

Компьютерное зрение '2014

Основы машинного обучения

Who? Александр Вахитов

When? April 25, 2014

А.Н.Колмогоров

Я принадлежу к тем крайне отчаянным кибернетикам, которые не видят никаких принципиальных ограничений в кибернетическом подходе к проблеме жизни и полагают, что можно анализировать жизнь во всей ее полноте, в том числе и человеческое сознание, методами кибернетики. Продвижение в понимании механизма высшей нервной деятельности, включая и высшие проявления человеческого творчества, по-моему, ничего не убавляет в ценности и красоте творческих достижений человека.

О чём мы поговорим

Основные
понятия

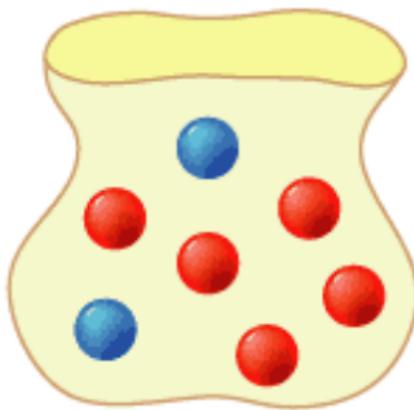
Линейные
модели

Невязка и шум

Шум в
наблюдениях

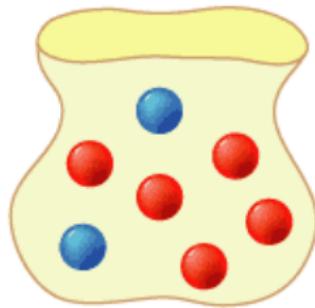
Эксперимент

Мешок с шарами 2 цветов



Достали N шаров, среди них ν - доля красных.
Задача: оценить, сколько красных в мешке?

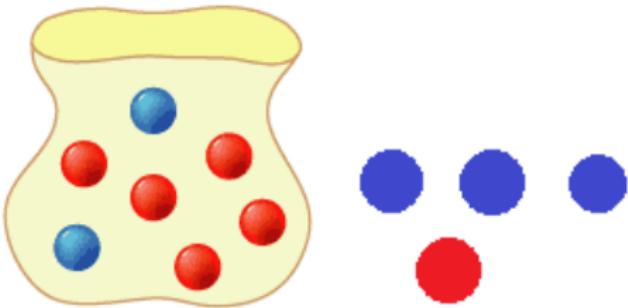
Эксперимент



$$P(\text{red}) = \mu; \quad P(\text{blue}) = 1 - \mu$$

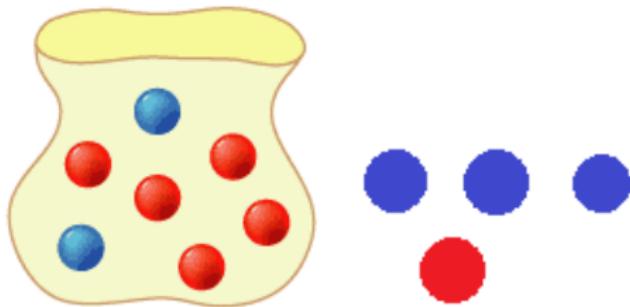
Необходимо найти μ

Эксперимент



Достали 4 шара из мешка. Что мы можем узнать о μ ?

Эксперимент



Общая интуиция:

Может быть, ν сильно отличается от μ

Скорее всего, ν примерно равно μ

Неравенство Бернштейна - Хеффдинга

Неравенство Бернштейна (Хеффдинга, Hoeffding)

Произведем выборку длины N , при этом все случайные величины, участвующие в выборке, независимы и одинаково распределены. Если значения с.в. ограничены, то справедливо неравенство:

$$P(|\nu - \mu| > \epsilon) \leq 2e^{-2\epsilon^2 N}$$

ν - среднее по выборке размера N

μ - математическое ожидание

Иными словами, $\mu = \nu$ асимптотически ($\nu \rightarrow_{N \rightarrow \infty} \mu$)

