

Гауссовские процессы в машинном обучении

Вячеслав Боровицкий (СПбГУ, ПОМИ РАН)

24 сентября 2020 г.

Структура презентации

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение

Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение

Гауссовские процессы: много миров

Теоретический мир, например

L_2 -small ball asymptotics for a family of
finite-dimensional perturbations of Gaussian functions

Petrova Yu.P.*

Прикладной мир, например

Efficiently Sampling Functions from Gaussian Process Posteriors

James T. Wilson^{*1} Viacheslav Borovitskiy^{*23} Alexander Terenin^{*1}
Peter Mostowsky^{*2} Marc Peter Deisenroth⁴

Гауссовские процессы в ML: одно из приложений

Байесовская оптимизация — алгоритм оптимизации, основанный на гауссовских процессах.

Bayesian Optimization in AlphaGo

**Yutian Chen, Aja Huang, Ziyu Wang, Ioannis Antonoglou, Julian Schrittwieser,
David Silver & Nando de Freitas**

DeepMind, London, UK
yutianc@google.com

Была использована для подбора гиперпараметров алгоритма, который в марте 2016 со счётом 4:1 победил в игру Го профессионала 9-го (высшего) дана Ли Седоля.

Содержание

- 1 Введение
- 2 Байесовский вывод**
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение

Теорема Байеса

Пусть Θ и \mathcal{D} — случайные величины. Тогда

$$\underbrace{\mathbb{P}(\Theta = \theta \mid \mathcal{D} = d)}_{\text{Апостериорное распр.}} = \frac{\overbrace{\mathbb{P}(\mathcal{D} = d \mid \Theta = \theta)}^{\text{Правдоподобие}} \overbrace{\mathbb{P}(\Theta = \theta)}^{\text{Априорное распр.}}}{\underbrace{\mathbb{P}(\mathcal{D} = d)}_{\text{Нормализующая константа}}}.$$

Наиболее распространенная в байесовской статистике запись формулы:

$$p(\theta \mid d) = \frac{p(d \mid \theta)p(\theta)}{p(d)}.$$

Модель определяется выбором

- априорного распределения $p(\theta)$,
- правдоподобия $p(d \mid \theta)$.

Теорема Байеса при данной модели позволяет вычислить по данным апостериорное распределение на параметры.

Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка**
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение

Байесовский вывод для монетки: теория

Задача: хотим оценить параметры нечестной монетки.

Пусть X — с.в., моделирующая нашу нечестную монетку. Она принимает два значения: 1 (Орел) и 0 (Решка):

$$\mathbb{P}(X = 1) = p, \quad \mathbb{P}(X = 0) = 1 - p.$$

Хотим оценить параметр p (вероятность выпадения Орла).

Frequentist approach

Ответ: конкретное число \hat{p} .

Инструмент: оценка макс. правдоподобия.

Дополнительно: —.

$$\hat{p} = \arg \max p^{\#1} (1 - p)^{\#0}$$

Bayesian approach

Ответ: распределение $\hat{\rho}(p)$.

Инструмент: теорема Байеса.

Дополнительно: априорное распределение $\rho(p)$.

$$\hat{\rho}(p) \propto p^{\#1} (1 - p)^{\#0} \rho(p)$$

Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.



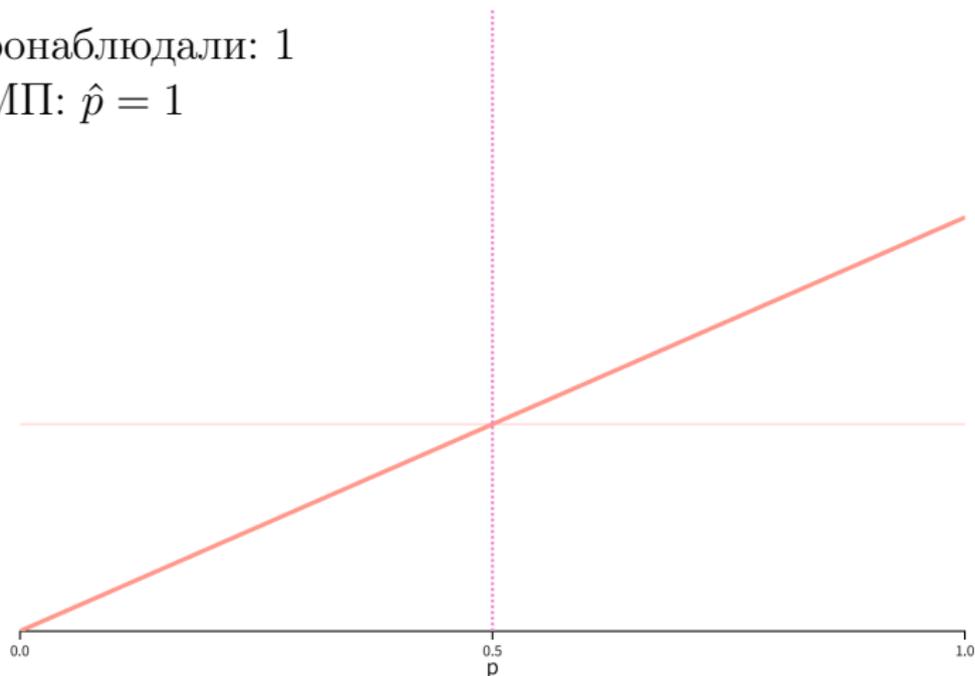
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 1

ОМП: $\hat{p} = 1$



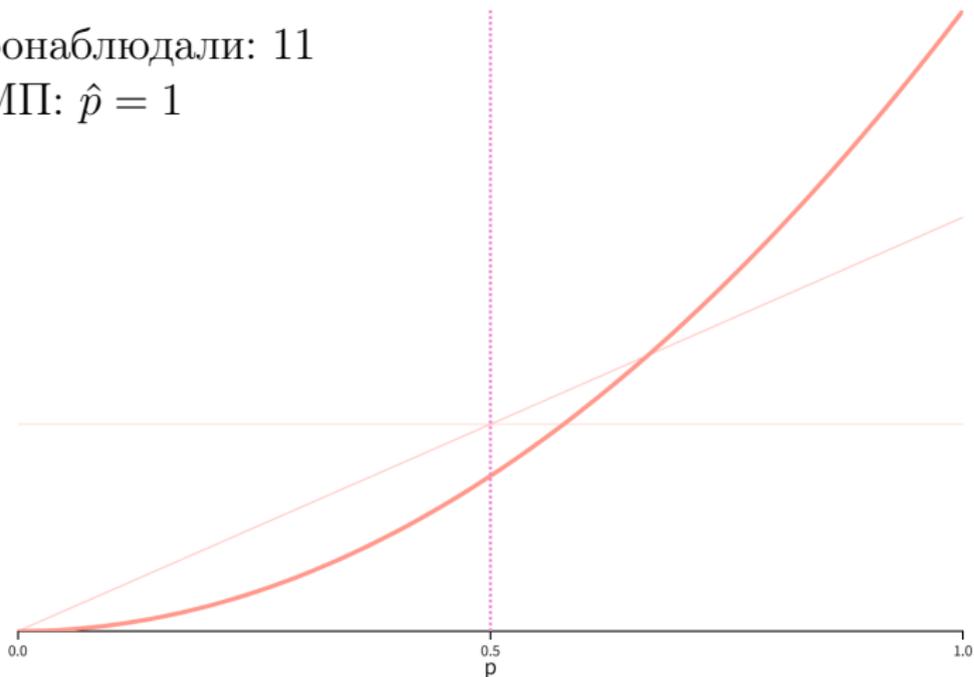
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 11

ОМП: $\hat{p} = 1$



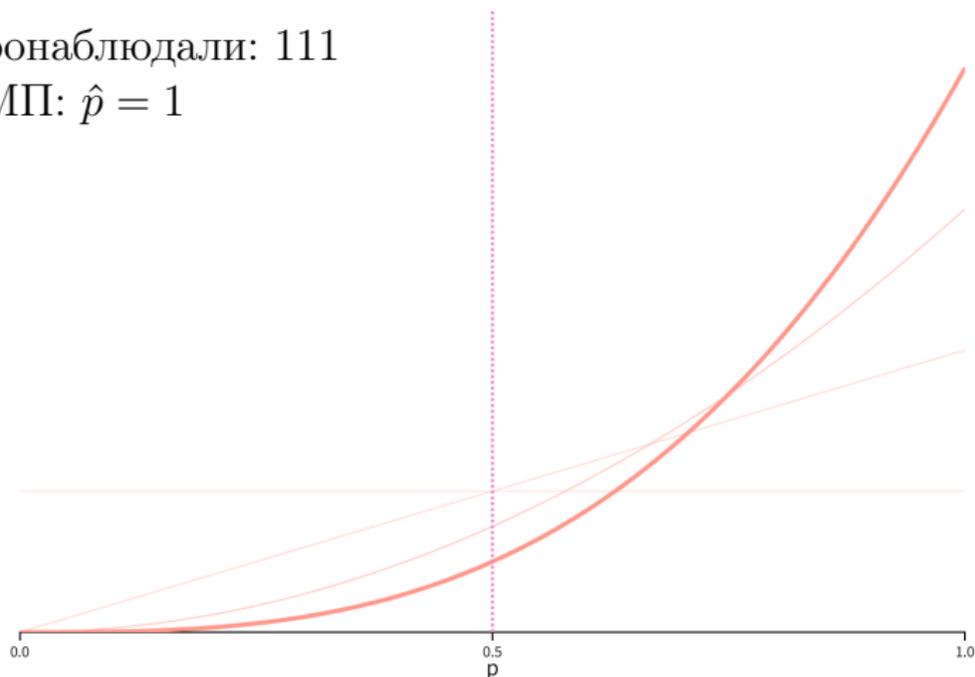
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 111

ОМП: $\hat{p} = 1$



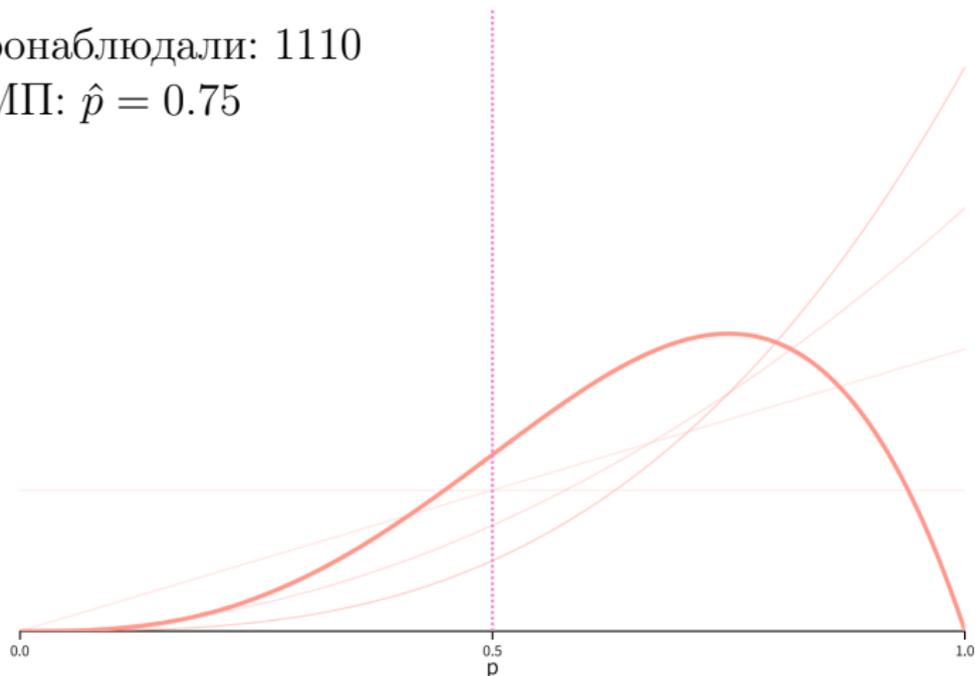
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 1110

ОМП: $\hat{p} = 0.75$



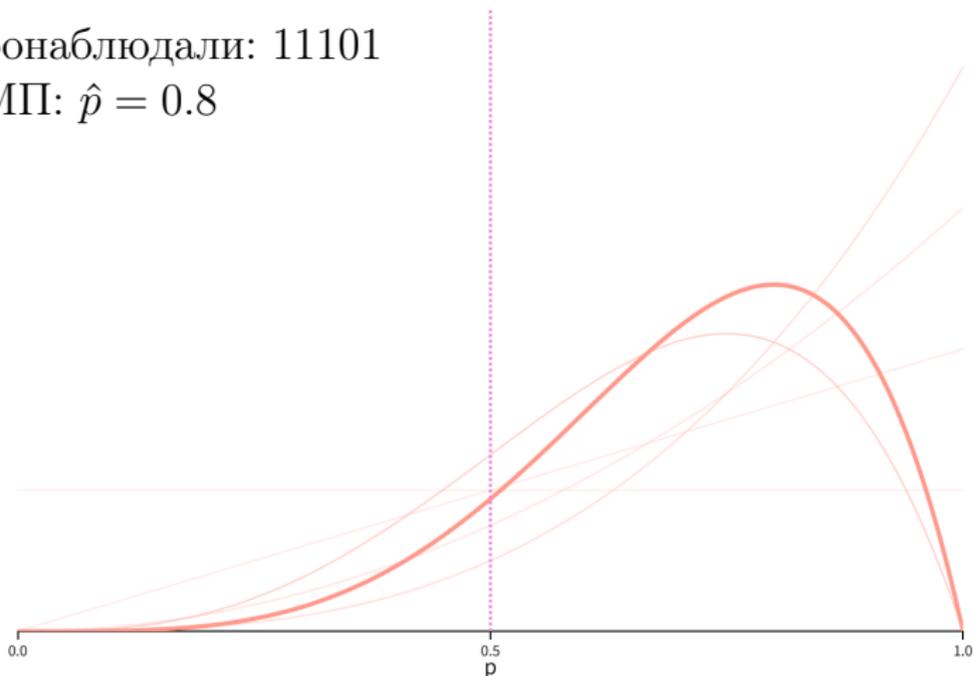
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 11101

ОМП: $\hat{p} = 0.8$



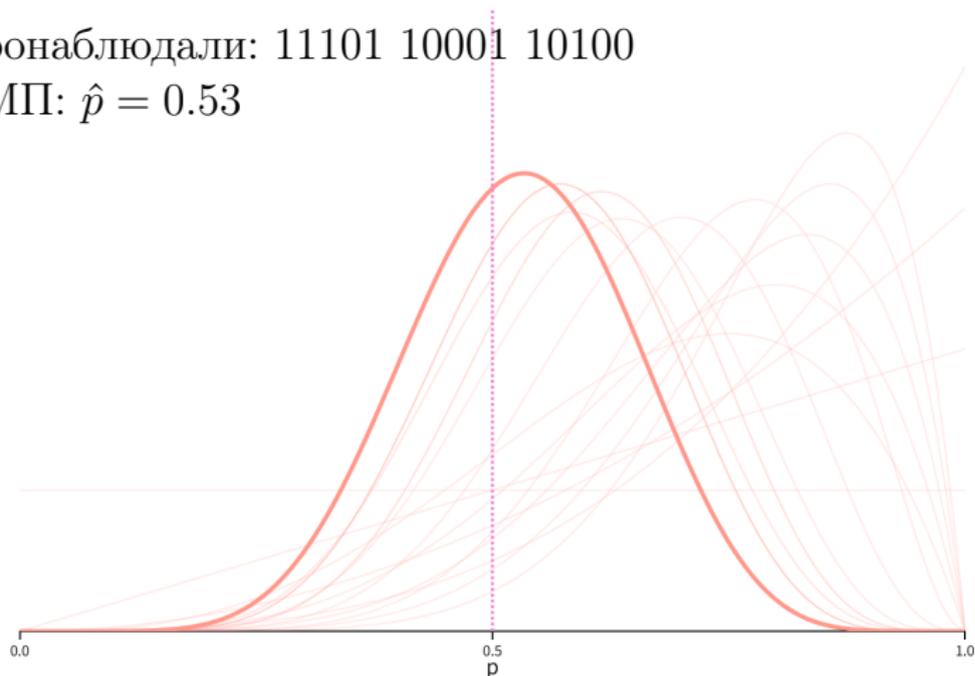
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 11101 10001 10100

ОМП: $\hat{p} = 0.53$



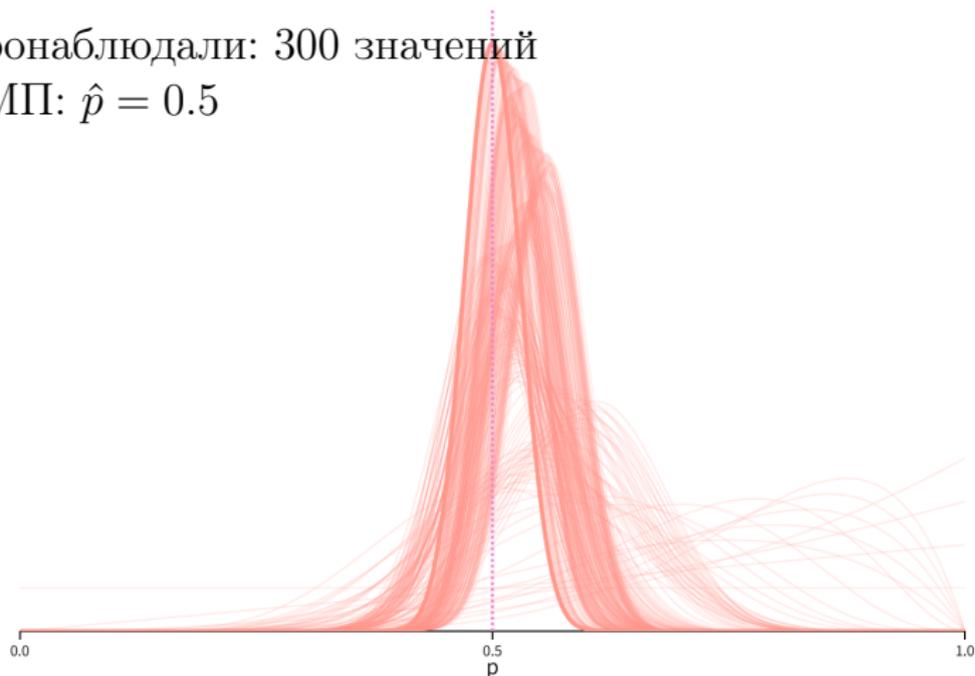
Байесовский вывод для монетки: пример

Пусть $\rho(p) := \mathbb{1}_{[0,1]}(p)$ — равномерное распределение на $[0, 1]$, то есть априори мы ничего не знаем о параметре p .

