method: $x_i^{(k+1)} = (b_i - \sum_{j=1}^{i-1} a_{ij} x_j^{(k+1)} - \sum_{j=i+1}^N a_{ij} x_j^{(k)}) / a_{ii}$

Using the known $x_j^{(k+1)}$ values enhances convergence.

$$x_1^{(k+1)} = (b_1 - a_{12}x_2^{(k)} - a_{13}x_3^{(k)} - \cdots - a_{1N}x_N^{(k)}) / a_{11}$$

$$x_2^{(k+1)} = (b_2 - a_{21}x_1^{(k+1)} - a_{23}x_3^{(k)} - \cdots - a_{2N}x_N^{(k)}) / a_{22}$$

Convergence is better for the Gauss-Seidel method,
While parallelization is more easy for the Jacobi method.

思いつき: Ridge回帰による解法


$$F(x) = \int_{-\infty}^{\infty} f(x')g(x - x')dx'$$

データ点 (x_i, y_i)

$$F(x_i) = \Delta x \sum_j f(x_j)g(x_j - x_i)$$

$g(x_j - x_i)$: 正規化された装置関数

$$\Delta x \sum_j g(x_j - x_i) = 1$$



$f(x_j)$ をこのまま求めると大きく振動する (過学習)



=> Ridge 回帰により振動を抑える

$$\sum_i (y_i - F(x_i))^2 + \alpha \sum_i f(x_j)^2$$

を最小化 (α : L2正則化係数)


デコンボリューションの注意

[tkprog_tutorial]¥spectrum¥polySnSe-100C.xlsx



Ridge回帰によるデコンボリューション結果

Ridge回帰だと、振動を抑える条件を見つけるのが難しい
Jacobi法やGauss-Seidel法の方が時間がかかるが、結局は早い



Fourier transformation

フーリエ変換

Fourier級数展開

周期: T

$$x(t) = \frac{a_0}{2} + \sum_{n=1}^{\infty} \left(a_n \cos \frac{2\pi n}{T} t + b_n \sin \frac{2\pi n}{T} t \right)$$

$$a_n = \frac{2}{T} \int_0^T x(t) \cos \frac{2\pi n}{T} t dt$$

$$b_n = \frac{2}{T} \int_0^T x(t) \sin \frac{2\pi n}{T} t dt$$

$$x(t) = \sum_{n=-\infty}^{\infty} c_n \exp \left(i \frac{2\pi n}{T} t \right)$$

$$c_n = \frac{1}{T} \int_0^T x(t) \exp \left(-i \frac{2\pi n}{T} t \right) dt$$

Riemann–Lebesgue lemma
(リーマン・ルベークの補題): $\lim_{n \rightarrow \infty} c_n = 0$

フーリエ変換

異なる定義があるので注意

$$\left\{ \begin{array}{ll} \text{FT (フーリエ変換)} & F(\omega) = \int_{-\infty}^{\infty} f(t) \exp(i\omega t) dt \\ \text{IFT (逆フーリエ変換)} & f(t) = \frac{1}{2\pi} \int_{-\infty}^{\infty} F(\omega) \exp(-i\omega t) d\omega \end{array} \right.$$
$$\left\{ \begin{array}{ll} \text{FT} & F(\omega) = \int_{-\infty}^{\infty} f(t) \exp(i2\pi ft) dt \\ \text{IFT} & f(t) = \int_{-\infty}^{\infty} F(\omega) \exp(-i2\pi ft) d\omega \end{array} \right.$$

フーリエ変換の特徴

- ・ 時間依存データを周波数依存データに変換
- ・ 位置依存データを波数依存データに変換
- ・ 元データの原点は逆空間全体に広がる
- ・ 元データの全体は逆空間の原点に収束する
- ・ フーリエ変換したデータ (FT) を逆変換 (IFT) すると元のデータに戻る