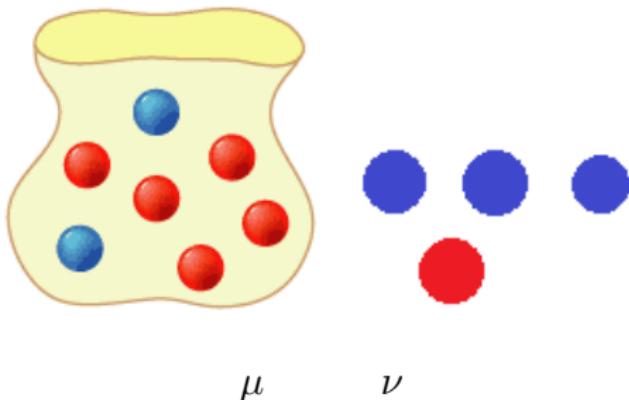
Достоинства неравенства Бернштейна - Хефдинга

$$P(|\nu - \mu| > \epsilon) \leq 2e^{-2\epsilon^2 N}$$

Правая часть не зависит от μ

Получим по выборке оценку неизвестного мат. ожидания числа шаров:

$$\nu \approx \mu \Rightarrow \mu \approx \nu$$



Гипотеза

Шар - точка $x \in X$

$f(x)$ - неизвестная функция на множестве шаров

$h(x)$ - функция-гипотеза

Мешок для гипотезы h - цвета шаров заданы как:

- Шар синий: гипотеза h верна (для этого x ,
 $h(x) = f(x)$)
 - Шар красный: гипотеза h не верна ($h(x) \neq f(x)$)
- Случайно выбирая шары из мешка, убеждаемся в истинности/ложности гипотезы для конкретного x
По выборке оцениваем долю шаров, для которых гипотеза истинна (ν)

Обучение как обобщение с выборки на множество

Задача машинного обучения - обобщение гипотезы h с выборки x_1, x_2, \dots, x_N (подмножества точек) с известными значениями f - на множество точек x_{N+1}, \dots с неизвестными значениями f .

Известно:

$$x_1, x_2, \dots, x_N \rightarrow f(x_1), f(x_2), \dots, f(x_N)$$

Находим:

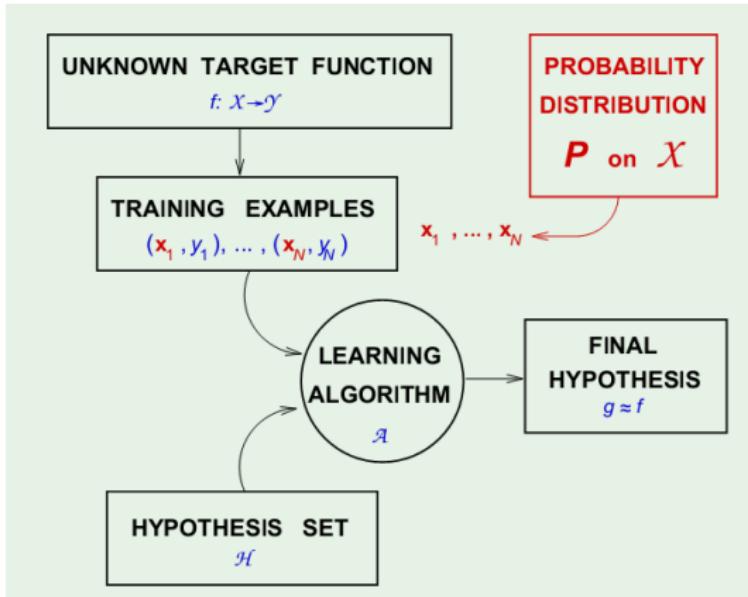
$$g : g(x_i) \text{ близко к } f(x_i), i = 1, \dots, N$$

$$\implies g(x_{N+1}) \text{ близко к } f(x_{N+1})$$

$$g(x_{N+2}) \text{ близко к } f(x_{N+2})$$

...

