

ベース最適化パッケージ PHYSBO の使い方

<https://github.com/issp-center-dev/PHYSBO>

<https://issp-center-dev.github.io/PHYSBO/manual/master/ja/index.html>

physbo-dev@issp.u-tokyo.ac.jp

東大物性研 本山裕一

PHYSBO のインストール

- ・ 最新版 (v1.0.1) は Python3.6 以上が必要
 - ・ v0.1.0 は Python2.7 で動作 (COMBO +bugfix +document)
- ・ `pip install physbo` でインストール可能
 - ・ インストール方法について詳しくは pip のマニュアルや文献を参照のこと
 - ・ バージョン更新は `pip install -U physbo`
 - ・ バージョン指定は `physbo==1.0.1`
 - ・ インストール場所の変更は `install --user` や `--prefix=PATH`
- ・ インストールには C コンパイラ及び NumPy, Cython が必要
 - ・ pip が十分新しければ後者は自動で入るが、だめなら手動で導入
 - ・ NumPy 1.20 以降と 1.19 以前とでバイナリに互換性がないので注意
 - ・ インストールに使ったバージョンと実際に使ったバージョンを合わせるのが一番安全
- ・ MateriApps LIVE! を使う場合は最初から入っています

PHYSBO の使用法（サンプル）

- PHYSBO を使う場合には自分でpython スクリプトを書く必要がある
 - 基本的にはサンプルスクリプトやチュートリアルを改造すればよい
 - サンプルスクリプトは pip install では入らない
 - <https://github.com/issp-center-dev/PHYSBO> から持ってくる
 - git clone https://github.com/issp-center-dev/PHYSBO
 - examples ディレクトリ以下にサンプルが存在
 - チュートリアルは
 - <https://issp-center-dev.github.io/PHYSBO/manual/master/ja/notebook/>
 - もととなっている jupyter notebook は docs/sphinx/manual/ja/source/notebook 以下にある
 - MateriApps LIVE! では /usr/share/physbo にexamples がインストールされている

PHYSBO の使用法 (Basic)

- PHYSBO を使ったベイズ最適化に必要な要素は大雑把に3つ

1. 解きたい最適化問題

- 目的関数 $y = f(x)$
 - PHYSBO は最大化問題であると仮定する
- x の探索空間（候補点の集合）
 - PHYSBO は離散空間中で最適化する

2. ベイズ最適化のパラメータ

- 初期データの準備
- 獲得関数の選択
- ガウス過程の表現能力

3. 結果の取り出し方

→ 実際にスクリプトを見ていきましょう

- 探索済みの点
- 獲得関数
- 学習したガウス過程（各点での期待値、分散）

PHYSBO の使用法 (Basic)(on MALIVE!)

```
# この2つは新しくMA LIVE! を準備した場合は不要です
$ sudo apt update                      # パッケージ一覧の更新
$ sudo apt install physbo               # PHYSBO の更新

$ mkdir physbo                          # 作業用ディレクトリを作成して
$ cd physbo                            # そこに移動
$ cp -r /usr/share/physbo/examples .  # サンプルのコピー
$ cd examples                           # とりあえず実行してみる
$ python3 simple.py

... 中略 ...

best_fx: -0.0023413821289715096 at [0.00970778 0.01407324
0.04526682]
# 亂数を固定していないので数字は異なる
```

PHYSBO の使用法 (Basic)

- `examples/simple.py` は以下の最適化問題を PHYSBO を用いて解くプログラム

- 探索空間が3次元
 - パラメータの数が3
 - 候補点は乱数生成
- 目的関数が

$$f(\vec{x}) = - \sum_{i=1}^3 x_i^2$$

```
import numpy as np
import physbo

# 候補点の集合を生成する
D = 3      # 探索パラメータの数 (パラメータ空間の次元)
N = 1000   # 候補点の数
test_X = np.random.randn(N, D)  # 正規分布

# 目的関数 (二次関数)
# 探索点の番号の配列から対応する目的関数の値の配列を返す
def simulator(actions):
    return -np.sum(test_X[actions, :] ** 2, axis=1)

# 最適化を行うクラス policy の初期化
policy = physbo.search.discrete.policy(test_X)

# ランダム探索 (10 個)
policy.random_search(max_num_probes=10, simulator=simulator)

# ベイズ探索 (100 回)
policy.bayes_search(
    max_num_probes=100, simulator=simulator, score="EI"
)

# これまでの最適解を表示
best_fx, best_actions = policy.history.export_sequence_best_fx()
print(f"best_fx: {best_fx[-1]} at {test_X[best_actions[-1], :]}")
```

次ページから解説

PHYSBO の使用法 (Basic)

