

# bayes\_gp\_plain.py

**目的: 複数条件 (記述子) と最適化する物性値 (目的関数) を  
ガウス過程を用いたベイズ最適化により推定する**

**(i) usage: python bayes\_gp\_plain.py infile max\_num\_probes num\_rand\_basis score\_mode interval**

**max\_num\_probes: Use a number to reach convergence**

**num\_rand\_basis: Use a large number so as to reproduce training data**

**score\_mode : [EI|PI|TS]**

**interval : # of cycles to update hyper parameters**

**ex: python bayes\_gp\_plain.py data\_simple.xlsx 1 200 EI 0**

**Input file: Excel (.xlsx) or CSV (.csv) file**

**Output file: Excel (.xlsx) file**

# Input file: Excel (.xlsx) or CSV (.csv)

data\_simple.xlsx (data\_simple.csv)

target	x	y
	-1	-1
	-0.8	-1
-2.33	-0.6	-1
-2.05	-0.4	-1
	-0.2	-1
-1.73	0	-1
	0.2	-1
	0.4	-1
	0.6	-1
-2.05	0.8	-1
2.22	1	1

**1<sup>st</sup> column: Target function**

**2<sup>nd</sup> and right columns: Descriptors**

**Target functions can leave blank data:**

**Non-blank data will be used for training**

**All data will be used to estimate prediction**

## IMPORTANT NOTE

**If descripts or target functions vary in exponential scale, take logarithm of those values to more linearize**

## IMPORTANT NOTE

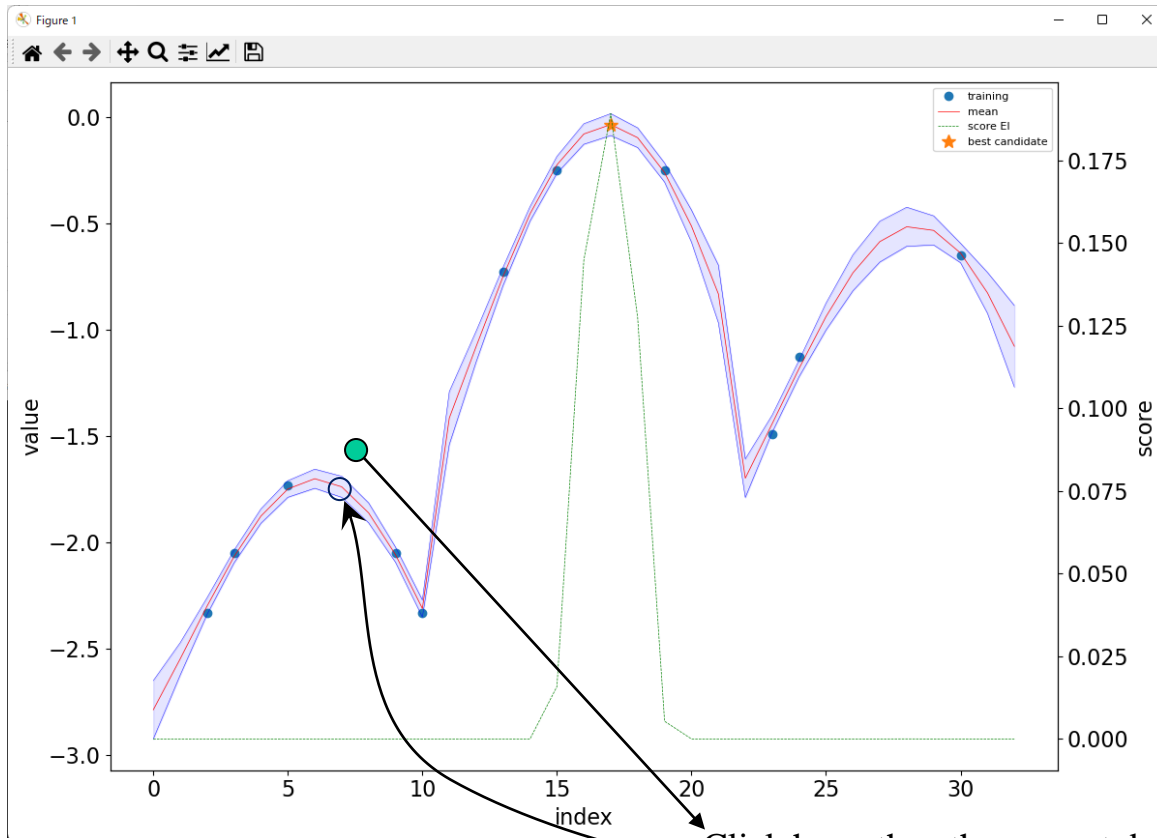
**At least ONE BLANK target fuction data is required. Or the program will be terminated by ERROR in base\_search()**

# Maximum search

python bayes\_gp\_plain.py

Equivalent to the default: **python bayes\_gp\_plain.py data\_simple.xlsx 1 200 EI**

Read data\_simple.xlsx, max\_num\_probes = 1, num\_rand\_basis = 200, score\_mode = 'EI', and interval = 0



Click here, then the nearest data information are shown in the console output:

clicked at **idx = 7 / line 9: descriptors = [ 0.4 -1. ]** given target value = nan  
predicted target value = -1.7141204429199943 +- 0.05214082204618646

# Input file for minimum search

data\_target\_min.xlsx

min:target	x	y	-z
	-1	-1	1
	-0.8	-1	1
-2.33	-0.6	-1	1
-2.05	-0.4	-1	1
	-0.2	-1	1
-1.73	0	-1	1
	0.2	-1	1
	0.4	-1	1
	0.6	-1	1
-2.05	0.8	-1	1

Header labels can have the following control tags at the top (case insensitive).

