

Пару слов про сэмплирование

И. Куралёнок

СПб, 2017

Понятие сэмплирования

Сэмплирование — метод исследования множества путём анализа его подмножеств.

Применяется когда:

- множество слишком велико для перебора;
- каждое дополнительное измерение дорого;
- предварительный анализ.

Алгоритм сэмплирования

- 1 Понять какое множество мы изучаем
- 2 Осознать, что из этого множества мы можем измерить
- 3 Определить количество измерений
- 4 Разработать план сэмплирования
- 5 Провести сэмплирование

Типы сэмплирования

- Вероятностное сэмплирование:

$$P(x), \forall x : P(x) > 0$$

- Невероятностное сэмплирование:

$$P(x), \exists x : P(x) = 0$$

- Без возвращений
- С возвращениями

Типы сэмплирования

- Вероятностное сэмплирование:

$$P(x), \forall x : P(x) > 0$$

Например: попробуем посчитать соотношение мужчин/женщин

- Невероятностное сэмплирование:

$$P(x), \exists x : P(x) = 0$$

- Без возвращений
- С возвращениями

Типы сэмплирования

- Вероятностное сэмплирование:

$$P(x), \forall x : P(x) > 0$$

- Невероятностное сэмплирование:

$$P(x), \exists x : P(x) = 0$$

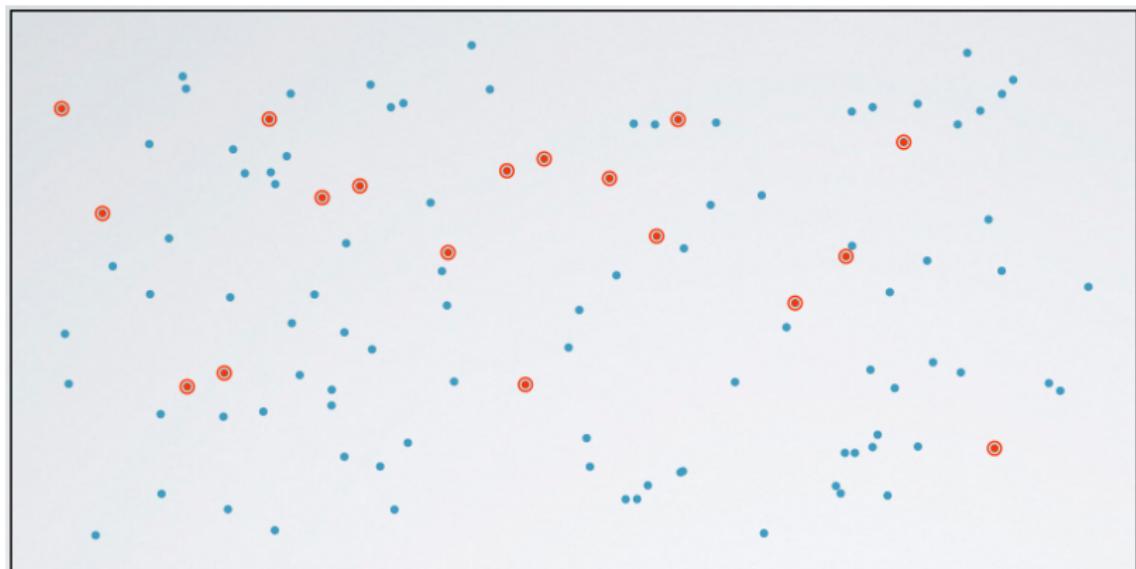
Например: “по результатам опроса superjob.ru, 100% россиян пользуются интернетом”