- PHYSBO は D 次元パラメータ空間中の N 個の点（候補点）の集合から、目的関数 $f(x)$ の値が最大となる点を探索する
- 候補点の集合 は N 行 D 列の行列 (`np.ndarray`)として表現する (`test_X`)
- 目的関数は候補点の番号 (action) の配列から対応する値の配列を返す関数として表現する (`simulator`)

```
import numpy as np
import physbo

# 候補点の集合を生成する
D = 3      # 探索パラメータの数 (パラメータ空間の次元)
N = 1000   # 候補点の数
test_X = np.random.randn(N, D)  # 正規分布

# 目的関数 (二次関数)
# 探索点の番号の配列から対応する目的関数の値の配列を返す
def simulator(actions):
    return -np.sum(test_X[actions, :] ** 2, axis=1)

# 最適化を行うクラス policy の初期化
policy = physbo.search.discrete.policy(test_X)

# ランダム探索 (10 個)
policy.random_search(max_num_probes=10, simulator=simulator)

# ベイズ探索 (100 回)
policy.bayes_search(
    max_num_probes=100, simulator=simulator, score="EI"
)

# これまでの最適解を表示
best_fx, best_actions = policy.history.export_sequence_best_fx()
print(f"best_fx: {best_fx[-1]} at {test_X[best_actions[-1], :]}")
```

PHYSBO の使用法 (Basic)

- `physbo.search.discrete.policy` が探索を行う
クラス
- `policy.random_search` で候補点集合からランダムに選び出し、目的関数の値を計算する
- 結果は`policy` が覚えている

```
import numpy as np
import physbo

# 候補点の集合を生成する
D = 3      # 探索パラメータの数 (パラメータ空間の次元)
N = 1000   # 候補点の数
test_X = np.random.randn(N, D)  # 正規分布

# 目的関数 (二次関数)
# 探索点の番号の配列から対応する目的関数の値の配列を返す
def simulator(actions):
    return -np.sum(test_X[actions, :] ** 2, axis=1)

# 最適化を行うクラス policy の初期化
policy = physbo.search.discrete.policy(test_X)

# ランダム探索 (10 個)
policy.random_search(max_num_probes=10, simulator=simulator)

# ベイズ探索 (100 回)
policy.bayes_search(
    max_num_probes=100, simulator=simulator, score="EI"
)

# これまでの最適解を表示
best_fx, best_actions = policy.history.export_sequence_best_fx()
print(f"best_fx: {best_fx[-1]} at {test_X[best_actions[-1], :]}")
```

PHYSBO の使用法 (Basic)

- `policy.bayes_search` でベイズ的に探索する
- 100ステップ行う
- 獲得関数はEI
- 結果は`policy` が覚えている

```
import numpy as np
import physbo

# 候補点の集合を生成する
D = 3      # 探索パラメータの数 (パラメータ空間の次元)
N = 1000   # 候補点の数
test_X = np.random.randn(N, D)  # 正規分布

# 目的関数 (二次関数)
# 探索点の番号の配列から対応する目的関数の値の配列を返す
def simulator(actions):
    return -np.sum(test_X[actions, :] ** 2, axis=1)

# 最適化を行うクラス policy の初期化
policy = physbo.search.discrete.policy(test_X)

# ランダム探索 (10 個)
policy.random_search(max_num_probes=10, simulator=simulator)

# ベイズ探索 (100 回)
policy.bayes_search(
    max_num_probes=100, simulator=simulator, score="EI"
)

# これまでの最適解を表示
best_fx, best_actions = policy.history.export_sequence_best_fx()
print(f"best_fx: {best_fx[-1]} at {test_X[best_actions[-1], :]}")
```

PHYSBO の使用法 (Basic)

- `policy.history` が過去の探索結果
- `history.export_sequence_best_fx` は、各ステップごとに、それまでの最適解（値と番号）を出力する
- 最後のステップは -1 で取れる

```
import numpy as np
import physbo

# 候補点の集合を生成する
D = 3      # 探索パラメータの数 (パラメータ空間の次元)
N = 1000   # 候補点の数
test_X = np.random.randn(N, D)  # 正規分布

# 目的関数 (二次関数)
# 探索点の番号の配列から対応する目的関数の値の配列を返す
def simulator(actions):
    return -np.sum(test_X[actions, :] ** 2, axis=1)

# 最適化を行うクラス policy の初期化
policy = physbo.search.discrete.policy(test_X)

# ランダム探索 (10 個)
policy.random_search(max_num_probes=10, simulator=simulator)

# ベイズ探索 (100 回)
policy.bayes_search(
    max_num_probes=100, simulator=simulator, score="EI"
)

# これまでの最適解を表示
best_fx, best_actions = policy.history.export_sequence_best_fx()
print(f"best_fx: {best_fx[-1]} at {test_X[best_actions[-1], :]}")
```

PHYSBO の使用法 (Basic)

- `policy.random_search` の出力

```
$ python3 simple.py  
0001-th step: f(x) = -5.936448 (action=631)  
    current best f(x) = -5.936448 (best action=631)  
        (中略)
```

- `policy.bayes_search` の出力

```
Start the initial hyper parameter searching ...  
Done
```

- まず、ガウス過程のハイパーパラメータ学習を行う

```
Start the hyper parameter learning ...  
0 -th epoch marginal likelihood 18.1115054749814  
    (中略)
```

- その後にベイズ最適化

```
500 -th epoch marginal likelihood 16.661922004077017  
Done
```

- 最終結果

```
0011-th step: f(x) = -0.017750 (action=452)  
    current best f(x) = -0.017750 (best action=452)  
        (中略)
```