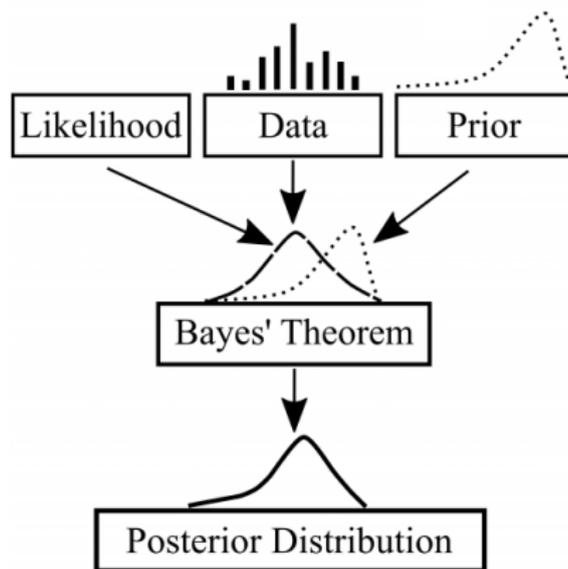
Пусть истинное значение p равно 0.5 , т.е. монетка честная.

Пронаблюдали: 300 значений

ОМП: $\hat{p} = 0.5$



Байесовский вывод для монетки: ИТОГ



Важнейшим преимуществом байесовского подхода является оценка неопределенности. Менее чуши с уверенным лицом.

Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы**
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение

Байесовский вывод для ГП: суть

Гауссовский процесс — распределение на функциях.

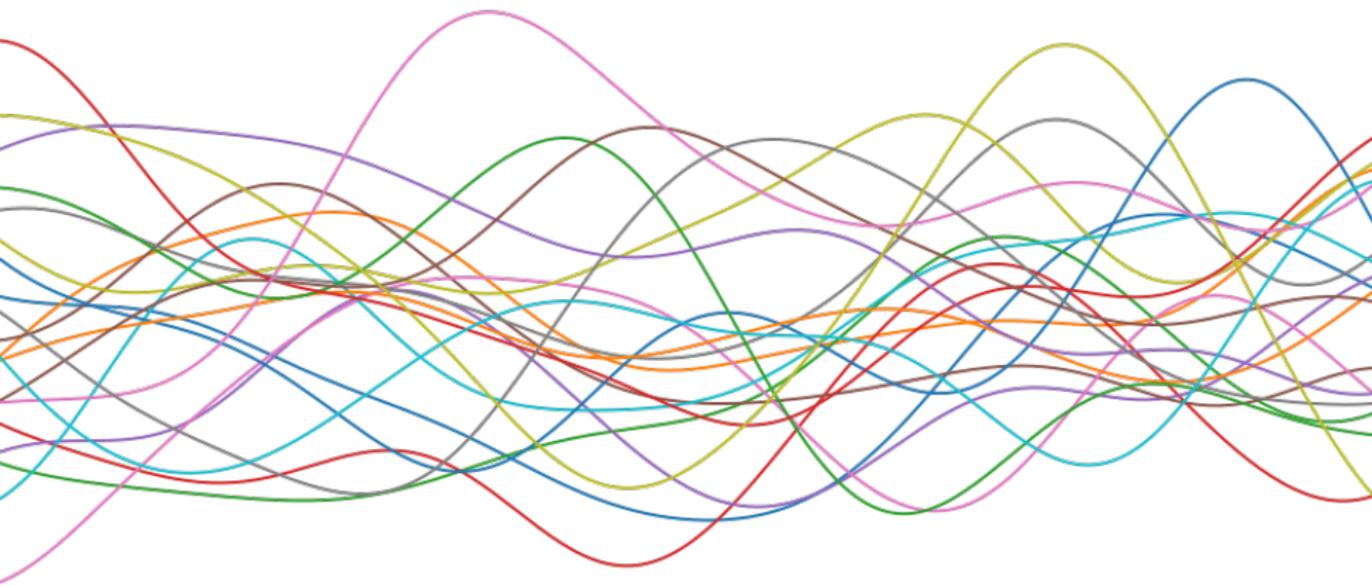
Модель:

- Априорное распределение: гауссовский процесс.
- Правдоподобие задается нормальным распределением.

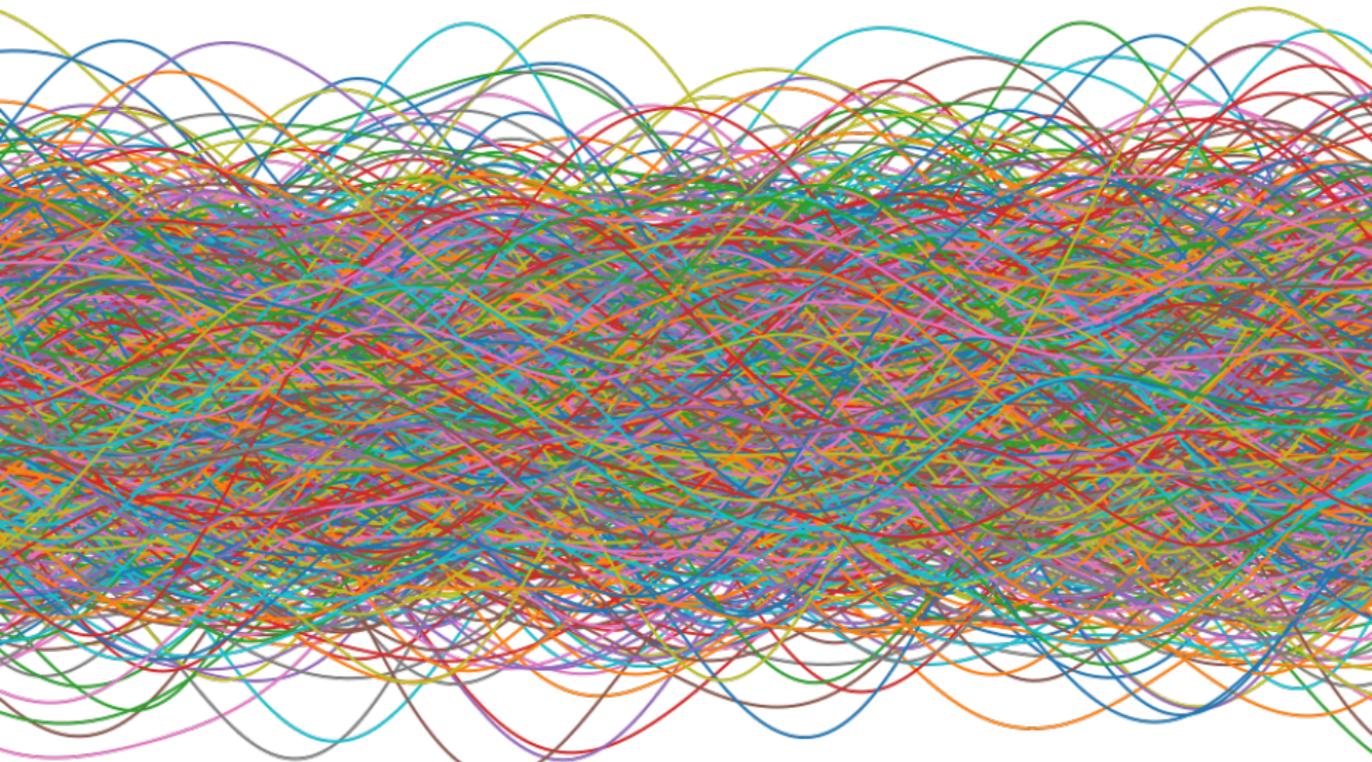
Данные: значения функции в каких-то точках.

Результат (апостериорное распределение): тоже гауссовский процесс, но другой.

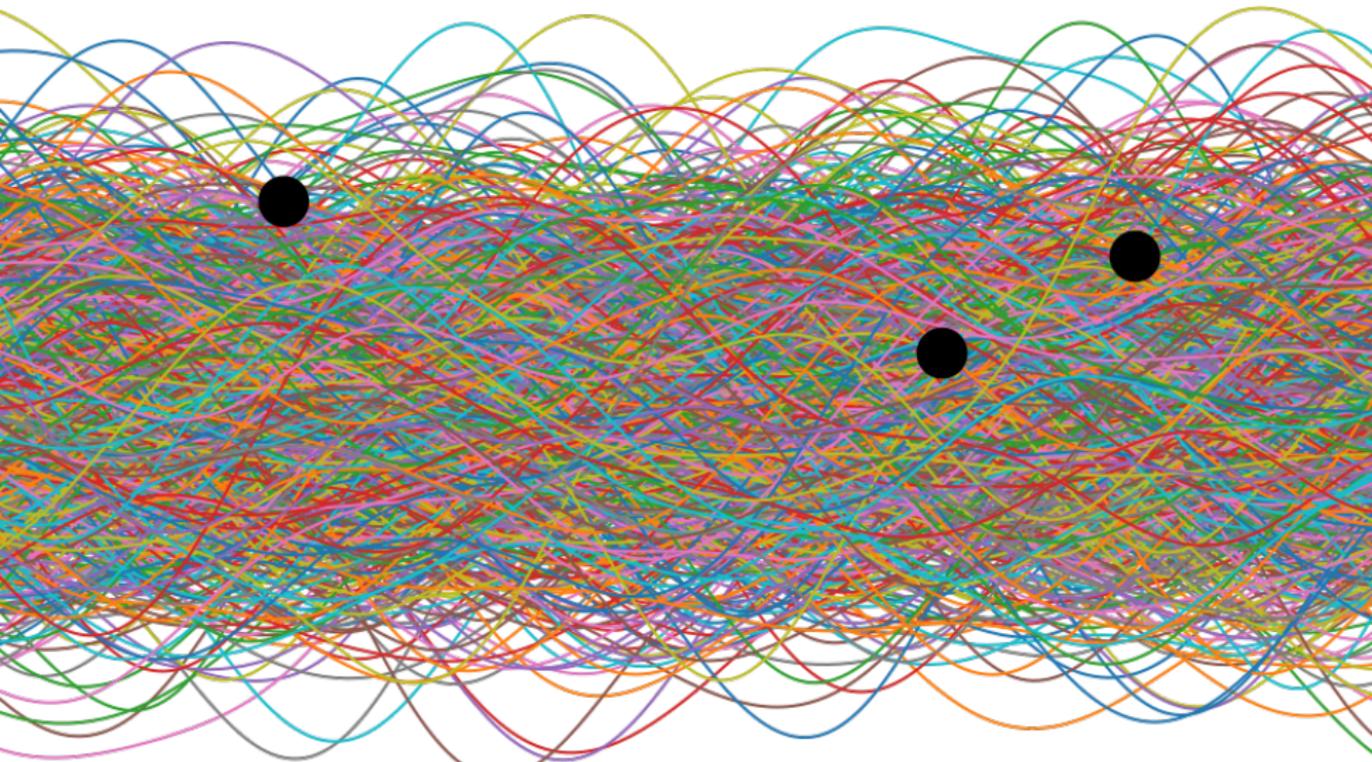
Байесовский вывод для ГП: иллюстрация



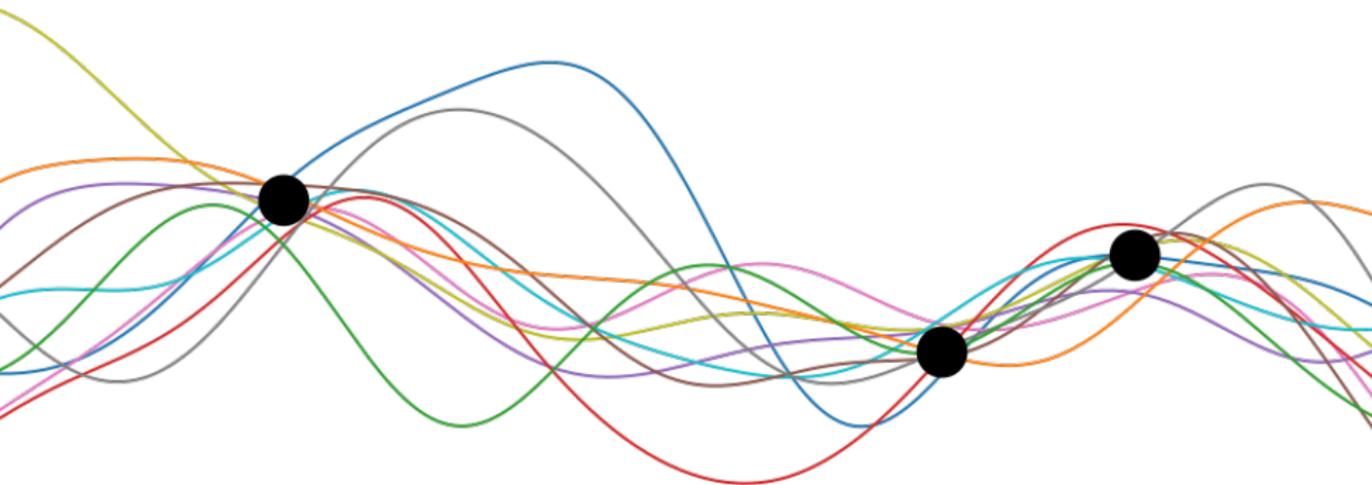
Байесовский вывод для ГП: иллюстрация



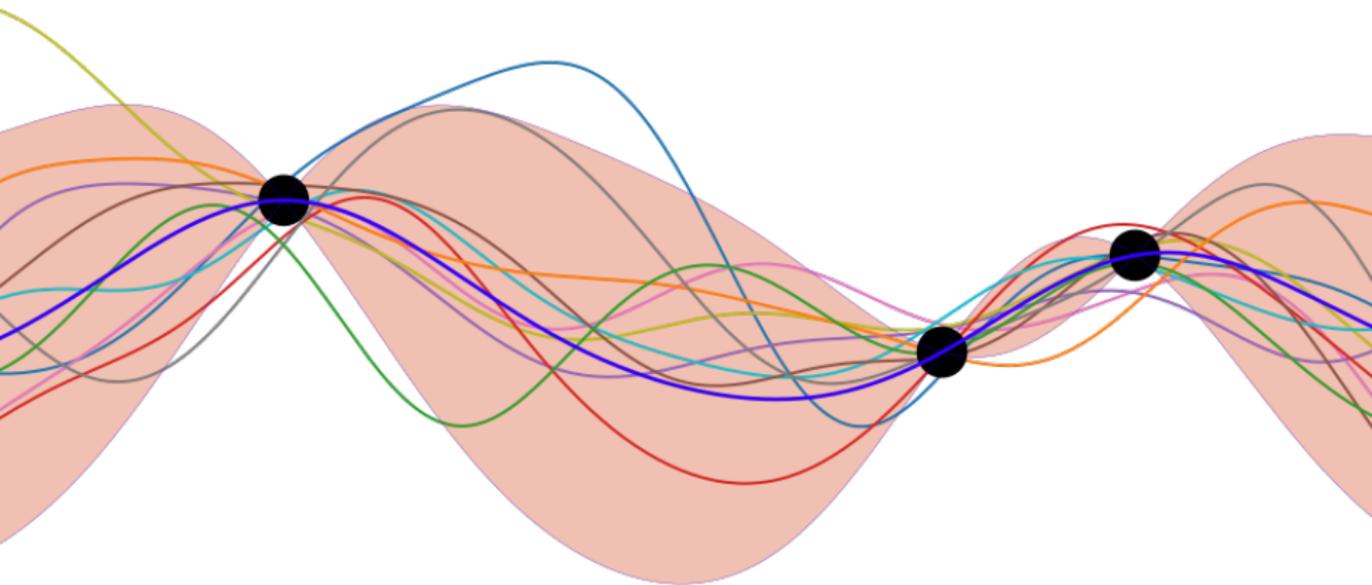
Байесовский вывод для ГП: иллюстрация



Байесовский вывод для ГП: иллюстрация



Байесовский вывод для ГП: иллюстрация



Байесовский вывод для ГП: что такое ГП?

Гауссовское распределение

- распределение на \mathbb{R} , обозначается $N(\mu, \sigma^2)$,
- определяется двумя числами: средним μ и дисперсией σ^2 .

Многомерное гауссовское распределение

- распределение на \mathbb{R}^d , обозначается $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$,
- определяется вектором средних $\boldsymbol{\mu}$ и матрицей ковариаций $\boldsymbol{\Sigma}$.

Гауссовский процесс

- распределение функций из X в \mathbb{R} , обозначается $GP(m, k)$,
- определяется функциями $m : X \rightarrow \mathbb{R}$ (средним) и $k : X \times X \rightarrow \mathbb{R}$ (ковариацией).

Гауссовский процесс — одно из многих распределений на функциях (случайных процессов).

Оно выделяется простотой вычислений.

Байесовский вывод для ГП: главное

Байесовский вывод для ГП по

- априорному распределению на функции вида $GP(m, k)$,
- значениям y_1, \dots, y_n моделируемой функции в точках x_1, \dots, x_n , “измеренным” с точн. до шума с дисперсией σ^2 .

дает апостериорное распределение на функции, которое имеет вид

$$GP(\hat{m}, \hat{k}).$$

Значения функций \hat{m} и \hat{k} пересчитываются из значений функций m и k за конечное время. Более точно:

$$\begin{aligned}\tilde{m}(u) &= m(u) + \mathbf{K}_{f(u)f(x)} \left(\mathbf{K}_{f(x)f(x)} + \sigma^2 I \right)^{-1} (\mathbf{y} - m(\mathbf{x})) \\ \tilde{k}(u, v) &= k(u, v) - \underbrace{\mathbf{K}_{f(u)f(x)}}_{\text{вектор } 1 \times n} \underbrace{\left(\mathbf{K}_{f(x)f(x)} + \sigma^2 I \right)^{-1}}_{\text{матрица } n \times n} \underbrace{\mathbf{K}_{f(x)f(v)}}_{\text{вектор } n \times 1}.\end{aligned}$$

Байесовский вывод для ГП: алгоритм

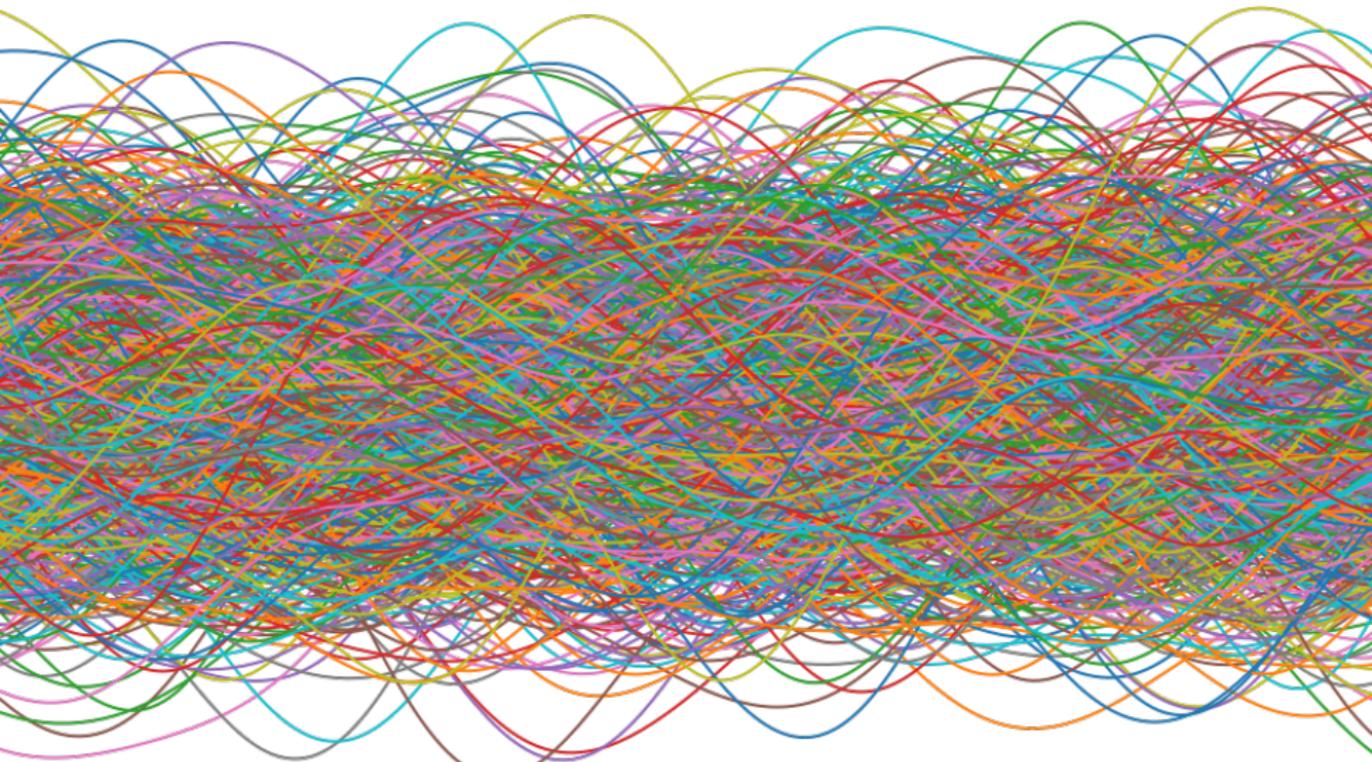
Как получить по данным $(x_1, y_1), \dots, (x_n, y_n)$ разумную стохастическую модель, их интерполирующую?