一般関数の線形最小二乗法

$$f(x) = \sum_{k=1}^n a_k f_k(x) \quad S = \sum_{i=1}^N \left(y_i - \sum_{k=1}^n a_k f_k(x_i) \right)^2$$
$$\frac{dS}{da_l} = - \sum_{i=1}^N f_l(x_i) \left(y_i - \sum_{k=1}^n a_k f_k(x_i) \right) = 0$$

$$\begin{pmatrix} \sum f_1(x_i)f_1(x_i) & \sum f_1(x_i)f_2(x_i) & \sum f_1(x_i)f_3(x_i) & \cdots & \sum f_1(x_i)f_N(x_i) \\ \sum f_2(x_i)f_1(x_i) & \sum f_2(x_i)f_2(x_i) & \sum f_2(x_i)f_3(x_i) & & \sum f_2(x_i)f_N(x_i) \\ \sum f_3(x_i)f_1(x_i) & \sum f_3(x_i)f_2(x_i) & \sum f_3(x_i)f_3(x_i) & & \sum f_3(x_i)f_N(x_i) \\ \vdots & & & \ddots & \\ \sum f_N(x_i)f_1(x_i) & \sum f_N(x_i)f_2(x_i) & \sum f_N(x_i)f_3(x_i) & & \sum f_N(x_i)f_N(x_i) \end{pmatrix} \begin{pmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \\ a_N \end{pmatrix} = \begin{pmatrix} \sum y_i f_1(x_i) \\ \sum y_i f_2(x_i) \\ \sum y_i f_3(x_i) \\ \vdots \\ \sum y_i f_N(x_i) \end{pmatrix}$$

三角関数級数展開への応用例




$$f_i(x) = \cos 2\pi f_i x \quad (i = \text{odd numbers (奇数)})$$

$$f_i(x) = \sin 2\pi f_i x \quad (i = \text{even numbers (偶数)})$$

Fourier級数展開への線形最小二乗

LSQ results

```
f1, p1, A1 = 1.5, pi/4.0, 1.0  
f2, p2, A2 = 3.0, pi/3.0, 0.3  
f3, p3, A3 = 10.0, pi/6.0, 0.5  
x += random(0.03) # noise is simulated by random()  
y = A1 * sin(2.0*pi * f1 * x + p1)  
  + A2 * sin(2.0*pi * f2 * x + p2)  
  + A3 * sin(2.0*pi * f3 * x + p3)  
Convolution: Gauss function with w = 0.03
```



Discrete FT (DFT, 離散フーリエ変換)

Assume $x(t)$ is periodic in the range $[0, T^w]$ and $x(0) = x(T^w)$

$$X(f_k) = T_s^w \sum_{j=0}^{N-1} x(t_j) \exp(-i2\pi f_k \cdot jT^w/N) \quad T_s^w = T^w/N$$

Usually the coefficient T_s^w is not included for DFT formulations

$$y(f_k) = \sum_{j=0}^{N-1} x(t_j) \exp(-i2\pi kj/N) \quad f_k = k/T^w$$

DFT can be carried out without many trigonometric function (三角関数) calculations

$$y_k = \sum_{j=0}^{N-1} x_j w_N^{kj}$$

$w_N = \exp(-i2\pi/N)$: Rotation factor (回転因子)

$$\begin{aligned} w_N^{k+1} &= (\cos(-2\pi k/N) + i \sin(-2\pi k/N))(\cos(-2\pi/N) + i \sin(-2\pi/N)) \\ &= (\cos(-2\pi k/N) w_{N,r} - \sin(-2\pi k/N) w_{N,i}) \\ &\quad + i(\cos(-2\pi k/N) w_{N,i} + \sin(-2\pi k/N) w_{N,r}) \\ &= (w_{N,r}^k w_{N,r} - w_{N,i}^k w_{N,i}) + i(w_{N,r}^k w_{N,i} + w_{N,i}^k w_{N,r}) \end{aligned}$$