- 「候補点の集合からの最適解」であることに注意

```
0110-th step: f(x) = -0.336775 (action=112)  
    current best f(x) = -0.017399 (best action=404)
```

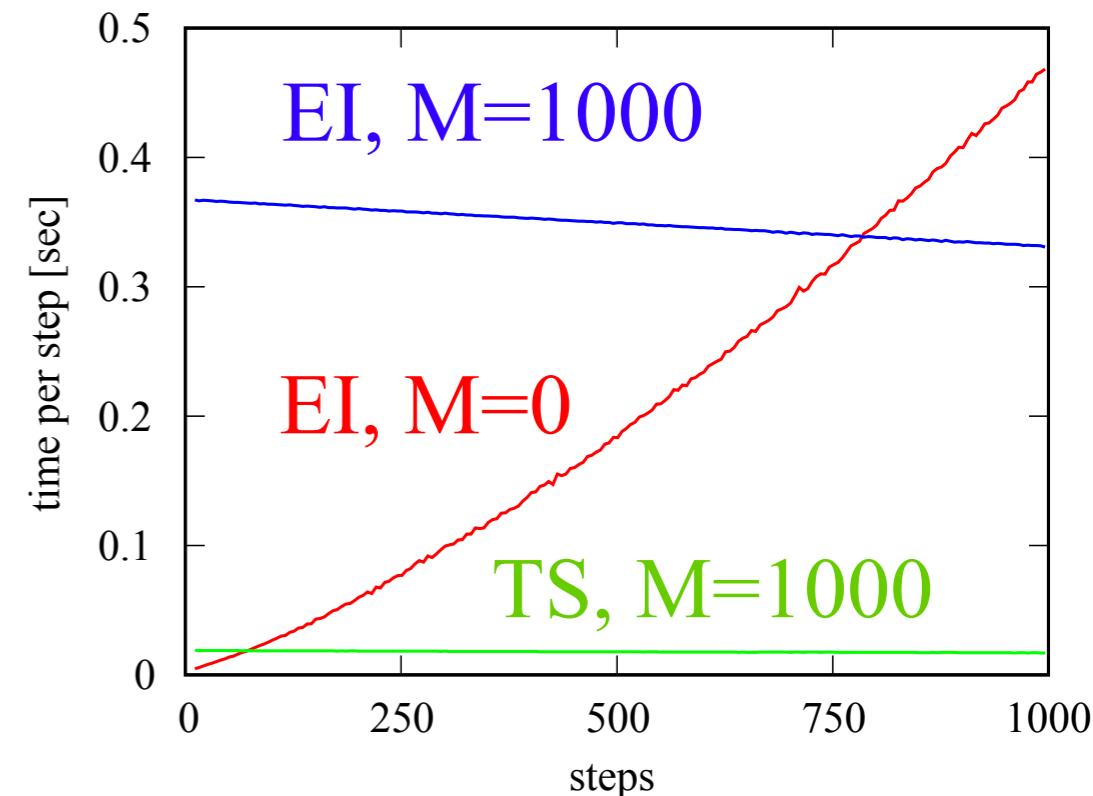
```
best_fx: -0.017399043740363704 at [-0.10011779  0.06464974  0.05653215]
```

PHYSBO の使用法 (Advanced)

- 目的関数の評価は自分でやりたい
 - チュートリアルの「[インタラクティブに実行する](#)」および「[既存の計算結果を読み込んで実行する](#)」を参照
 - 例：実験で測定したい
 - bayes_search に simulator を渡さないと、この関数は次に測定すべき候補点（の番号）を返す
 - `next_actions = policy.bayes_search(max_num_probes=1)`
 - 評価結果 `t = simulator(next_actions)` は `policy.write` で登録する
 - `policy.write(actions, t)`
 - 既知の測定結果（候補点番号と目的関数の組）は `policy` の初期化時にも渡せる
 - `discrete.policy(test_X, initial_data=(actions, fs))`
- 複数の目的関数を同時に扱いたい（多目的最適化）
 - `examples/multiple.py`
 - [公式ドキュメント](#)を参照

PHYSBO の使用法 (Advanced)

- 高速化したい (その1)
 - random feature mapを用いる (付録やマニュアルの「アルゴリズム」を参照)
 - ランダム基底関数の数 M を `num_rand_basis` として渡す
 - `policy.bayes_search(num_rand_basis=1000)`
 - デフォルトは0 (「普通の」ガウス過程回帰を用いる)
 - M が大きいほどモデル関数の表現能力が上がる
 - $N=10000$ 個の探索空間から次の候補点を求めるのにかかった時間 (ステップあたり)
 - $M>0$ では測定済み点数に対してほぼ定数
 - 測定済み点数が大きいときに効果的
 - 獲得関数をトンプソンサンプリング("TS")にするとより効果的