**‘max:’ (default): Find maximum score**

**‘min:’: Find minimum score**

Target function is converted to  $-t$

( $t$  denotes the target function)

**‘=value’: Find closest data to ‘value’**

( $value$  is given by a floating point number)

Target function is converted to  $-(t - value)^2$

*Note:  $(t - value)^2$  does not follow the Gauss process.*

*This option loses theoretical basis*

**‘-’: Ignore this column**

**neither as target function nor descriptors**

**1<sup>st</sup> column: Target function, converted to  $-t$**

**2<sup>nd</sup> and 3<sup>rd</sup> columns: Descriptors**

**4<sup>th</sup> column: with ‘-’ so is ignored**

## IMPORTANT NOTE

At least ONE BLANK target function data is required. Or the program will be terminated by ERROR in base\_search()

# Input file for value search

data\_target\_value.xlsx

=-0.5:target	x	y	-z
	-1	-1	1
	-0.8	-1	1
-2.33	-0.6	-1	1
-2.05	-0.4	-1	1
	-0.2	-1	1
-1.73	0	-1	1
	0.2	-1	1
	0.4	-1	1
	0.6	-1	1
-2.05	0.8	-1	1

**1<sup>st</sup> column:** Target function, converted to  $-(t - (-0.5))^2$

**2<sup>nd</sup> and 3<sup>rd</sup> columns:** Descriptors

**4<sup>th</sup> column:** with '-' so is ignored

## IMPORTANT NOTE


At least ONE BLANK target function data is required. Or the program will be terminated by ERROR in base\_search()

# Value search

python bayes\_gp\_plain.py data\_target\_value.xlsx

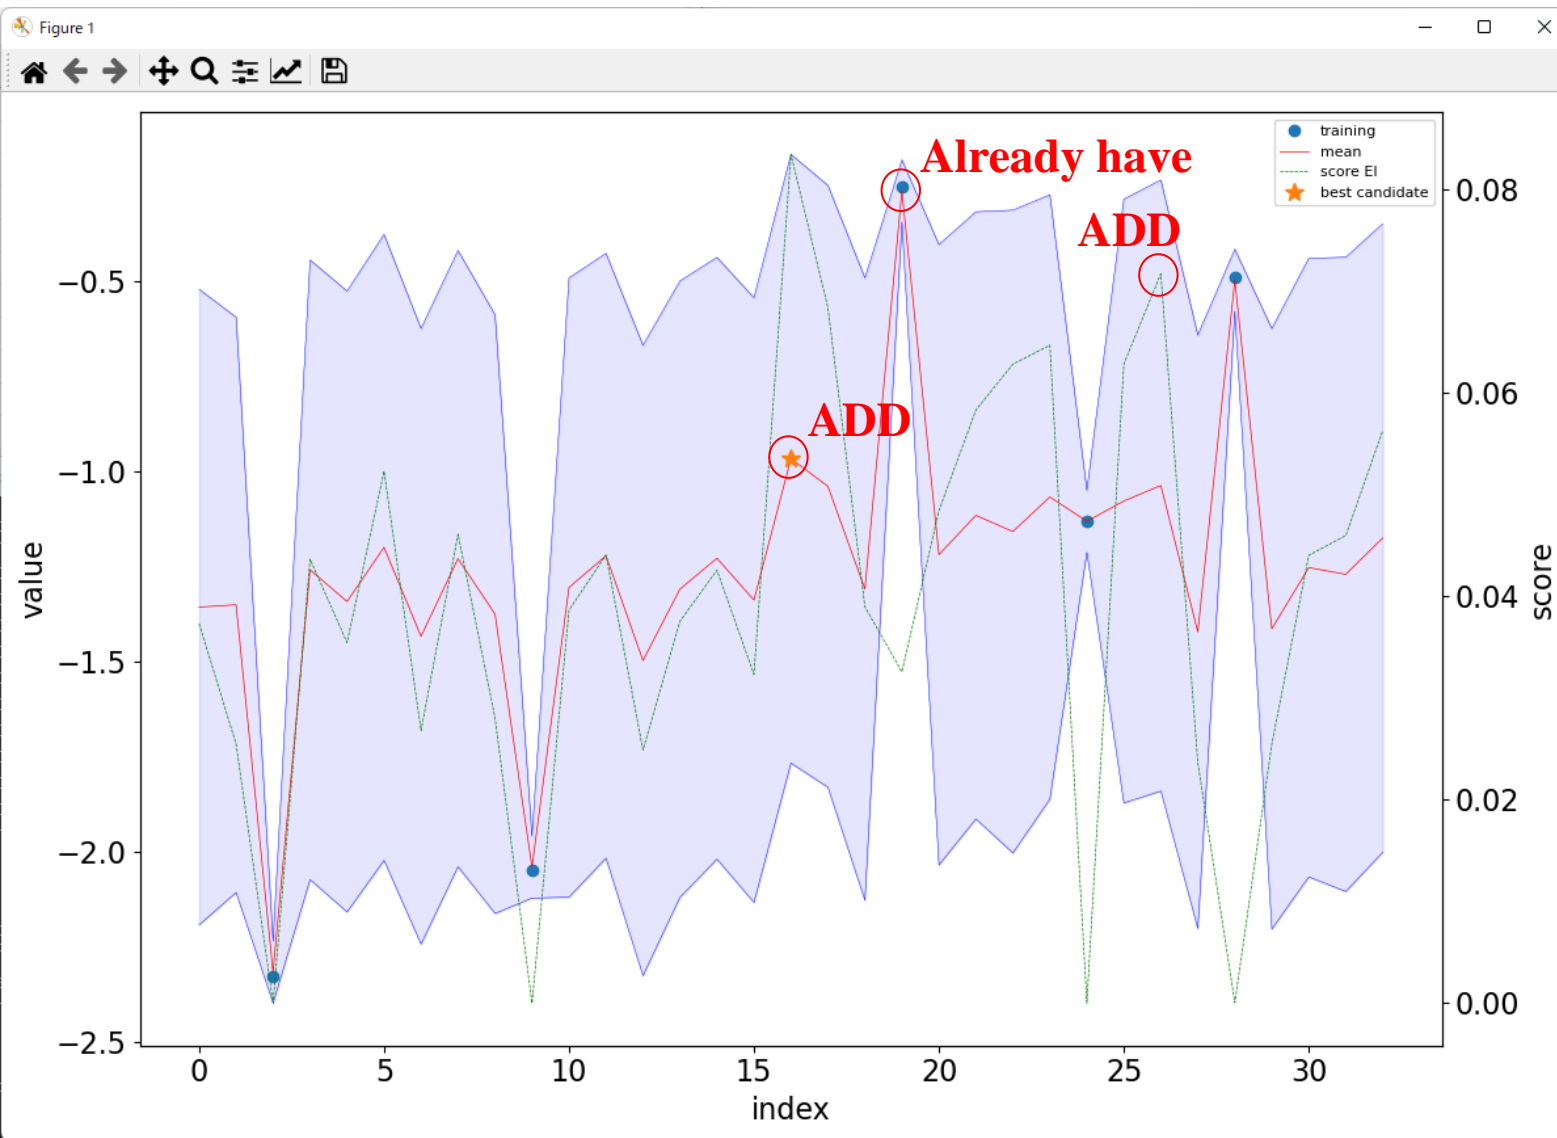
**Zero line corresponds to the target value of the target function**