- Без возвращений
- С возвращениями

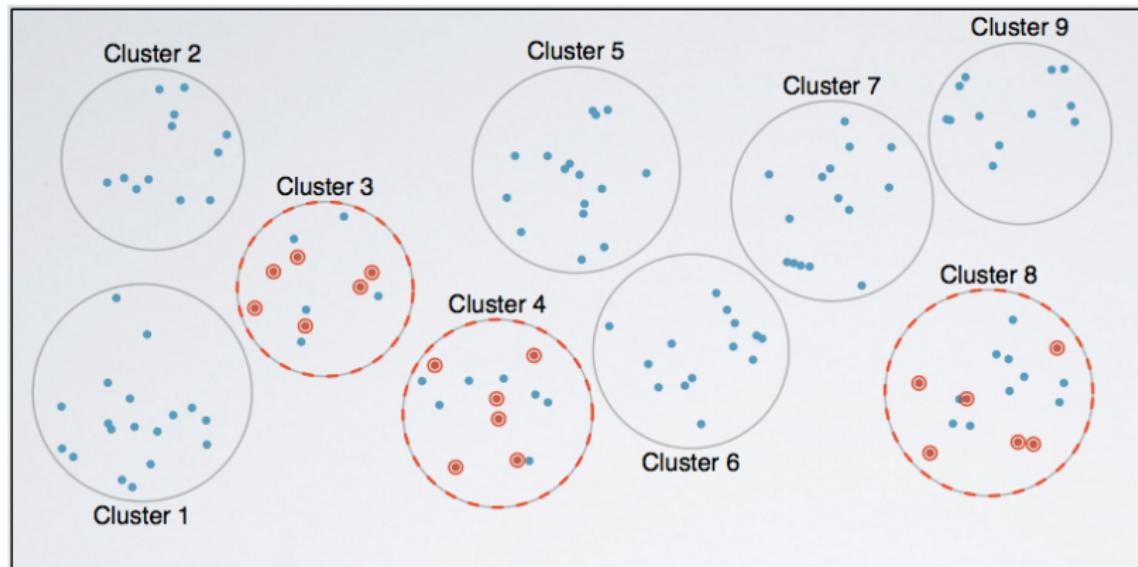
Виды сэмплирования

- Вероятностное сэмплирование
 - Простое вероятностное
 - Систематическое
 - Пропорциональное
 - Кластерное
 - Стратифицированное
- Невероятностное сэмплирование
 - Опрос ближайших
 - Панельное сэмплирование

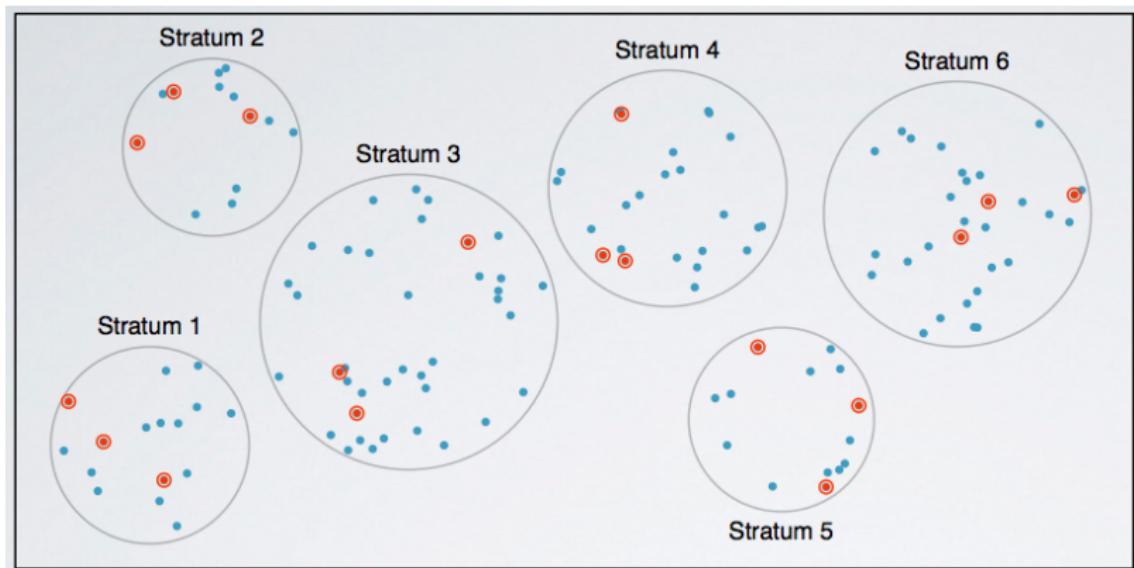
Простое вероятностное



Кластерное



Стратифицированное



Как выбрать нужное?

Надо учитывать:

- природа и размер возможного сэмпла;
- наличие дополнительной информации об элементах;
- необходимая точность измерений;
- точность отдельных измерений в сэмплировании;
- стоимость измерений.