DFT: Matrix expression (行列表現)

$$y(f_k) = \sum_{j=0}^{N-1} x(t_j) \exp(-i2\pi \cdot k \cdot j/N)$$

$$\mathbf{y}_k = \sum_{j=0}^{N-1} \mathbf{x}_j \mathbf{w}_N^{kj}$$

$$\mathbf{w}_N = \exp(-i2\pi/N)$$

DFT

$$\begin{pmatrix} y_0 \\ y_1 \\ \vdots \\ y_{N-1} \end{pmatrix} = \begin{pmatrix} 1 & 1 & \cdots & 1 \\ 1 & \mathbf{w}_N^1 & \mathbf{w}_N^2 & \mathbf{w}_N^{N-1} \\ \vdots & \mathbf{w}_N^2 & \ddots & \vdots \\ 1 & \mathbf{w}_N^{N-1} & \cdots & \mathbf{w}_N^{(N-1)(N-1)} \end{pmatrix} \begin{pmatrix} x_0 \\ x_1 \\ \vdots \\ x_{N-1} \end{pmatrix}$$

Inverse DFT

$$\begin{pmatrix} x_0 \\ x_1 \\ \vdots \\ x_{N-1} \end{pmatrix} = \frac{1}{N} \begin{pmatrix} 1 & 1 & \cdots & 1 \\ 1 & \mathbf{w}_N^{-1} & \mathbf{w}_N^{-2} & \mathbf{w}_N^{-(N-1)} \\ \vdots & \mathbf{w}_N^{-2} & \ddots & \vdots \\ 1 & \mathbf{w}_N^{-(N-1)} & \cdots & \mathbf{w}_N^{-(N-1)(N-1)} \end{pmatrix} \begin{pmatrix} y_0 \\ y_1 \\ \vdots \\ y_{N-1} \end{pmatrix}$$

Using $\mathbf{w}_N^k = \mathbf{w}_N^{k \bmod N}$ and $\mathbf{w}_N^{k+N/2} = -\mathbf{w}_N^k$, only $k = 1 - N/2$ terms should be calculated

Fast FT (FFT, 高速フーリエ変換)

金谷健一, これならわかる応用数学教室, 共立出版社 (2003)

1. The data number must be $N = 2^m$ (m : integer)
2. The identical calculation to DFT, but the calculation cost is proportional only to $M \log N$ (proportional to N^2 for DFT)
3. Simple circuits can implement FFT, easy for parallelization (GPU)

The DFT formulation is written as polynomial by converting $w_N^k = z$

$$\begin{aligned} y_k &= \sum_{j=0}^{N-1} x_j w_N^{kj} = \sum_{j=0}^{N-1} x_j z^j \\ y_k &= x_0 z^0 + x_1 z^1 + x_2 z^2 + \cdots + x_{N-1} z^{N-1} \\ &= x_0 z^0 + x_2 z^2 + \cdots + x_{N-2} z^{N-2} \\ &\quad + z(x_1 z^0 + x_3 z^2 + \cdots + x_{N-1} z^{N-2}) \end{aligned}$$

Note that the last line equation becomes a polynomial with respect to $z_2 = z^2$ with a half number of the terms

$$y_k = \sum_{j=0}^{N/2-1} x_{2j} z_2^j + z \sum_{j=0}^{N/2-1} x_{2j+1} z_2^j$$

FFT

金谷健一, これならわかる応用数学教室, 共立出版社 (2003)

$$\begin{aligned}y_{k,N} &= x_0(z^2)^0 + x_2(z^2)^1 + \cdots + x_{N-2}(z^2)^{\frac{N}{2}-1} + z \left(x_1(z^2)^0 + x_3(z^2)^1 + \cdots + x_{N-1}(z^2)^{\frac{N}{2}-1} \right) \\&= y_{k,N/2,1} + z y_{k,N/2,2} \\y_{k,N/2,1} &= x_0(z^4)^0 + x_4(z^4)^1 + \cdots + x_{N-2}(z^4)^{\frac{N}{4}-1} + (z^2) \left(x_2(z^4)^0 + x_6(z^4)^1 + \cdots + x_{N-3}(z^4)^{\frac{N}{4}-1} \right) \\&= y_{k,N/4,1} + (z^2) y_{k,N/4,3} \\y_{k,N/2,2} &= x_1(z^4)^0 + x_5(z^4)^1 + \cdots + x_{N-1}(z^4)^{\frac{N}{4}-1} + (z^2) \left(x_3(z^4)^0 + x_7(z^4)^1 + \cdots + x_{N-2}(z^4)^{\frac{N}{4}-1} \right) \\&= y_{k,N/4,2} + (z^2) y_{k,N/4,4}\end{aligned}$$