Note: The values cannot be positive as they are  $(t - \text{value})^2$   
so the positive prediction values and the symmetric standard deviations  
have **no theoretical validness**



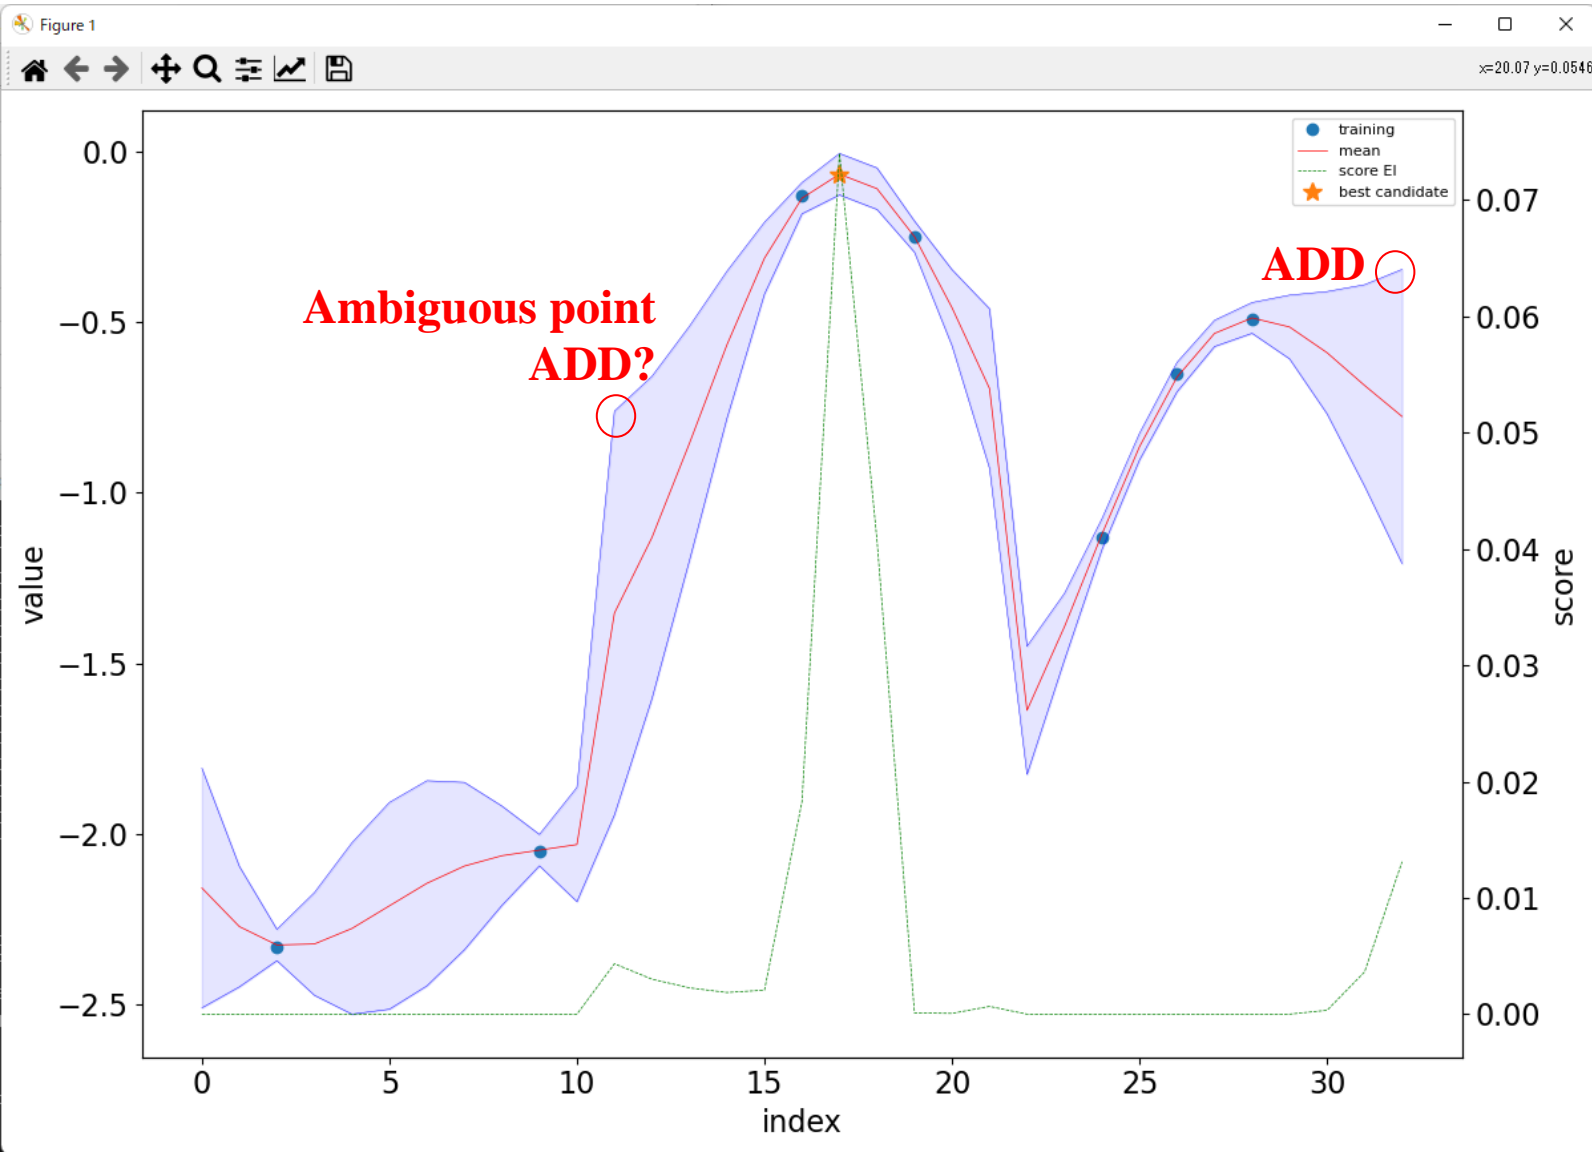