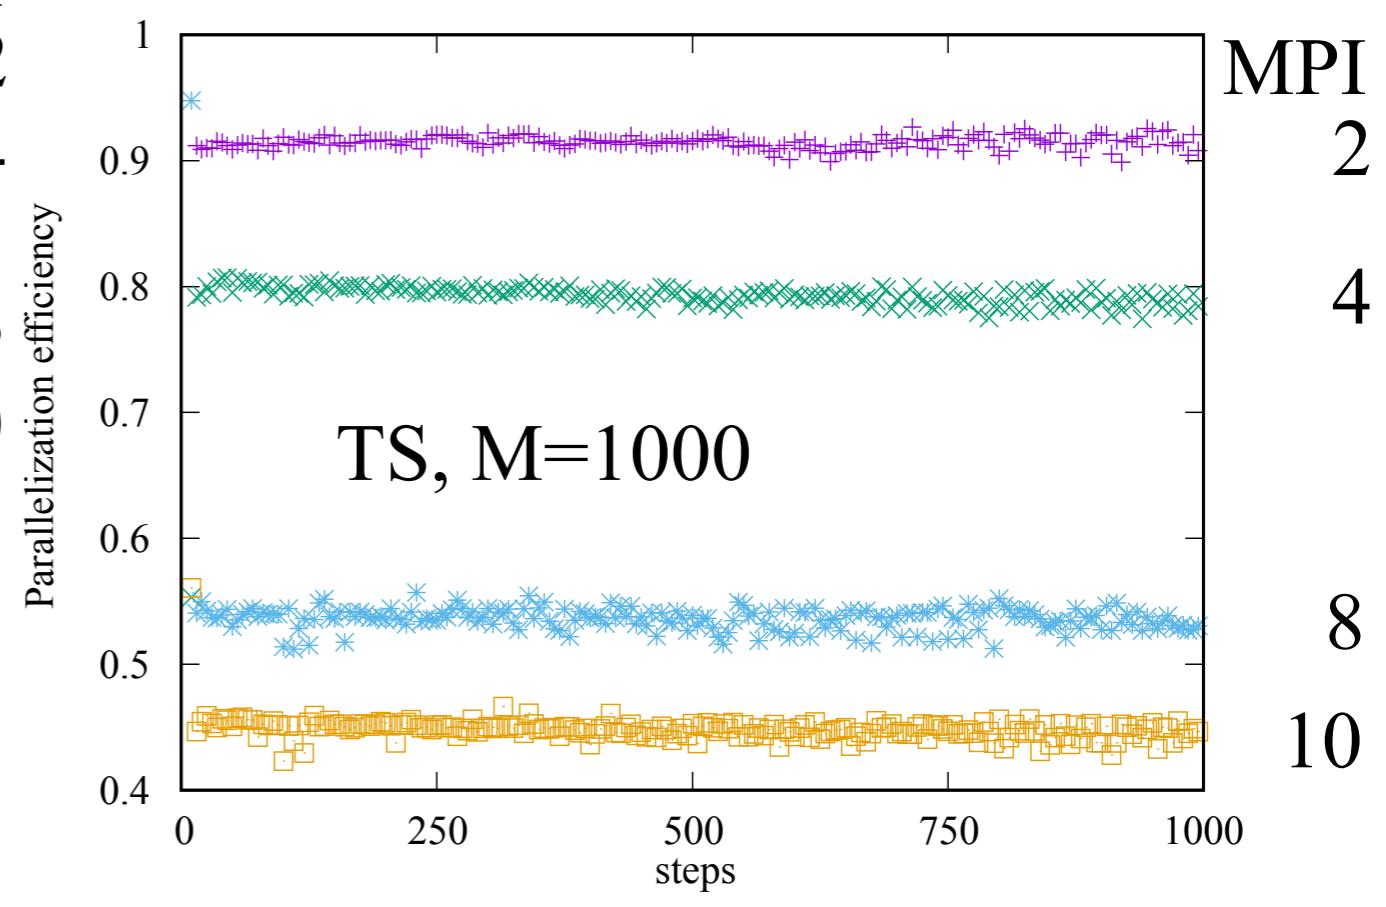
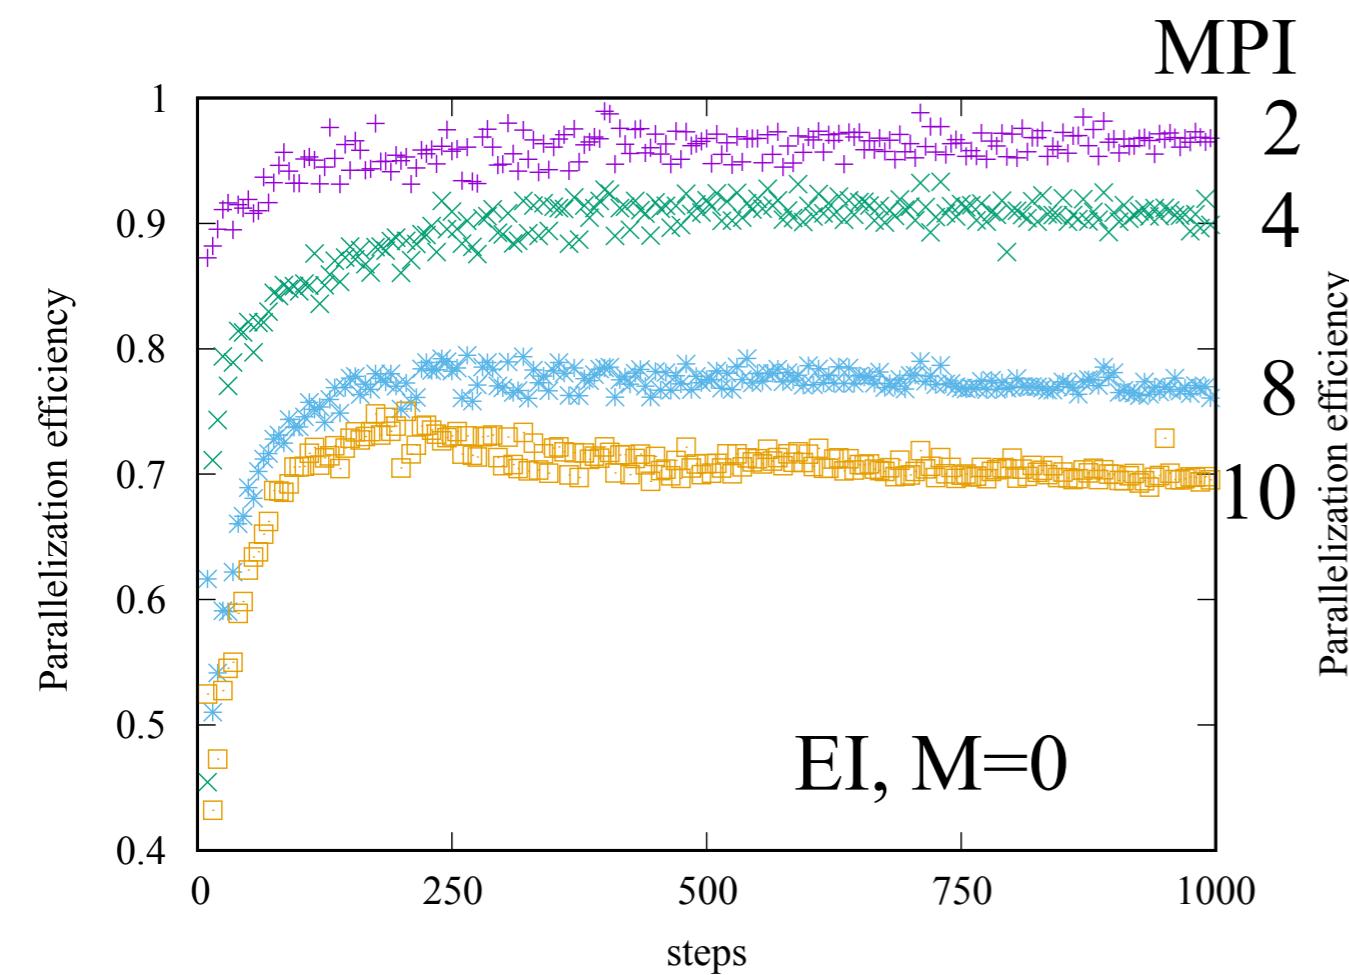