Диаграмма обучения



(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Задача обучения

Необходимо найти наилучшее $g \in H$ из допустимого множества гипотез

Для гипотезы $h \in H$ определим

- in sample error (ошибка по выборке) $E_{in}(h) = \nu$ - доля истинных “предсказаний” значений f гипотезой h по выборке
- out of sample error (ошибка по пространству) $E_{out}(h) = \mu$ - доля истинных “предсказаний” значений f гипотезой h по всему множеству

$$P(|E_{in}(h) - E_{out}(h)| > \epsilon) \leq 2e^{-2\epsilon^2 N}$$

Немаловажная деталь

$$P(|E_{in}(h) - E_{out}(h)| > \epsilon) \leq 2e^{-2\epsilon^2 N}$$

Для каждой конкретной гипотезы неравенство выполнено.

Пусть есть множество гипотез H .

Какова вероятность, что гипотеза $g \in H$, наилучшим образом приближающая f по выборке, будет наилучшим образом приближать f по всему множеству?

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз?

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз? (0,001)

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз? (0,001)

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз? (0,001)

С какой вероятностью одна из 1000 монет, каждая из которых подброшена 10 раз, выпадет одной и той же стороной все 10 раз?

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз? (0,001)

С какой вероятностью одна из 1000 монет, каждая из которых подброшена 10 раз, выпадет одной и той же стороной все 10 раз?

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз? (0,001)

С какой вероятностью одна из 1000 монет, каждая из которых подброшена 10 раз, выпадет одной и той же стороной все 10 раз? (0,63)

Простая аналогия

С какой вероятностью монета, подброшенная 10 раз, выпадет одной и той же стороной все 10 раз? (0,001)

С какой вероятностью одна из 1000 монет, каждая из которых подброшена 10 раз, выпадет одной и той же стороной все 10 раз? (0,63)

Простое решение

$$\begin{aligned} P(|E_{in}(g) - E_{out}(g)| > \epsilon) &\leq \\ P(|E_{in}(h_1) - E_{out}(h_1)| > \epsilon \text{ или } |E_{in}(h_2) - E_{out}(h_2)| > \epsilon \text{ или } \dots \text{ или } |E_{in}(h_M) - E_{out}(h_M)| > \epsilon) &= \\ = \sum_{i=1}^M P(|E_{in}(h_i) - E_{out}(h_i)| > \epsilon) & \\ &\leq 2M e^{-2\epsilon^2 N} \end{aligned}$$

Чем плохо?

Как улучшить?

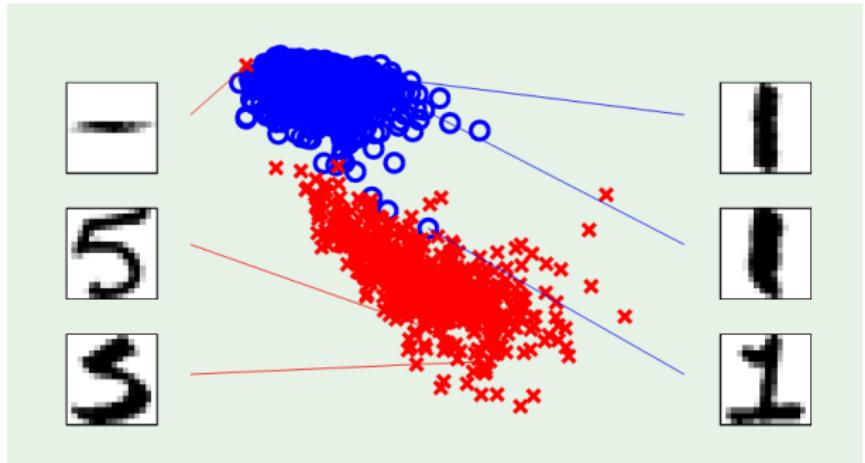
Классификация. Распознавание рукописных цифр



Выделим признаки

"Сырой" вход: значения пикселей (x_1, \dots, x_{256})
"Признаки": извлечение полезной информации
(интенсивность, симметрия x_1, x_2)