$$y_{k,N} = y_{k,N/2,1} + z y_{k,N/2,2}$$

$$y_{k,N/2,1} = y_{k,N/4,1} + z^2 y_{k,N/4,3}$$

$$y_{k,N/2,2} = y_{k,N/4,2} + z^2 y_{k,N/4,4}$$

$$y_{k,N/4,1} = y_{k,N/8,1} + z^4 y_{k,N/8,5}$$

$$y_{k,N/4,2} = y_{k,N/8,2} + z^4 y_{k,N/8,6}$$

$$y_{k,N/4,3} = y_{k,N/8,5} + z^4 y_{k,N/8,7}$$

$$y_{k,N/4,4} = y_{k,N/8,6} + z^4 y_{k,N/8,8}$$

The above is a recursion formula and can be solved from the last two-terms FT to upper equations in the series of the number of terms $2^2, 2^3, \dots, 2^N$

漸化式の形になっているので、最後の項数2のFTから順次 項数 $2^2, 2^3, \dots, 2^N$ のFTの計算をすることでFT計算ができる

FFT演算の項順序の変換: ビット反転

N 個のデータ列 $x_0 x_1 x_2 \cdots x_{N-1} \Rightarrow \text{FT: } X_0 X_1 X_2 \cdots X_{N-1}$


順序数を二進数であらわす

FFTのそれぞれの段階で「奇数番目のデータを後半にずらす」操作をする

$\Rightarrow$ 順序数の右から「段階数に対応するビットが1のデータを後半にずらす」

$\Rightarrow$ 順序数の変換がビット反転に対応する

最初のデータの並び順 (カッコ内は順序数のビット反転)



バタフライ演算

FFTの和を取る順番は x_i の並び順と変わる。

最初の順序数の二進数表現 (カッコ内の数字) をビット反転 (カッコ外の数字) してソートすると、その順序でFFTの和をとれる

Logical operations (bitwise operations)

(論理演算, ビット演算)

Logical NOT (Bitwise inversion) (論理否定, ビット反転)

NOT 0 = 1; NOT 1 = 0

python: ~x, not x

~1 == 0, ~0 == 1

Logical AND (論理積)

0 AND 0 = 0; 1 AND 0 = 0

0 AND 1 = 0; 1 AND 1 = 1

python: x & y, x and y

1 & 1 == 1

Logical OR (論理和)

0 OR 0 = 0; 1 OR 0 = 1

0 OR 1 = 1; 1 OR 1 = 1

python: x | y, x or y

Logical Exclusive OR (排他的論理和)

0 XOR 0 = 0; 1 XOR 0 = 1

0 XOR 1 = 1; 1 XOR 1 = 0

python: x ^ y, x xor y

Bit shift (n bit shift)

python: a << n, a >> n

0b0001 << 2 == 0b0100

0b0110 >> 1 == 0b0011

Bit reversal (ビット列反転)

Note: bit reversal (ビット列反転) != bitwise inversion (ビット反転) ($\sim x$, not x)

bit_reverse.py

```
def bit_reverse(val):
```

```
    ret = 0
```

```
    while 1:
```

```
        v0 = val & 0b001
```

```
        ret = ret | v0
```

```
        val = val >> 1
```

```
    if val == 0:
```

```
        break
```

```
    else:
```

```
        ret = ret << 1
```

```
    return ret
```