# Variation of predictions

python bayes\_gp\_plain.py data\_test.xlsx



# Variation of predictions

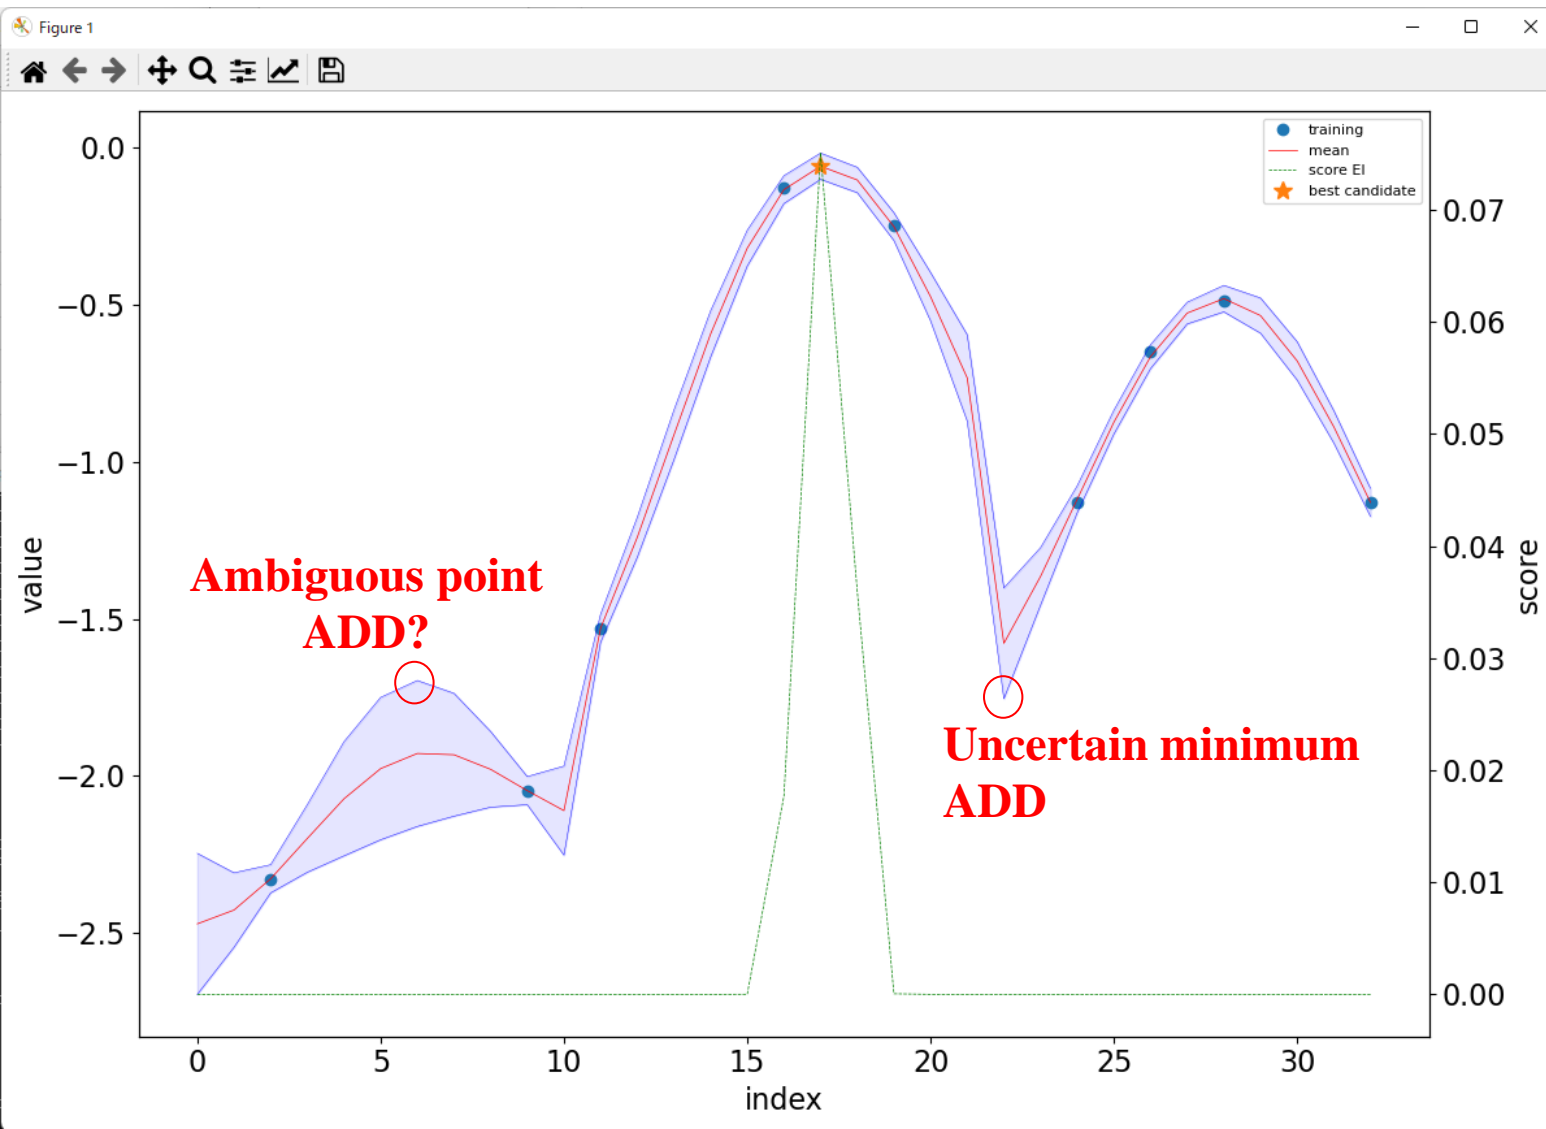
python bayes\_gp\_plain.py data\_test.xlsx