- 1 Взять с неба априорное среднее m и параметрическое семейство k_θ априорных ковариационных функций.
- 2 По данным $(x_1, y_1), \dots, (x_n, y_n)$ выбрать оптимальное значение параметров θ и шума σ^2 .
- 3 Байесовский вывод с априорными m и k_θ по данным $(x_1, y_1), \dots, (x_n, y_n)$ с шумом σ^2 .
В результате имеем апостериорные \tilde{m} и \tilde{k} .
- 4 Использовать
 - ▶ $N(\tilde{m}(u), \tilde{k}(u, u))$ как стохастический прогноз в точке u .
 - ▶ сэмплы апостериорного процесса $GP(\tilde{m}, \tilde{k})$ как ансамбль возможных детерминистических моделей.

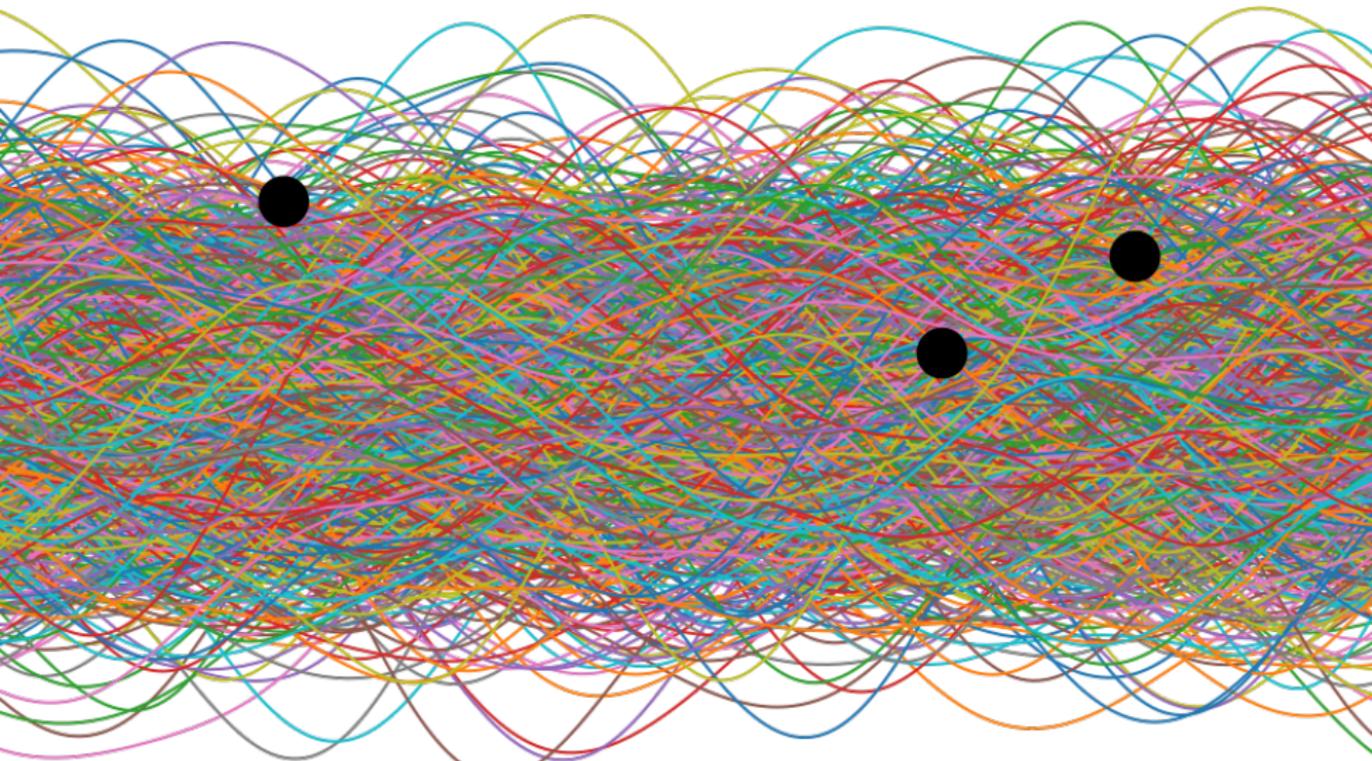
Байесовский вывод для ГП: иллюстрация



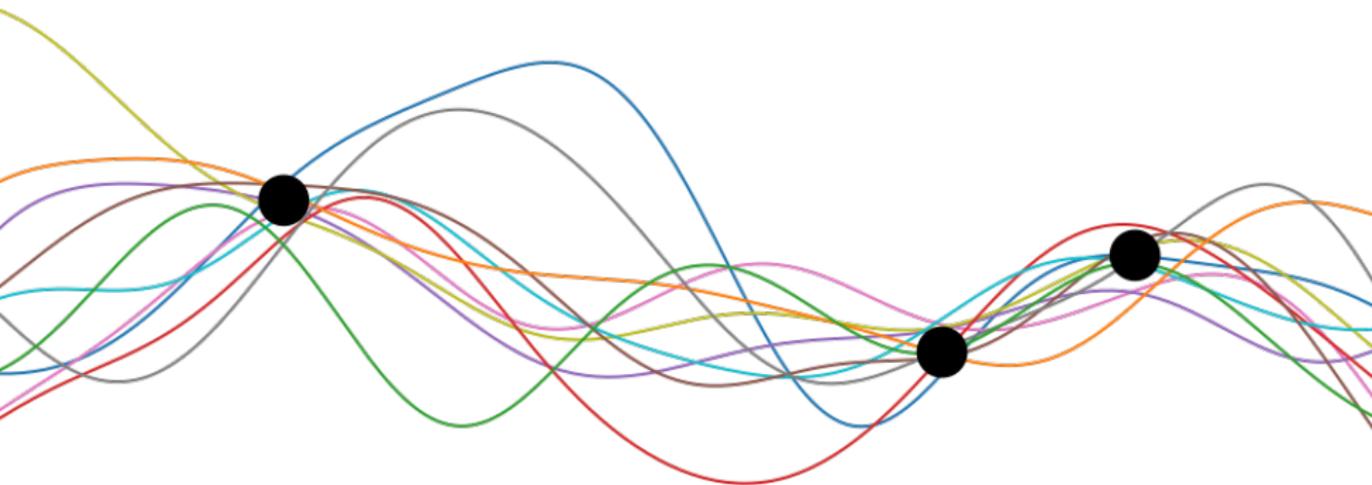
Байесовский вывод для ГП: иллюстрация



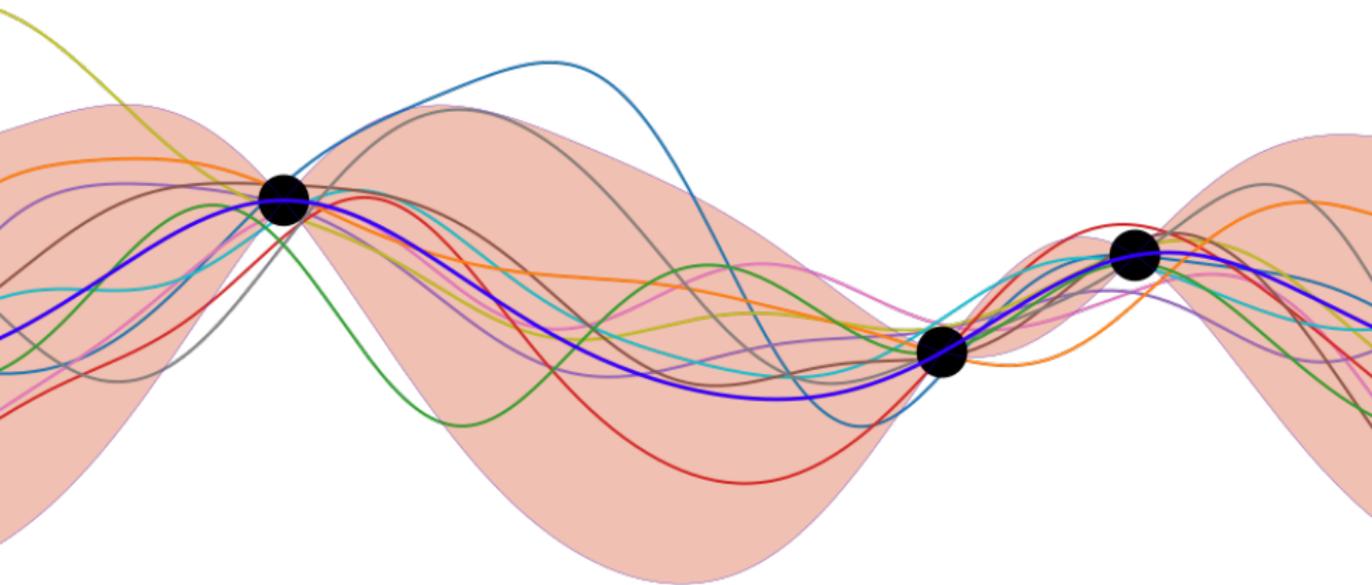
Байесовский вывод для ГП: иллюстрация



Байесовский вывод для ГП: иллюстрация



Байесовский вывод для ГП: иллюстрация



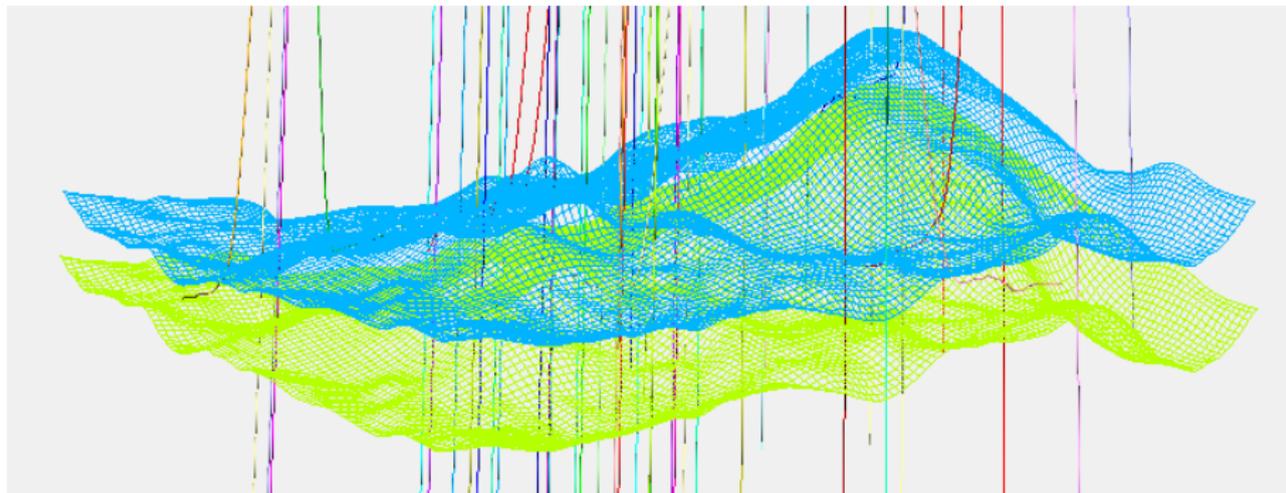
Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений**
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение

Геостатистическое моделирование

Задача: интерполяция данных со скважин в межскважинное пространство.

Данных очень мало, поэтому детерминистический прогноз – плохо, а стохастический – хорошо.

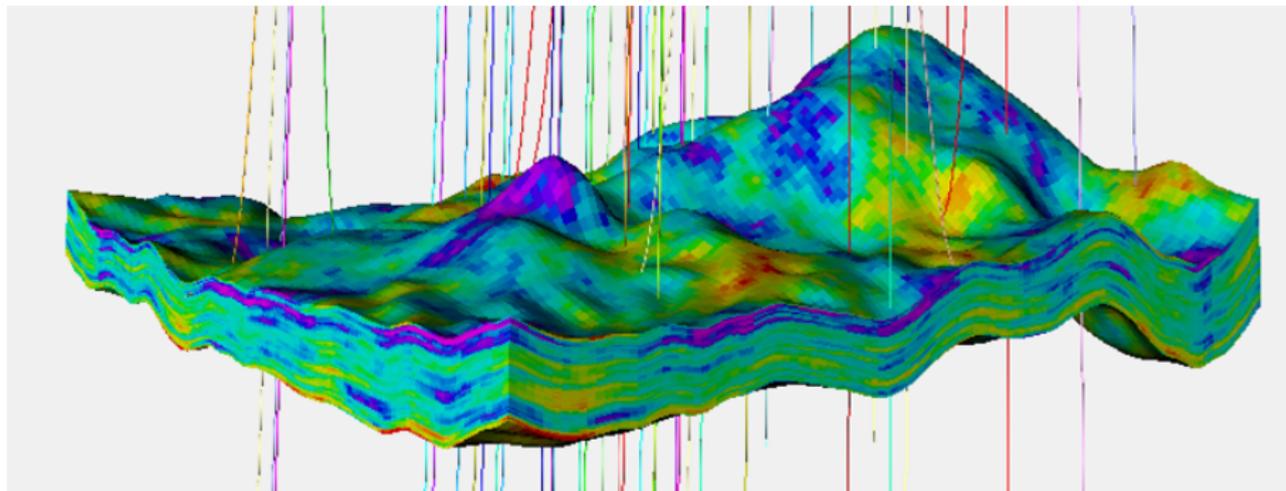


Структура пласта, расположение скважин.

Геостатистическое моделирование

Задача: интерполяция данных со скважин в межскважинное пространство.

Данных очень мало, поэтому детерминистический прогноз – плохо, а стохастический – хорошо.



Сэмпл гауссовского процесса в межскважинном пространстве

Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация**
- 7 Приложения: роботы
- 8 Заключение

Байесовская оптимизация: суть

Задача: минимизация сложно-вычислимой black-box function.

Пусть на шаге n оптимизируемая функция $\phi : \mathbb{R}^d \rightarrow \mathbb{R}$ вычислена в точках x_1, \dots, x_n . Как выбрать x_{n+1} ?

Строим условный гауссовский процесс f по данным

$$x_1, \dots, x_n, \quad \phi(x_1), \dots, \phi(x_n).$$

Упорядочим x_1, \dots, x_n так, чтобы $\phi(x_1) \geq \phi(x_2) \geq \dots \geq \phi(x_n)$.

Выбираем

$$x_{n+1} = \arg \max_{x \in \mathbb{R}^d} \mathbb{P}(f(x) < \phi(x_n)). \quad (MPI)$$

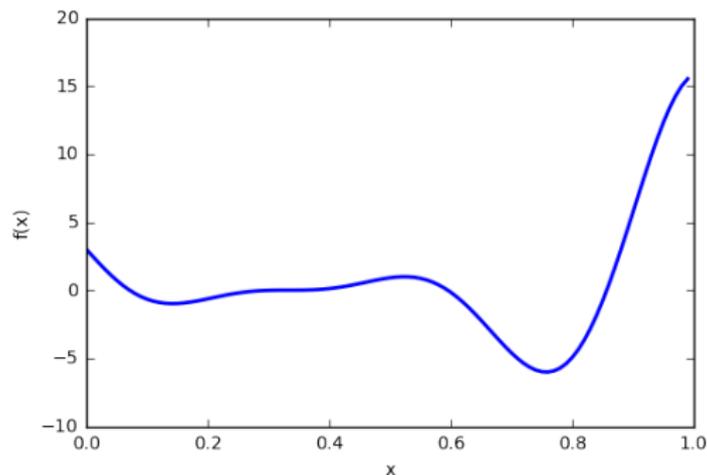
или

$$x_{n+1} = \arg \max_{x \in \mathbb{R}^d} \mathbb{E} \max(\phi(x_n) - f(x), 0). \quad (EI)$$

Автоматический Exploration/exploitation trade-off.

Байесовская оптимизация: пример

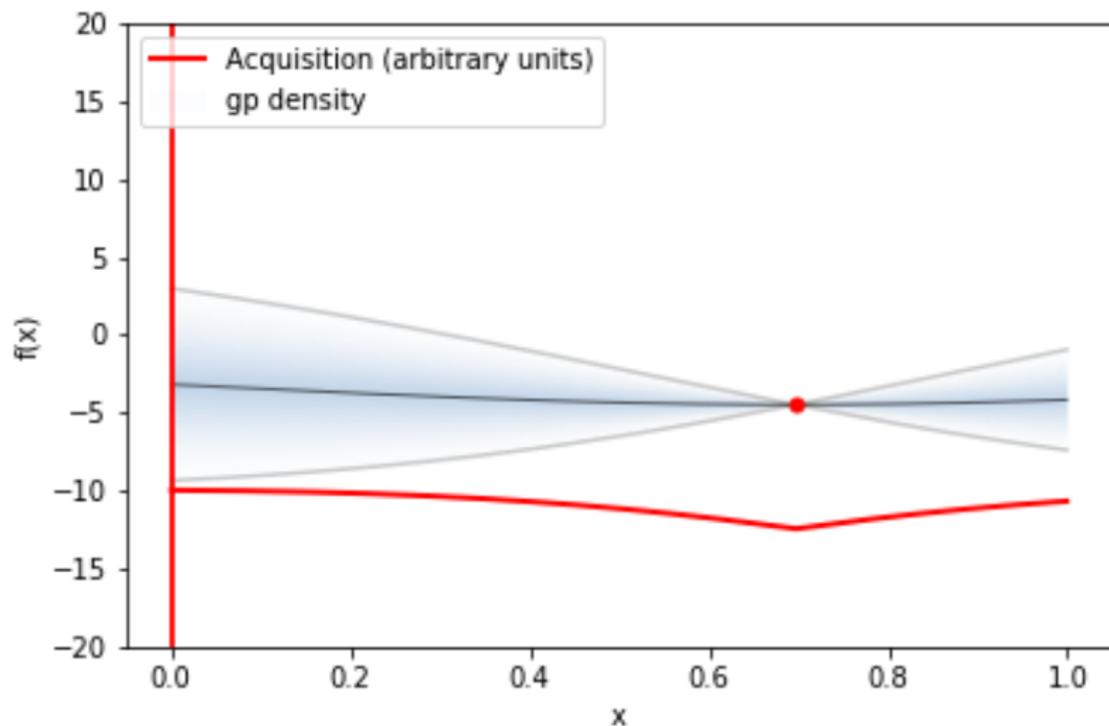
Попробуем найти минимум функции Форрестера $f(x) = (6x - 2)^2 \sin(12x - 4)$.