val = 11001₂ を例に

ret = 0

ビット反転値を0で初期化

1. $v0 = val \& 1_2 \Rightarrow 11001_2 \& 001_2 = 1$

第1桁のビット値を v0 に保存

2. $ret = ret | v0 \Rightarrow 0 | 1 = 1_2$

retの第1桁に v0 を設定

3. $val = val >> 1 \Rightarrow 11001_2 >> 1 = 1100_2$

一桁右にビットシフトし、valの2桁目を第1桁に移動

4. val が 0 の場合、処理するbitが残っていないので

ループを終了

5. val が 0 でない場合、ret を1ビットシフトし、2.で ret の第1位に設定した v0 を左にずらす。

$ret = ret << 1 \Rightarrow 1_2 << 1 = 10_2$

1.に戻って繰り返し

6. $v0 = val \& 1_2 \Rightarrow 1100_2 \& 001_2 = 0$

第1桁のビット値を v0 に保存

7. $ret = ret | v0 \Rightarrow 10_2 | 0 = 10_2$

retの第1桁に v0 を設定

8. $val = val >> 1 \Rightarrow 1100_2 >> 1 = 110_2$

9. $ret = ret << 1 \Rightarrow 10_2 << 1 = 100_2$

1.に戻って繰り返し

10. $v0 = val \& 1_2 \Rightarrow 110_2 \& 001_2 = 0$

11. $ret = ret | v0 \Rightarrow 100_2 | 0 = 100_2$

12. $val = val >> 1 \Rightarrow 110_2 >> 1 = 11_2$

13. $ret = ret << 1 \Rightarrow 100_2 << 1 = 1000_2$

1.に戻って繰り返し

14. $v0 = val \& 1_2 \Rightarrow 11_2 \& 1_2 = 1$

15. $ret = ret | v0 \Rightarrow 1000_2 | 1 = 1001_2$

16. $val = val >> 1 \Rightarrow 11_2 >> 1 = 1_2$

17. $ret = ret << 1 \Rightarrow 1001_2 << 1 = 10010_2$

1.に戻って繰り返し

18. $v0 = val \& 1_2 \Rightarrow 1_2 \& 1_2 = 1$

19. $ret = ret | v0 \Rightarrow 10010_2 | 1 = 10011_2$

20. $val = val >> 1 \Rightarrow 1_2 >> 1 = 0_2 \Rightarrow$ ループ終了 解: $ret = 10011_2$

Bitwise operation can be replaced with other op

Usually bitwise operations are faster, but it is not the case for python ...

python bit_reverse_compare.py 1001100011110101101111011 1000000

measure time to reverse $1001100011110101101111011_2$ for 1000000 times

by bitwise operation : 6.265091180801392 s

without bitwise operation: 4.462110280990601 s

bit_reverse_compare.py

```
def bit_reverse(val):
```

```
    ret = 0
```

```
    while 1:
```

```
        v0 = val & 0b001
```

```
        ret = ret | v0
```

```
        val = val >> 1
```

```
    if val == 0:
```

```
        break
```

```
    else:
```

```
        ret = ret << 1
```

```
    return ret
```

bit_reverse_compare.py

```
def bit_reverse_nobitop(val):
```

```
    ret = 0
```

```
    while 1:
```

```
        v0 = val % 2           # save the final bit to v0
```

```
        ret = ret + v0         # put v0 to the final bit of ret
```

```
        val = val // 2         # bit shift for next iteration
```

```
    if val == 0:
```

```
        break
```

```
    else:
```

```
        ret = ret * 2          # bit shift ret to left
```

```
    return ret
```

Comparison: Calculation time by python

Usage: `python dft.py ndata`

ex: `python dft.py 1024`

`python dft.py 2048`

DFT1: DFT using rotation factor

DFT2: DFT not using rotation factor (calculate sin/cos every time)

FFT : `numpy.fft.fft()`


Time for DFT/FFT (sec)

N	DFT1	DFT2	FFT	N log N
1024	1.32	2.41	1.87e-5	3080
2048	5.59	10.3	3.54e-5	6780
4096	23.6	47.7	6.62e-5	14800
8192	97.3	165	16.1e-5	32100

Problems of DFT/FFT

南茂夫, 科学計測のための波形データ処理, CQ出版社 (1986)

- Usually FT needs integration from $-\infty$ to ∞ , but DFT/FFT reduces data to finite range $\Rightarrow$ Loss of data
ex.: Fourier charge analysis by XRD gives **ghost peaks and fringes**
- Original data include noise/errors, giving rise to extra frequency peak
- Artificial periodicity required for DFT/FFT gives rise to artefact frequency peaks $\Rightarrow$ can be suppressed by **Hanning Window** (窓関数), but it may also give extra peaks



Maximum entropy method (MEM, 最大エントロピー法)

南茂夫, 科学計測のための波形データ処理, CQ出版社 (1986)