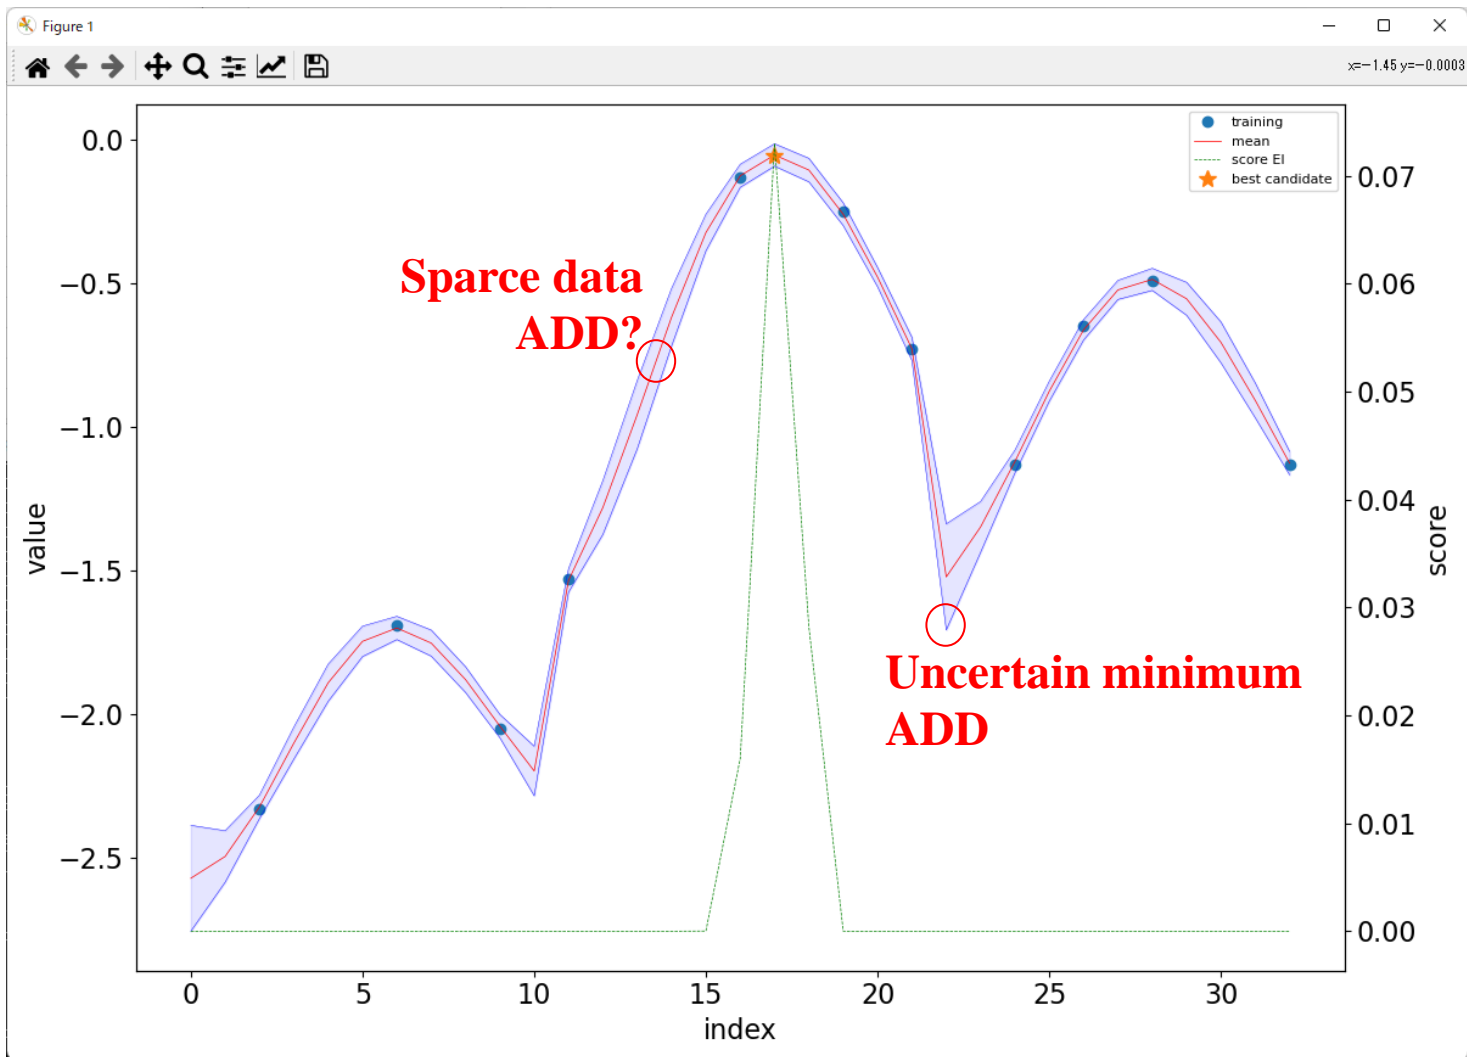
# Variation of predictions

python bayes\_gp\_plain.py data\_test.xlsx




# Variation of predictions

python bayes\_gp\_plain.py data\_test.xlsx



# Variation of predictions

python bayes\_gp\_plain.py data\_test.xlsx



**Theory**

# ベイズ推定・ベイズ最適化

強化学習の1つとして使われる

ガウス過程にベイズ推定を取り込み、最適化に利用

- ・ 観測データ  $\{X'_i, y_i\}$ 、誤差  $\varepsilon_i$  が正規分布に従うとする
- ・ 予測値をガウス基底で展開

$$t_i = \sum_k w_k \exp\left(-\sum_{k',k''} A_{k,k',k''} (x_{i,k'} - \mu_{k,k'}) (x_{i,k''} - \mu_{k,k''})\right)$$

$$A_{k,k',k''} = \frac{1}{2\sigma_{k,k',k''}^2} \quad \mu_{k,k'}, \sigma_{k,k',k''}^2: k\text{番目の基底の平均と共分散行列}$$