Априорный процесс выберем как $f_0 \sim \text{GP}(0, \text{Matern}_{5/2})$

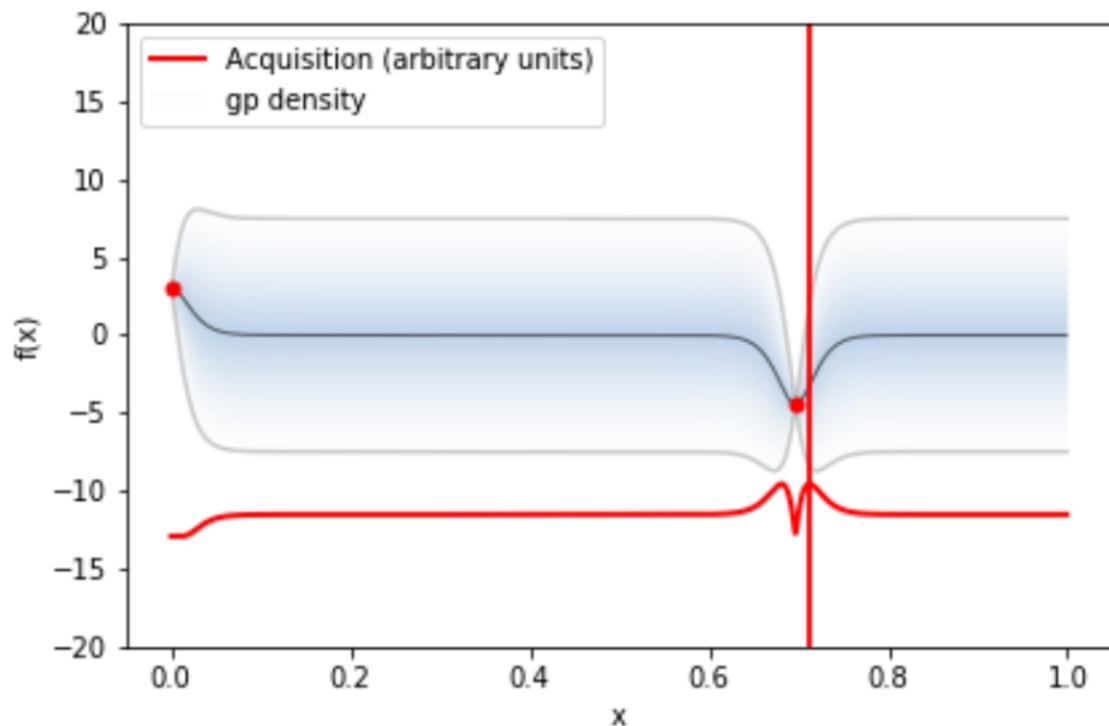
Байесовская оптимизация: пример

Итерация 1.



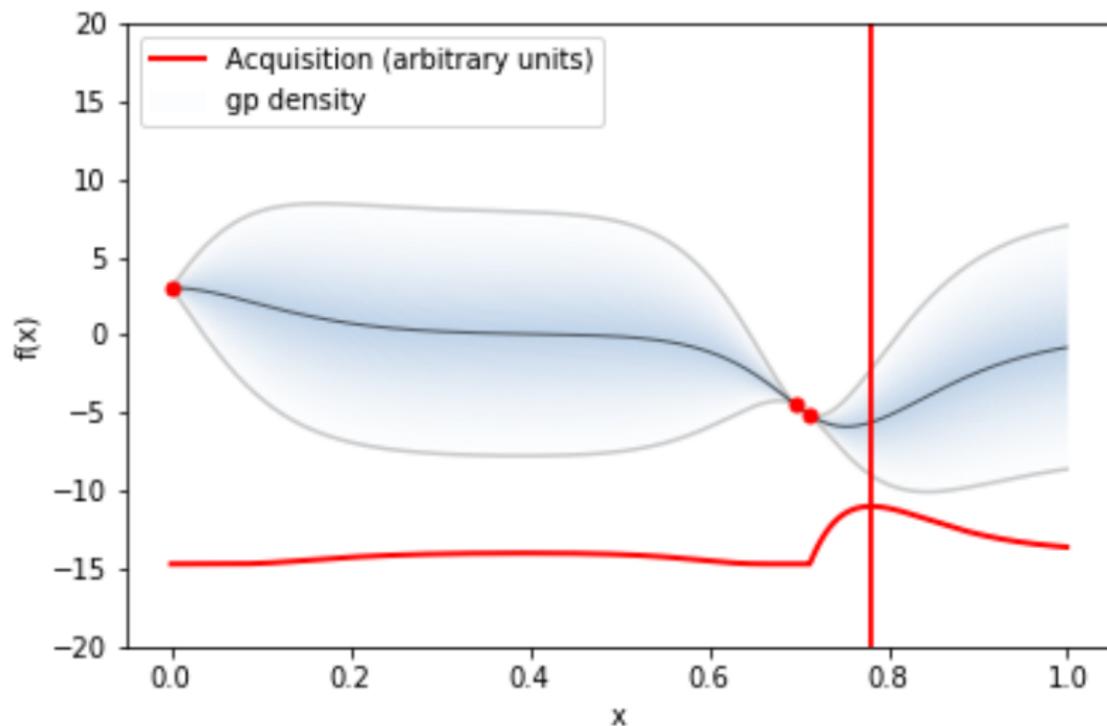
Байесовская оптимизация: пример

Итерация 2.



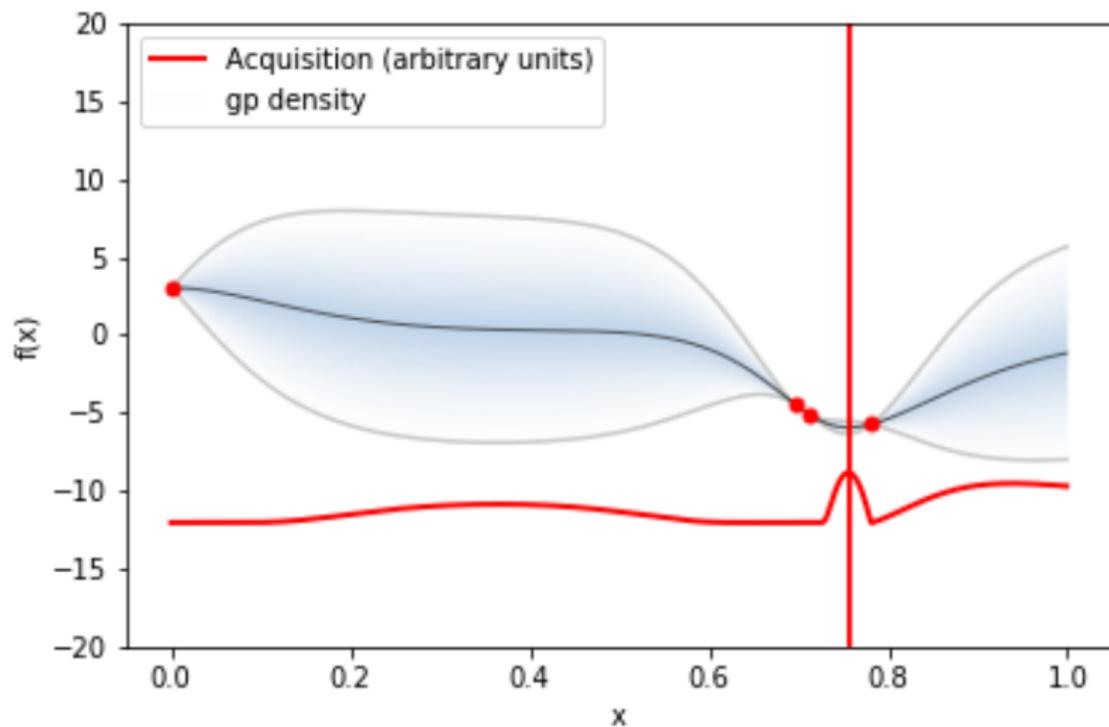
Байесовская оптимизация: пример

Итерация 3.



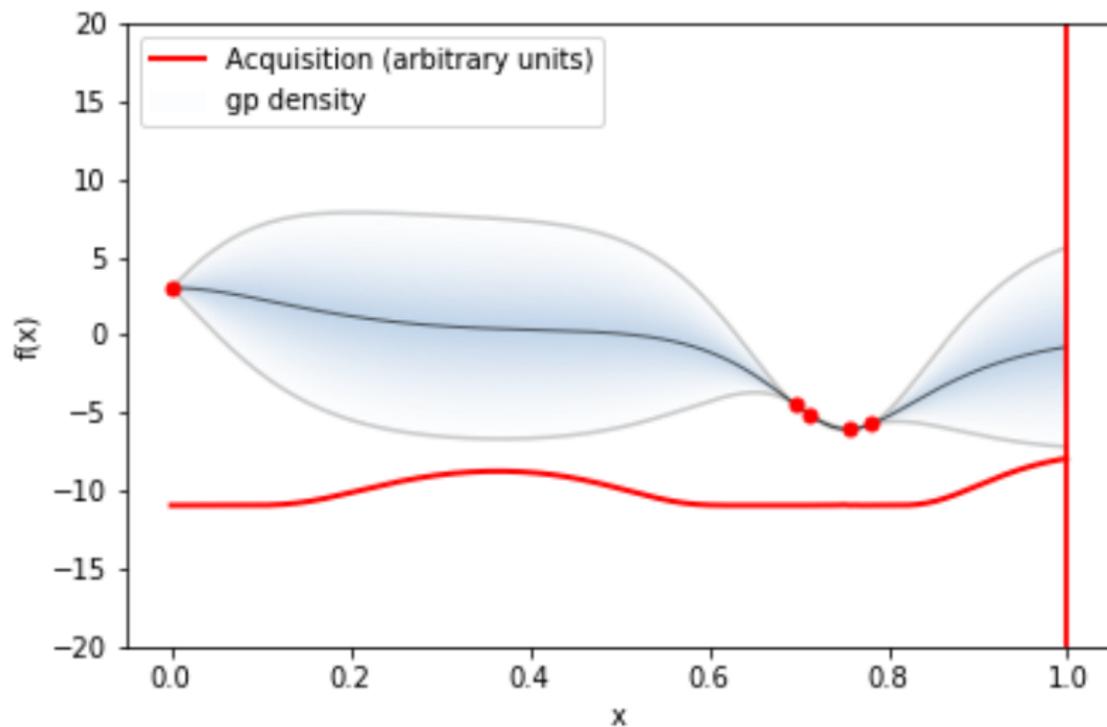
Байесовская оптимизация: пример

Итерация 4.



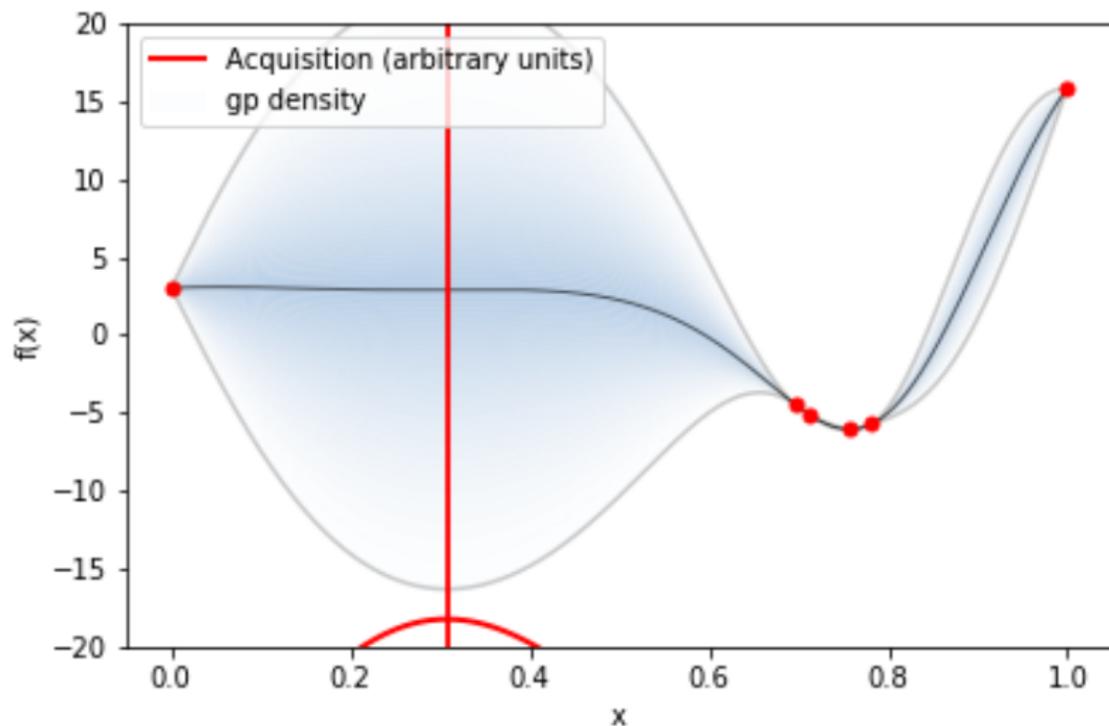
Байесовская оптимизация: пример

Итерация 5.



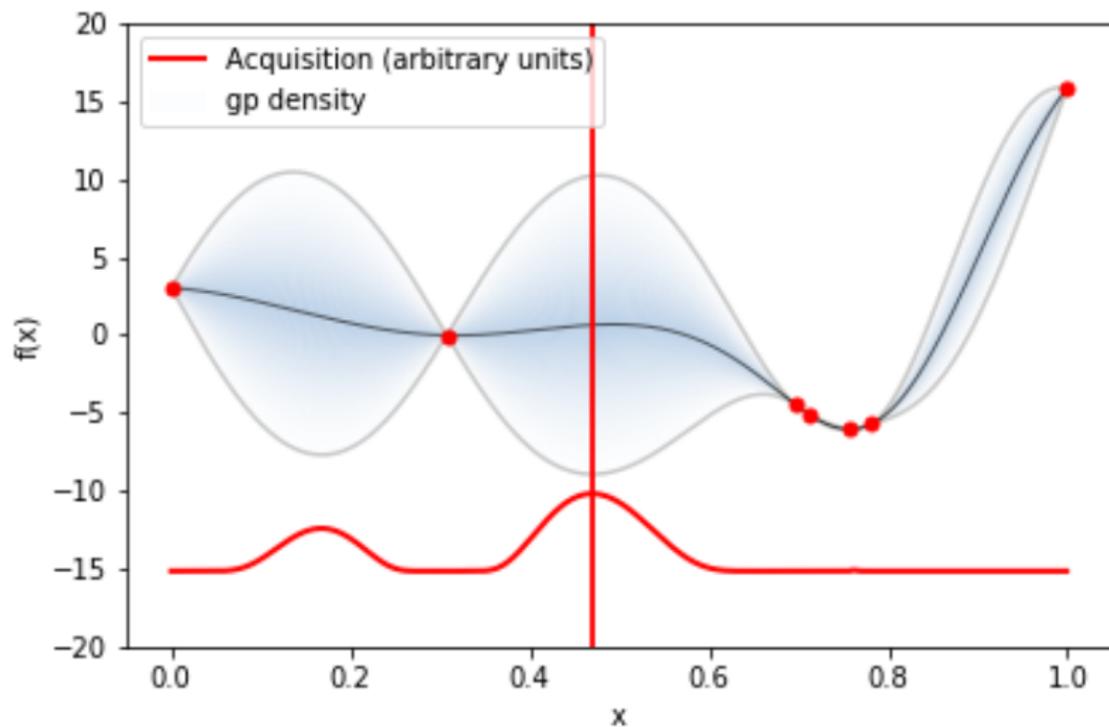
Байесовская оптимизация: пример

Итерация 6.



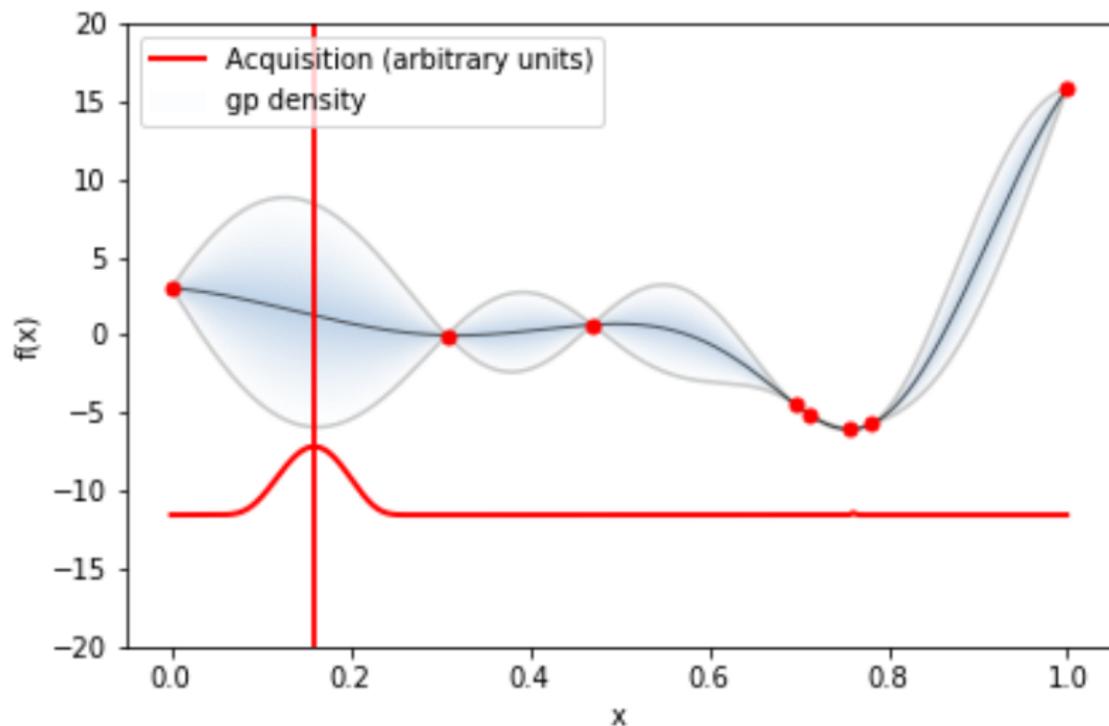
Байесовская оптимизация: пример

Итерация 7.