Concept of MEM


- Assume the lost data would have some constraints
- Use the concept of 'information entropy' and maximize it to estimate the spectrum
- Akaike's autoregressive model (赤池による自己回帰モデル) => identical to MEM

The order of the autoregressive model m must be determined

- So as to minimize Final Prediction Error (最終予測誤差)
- Algorithms: Burg method, etc

Features

- Sharper spectrum than FFT
- Less ghost peaks and fringes



MEM-Rietveld analysis

坂田誠 日本結晶学会誌 30, 135 (1988)

Charge density calculated from structure factors $\tau'_i = \tau_i / \sum \tau_i$

Charge density calculated from structure model $\rho'_i = \rho_i / \sum \rho_i$

Constrained entropy: $S = -\sum \rho'_i \ln \frac{\rho'_i}{\tau'_i}$

=> smoothing ρ' and suppress fringes and ghost peaks

Minimize the structure factor residual $C = \sum \frac{|F_{\text{cal}}^{hkl} - F_{\text{obs}}^{hkl}|^2}{\sigma_{hkl}^2}$

Maximize constrained entropy $Q(\lambda) = -\sum \rho'_i \ln \frac{\rho'_i}{\tau'_i} - \frac{\lambda}{2} \sum \frac{|F_{\text{cal}}^{hkl} - F_{\text{obs}}^{hkl}|^2}{\sigma_{hkl}^2}$

=> $\rho = \exp(\ln \tau + \text{difference Fourier (差フーリエ) term})$

When converged to $F_{\text{cal}} = F_{\text{obs}}$, $\rho = \tau$ will be achieved

Kramers-Kronig Transformation

クラマースークローニツヒ (KK) の関係式

因果律が成立していれば

(現在の状態が、過去の履歴の蓄積で決定していれば)、
線形応答の範囲で、周波数応答関数 $\varepsilon(\omega)$ の実部と虚部には
以下のKramers-Kronigの関係が成立する

$$\varepsilon_r = 1 + \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{\omega' \varepsilon_i(\omega')}{\omega'^2 - \omega^2} d\omega' \left(= 1 + \frac{2}{\pi} P \int_0^{\infty} \frac{\omega' \varepsilon_i(\omega')}{\omega'^2 - \omega^2} d\omega' \right)$$

$$\varepsilon_i = -\frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{\varepsilon_r(\omega') - 1}{\omega'^2 - \omega^2} d\omega' \left(= -\frac{2}{\pi} P \int_0^{\infty} \frac{\varepsilon_r(\omega') - 1}{\omega'^2 - \omega^2} d\omega' \right)$$

インパルス応答が実数の
場合、カッコ内の式が使える

$$P: \text{積分の主値} \quad P \int_0^{\infty} d\omega' \equiv \lim_{\delta \rightarrow 0} \left(\int_0^{\omega-\delta} d\omega' + \int_0^{\omega+\delta} d\omega' \right)$$

注意: 主値積分は極限の取り方によって値が変わる
=> 必ず ω の両側から同じように極限を取る

クラマースークローニツヒの関係式

Kramers-Kronig relation

$$\varepsilon_r = 1 + \frac{2}{\pi} P \int_0^\infty \frac{\omega' \varepsilon_i(\omega')}{\omega'^2 - \omega^2} d\omega'$$

$$\varepsilon_i = -\frac{2}{\pi} P \int_0^\infty \frac{\varepsilon_r(\omega') - 1}{\omega'^2 - \omega^2} d\omega'$$

P : Principal value of the integral

$$P \int_0^\infty d\omega' \equiv \lim_{\delta \rightarrow 0} \left(\int_0^{\omega-\delta} d\omega' + \int_0^{\omega+\delta} d\omega' \right)$$

The above equation is derived from Cauchy integral $\alpha(\omega) = \frac{1}{\pi i} P \int_0^\infty \frac{\alpha(s)}{s - \omega} ds$ that is valid for complex functions $\alpha(\omega)$ satisfying $\lim_{|\omega| \rightarrow \infty} \alpha(\omega) = 0$

KK relation: Refractivity spectrum and phase 反射率と位相

$$r^*(\nu) = \sqrt{R(\nu)} e^{i\theta(\nu)} \quad \ln r^*(\nu) = \ln R^{1/2} + i\theta(\nu)$$