- ・  $w_k$  が正規分布に従うと仮定
- ・ ベイズ推定により、 $w_k$  の平均、分散が求まる

⇒ 予測値  $t_i$  も正規分布に従う

- ・ ガウス過程であれば、カーネルトリックを利用して

$t_i$  の平均、分散を(比較的)簡単に求めることができる

# ガウス過程 (Gauss process)

観測データ  $\{X'_i, y_i\}$  をガウス基底で展開

観測データに誤差  $\varepsilon_i$  があることを考慮すると、

$$t_i = \sum_k w_k \phi_k(X'_i)$$

$$y_i = t_i + \varepsilon_i$$

とあらわされる。一連の関数  $\phi_k(X'_i)$ 、 $\varepsilon_i$ 、 $y_i$ 、 $w_k$ 、 $t_i$  が正規分布に従うとき、これを**ガウス過程**と呼ぶ

*Wikipedia:*

確率過程  $\{X_t\}_{t \in T}$  は、任意に(有限個の)  $X_{t_1}, \dots, X_{t_k}$  を選んで作った線型結合(あるいはより一般に、 $\{X_t\}_{t \in T}$  を標本関数  $X_t$  全体からなる連続濃度の函数空間と見たときの、任意の線型汎関数)が正規分布に従うとき、**ガウス過程**という。