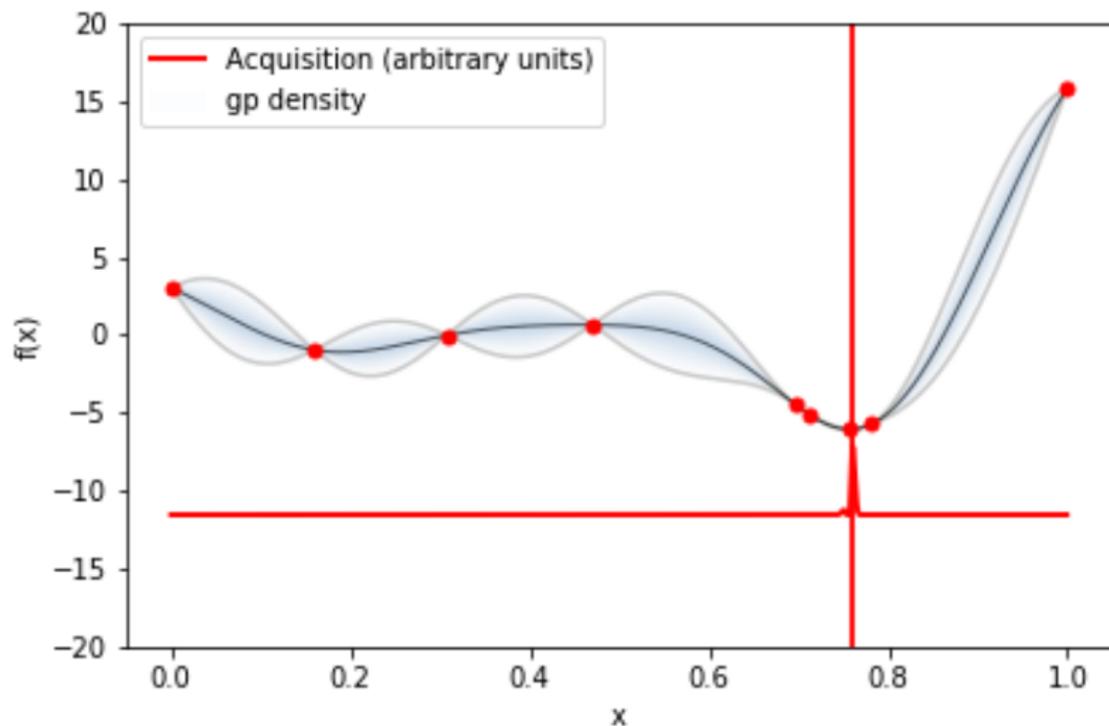
Байесовская оптимизация: пример

Итерация 8.



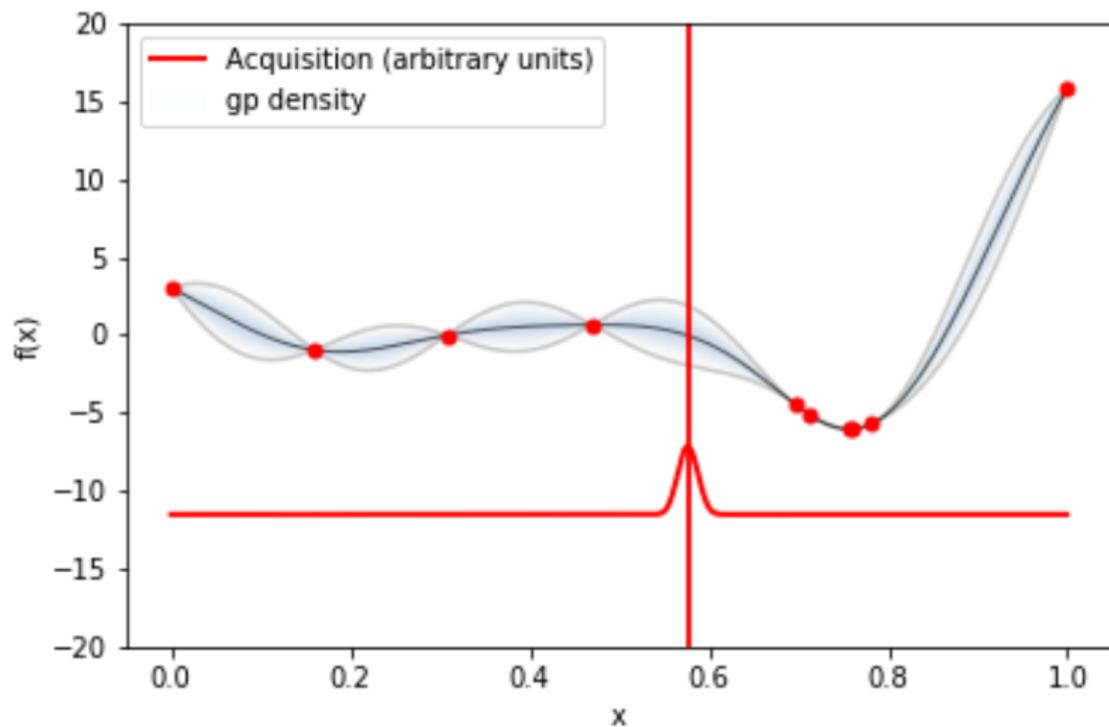
Байесовская оптимизация: пример

Итерация 9.



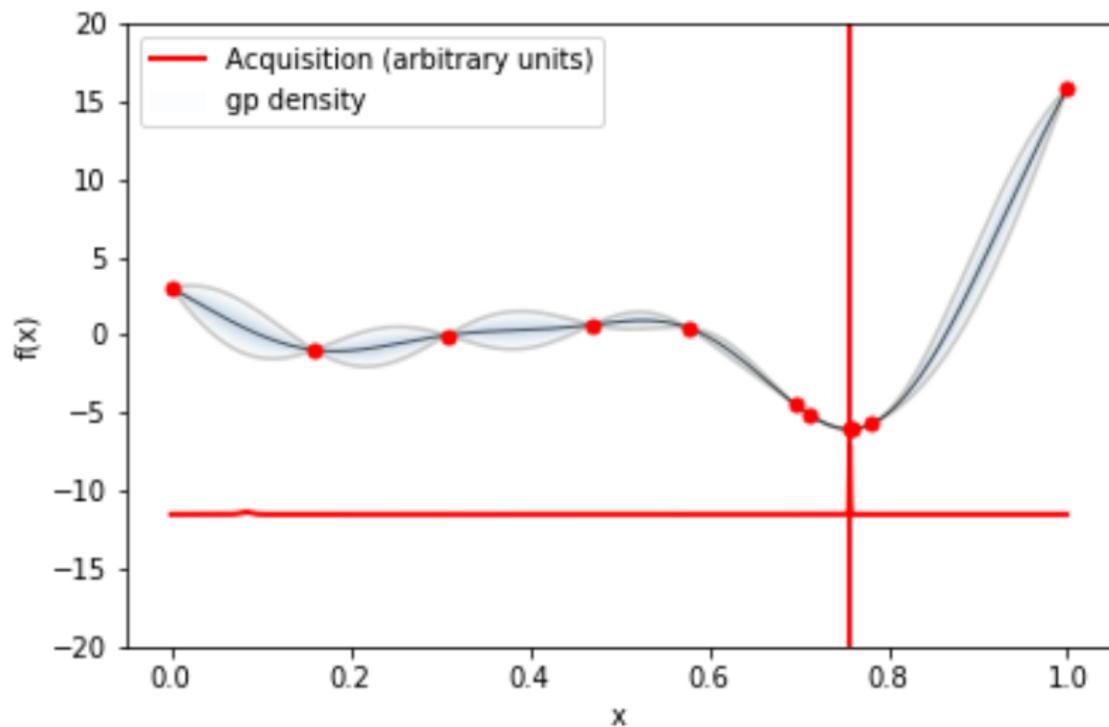
Байесовская оптимизация: пример

Итерация 10.



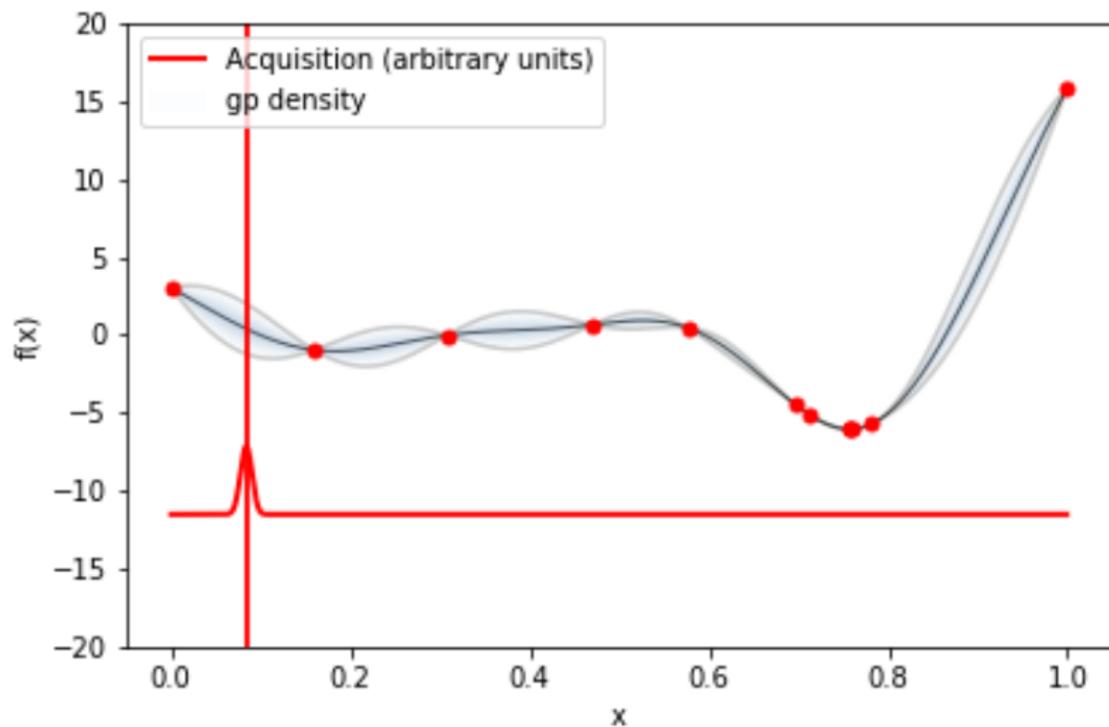
Байесовская оптимизация: пример

Итерация 11.



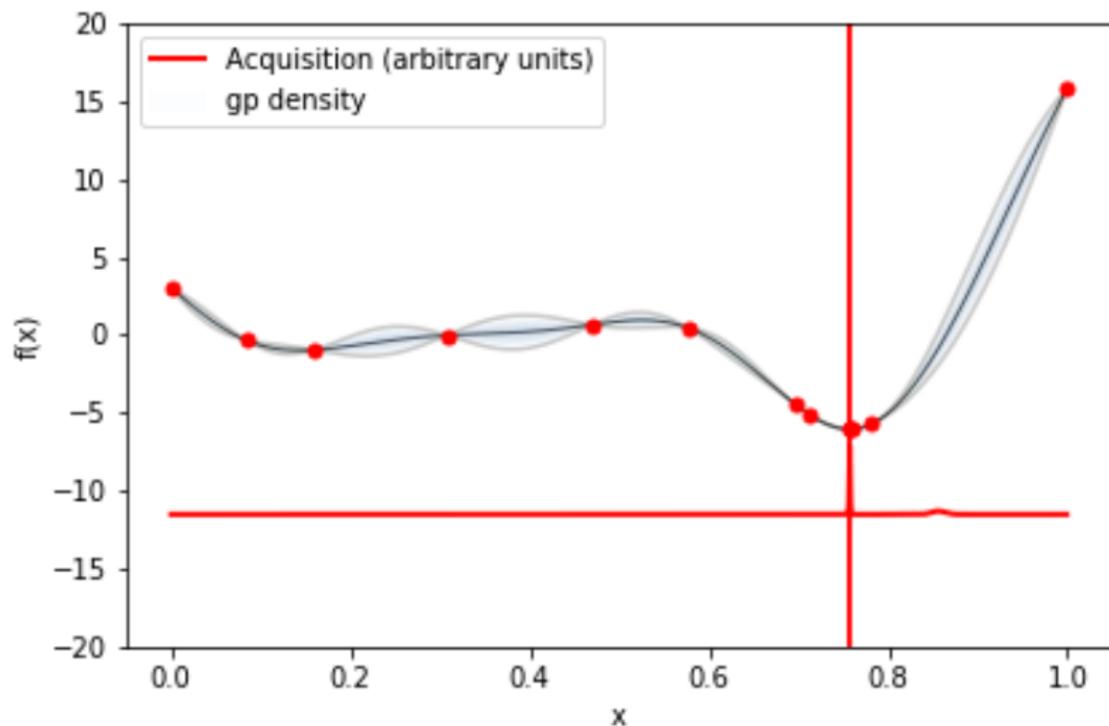
Байесовская оптимизация: пример

Итерация 12.



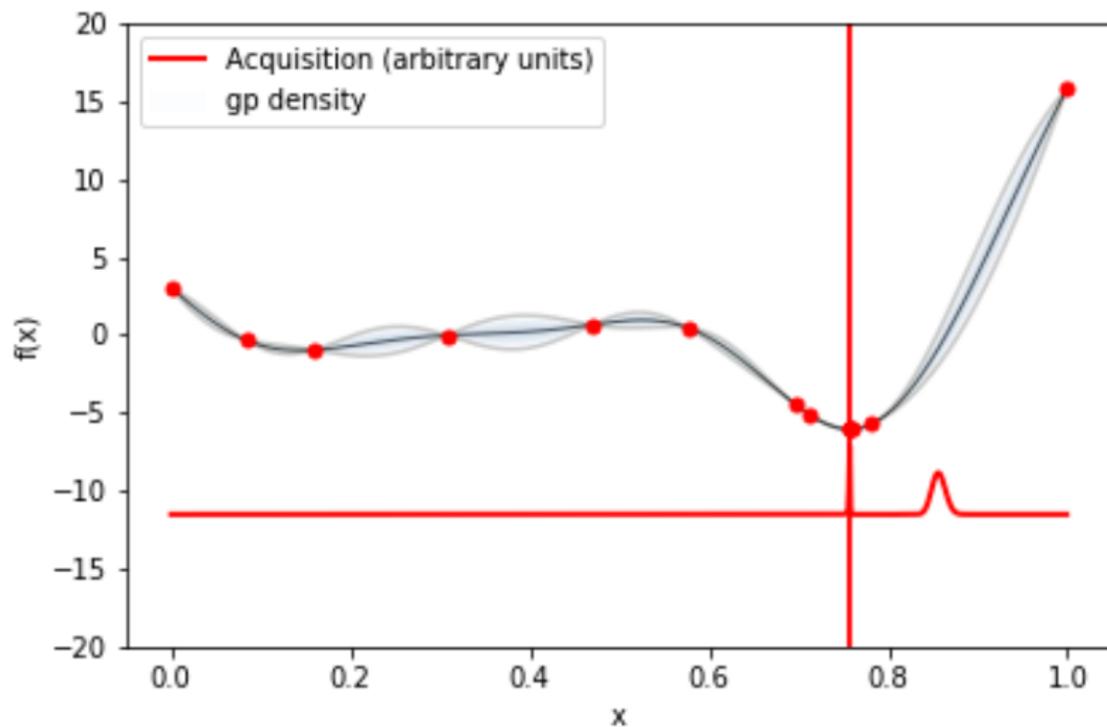
Байесовская оптимизация: пример

Итерация 13.



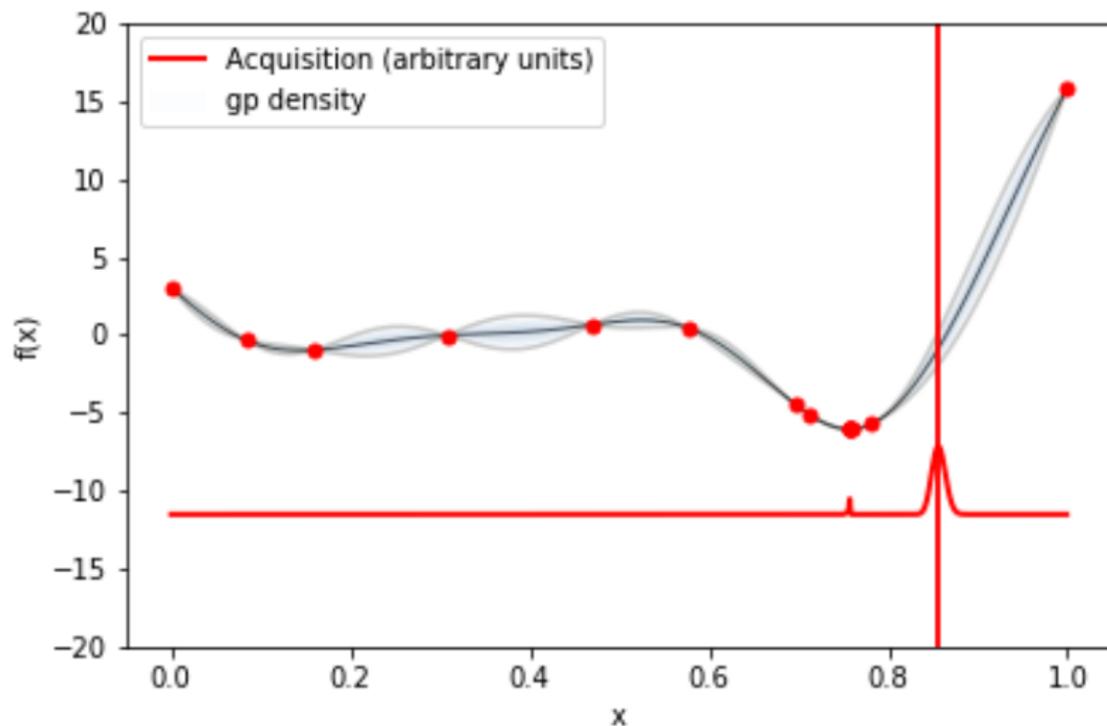
Байесовская оптимизация: пример

Итерация 14.