Как делать не нужно

Байки про ошибки в создании обучающей выборки

- Соотношение положительных и отрицательных примеров
- Все решения одинаково бесполезны
- Ошибка в данных больше разницы между методами
- Правда в глазах смотрящего (про ошибки в примерах)
- Нужно следить за распределением важных параметров, независимо от способа сбора данных
- Устаревшие данные
- Correlation vs. Causation
- Зависимость результата от одной точки или класса точек
- Закодировать ответ в DS

Создание DS — тоже оптимизация

Как же понять что построенное множество хорошее? Хотим такого:

$$\begin{aligned}\hat{H} &= \arg \max_H \mu_{\xi \sim D} T(y_\xi, H(x_\xi)) \\ &= \arg \max_H \mu_{\xi \sim \Gamma} T(y_\xi, H(x_\xi))\end{aligned}$$

Но делать будем иначе:

$$D = \arg \max_D \mu_{\eta \sim \Gamma} T(y_\eta, \arg \max_H \mu_{\xi \sim D} T(y_\xi, H(x_\xi))(x_\eta))$$

Это такая оптимизация

Заключение о построении DS

Это все область выборочного контроля про которую много написано:

George E.P. Box, A. И. Орлов, В.П. Боровиков Создание хорошего обучающего множества — половина успеха. У меня нету универсальной схемы как такое делать, и есть ощущение, что это на грани искусства.

Выборка как генеральная совокупность

- LOO методы и jackknife оценки
- Bootstraping подход (Монте-Карло на выборке)
- Слабая аксиоматика Воронцова

Leave One Out

Выберем один из примеров и посмотрим насколько поменяется выборка, если его в ней не будет. Усредним по всем.

Эту логику можно применять например так:

$$Var_{LOO}(\{x_i\}) = \frac{1}{m} \sum_{i=1}^m (x_i - \bar{x}_{-i})^2 = \frac{1}{(m-1)^2} Var(\{x_i\})$$

Jackknife оценки

Пускай нас интересует статистика θ , $\hat{\theta}$ —ее выборочная оценка и $\bar{\theta} = \frac{1}{m} \sum_i \hat{\theta}_{-i}$.

$$\begin{aligned}\mathbb{E}(\hat{\theta}) &= \theta + \frac{a}{m} + \frac{b}{m^2} + O(m^{-3}) \\ \Rightarrow \mathbb{E}(\hat{\theta} - \bar{\theta}) &= \frac{a}{m(m-1)} + O(m^{-3}) \\ \Rightarrow b_{jack} &= (m-1)(\bar{\theta} - \hat{\theta})\end{aligned}$$

Bootstrapping

B. Efron "Bootstrap methods: another look at the jackknife"

Зачем ограничиваться одним примером? Устроим на нашей "генеральной совокупности" Монте-Карло:

- ➊ рассматривая выборку как генеральную совокупность, породим повторную выборку X'
- ➋ вычислим интересующую нас статистику $\hat{\theta}$ на X'
- ➌ проделаем 1 и 2 достаточное количество раз и построим эмпирическое распределение $\hat{\theta}$
- ➍ исследуем эмпирическое распределение и сделаем выводы про θ

Bootstrapping: простая реализация

- ➊ случайно отсортируем исходную выборку
- ➋ выбросим i равномерное от 1 до m
- ➌ возьмем i -й пример в новую выборку
- ➍ повторим п. 2 и 3 m раз
- ➎ посчитаем на полученной выборке значение θ
- ➏ исследуем поведение θ на порожденных выборках

Bootstrapping: практические реализации

К сожалению в исходной версии bootstrap часто не эффективен с точки зрения производительности

- Бросить много пуассонов с $\lambda = 1$
- Байесовский bootstrap (волшебный log)
- Гладкий bootstrap (шумный сигнал)
- etc.

Bootstrapping: практические реализации

К сожалению в исходной версии bootstrap часто не эффективен с точки зрения производительности
(Почему?)

- Бросить много пуассонов с $\lambda = 1$
- Байесовский bootstrap (волшебный log)
- Гладкий bootstrap (шумный сигнал)
- etc.

Несколько рекомендаций

Когда нельзя пользоваться bootstrapping'ом:

- Когда бесконечная дисперсия
- Когда совсем мало примеров и возможны повторы X'

Нужно всегда помнить что:

- Повторные выборки зависимы и степень зависимости варьируется от t
- В повторных выборках значение, например, дисперсии часто ниже чем на генеральной совокупности
- Чтобы понять насколько результат смещен можно применить дополнительные деления выборки

Домашнее задание

- Сгенерировать последовательность $\{(x_i, y_i) | x_i, y_i \sim U(0, 1)\}_{i=1}^m, m = 10000$
- Выбросить минимально возможное количество примеров так, чтобы y стало линейно зависимо от x с уровнем значимости $\alpha = 0.05$
- Сообщить процент выброшенного

Переборные методы как частный случай сэмплирования

Сэмплирование можно использовать не только для сбора данных! Представим себе, что процесс оптимизации устроен так:

$$\hat{H} = \arg \max_{\beta \in \mathbb{R}^m} \mathbb{E}_{\xi \sim D}(T(y_\xi, H(x_\xi, \beta)))$$

И нету у нас никаких способов понять свойства зависимости T от β .