PHYSBO の使用法 (Advanced)

- 高速化したい (その2)
 - 獲得関数の最適化に関して、MPI 並列可能 (mpi4py を利用)
 - 高次元など、候補点が多い場合に有効
 - policy を作るときに MPI コミュニケータ mpi4py.MPI.Comm を渡す
 - `physbo.search.discrete.policy(test_X, comm=MPI.COMM_WORLD)`
 - `$ mpiexec -np 2 python3 simple.py`
 - 現状では、目的関数の計算は `rank==0` のものだけが行う
 - MateriApps LIVE! で試したい場合
 - VirtualBox の設定で利用する物理コアの数を変える
 - 一旦 MateriApps LIVE! からログアウトする
 - 仮想マシン一覧から設定するマシンを右クリック→設定→システム→プロセッサー

PHYSBO の使用法 (Advanced)

- 高速化したい (その2)
 - 獲得関数の最適化に関して、MPI 並列可能 (mpi4py を利用)
 - 並列化効率を示したものが下図

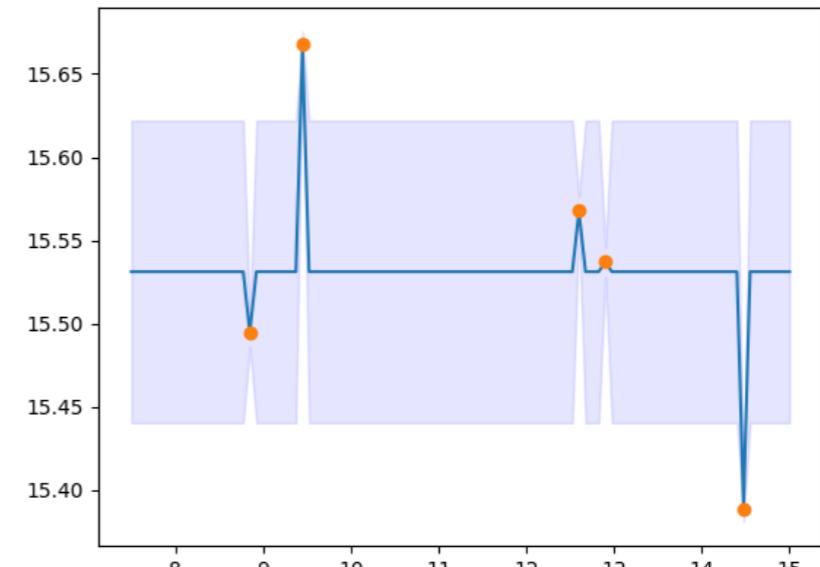
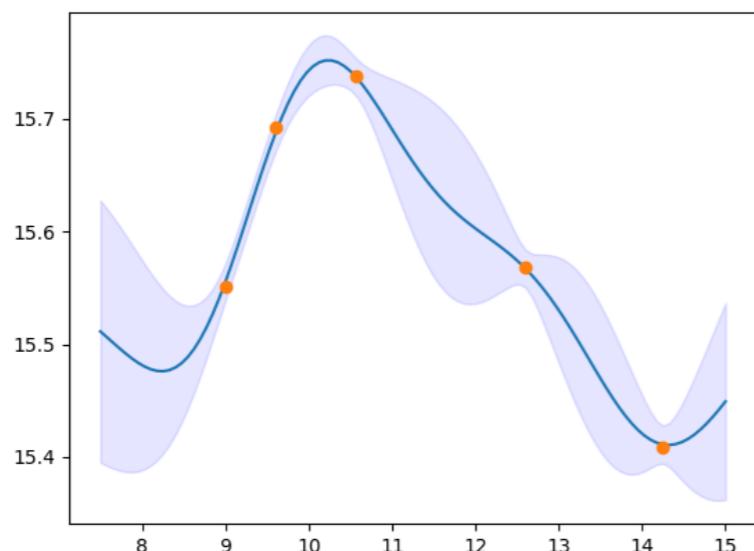