Пространство признаков



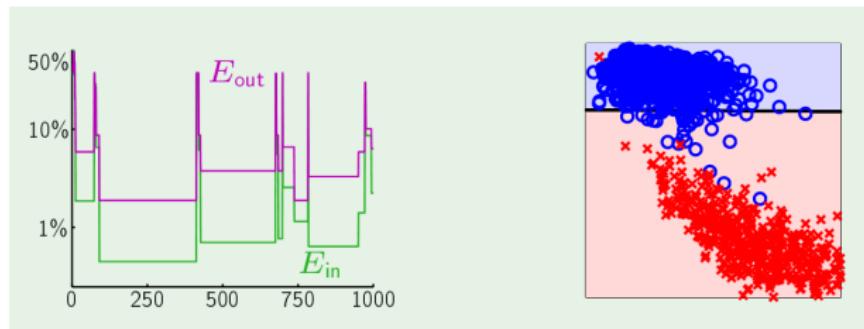
(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Обучение перцептрана (PLA)

разделяющая плоскость $h(x) = \text{sign}(w^T x)$

точка неверного предсказания: $\text{sign}(w^T x_n) \neq y_n$

$$w := w + y_n x_n$$



(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Линейная регрессия. Выдача кредита

Входы: возраст $x^{(1)}$
зарплата $x^{(2)}$

Выход: размер кредита

Задача: построить линейную функцию,
связывающую входы и выходы

$$h(x) = \sum_{i=0}^d w^{(i)} x^{(i)} = w^T x$$

Задача: репликация поведения
кредитного менеджера

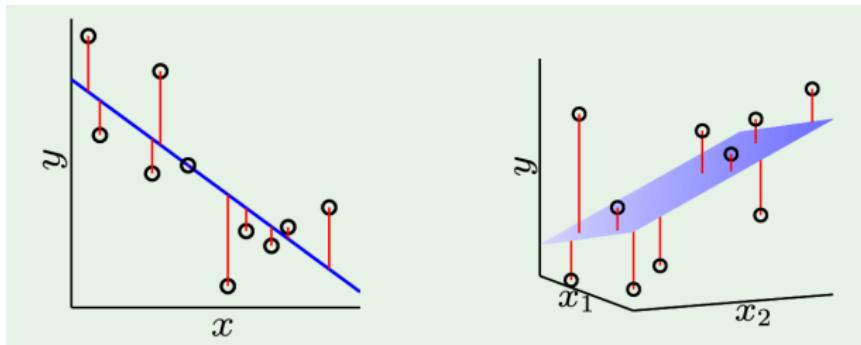
$$(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$$

Измерение ошибки

Будем использовать квадратичную невязку:

$$E_{in}(h) = \frac{1}{N} \sum_{i=1}^N (h(x_n) - y_n)^2$$

Результат линейной регрессии



(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Результат линейной регрессии

$$\nabla E_{in}(h) = 0$$

$$\begin{aligned} E_{in}(h) &= \frac{1}{N} \sum_{i=1}^N (h(x_n) - y_n)^2 = \frac{1}{N} \sum_{i=1}^N (w^T x_n - y_n)^2 \\ &= \frac{1}{N} \|Xw - y\|^2 \end{aligned}$$

Отсюда

$$\begin{aligned} \nabla E_{in}(h) &= \nabla_w \frac{1}{N} \|Xw - y\|^2 = \frac{2}{N} X^T (Xw - y) = 0 \\ X^T Xw &= X^T y \end{aligned}$$

Псевдообратная матрица

A - матрица линейного преобразования из \mathbb{R}^d в \mathbb{R}^q ,
 $q < d$.

A^+ - псевдообратная матрица для A .

Для $v \in Ker(A)$, $x \notin Ker(A)$ $A(x + v) = Ax$,

$$A^+(Ax) = x$$

Для $v \notin Ker(A)$ $Av = m$, $A^+m = v$

Через svd разложение:

$$A = U \begin{matrix} diag(\sigma_1, \dots, \sigma_n) \\ 0 \end{matrix} V^T,$$

$$A^+ = V \begin{matrix} diag(1/\sigma_1, \dots, 1/\sigma_n) \\ 0 \end{matrix} U^T,$$

Вопрос: для $v \in Ker(A)$ существует ли
 $w : A^+w = v$?