Формальная постановка

$$\hat{H} = \arg \max_H P(H|X)$$

- + если известны вероятности можно попробовать посэмплировать решения;
- не определено пространство F ;
- неясно как устроить обход.

Иногда все просто

$$\hat{H} = \arg \max_{H \in \{H_i\}_{i=1}^n} P(H|X)$$

- ➊ введём порядок обхода;
- ➋ переберём все возможные решения;
- ➌ составим взвешенное решение/выберем лучшее.

Но чаще всё непросто

$$\hat{H} = \arg \max_{H \in \{H_i\}_{i=1}^{\infty}} P(H|X)$$

или совсем запущено:

$$\hat{H} = \arg \max_{H(x, \beta), \beta \in \mathbb{R}^k} P(H|X)$$

- ➊ введём порядок обхода;
- ➋ применим систематическое сэмплирование;
- ➌ составим взвешенное решение/выберем лучшее.

Случайное блуждание I

$$H = H(x, \beta), \beta \in \mathbb{R}^k$$

Чтобы построить порядок обхода можно воспользоваться такой схемой:

$$\begin{aligned} H_t &= H(x, \beta_t) \\ \mathcal{A} &= \left\{ \begin{array}{l} \beta_{t+1} = \beta_t + \xi \\ C(\beta_{t+1} | \{\beta_i\}_0^t) \end{array} \right. \end{aligned}$$

Для этого необходимо определить:

- 1 начальную точку β_0 ;
- 2 способ сделать шаг ξ ;
- 3 условие принятия этого шага C .

Случайное блуждание II

На что стоит обратить внимание при построении блуждания:

- размерность β может быть меньше чем кажется;
- ограничения на β существенно осложняют процедуру.

Некоторые виды случайного блуждания

- множество фиксированных шагов $\xi \sim U(\{\xi_i\}_1^m)$;
- гауссовское $\xi_t \sim N(\mu, \sigma^2)$;
- самозависимое (генетика, рои, etc.);
- etc.

Simple hill climbing

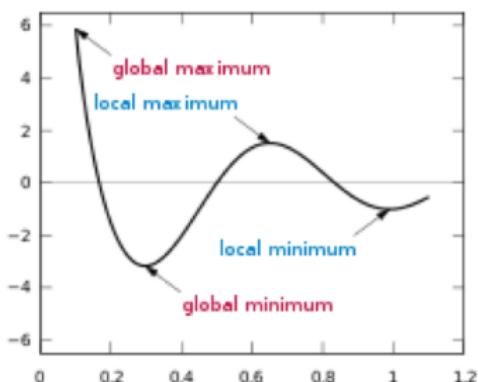
$$\xi \sim U(\{\xi_i\}_1^{2k}), \xi_i = -1^{i \bmod 2} \omega_t,$$

$$C(\beta_{t+1} | \beta_t) = \frac{P(H(\beta_{t+1}) | X)}{P(H(\beta_t) | X)} > 1$$

Свойства:

- простой;
- быстро сходится;
- зависим от выбора начальной точки;
- etc.

Random-restart (shotgun) hill climbing



Проблемы:

- сходится в локальный максимум;
- может долго сходиться, если начало далеко от максимума;
- аллеи.

⇒ Можно рестартить hill climbing из разных начальных точек

Интуиция

Мы бы хотели получить сэмплирование, а для этого:

- хорошо бы обойти всё пространство;
- нельзя всегда ходить "по шерсти";
- скорость движения должна меняться в зависимости от плотности.