PHYSBO の使用法 (Advanced)

- 学習したモデル関数や獲得関数を見てみたい
 - 期待値
 - `policy.get_post_fmean(xs=test_X)`
 - 分散
 - `policy.get_post_fcov(xs=test_X)`
 - 獲得関数
 - `policy.get_score(mode="EI", xs=test_X)`
 - もちろん `xs` や`mode` は学習に使ったものと異なっていても良い
- `examples/simple_score.py` がサンプルスクリプト
 - 結果を愚直に `print` しているだけ
 - (単純な) 可視化の例としてはチュートリアルの「[PHYSBO の基本](#)」

PHYSBO の使用法 (Advanced)

- ハイパーパラメータの学習
 - ガウスカーネルの幅 η と測定にかかる誤差 σ という2つのハイパーパラメータがある
 - PHYSBO では自動的に学習する (最尤法)
 - 初期データが少なく、偏っている場合、失敗することもある
 - 下は同じ関数から別々に 5点取ってきてハイパーパラメータ学習したもの
 - 右の状態では恒等関数しか表現できない



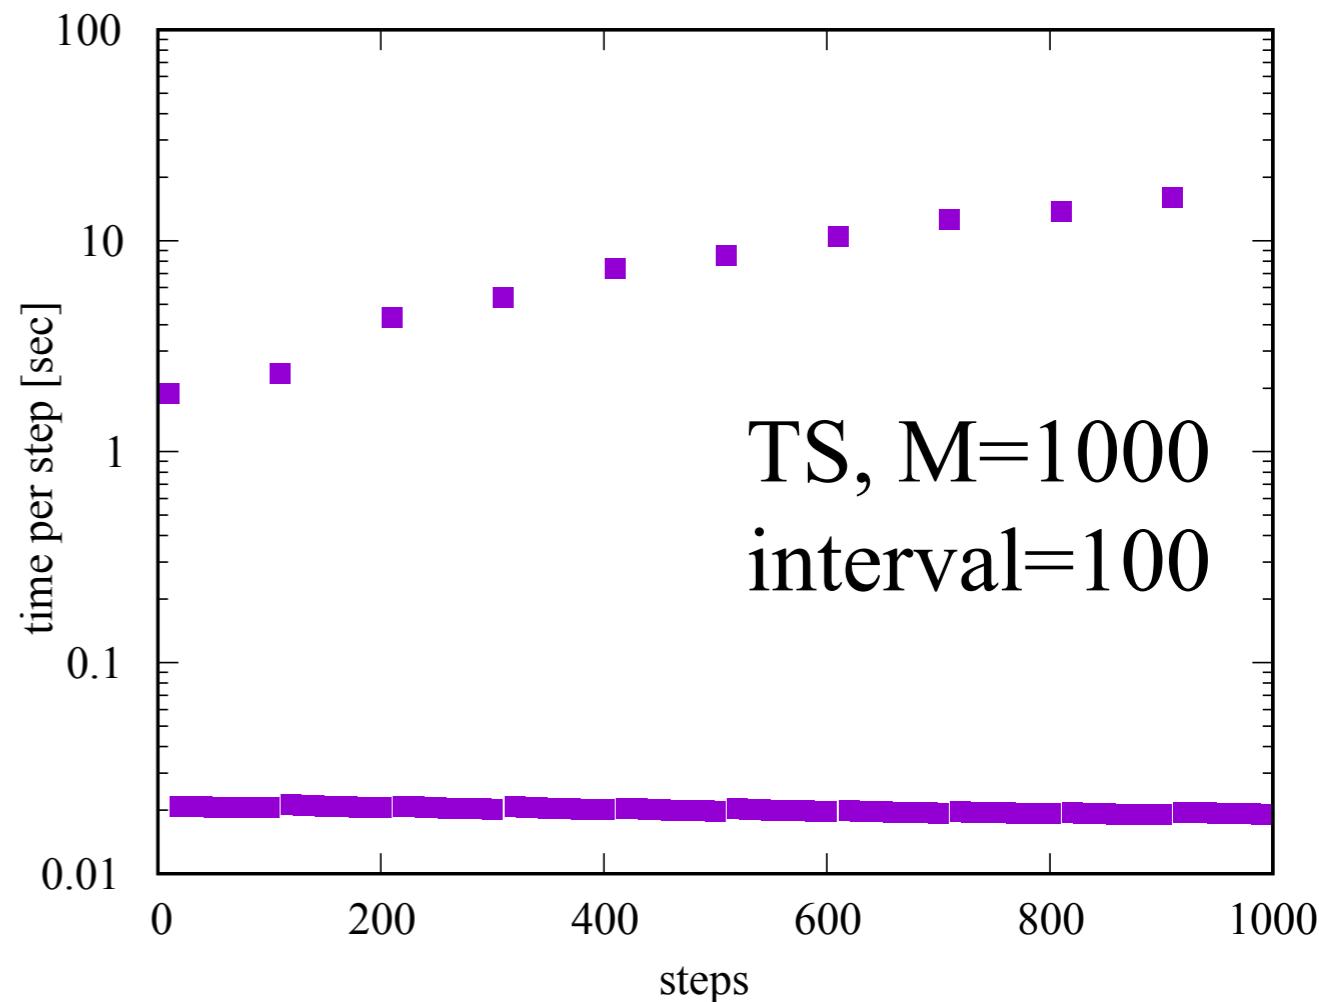
PHYSBO の使用法 (Advanced)