# 統計学

## 頻度主義 (frequentism) 統計学

確率が結果 (データ) を決める

## ベイズ主義 (Bayesianism) 統計学

データは定数、確率分布 (確率分布関数に含まれる定数) が分布をもつ

## 客観確率 (objective probability)

実験または理論的考察 (思考実験) から求められ、客観的な観測結果と比較できるランダムな事象についての確率

## 主観確率 (subjective probability)

人間の主観的な信念あるいは信頼の度合

# 確率に関するベイズの定理

$$p(A, B) = p(B|A)p(A) = p(A|B)p(B)$$

同時確率

事後確率

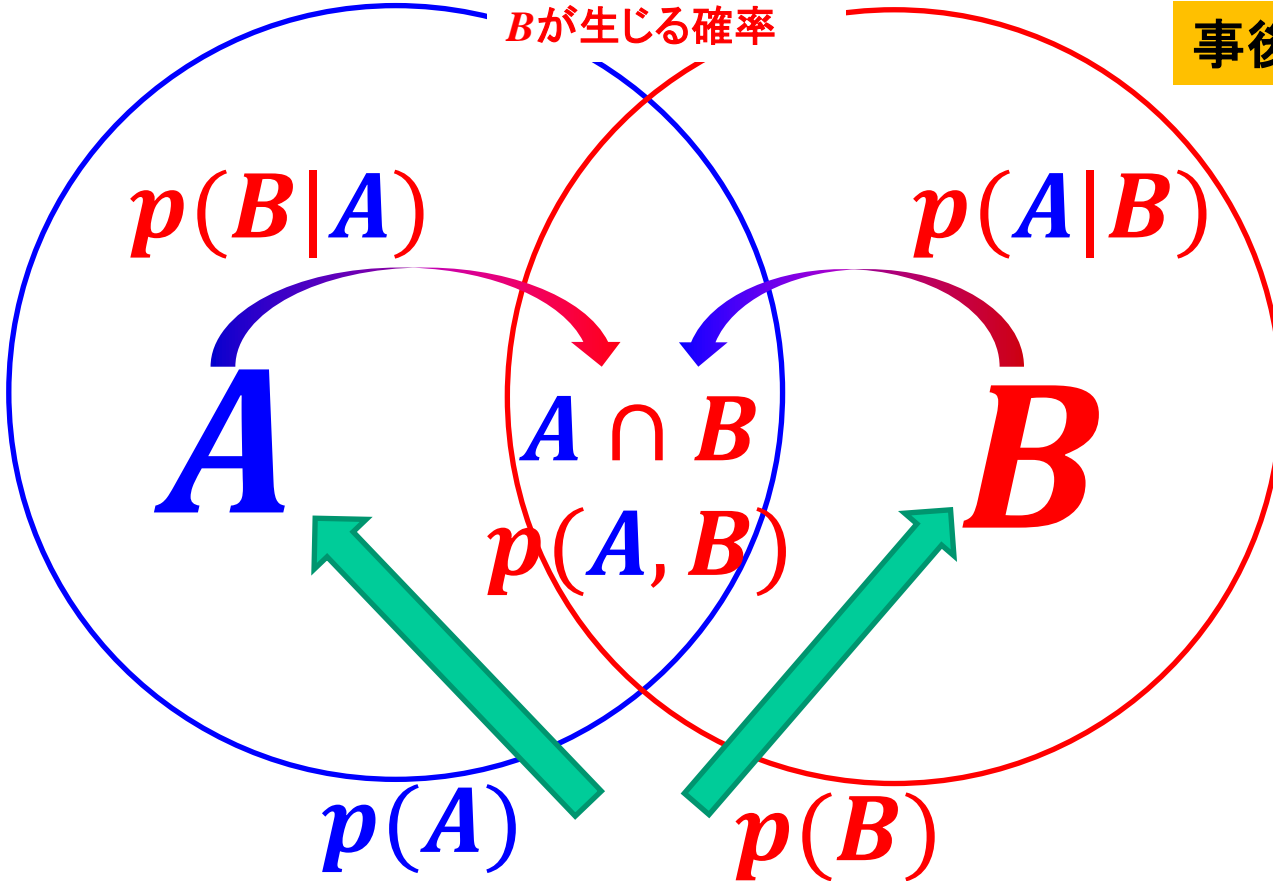
事前確率

AとBが同時に生じる確率

Aが生じた場合に  
Bが生じる確率

Aが生じる確率

事後確率 = 条件付き確率



ベイズの定理:  $p(A|B) = p(B|A)p(A)/p(B)$

事後確率

事前確率



# ベイズの定理と材料研究

$$p(A, B) = p(B|A)p(A) = p(A|B)p(B)$$

$p(A, B)$ : AとBが同時に生じる確率  
 $p(B|A)$ : Aが生じた場合にBが生じる確率  
 $p(A)$ : Aが生じる確率  
 $p(A|B)$ : Bが生じた場合にAが生じる確率  
 $p(B)$ : Bが生じる確率

$$\text{ベイズの定理: } p(A|B) = p(B|A)p(A)/p(B)$$

Bが生じた場合に  
Aが生じる確率

事前確率

A: 実験条件 B: 測定結果 と考えると、  
 $p(B|A)$ : A の条件で実験を行った結果、B が得られる確率

ベイズの定理により、

B が得られる確率の高い条件 A を  $p(A|B)$  から推定できる

問題:  $p(B) = \sum_A p(B|A)$  を決めるためにはすべての実験をやらないといけない

↑今日はこの問題は忘れて説明を続ける

# 主観確率 (subjective probability) の問題

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

殺人事件が起こり、容疑者 X を捕まえた。X の血液鑑定をしたところ、血液の特徴が一致した。  
X が犯人である確率 [事後確率  $p(\text{犯人}|一致)$ ] はいくらか。

条件付確率：偶然血液の特徴が一致する確率は  $10^{-5}$

$$p(\text{一致}|\text{犯人でない}) = 10^{-5} \quad p(\text{一致}|\text{犯人}) = 1$$

(0) 単純に考えて、 $p(\text{犯人}) = 1 - p(\text{一致}|\text{犯人でない}) = 0.99999$  としていいか？

日本人口 12,000万人のうち、血液型が一致するのは1,200人もいる  $\Rightarrow$  それじゃ、約1/1200？

世界人口 700,000万人のうち、血液型が一致するのは70,000人もいる  $\Rightarrow$  それじゃ、約1/70000？

$$\begin{aligned} \text{事後確率 } p(\text{犯人}|一致) &= p(A|B) = \frac{p(B|A)p(A)}{p(B)} = \frac{p(B|A)p(A)}{\sum_A p(B|A)p(A)} \\ &= \frac{p(\text{一致}|\text{犯人})p(\text{犯人})}{p(\text{一致}|\text{犯人})p(\text{犯人}) + p(\text{一致}|\text{犯人でない})\{1 - p(\text{犯人})\}} = \frac{p(\text{犯人})}{p(\text{犯人}) + 10^{-5}\{1 - p(\text{犯人})\}} \end{aligned}$$

事前確率の仮定:

(1) 理由不十分の原則 :  $p(\text{犯人}) = 1/2$

$$p(B) = p(\text{一致}) = 0.50005 \Rightarrow p(\text{犯人}|一致) = 0.99999: \text{犯人確定}$$

(2) 一人当たりの殺人率:  $p(\text{犯人}) = 10^{-5}$

$$p(B) = p(\text{一致}) = 1.99999 \times 10^{-5} \Rightarrow p(\text{犯人}|一致) = 0.5$$

事前確率で「犯人を見つける確率は非常に低い」という思い込み (主観) があるため、事後確率が下がる

(3) 犯人を含んでいるとみられる地域には3700万人の人が住んでいる:  $p(\text{犯人}) = 1/37000000$

$$p(B) = p(\text{一致}) = 1.003 \times 10^{-5} \Rightarrow p(\text{犯人}|一致) = 0.0027$$

3700万人の対象者中、血液の特徴が一致する人は370人いる。 $p(B) \sim 1/370$

# ベイズ更新 (Bayesian updating)

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

メール  $A$  が迷惑メール  $A_1$  である確率を求める。メールの特徴を  $B$  としたとき:

迷惑メール  $A_1$  である確率  $p(A_1|B)$ 、迷惑メールでない  $A_2$  である確率:  $p(A_2|B)$

$\Rightarrow p(A|B)$  が得られているとする。

ここに、ほかの特徴  $C$  による判定を加える。

$$p(A, B, C) = p(A|B, C)p(B, C) = p(B, C|A)p(A)$$

$$\Rightarrow p(A|B, C) = \frac{p(B, C|A)p(A)}{p(B, C)}$$

$A, B$  が独立であれば  $p(B, C) = p(B)p(C)$ 、

$A$  が与えられた条件で  $B$  と  $C$  が独立であれば  $p(B, C|A) = p(B|A)p(C|A)$

$$\Rightarrow p(A|B, C) = \frac{p(B|A)p(C|A)p(A)}{p(B)p(C)} = \frac{p(C|A)}{p(C)} \frac{p(B|A)p(A)}{p(B)}$$

$p(A, B) = p(A|B)p(B) = p(B|A)p(A)$  から、

$$p(A|B, C) = \frac{p(C|A)}{p(C)} p(A|B)$$

※  $B$  の情報から  $A$  が迷惑メールであるかどうかの確率  $p(A|B)$  がわかっている場合に、

$C$  による情報  $\frac{p(C|A)}{p(C)}$  を加えて、 $A$  が迷惑メールである確率を更新 (改善) できる

# 確率に関するベイズの定理

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

$$p(A|B) = \frac{p(B|A)p(A)}{p(B)}$$

$A, B$ : 事象 (event)

$p(A)$ : 事象Aが観察される確率

$p(A, B)$ : 同時確率 (joint probability)。事象AとBが同時に観察される確率

$$\sum_{i,j} p(A_i, B_j) = 1$$

$\sum_i p(A_i, B_j) = p(B_j)$ : 周辺確率 (marginal probability)