⇒ Markov Chain Monte-Carlo (MCMC)

Metropolis-Hastings алгоритм

Введем $p(\beta_1|\beta_2)$, отвечающую за локальность.

$$\alpha = \frac{P(H_{\beta_{t+1}}|X)P(\beta_{t+1}|\beta_t)}{P(H_{\beta_t}|X)P(\beta_t|\beta_{t+1})}$$

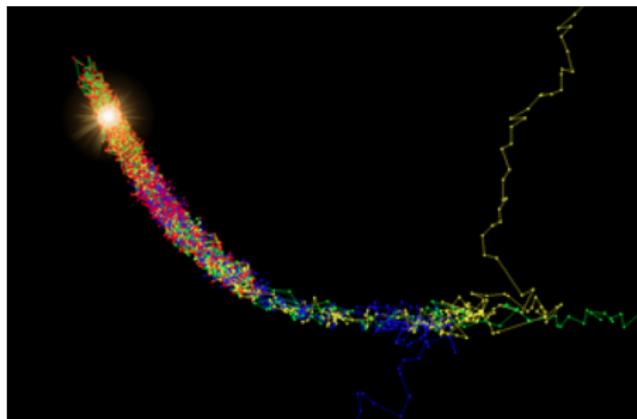
$$\psi \sim U(0, 1)$$

$$C(\beta_{t+1}|\beta_t) = \begin{cases} 1, & \alpha \geq \psi \\ 0 & \end{cases}$$

Например, $P(\beta_{t+1}|\beta_t) \sim N(\beta_t, \sigma^2 E)$

Если $P(\beta_1|\beta_2) = P(\beta_2|\beta_1)$ — это Metropolis

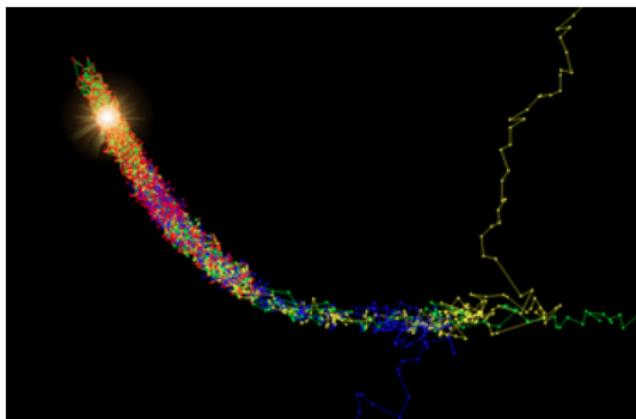
Свойства



- + Обходит всё пространство
- + Это действительно взвешенное сэмплирование
- Последовательные сэмплы похожи друг на друга
- На этапе разогрева показывает что-то странное

⇒ Точно придём в максимум!

Свойства



- + Обходит всё пространство
- + Это действительно взвешенное сэмплирование
- Последовательные samples похожи друг на друга
- На этапе разогрева показывает что-то странное

⇒ Точно придём в максимум!

Проблема только с тем, что придём за бесконечное время

Сложности в использовании

- Сходимость зависит от выбора $P(\beta_{t+1}|\beta_t)$
- Если хотим использовать разумное распределение, оно многомерное \Rightarrow его сложно реализовывать

Пример с дартс I

Вася и Петя повесели на стене мишень и поиграли в дартс. На следующий день пришел их бригадир Юра и задался вопросом кто из подчиненных будет заделывать дырки в стенах.

- Будет честнее, чтобы “косой” платил больше
- Дырки все одинаковые
- Каждый говорит: “да я токо разок кинул!”
- Один признался, что: “ну вот это — моя дырка”
- Играли без употребления, так что можно считать, что кидали $\sim N(m_i, \Sigma_i)$, $i \in \{\text{Вася, Петя}\}$ и параметры не менялись во времени

Надо помочь Юре!

Пример с дартс II

При фиксированных параметрах вероятность увидеть дырки $\{x_j\}, x_j \in \mathbb{R}^2$

$$LL = \sum_j \log(\pi N(m_A, \Sigma_A)(x_j) + (1 - \pi)N(m_B, \Sigma_B)(x_j))$$

где A — Вася, B — Петя, π — доля Васиных бросков, m_i — сбитость прицела, Σ_i — разброс стрелка.

Максимизировать такое добро трудновато из-за суммы под логарифмом. Было бы классно точно знать, что тот или иной бросок точно сделал Вася $A_t \in \{0, 1\}$:

$$LL = \sum_t A_t \log(N(m_A, \Sigma_A)(x_j)) + (1 - A_t) \log(N(m_B, \Sigma_B)(x_j))$$

В таком варианте все совсем просто считается (если мы еще не забыли формулу плотности нормального многомерного распределения :))

Пример с дартс III

Если чуть более формально, то мы ввели скрытую/ненаблюдаемую переменную $I(A)$ (такое называется *data augmentation*) и хотим:

- ➊ Прикинуть начальные m_i, Σ_i, π
- ➋ Посчитать ожидание скрытого параметра $A_j = \mu((m_i, \Sigma_i, \pi))$
- ➌ В условиях найденных A_j максимизировать LL
- ➍ Перейти к второму шагу до сходимости