- ハイパーパラメータの再学習
 - データ点を増やしてから学習しなおすとたいていは直る
 - `bayes_search` のキーワード引数 `interval` でハイパーパラメータの再学習頻度を指定可能
 - `policy.bayes_search(interval=10)`
 - デフォルトは0で、この場合は最初に学習したのち再学習しない
 - 最初に失敗すると最後までダメ
 - 負数を渡すと最初の学習も行わない
 - 獲得関数など、途中経過を出力した後に続行したいときには有用
 - v1.1では安全のため、デフォルト値を1に変更する予定
 - つまり各ステップで毎回再学習する

PHYSBO の使用法 (Advanced)

- ・ ハイパーパラメータの再学習
 - ・ ハイパーパラメータ学習はモデル関数や獲得関数の計算と比べて、文字通り桁違いに時間がかかることに注意
 - ・ 最初の学習の段階で可視化をしておくのが良い

- ・ 右図はステップごとの所要時間
- ・ 100回に1回行っているハイパーパラメータ学習は、次候補選定と比べて100倍重い



演習例

- モデル関数を可視化する（おすすめ）
 - まずは 1 パラメータの探索から始めるのがよいでしょう
- 獲得関数の種類やランダム基底の数、再学習頻度、並列化数を変えて遊んでみる
 - UNIX の time コマンドや Python の time.time 関数を使ってみましょう
 - 今回のスライドにあるような細かい経過時間の出力は将来バージョンで入ります
- 他のシミュレーションソフトウェアと連携する（時間内にやるのは難しい）
 - DFT ソフトウェア（例：Quantum ESPRESSO）と組み合わせて安定構造を探索する
 - 例：Si について、エネルギーが最小となるような格子定数を探る
 - 模型ソルバ（例：HΦ）と組み合わせてハミルトニアンのパラメータ探索
 - 例：スピinn模型について、与えられた磁化曲線を再現するようなパラメータ（結合定数など）を探る
 - <https://ma.issp.u-tokyo.ac.jp/app-post/2179?appid=1432>

付録

ガウス過程
ガウスカーネル
線形ベイズ回帰

ガウス過程

- 関数 $f(x)$ について、 n 個の任意の点 $\{x_1, x_2, \dots, x_n\}$ に対する値の同時確率分布が次のような n 次元の正規分布となるとき、 $f(x)$ はガウス過程 $GP(m, k)$ である

$$\begin{pmatrix} f(x_1) \\ f(x_2) \\ \vdots \\ f(x_n) \end{pmatrix} \sim N \left(\begin{pmatrix} m(x_1) \\ m(x_2) \\ \vdots \\ m(x_n) \end{pmatrix}, \begin{pmatrix} k(x_1, x_1) & k(x_1, x_2) & \dots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \dots & k(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1) & k(x_2, x_n) & \dots & k(x_n, x_n) \end{pmatrix} \right)$$

- とても大雑把には、 n 次元の正規分布を $n \rightarrow \infty$ に飛ばした極限
- 関数を ∞ 次元のベクトルだとみなせるようなもの
- 以下では分散共分散行列を K と書く
- k をカーネル関数と呼ぶ