$p(B|A)$ : 条件付き確率 (conditional probability)。

事象Aが観察されたという条件の下で、Bが観察される確率

$$p(B_j|A_i) = \frac{p(A_i, B_j)}{p(A_i)}$$

$$\sum_j p(B_j|A_i) = 1$$

乗法の定理 (multiplication theorem of probability):  $p(A_i, B_j) = p(B_j|A_i) p(A_i) = p(A_i|A_j) p(B_j)$

全確率の公式 (law of total probability):  $p(B_j) = \sum_i p(A_i, B_j)p(A_i)$

ベイズの定理 (Bayes' theorem):  $p(A_i|B_j) = \frac{p(B_j|A_i)p(A_i)}{p(B_j)} = \frac{p(B_j|A_i)p(A_i)}{\sum_i p(B_j|A_i)p(A_i)}$

$p(A_i)$  : 事前確率 (prior probability)

$p(A_i|B_j)$ : 事後確率 (posterior probability)

$p(A_i|B_j) = p(B_j|A_i)$ : AとBは互いに独立である(independent)  $\Rightarrow p(A_i, B_j) = p(A_i)p(B_j)$

# 確率分布に関するベイズの定理

豊田秀樹著、基礎からのベイズ統計学、朝倉書店(2015)

母数  $\theta$  を確率変数として扱う

$f(\theta)$  : 確率変数の確率分布。事前確率分布 (prior probability distribution)

$f(\theta, x) = f(x|\theta)f(\theta) = f(\theta|x)f(x)$ : 確率変数が  $\theta$  をとり、データが  $x$  をとる同時確率

$f(\theta|x)$ : データによる母数の条件付き分布。事後確率分布 (posterior probability distribution)

データが確定している場合の  $\theta$  の条件付き確率を

$\theta$  の関数として **尤度関数** (likelihood function) と呼ぶ

$f(x|\theta)$ : 確率変数が  $\theta$  をとるとき、データが  $x$  を取る条件付き確率。

一般に **確率密度分布関数** と呼ばれる

$$f(x) = \int f(x|\theta) f(\theta) d\theta$$

$$f(\theta|x) = \frac{f(x|\theta)f(\theta)}{f(x)} = \frac{f(x|\theta)f(\theta)}{\int f(x|\theta)f(\theta) d\theta}: \text{確率分布に関するベイズの定理}$$

⇒ 観測データ  $\{x_i, y_i\}$  があるとき、分布関数の母数  $\theta$  の分布がわかる

例えばフィッティング変数  $w_i$  が正規分布

$$f(w_i|x_i, y_i) = N(\mu, \sigma^2) = \frac{1}{\sqrt{2\sigma^2}} \exp\left(-\frac{(x_i-\mu)^2}{2\sigma^2}\right)$$

に従う場合、 $w_i$  の期待値  $\mu$  と標準偏差  $\sigma$  が求まる

# 線形回帰

## 線形回帰:

観測データ  $\{X_i, y_i\}$  を  $y = a_0 + \sum_i a_i x_i$  でフィッティングし、

係数  $a_i$  ( $i = 0, 1, \dots, N$ ) を求めること

$X_i = \{x_{i,j}\}$ : 記述子 (descriptor) の組	実験条件、計算条件に対応
$y_i$ : 目的関数	実測値、計算値に対応

記述子  $x_{i,j}$ 、目的関数  $y_i$  は平均  $\mu_{i,j}$  と標準偏差  $\sigma_{i,j}$  を使って

**標準化**する: 平均 0、標準偏差 1になる

$$x'_{i,j} = \frac{x_{i,j} - \mu_{i,j}}{\sigma_{i,j}} \Rightarrow y' = \sum_i a_i X'_i \text{ でフィッティングすればよい}$$

単回帰: 記述子が1種類だけ

重回帰: 記述子が複数

# 最尤推定法

誤差  $\varepsilon_i = f(x_i, a_i) - y_i$  が分散  $\sigma_i$  の正規分布に従うとする。データ  $(x_i, y_i)$  に対するパラメータ  $(a_i)$  の尤度関数は

$$P(a_i) = \prod_i \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left[-\frac{\varepsilon_i^2}{2\sigma_i^2}\right]$$

尤度を最大化するパラメータを求めるのが「最尤推定法」。

$$\max P(a_i) = \max \ln P(a_i) = \min \sum_i \frac{\varepsilon_i^2}{\sigma_i^2}: \text{最小二乗法に一致する}$$

# 線形最小二乗法

誤差の自乗和 (L2 norm)  $S = \sum (f(x_i) - y_i)^2$  を最小化

$$f(x_i) = a + bx_i$$

$$S = \sum (a + bx_i - y_i)^2$$

$$dS/da = 2\sum (a + bx_i - y_i) = 2an + 2b\sum x_i - 2\sum y_i = 0$$

$$dS/db = 2\sum x_i(a + bx_i - y_i) = 2a\sum x_i + 2b\sum x_i^2 - 2\sum x_i y_i = 0$$

$$\begin{pmatrix} n & \sum x_i \\ \sum x_i & \sum x_i^2 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} \sum y_i \\ \sum x_i y_i \end{pmatrix}$$



# 線形回帰を非線形問題へ

重回帰: 観測データ  $\{X_i, y_i\}$  を  $y = \sum_i a_i X'_i$  でフィッティング

$\Rightarrow y = \sum_k a_k f_k(X'_i)$  でフィッティングしても、

未知変数  $a_i$  に関しては線型方程式のまま

$\Rightarrow$  線形回帰の方法がそのまま使える

例:  $f_k(x) = x^k$ : 多項式回帰

$f_k(x) = \exp\left(-\frac{(x_i - \mu)^2}{2\sigma^2}\right)$ : ガウス基底

# 線形最小二乗法：一般関数の場合：行列表示

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

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

係数に関して線形であれば、1度の行列計算で最終解が得られる

$$\text{例: } f(x) = a + b \log x + c/x$$
$$f(x, y) = a + bxy + cy/x$$