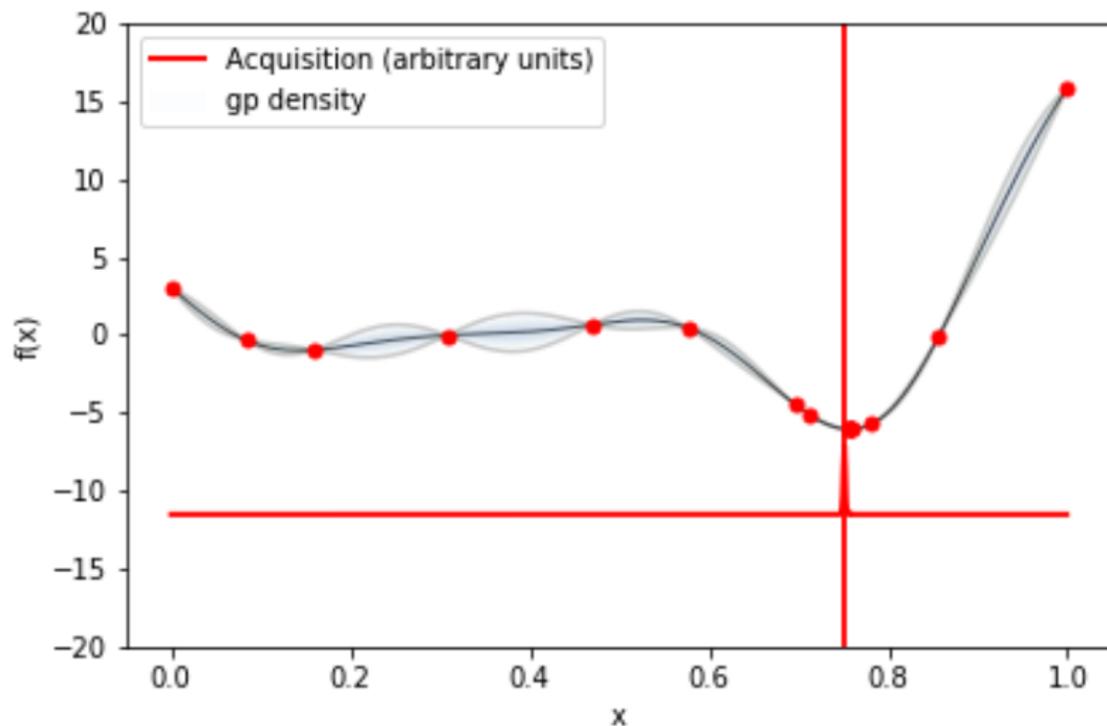
Байесовская оптимизация: пример

Итерация 15.



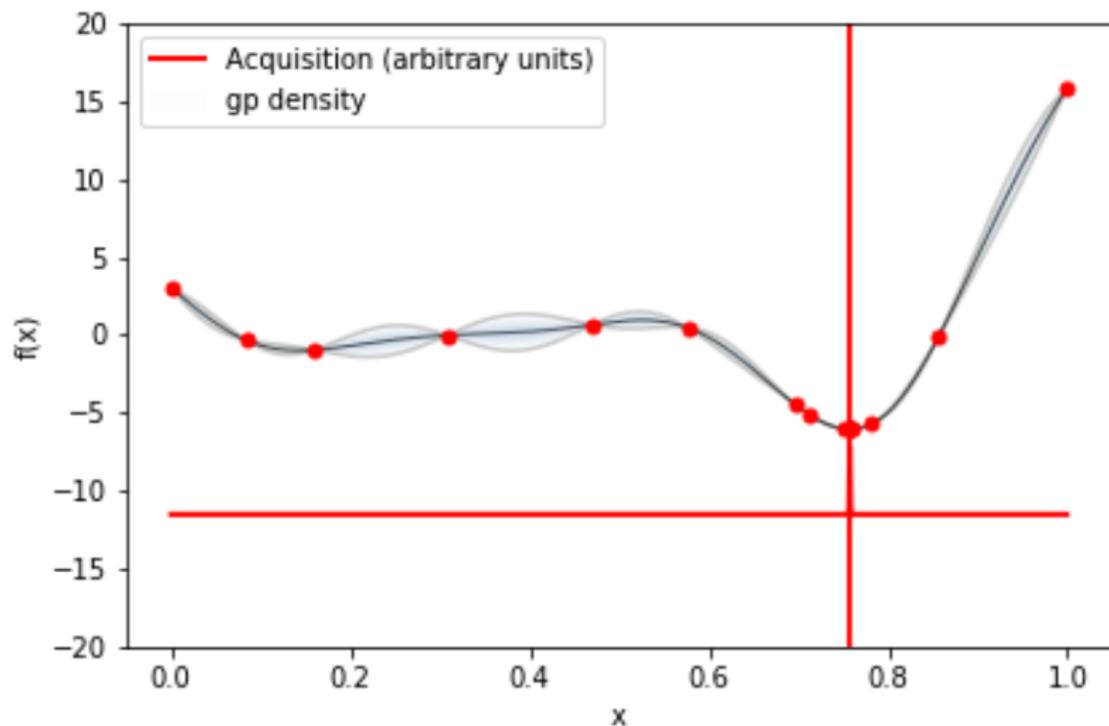
Байесовская оптимизация: пример

Итерация 16.



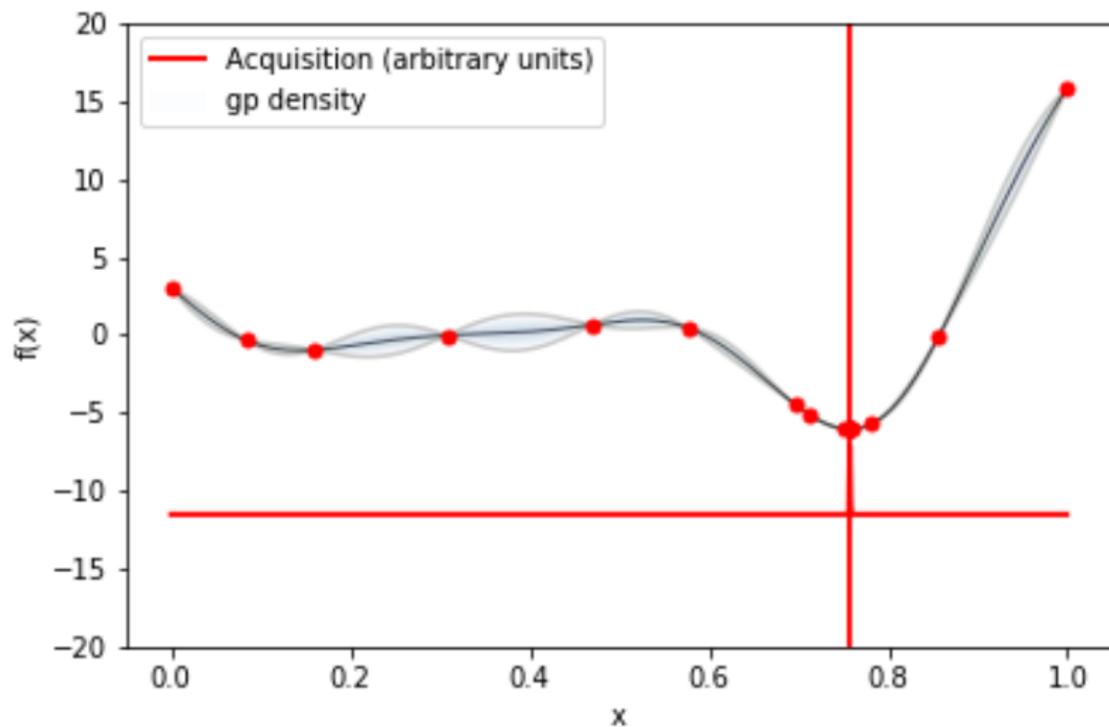
Байесовская оптимизация: пример

Итерация 17.



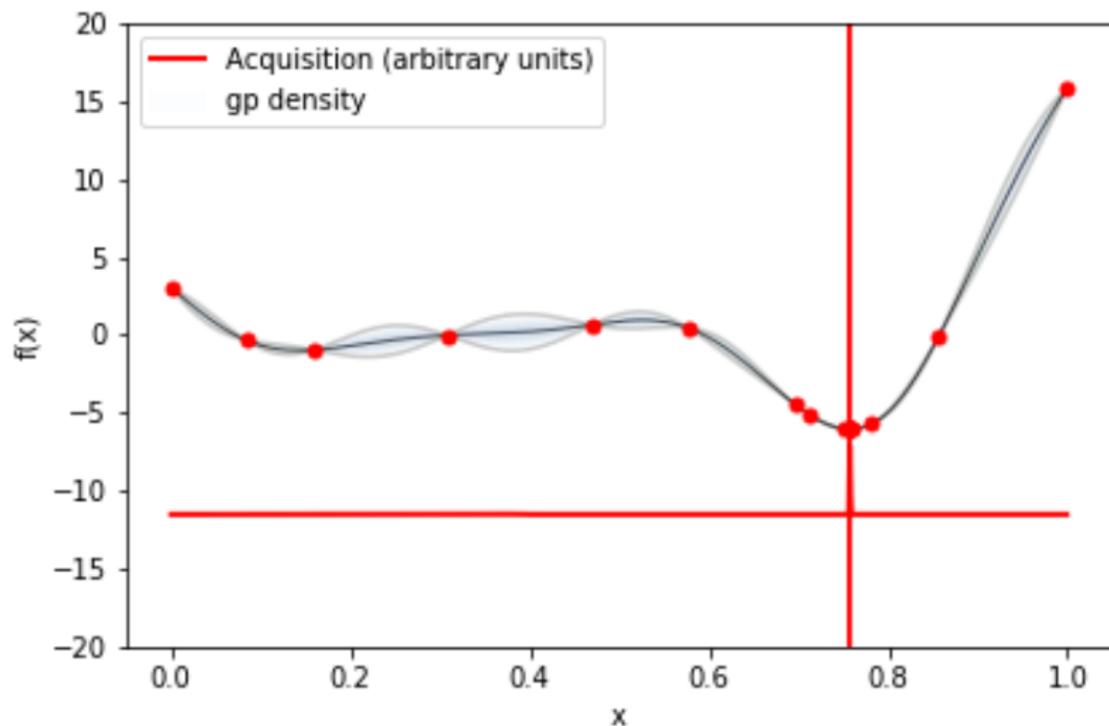
Байесовская оптимизация: пример

Итерация 18.



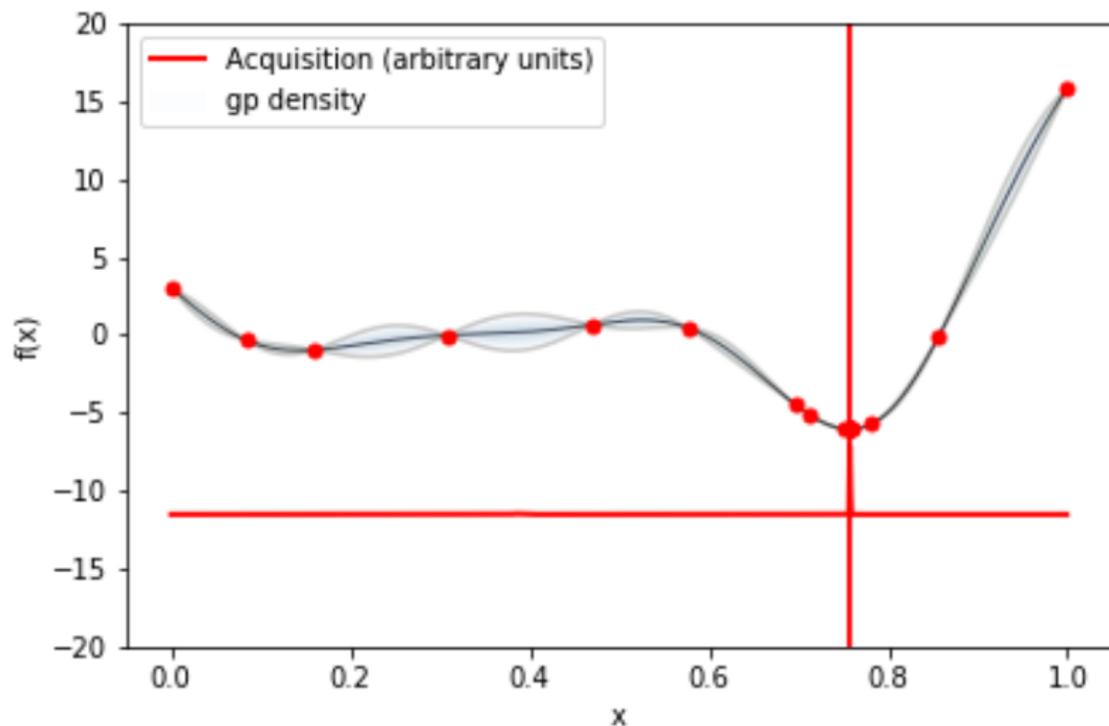
Байесовская оптимизация: пример

Итерация 19.



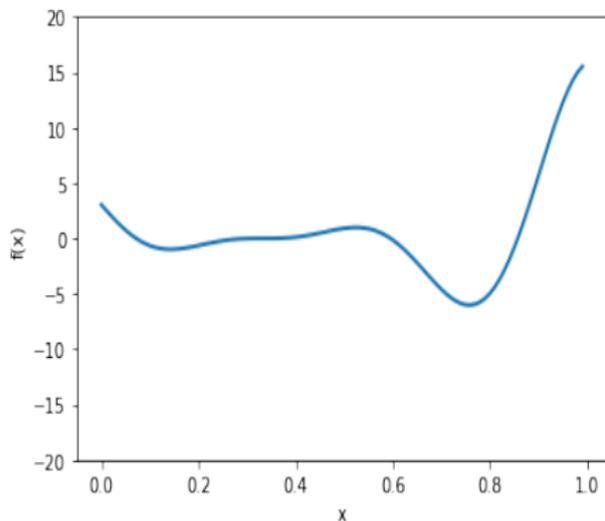
Байесовская оптимизация: пример

Итерация 20.

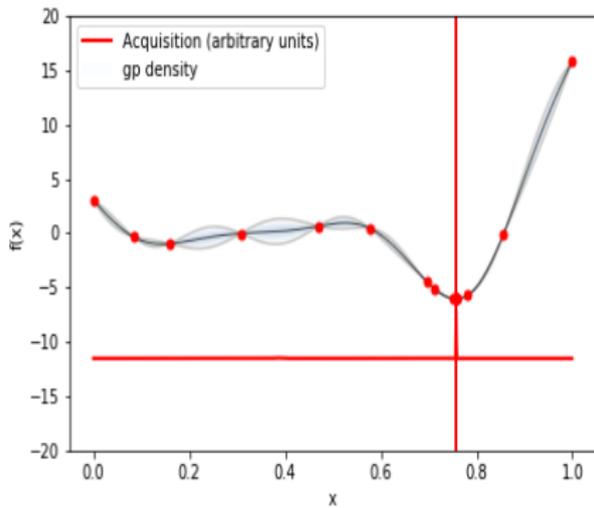


Байесовская оптимизация: пример

Сравним полученное на 20 итерации приближение с оригинальной функцией.



(a) Оригинальная функция



(b) Аппроксимирующий ГП

Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы**
- 8 Заключение

Управление роботами: мотивация

Классическая постановка задачи управления: знаем физику, ищем оптимальное управление.

Современная постановка задачи управления: не знаем физику, пытаемся ее выучить и на ходу найти оптимальное управление.

Машины, для которых достаточен первый подход, дороги.

Для дешевых машин:

- мы не знаем их физику (она очень сильно отклоняется от “идеальной”),
- у нас нет возможности в ручном режиме эту физику изучать (строить подходящую модель), так как это сильно повышает цену.

Управление роботами: PILCO

PILCO (Probabilistic Inference for Learning COntrol) — подход, использующий гауссовские процессы для “изучения физики”.

PILCO: A Model-Based and Data-Efficient Approach to Policy Search

Marc Peter Deisenroth

Department of Computer Science & Engineering, University of Washington, USA

MARC@CS.WASHINGTON.EDU

Carl Edward Rasmussen

Department of Engineering, University of Cambridge, UK

CER54@CAM.AC.UK

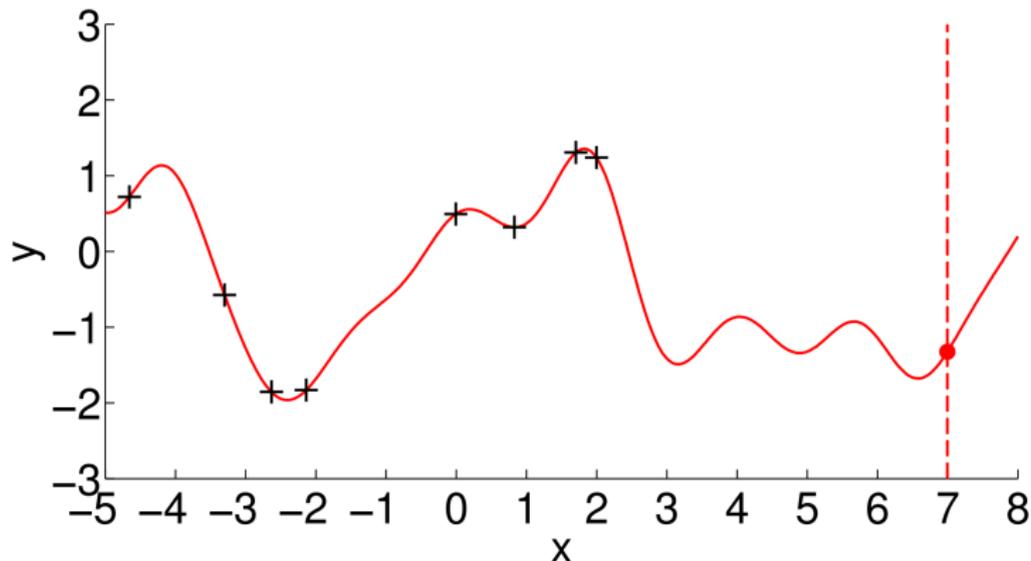
Модель системы можно записать в виде

$$x_{t+1} = f(x_t, u_t) + w, \quad \text{где}$$

- x_t — траектория системы,
- u_t — управление,
- f моделирует физику,
- $w \sim N(0, \sigma^2)$ — случайный шум.

Управление роботами: PILCO

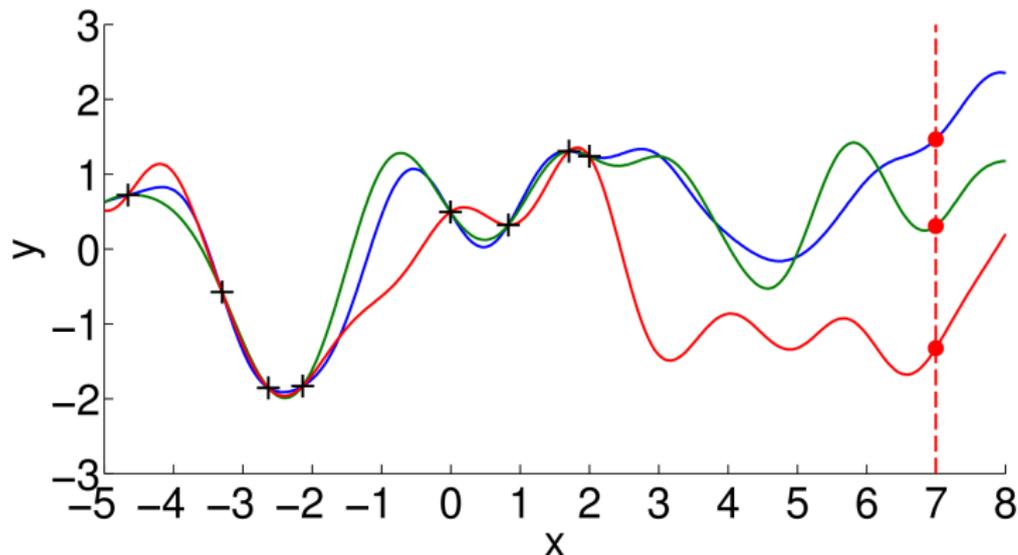
Представим, что f моделируется детерминистично.