Результат линейной регрессии

$$X^T X w = X^T y$$

Если $X^T X$ обратима,

$$w = (X^T X)^{-1} X^T y$$

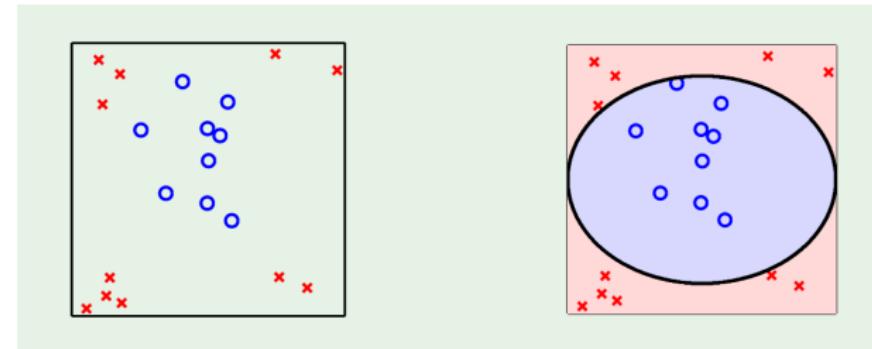
Если нет (обычно, тк измерений больше чем параметров):

$$w = (X^T X)^+ X^T y$$

Линейная регрессия для классификации

$$y = \text{sign}(w^T x) = +1 \vee -1$$

Нелинейная классификация



(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Нелинейная классификация через линейную

$$1. X = (x^{(1)}, x^{(2)}) \rightarrow (x^{(1)^2}, x^{(2)^2}) = \hat{X}$$

$$2. w = (\hat{X}^T \hat{X})^+ \hat{X}^T y$$

Определение хорошей гипотезы

$f \approx h$ - что это значит?

Почти всегда невязка определяется поточечно:

$$e(f(x), h(x))$$

Примеры:

- 1 квадратичная $e(f(x), h(x)) = (f(x) - h(x))^2$
- 2 бинарная $e(f(x), h(x)) = id(f(x) \neq h(x))$

Полная и поточечная ошибка

Полная ошибка определяется через поточечные
 $e(f(x), h(x))$:

$$E_{in} = \frac{1}{N} \sum_{n=1}^N e(f(x_n), h(x_n))$$

$$E_{out} = \mathbb{E}_x e(f(x), h(x))$$

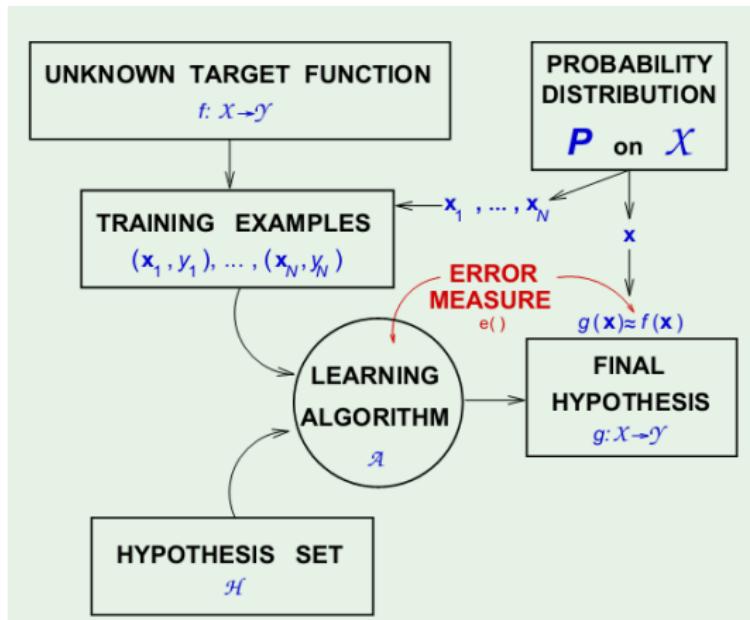
Классификация: как выбрать ошибку?

-	f	f	f
h	-	+1	-1
h	+1	true accept	false accept
h	-1	false reject	true reject
ЦРУ			Супермаркет vs

Классификация: как выбрать ошибку?