Expectation maximization алгоритм

Фокус, который мы проделали называется *EM*-алгоритм. Пускай данные у нас состоят из видимой части L и скрытой Z , $X = (L, Z)$. Мы хотим найти оптимальные параметры β :

$$\log P(L|\beta) = \log P(X|\beta)$$

- 1 Возьмем какой-то β_0
- 2 Посчитаем ожидание (expectation step):

$$\mathbb{E}(\beta|\beta_t) = \mathbb{E}_Z (\log P(X, \beta, Z|\beta_t))$$

- 3 Проведем оптимизацию (maximization step):

$$\beta_{t+1} = \arg \max_{\beta} \mathbb{E}(\beta|\beta_t)$$

- 4 Перейти к второму шагу до сходимости

Немного про Гиббса/Больцмана

Есть такое распределение:

$$p(x) = \frac{e^{\frac{e(x)}{kT}}}{Z = \int_x e^{\frac{e(x)}{kT}} dx}$$

Про него известно, для фиксированной функции
 $e(x) \geq 0 : Z < \infty$ и условии на общую энергию
системы:

$$\int_x e(x) dP(x) \leq const$$

оно доставляет в максимум энтропию. А еще это добро
эквивалентно MRF.

Алгоритм Гиббса

В Метрополисе есть проблема: многомерное распределение $P(H|X) = P(\beta|X)$. Можно попробовать рассматривать его по частям.

- ➊ Начнем с какого-то β
- ➋ Сгенерируем β_{t+1} по правилам

$$P(\beta_{t+1,i}|X, \beta_{t+1,1}, \dots, \beta_{t+1,i-1}, \beta_{t,i+1}, \dots, \beta_{t,n})$$

- ➌ Будем бегать по $i = 1 \dots n$, пока не сойдется
- ➍ Полученная β — следующая точка сэмплирования
- ➎ Пока хочется идем в п.2

Пример с дартс IV

На языке товарищей Геман:

- ➊ Прикинуть начальные m_i, Σ_i, π
- ➋ Для каждого сампла сгенерировать A_j из текущего π
- ➌ В условиях найденных A_j максимизировать LL
- ➍ Перейти к второму шагу до сходимости того момента пока распределение параметров не перестанет меняться

Как можно построить $P(F|X)$ для RMSE

$$P(\beta|X) = \frac{e^{-c\|H(\beta|X) - Y\|_2}}{Z}$$

$$Z = \int_{\beta} e^{-c\|H(\beta|X) - Y\|} d\beta$$

Если максимизируем, то надеемся задрать Y так, чтобы Z был определён.

Есть только одна проблема:

Как можно построить $P(F|X)$ для RMSE

$$P(\beta|X) = \frac{e^{-c\|H(\beta|X) - Y\|_2}}{Z}$$

$$Z = \int_{\beta} e^{-c\|H(\beta|X) - Y\|} d\beta$$

Если максимизируем, то надеемся задрать Y так, чтобы Z был определён.

Есть только одна проблема: мы хотим максимизировать, а не считать среднее :)

NFL: формальная формулировка

$$d_m = \{(d_m^x(1), d_m^y(1)), \dots, (d_m^x(m), d_m^y(m))\}$$

$$f : \mathcal{X} \rightarrow \mathcal{Y}$$

$$\mathcal{F} = \mathcal{Y}^{\mathcal{X}}$$

$$p(f) = \frac{1}{|\mathcal{F}|}$$

Theorem (David Wolpert and William G. Macready (1997))

Для любых двух способов обхода a_1 и a_2 :

$$\sum_f P(d_m^y | f, m, a_1) = \sum_f P(d_m^y | f, m, a_2)$$

NFL: следствия

- Нам всем хватит работы :)
- Полоса белая, полоса черная
- Нужно искать близкие задачи

Заключение

Сэмплирование очень полезная вещь:

- собирать данные;
- брать интегралы;
- обучаться.

Посмотрите на bayesian inference и библиотеку Гиббса для него: BUGS.

Задание на дом

- Датасет, как обычно, в svn
- Суть - учимся предсказывать размер аудитории сервиса
- $N(t) = \left(\frac{1}{1+e^{at+b}}\right)N_0$
- Ищем a , b , N_0
- Можно прямо hill climbing
- Можно подумать и воспользоваться алгоритмом Гиббса (это будет плюсом)
- Дедлайн 17 октября