Рассмотрим прогноз в точке $x = 7$.

Управление роботами: PILCO

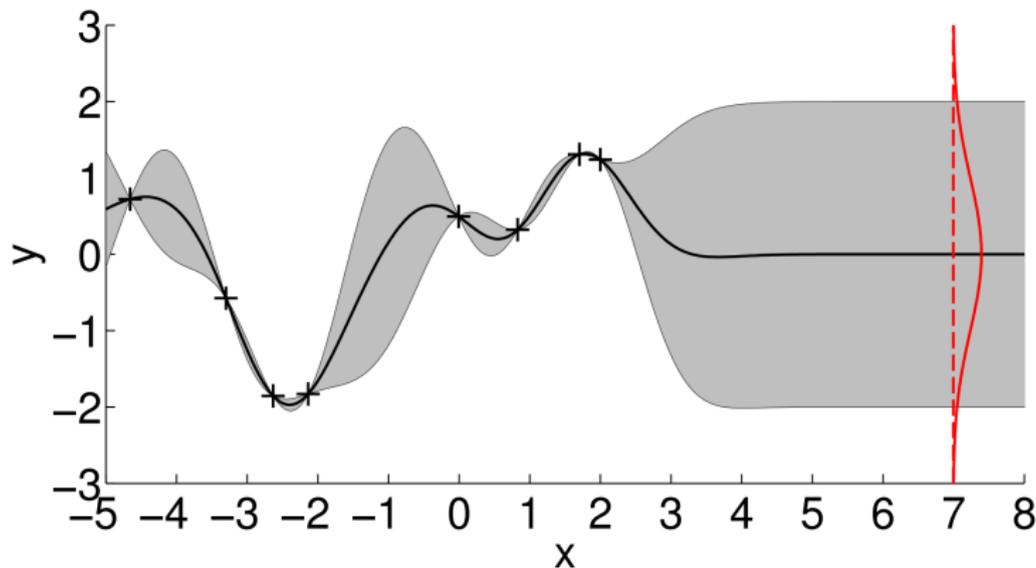
Представим, что f моделируется детерминистично.



Множество правдоподобных моделей, множество прогнозов.

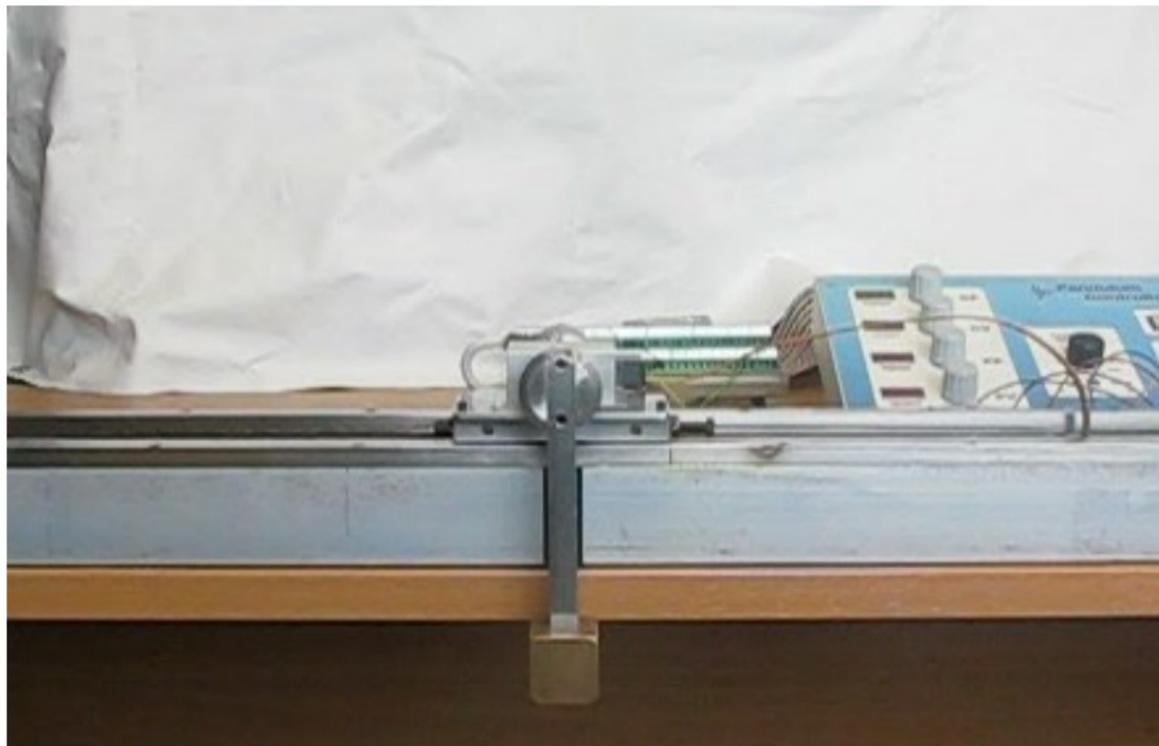
Управление роботами: PILCO

Что если моделировать f как гауссовский процесс?

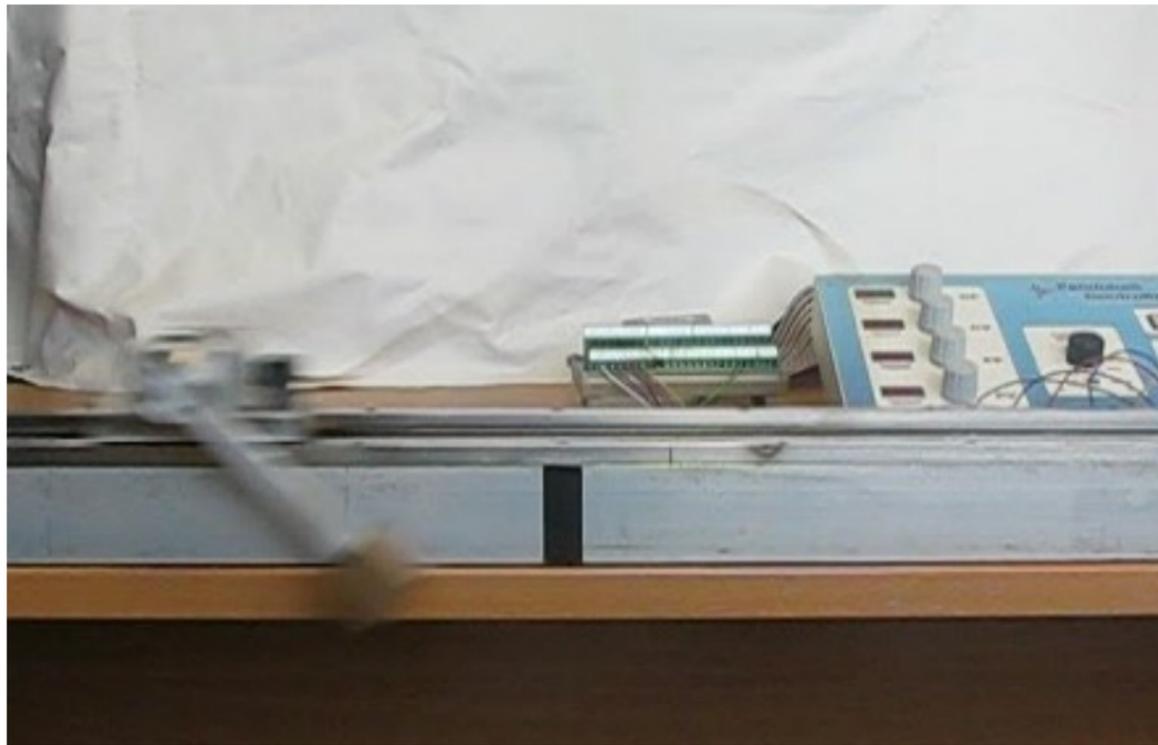


Если использовать ГП, появляется возможность учитывать неопределенность.

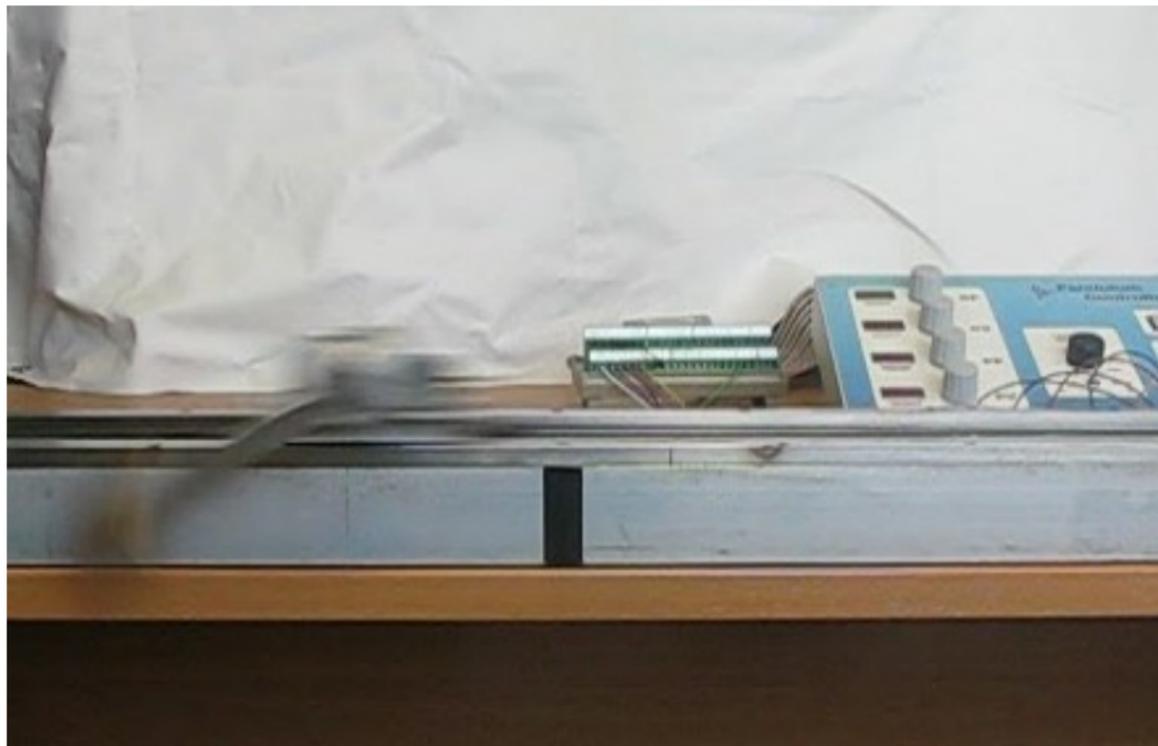
Управление роботами: пример (маятник)



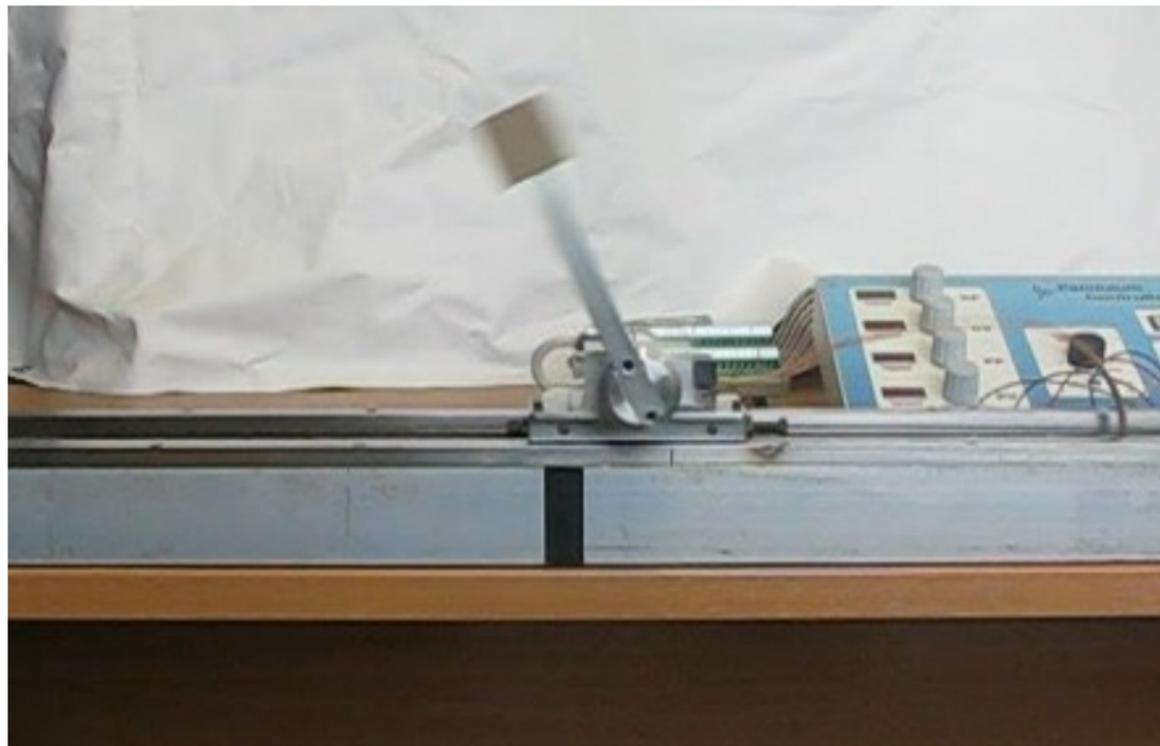
Управление роботами: пример (маятник)



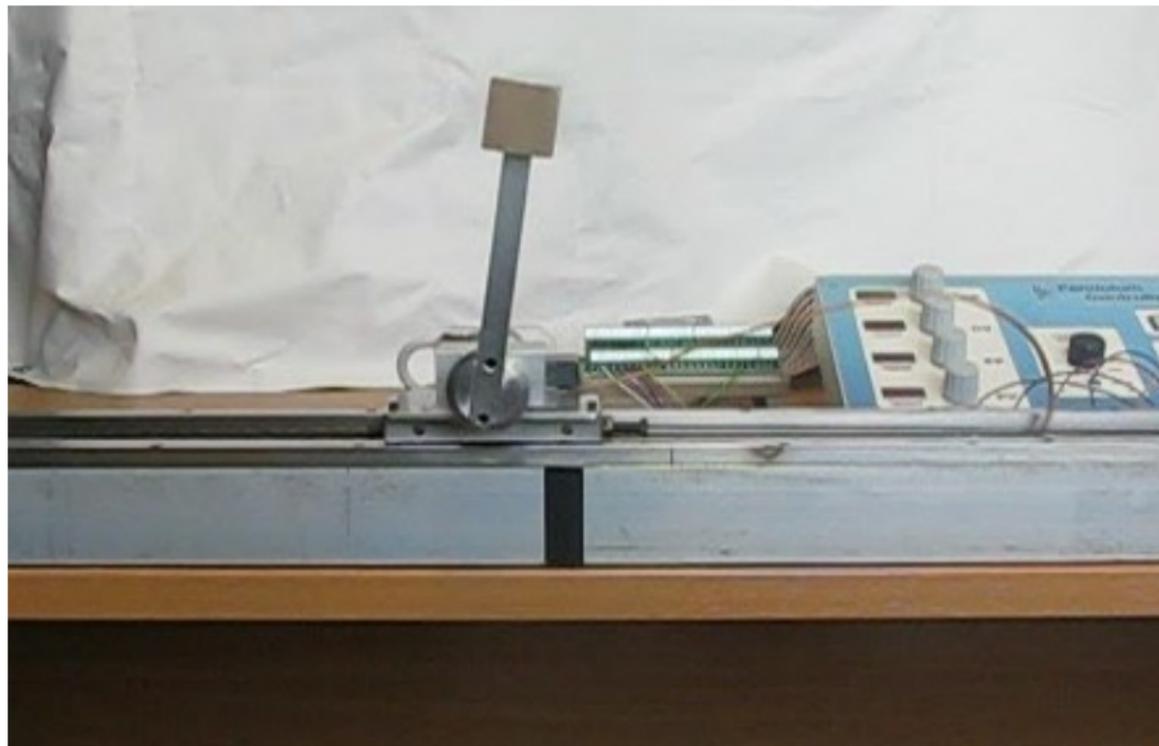
Управление роботами: пример (маятник)



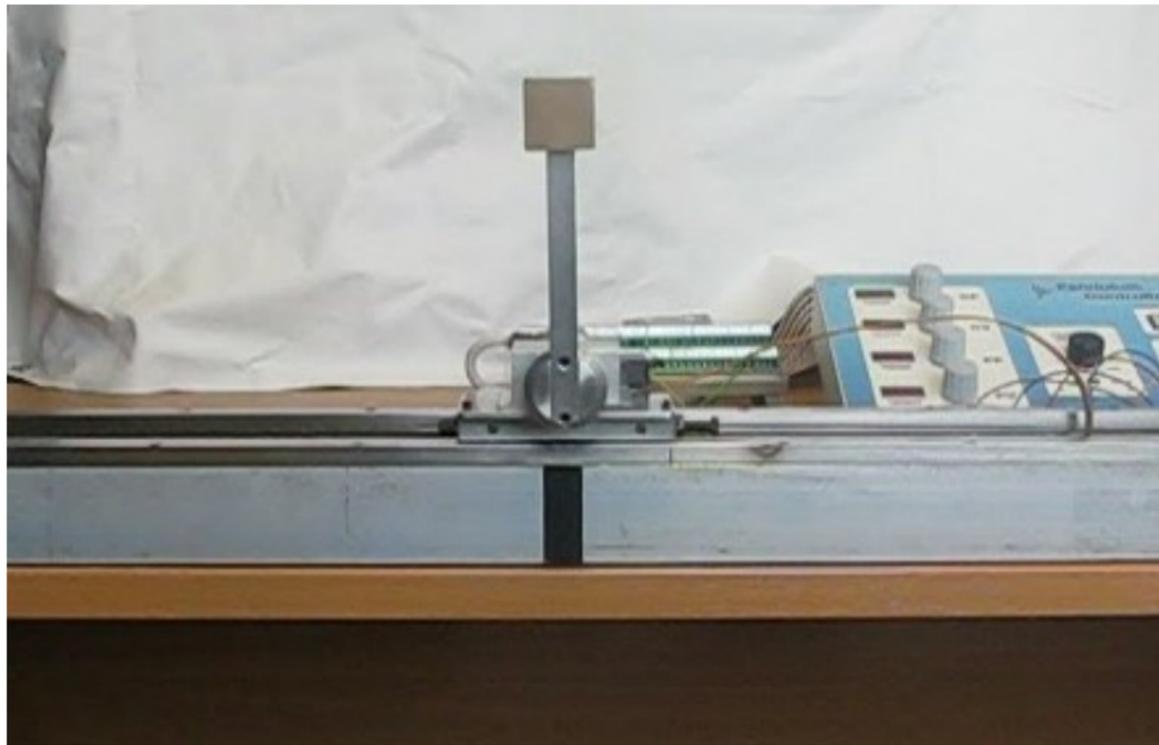
Управление роботами: пример (маятник)