-	f	f	f
h	-	+1	-1
h	+1	true accept	false accept
h	-1	false reject	true reject
ЦРУ			Супермаркет vs

Роль функции ошибки



(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Задача: кредит

Входы: возраст $x^{(1)}$
зарплата $x^{(2)}$

Выход: размер кредита

Проблема входы одинаковые, выход - разный.
Что делать?

Шум в наблюдениях

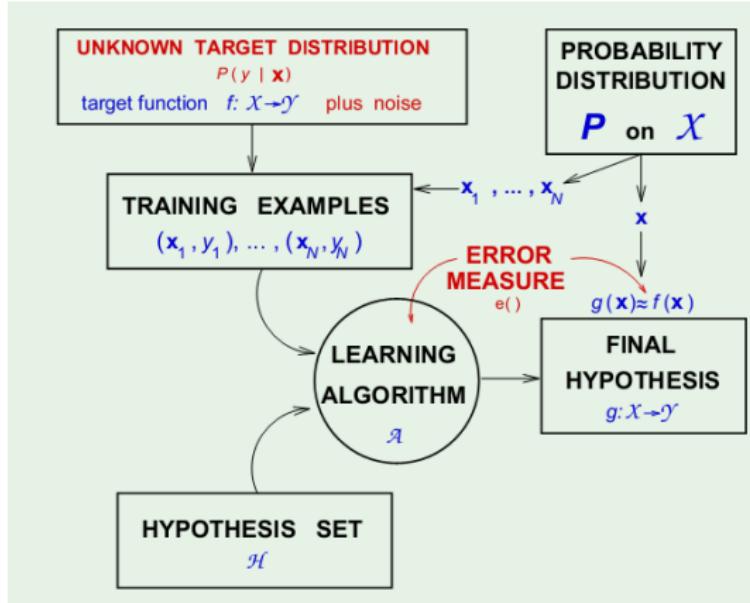
Вместо $y = f(x)$ будем использовать $P(y|x)$, так как наблюдение подвергается зашумлению
 (x, y) генерируются распределением $P(y|x)P(x)$
Детерминированная компонента:

$$f(x) = \mathbb{E}(y|x)$$

Случайная компонента:

$$y - f(x)$$

Роль распределения y



(c) Y. Abu-Mostafa, Learning From Data (Caltech online)

Цель обучения в терминах вероятности

Хотим:

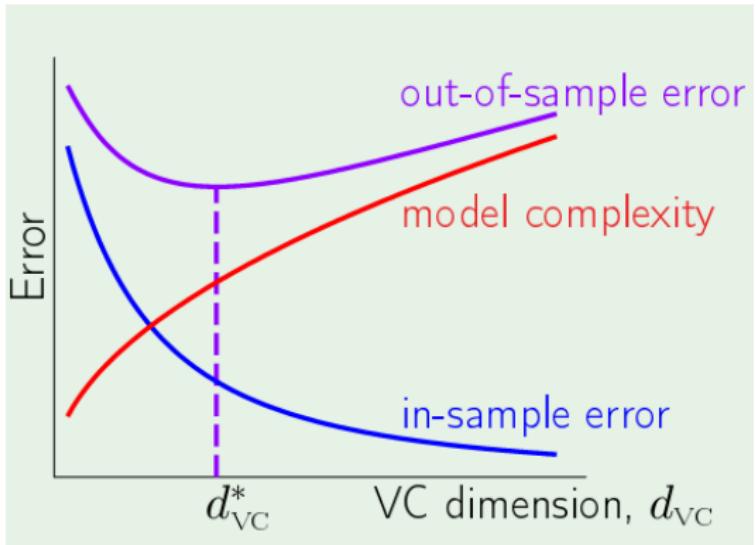
$$E_{out}(g) = 0$$

Пытаемся достичь:

$$E_{in}(g) \approx E_{out}(g) \quad E_{in}(g) = 0$$

1. Можно ли судить о E_{out} по E_{in} ?
2. Как уменьшить E_{in} ?

Будущая теория



Динамика ошибки от сложности модели
(с) Y. Abu-Mostafa, Learning From Data (Caltech online)