にKK変換を当てはめる

$$\theta(\nu) = -\frac{1}{2\pi} P \int_0^\infty \frac{\ln R(\nu')}{\nu'^2 - \nu^2} d\nu' = -\frac{1}{2\pi} \int_0^\infty \ln \frac{|\nu' + \nu|}{|\nu' - \nu|} \frac{dR(\nu')}{d\nu'} d\nu'$$

Optical spectrum (誘電関数 ϵ^* , 吸収係数 α)

$$\mathcal{H} = \mathcal{H}_0 - \mathbf{e}r \cdot \mathbf{E}$$

$$\epsilon_1(\omega) = 1 + 4\pi \sum_j \frac{e^2 |T_{0j}|^2}{\hbar} \frac{2\omega_j}{\omega_j^2 - \omega^2}$$

$$T_{ij} = \langle \Psi_i | \mathbf{r} | \Psi_j \rangle = \int \Psi_i^* \mathbf{r} \Psi_j d\mathbf{r}$$

Kramers-Kronig transformation

$$\begin{aligned} \epsilon_2(\omega) &= \frac{4\pi N e^2}{m} \sum_j f_j \pi \delta(\omega^2 - \omega_j^2) \\ &= \frac{4\pi N e^2}{m} \sum_j f_j \frac{\pi}{2\omega} [\delta(\omega - \omega_j) + \delta(\omega + \omega_j)] \end{aligned}$$

$$n(\omega) - i\kappa(\omega) = \sqrt{\epsilon_1(\omega) - i\epsilon_2(\omega)}$$

$$\alpha(\omega) = \frac{4\pi}{\lambda} \kappa(\omega)$$

KK transformation: Numerical approach

$$\theta(\nu_g) = -\frac{2\nu_g}{\pi} \int_0^\infty \frac{\ln \sqrt{R(\nu)/R(\nu_g)}}{\nu^2 - \nu_g^2} d\nu$$

$$\theta_{med}(\nu_g) = \frac{4\nu_g}{\pi} \Delta\nu \sum_{i=odd \text{ or even}}^{i \leq nData} \frac{\ln \sqrt{R_i}}{\nu_i^2 - \nu_g^2}$$

**Numerical integration
for given data**

$$\theta_{high}(\nu_g) = -\frac{\ln \sqrt{R_{high}}}{\pi} \ln \frac{\nu_{max} + \nu_g}{\nu_{max} - \nu_g}$$

Extrapolation to high f

$$\theta_{low}(\nu_g) = -\frac{\ln \sqrt{R_{low}}}{\pi} \ln \frac{\nu_g - \nu_{min}}{\nu_{min} + \nu_g}$$

Extrapolation to low f

$$n(\nu) = \frac{1 - R(\nu)}{1 + R(\nu) - 2\sqrt{R(\nu)} \cos \theta}$$

$$k(\nu) = \frac{2\sqrt{R(\nu)} \sin \theta}{1 + R(\nu) - 2\sqrt{R(\nu)} \cos \theta}$$

光学スペクトルのKK変換: 外挿問題

Fourier変換と同様に、測定周波数外の情報がないことが問題
測定周波数外のデータは結果に大きく影響する

0.1eVにおける分散を正確に求める場合、
少なくとも4~5eVまでの測定が必要

- ・高エネルギー領域: ν^{-4} で外挿するのが一般的
- ・知りたい領域が0.1eV以下:
 - ・金属の低エネルギー領域: Drude反射率で外挿
 - ・半導体・誘電体の低エネルギー領域:
静的誘電率 ϵ_0 から求めた反射率 で外挿 $(\sqrt{\epsilon_0} - 1)^2 / (\sqrt{\epsilon_0} + 1)^2$
- ・知りたい領域が1eV程度まで:
フォノン分散の始まる0.1eV以下は考慮する必要はない
- ・半導体・誘電体の低エネルギー領域:
高周波誘電率 ϵ_∞ から求めた反射率 で外挿 $(\sqrt{\epsilon_\infty} - 1)^2 / (\sqrt{\epsilon_\infty} + 1)^2$