Управление роботами: пример (маятник)

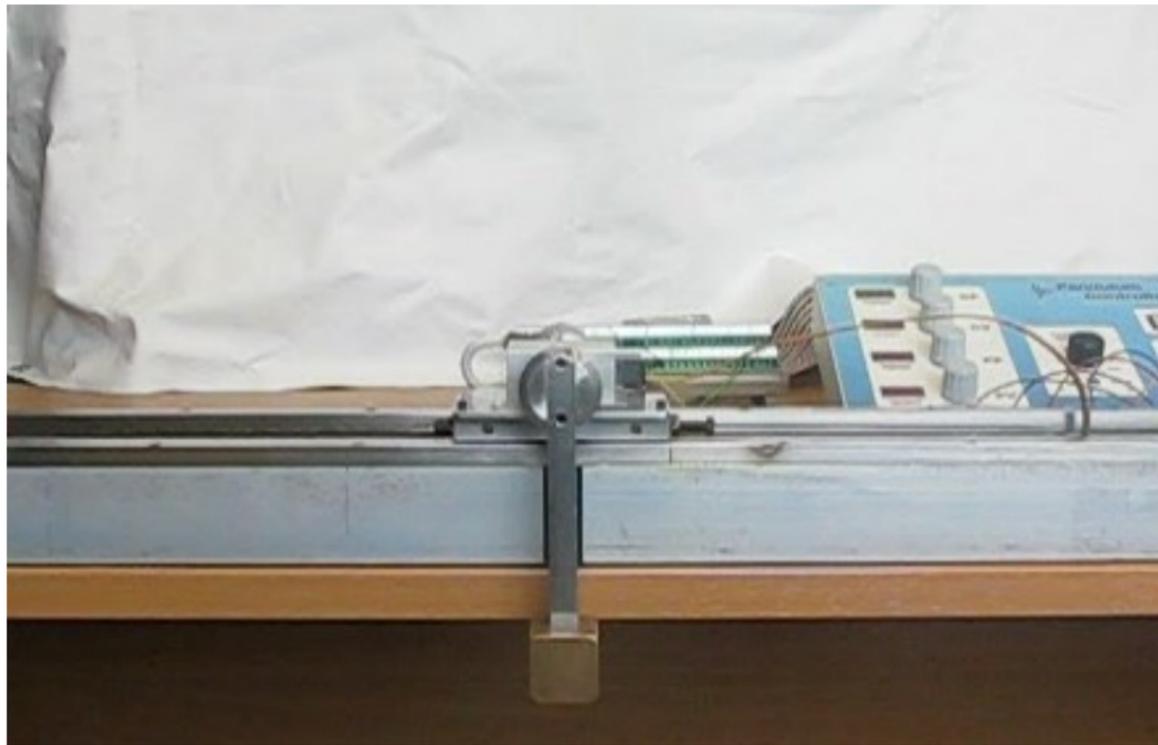


Управление роботами: пример (маятник)

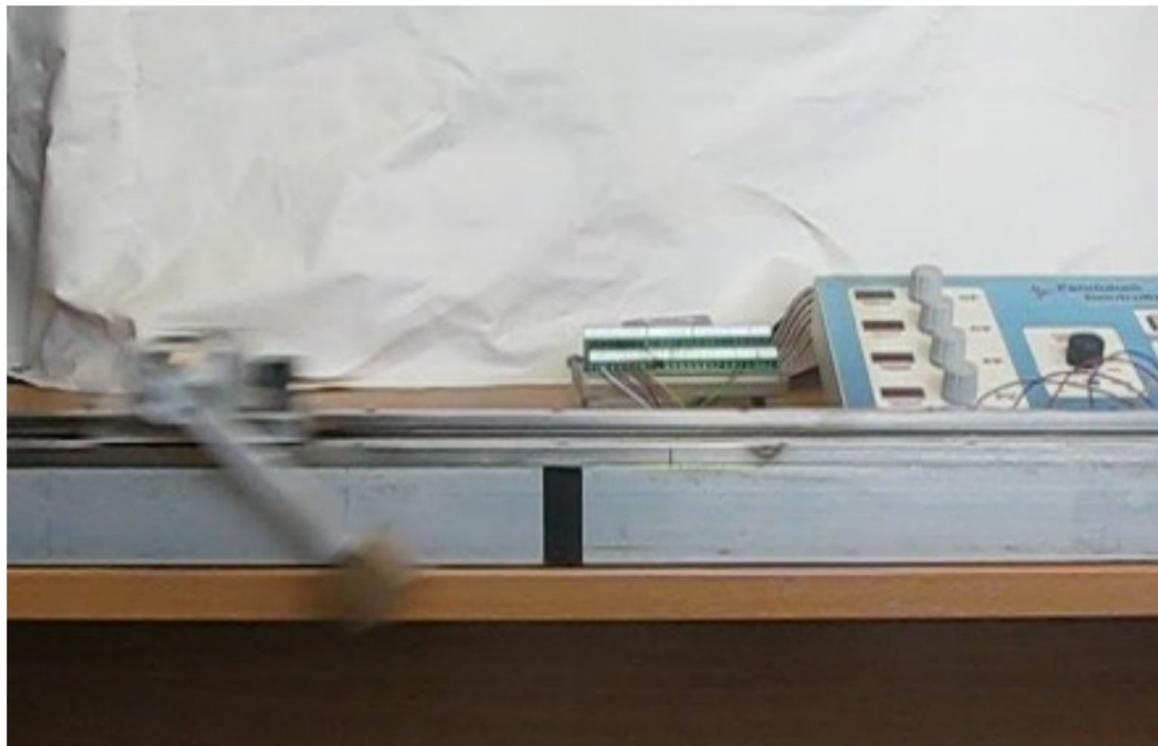


Еще разок...

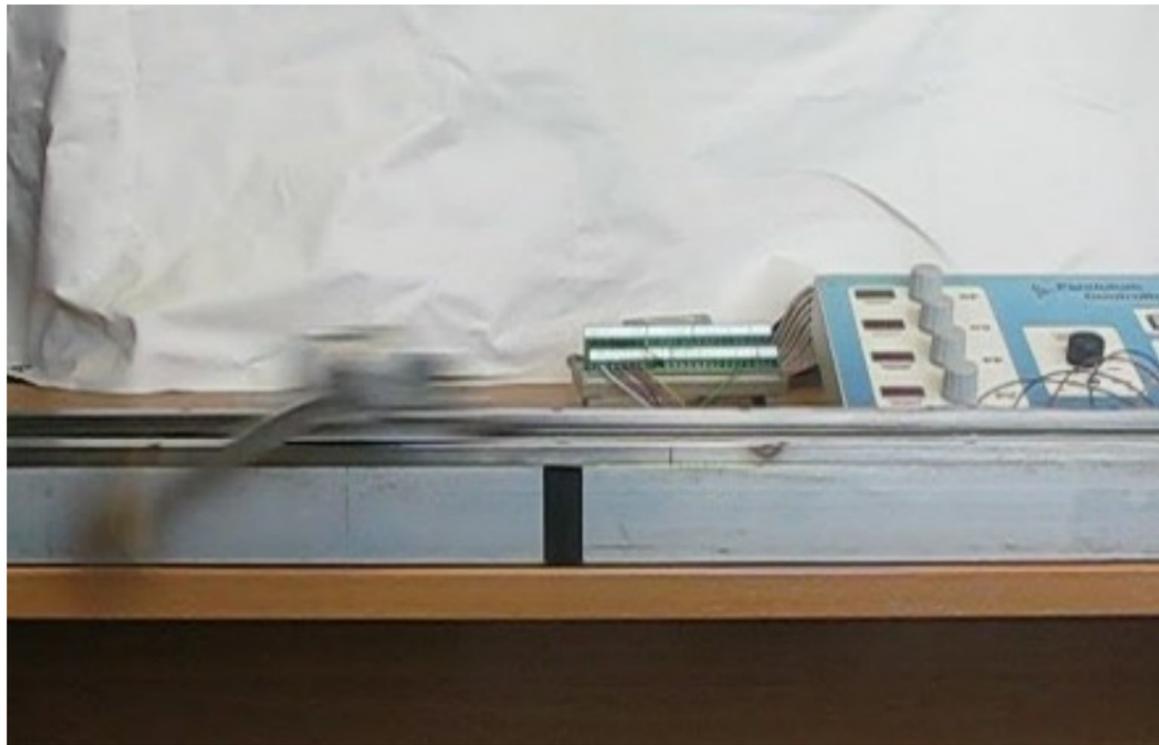
Управление роботами: пример (маятник)



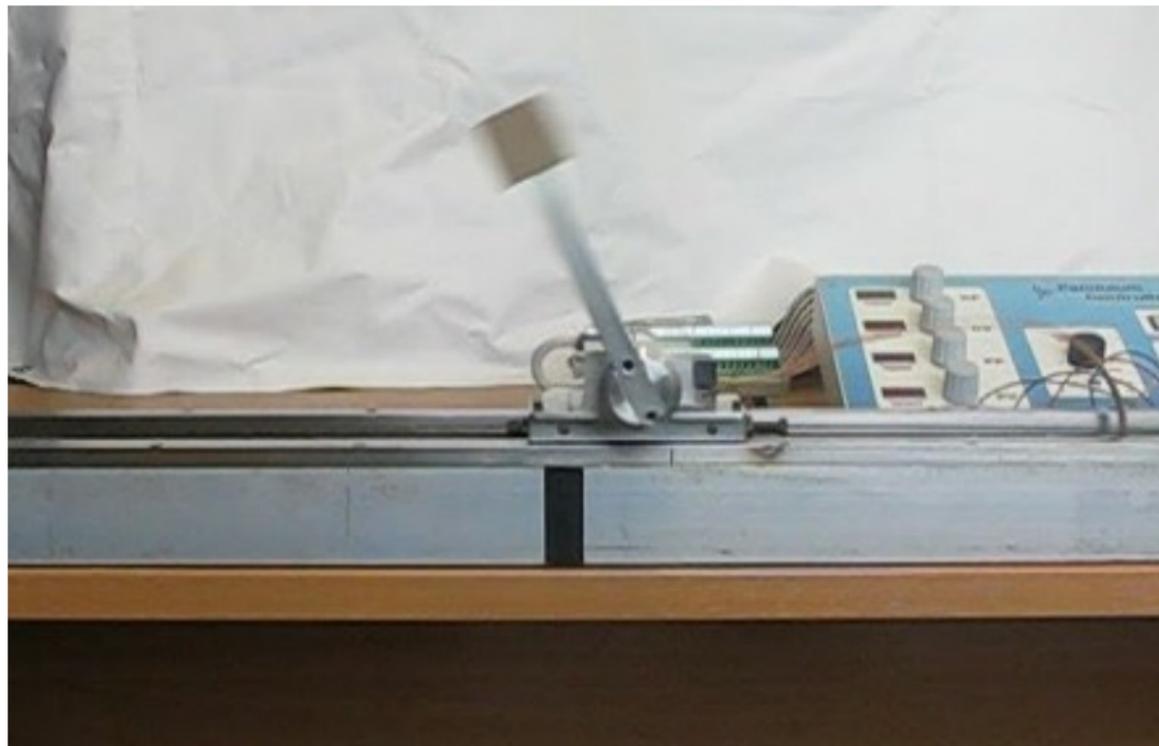
Управление роботами: пример (маятник)



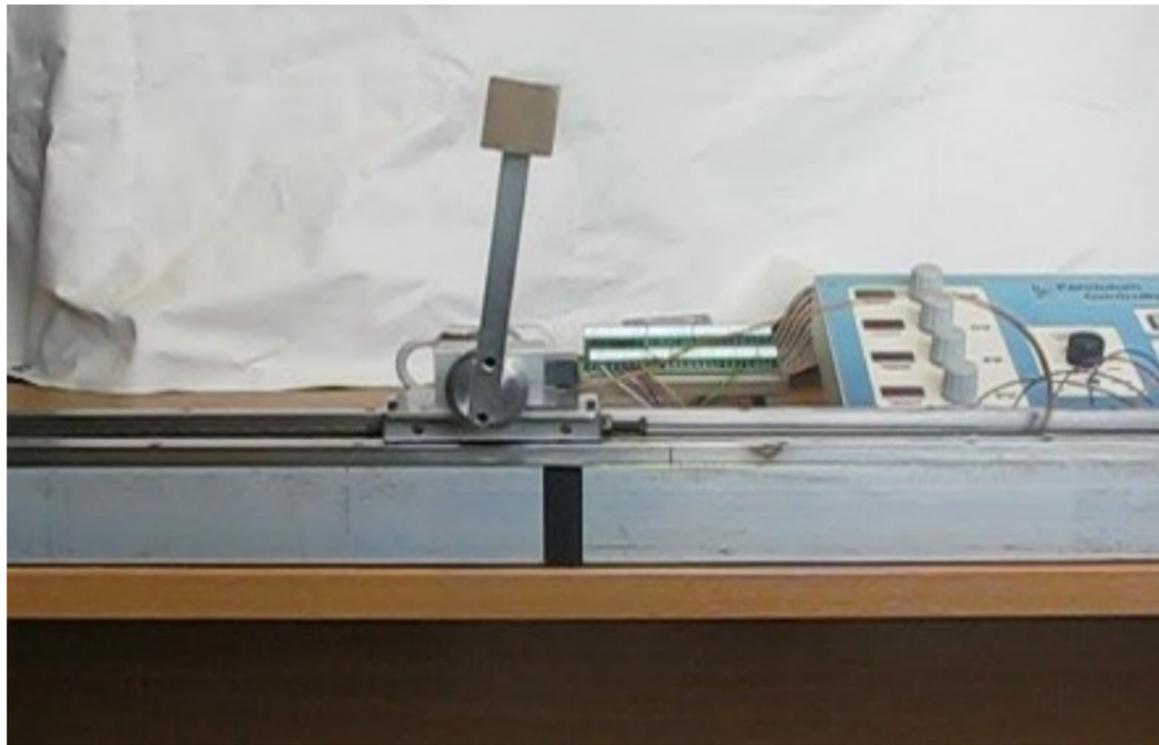
Управление роботами: пример (маятник)



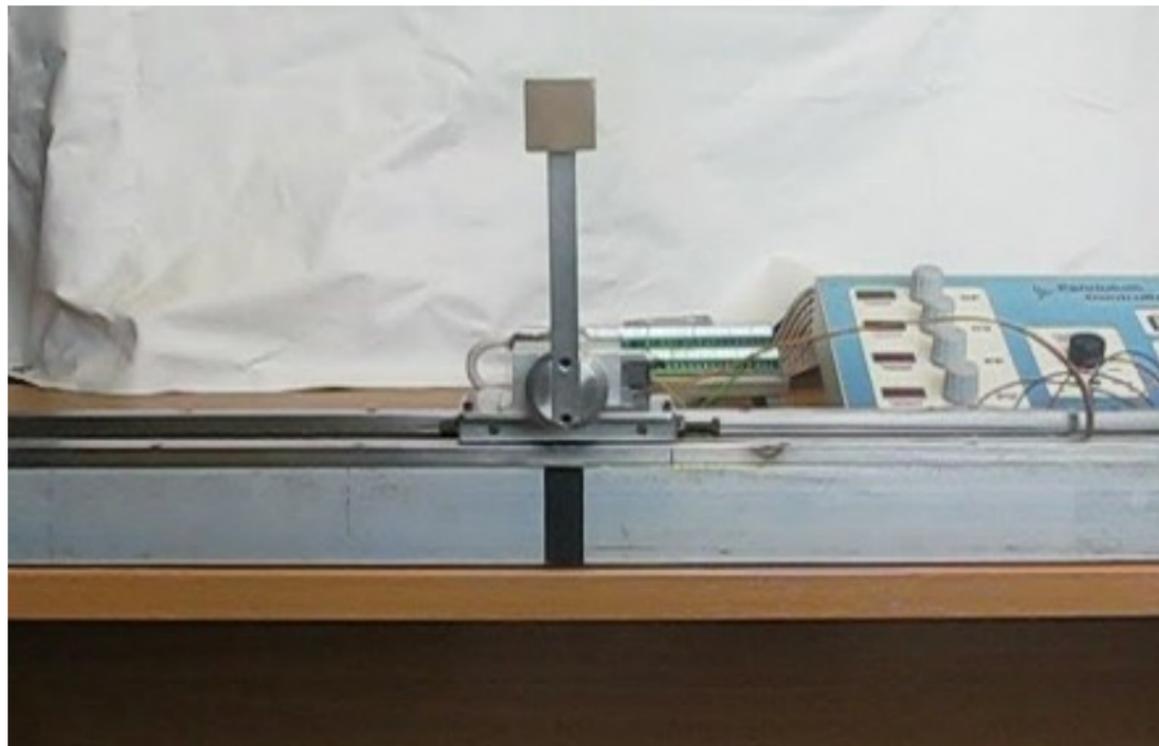
Управление роботами: пример (маятник)



Управление роботами: пример (маятник)



Управление роботами: пример (маятник)



Содержание

- 1 Введение
- 2 Байесовский вывод
- 3 Байесовский вывод: монетка
- 4 Байесовский вывод: гауссовские процессы
- 5 Приложения: моделирование нефтяных месторождений
- 6 Приложения: оптимизация
- 7 Приложения: роботы
- 8 Заключение**

Место ГП в современном машинном обучении

State of the art модели для

- маленьких датасетов (small data),
- задач, где нужна оценка неопределенности (uncertainty quantification).

Для практического применения

- библиотека (Python) <https://sheffieldml.github.io/GPy/>,
- tutoriales nbviewer.jupyter.org/github/SheffieldML/notebook/blob/master/GPy/index.ipynb,
- книжка (в свободном доступе) С. Е. Rasmussen & С. К. I. Williams, Gaussian Processes for Machine Learning,
- библиотека на основе TensorFlow github.com/GPflow/GPflow.

Еще современные методы и задачи

- Что, если мы хотим делать не регрессию, а, например, классификацию?
Ключевые слова: non-Gaussian likelihoods.
- Дополнительные приложения.
Например, Gaussian Process Latent Variable Model — понижение размерности с помощью ГП.
- Гауссовские процессы и большие данные.
Ключевые слова: Sparse Gaussian Processes.
- Более сложные модели.
Например, Deep Gaussian Processes, Convolutional GPs.
- Теоретические вопросы.
Например, сходимость байесовских нейронных сетей к ГП.

Спасибо за внимание!

viacheslav.borovitskiy@gmail.com

Материалы по теме:

- distill.pub/2019/visual-exploration-gaussian-processes
- C. E. Rasmussen & C. K. I. Williams, Gaussian Processes for Machine Learning
- cs.bath.ac.uk/~nc537/research/fonts
- mlg.eng.cam.ac.uk/pilco

В презентации были использованы иллюстрации из:
seeing-theory.brown.edu, inverseprobability.com/talks,
github.com/paintception/RandomWalk,
deisenroth.cc/talks/2020-02-13-aalto.pdf