ガウス過程回帰

- n 組の既知データから、別の座標 x^* に対する未知データ y^* の値を推測したい
- 関数 $y = f(x)$ が、あるカーネル関数 k を持つガウス過程であると仮定すると、 y^* の平均 μ_c 及び分散 σ_c^2 は以下のように計算できる

$$\mu_c(x^*) = \mathbf{k}(x^*)^T(K + \sigma^2 I)^{-1}\mathbf{y}$$

$$\sigma_c^2(x^*) = k(x^*, x^*) + \sigma^2 - \mathbf{k}(x^*)^T(K + \sigma^2 I)^{-1}\mathbf{k}(x^*)$$

- ここで \mathbf{y} は既知データ $\mathbf{y} = [y_1, y_2, \dots, y_n]^T$
- \mathbf{k} はカーネルの組 $\mathbf{k}(x^*) = [k(x^*, x_1), k(x^*, x_2), \dots, k(x^*, x_n)]^T$
- σ は回帰のハイパーパラメータ（測定にかかる誤差の大きさ）
- 計算量は $O(n^3)$ （逆行列の計算）
- x^* にはよらないので、一度やれば使い回せる

カーネル関数

- ・ カーネル関数 k 自体の選択も重要
 - ・ 2点がどのくらい「近い (=互いに影響を与える)」か
- ・ PHYSBO ではガウスカーネルを用いる
 - ・ Squared Exponential (SE) とかよばれることも

$$k(x, x') = \exp \left[-\frac{1}{2\eta^2} \|x - x'\|^2 \right]$$

- ・ η はカーネル関数をチューニングするハイパーパラメータ
 - ・ 大きいほど距離に鈍感
 - ・ 回帰のパラメータ σ とともに、実行中にチューニング可能
 - ・ PHYSBO は最尤法を用いている

特徴空間への写像 ϕ

- ・ 次のようなパラメータ付けられた関数 z を考える

$$z_{\vec{\omega}, b}(\vec{x}) = \sqrt{2} \cos(\vec{\omega} \cdot \vec{x} + b)$$

- ・ ここで ω は D 次元正規分布 $N(0, I_D)$ に従う確率変数で、 b は一様分布 $[0, 2\pi)$ に従う確率変数
- ・ z の積について、 ω と b に関する期待値はガウスカーネルに一致する

$$E [z_{\vec{\omega}, b}(\vec{x}) z_{\vec{\omega}, b}(\vec{x}')]_{\vec{\omega}, b} = \exp \left[-\frac{1}{2\eta^2} \|\vec{x} - \vec{x}'\|^2 \right] = k(\vec{x}, \vec{x}')$$

- ・ x から M 次元特徴空間への次の写像 ϕ を考えると

$$\vec{\phi}(\vec{x}) = [z_{\vec{\omega}_1, b_1}(\vec{x}/\eta), \dots, z_{\vec{\omega}_M, b_M}(\vec{x}/\eta)]^T$$

- ・ ϕ の内積でガウスカーネルを近似可能 ($M \rightarrow \infty$ 極限で厳密 \because 大数の法則)

$$k(\vec{x}, \vec{x}') \simeq \vec{\phi}(\vec{x})^T \vec{\phi}(\vec{x}')$$

ベイズ線形回帰

- ϕ がガウスカーネルを（近似的に）生成するので、もともとを考えていたガウスカーネルガウス過程回帰は次の ϕ によるベイズ線形回帰の双対となる

$$y = \vec{w}^T \vec{\phi}(\vec{x})$$

- 学習データDのもとで、係数ベクトルWの事後分布は次のガウス分布になる

$$p(\vec{w}|D) = N(\vec{\mu}, \Sigma)$$

$$\vec{\mu} = [\Phi \Phi^T + \sigma^2 I]^{-1} \Phi \vec{y}$$

$$\Sigma = \sigma^2 [\Phi \Phi^T + \sigma^2 I]^{-1}$$

$$\Phi = \left(\vec{\phi}(\vec{x}_1), \dots, \vec{\phi}(\vec{x}_n) \right)$$

トンプソンサンプリング

- ・ 事後分布に従って係数ベクトルを一つサンプリングして w^* とする
- ・ トンプソンサンプリングにおいて、 x における獲得関数 $TS(x)$ は、 y の事後分布からのサンプリング値 y^* になるが、これは次の単純な形になる

$$y^* = \vec{w}^* \cdot \vec{\phi}(\vec{x})$$

- ・ ひとたび w^* を決めてしまえば、獲得関数の計算が $O(M)$ ができる

w^* のサンプリング

- w の事後分布を簡単に書くために、次のM次元対称行列A を導入する

$$A = \frac{1}{\sigma^2} \Phi \Phi^T + I$$

- w の事後分布は $p(\vec{w}|D) = N\left(\frac{1}{\sigma^2} A^{-1} \Phi \vec{y}, A^{-1}\right)$
- Aの逆行列計算はnaive には $O(M^3)$
- データが増えた場合、A の更新は Φ に列が増えることによってなされる

$$A' = A + \frac{1}{\sigma^2} \vec{\phi}(\vec{x}') \vec{\phi}(\vec{x}')^T$$

- あらかじめA をコレスキーフィー分解 ($A=L^T L$) しておくことで A^{-1} の計算コストが $O(M^2)$ になる