
Введение в Data Science и Machine Learning

Константин Ильченко • 24.03.2019

Обзор

Общие рассуждения:

- интеллект;
- свойство разумности;
- отличие машинного обучения от обычного программирования.

Намеки на базовые понятия:

- типы задач и методы обучения;
- методы обучения.

Основные “школы познания”:

- символисты;
- коннекционисты;
- эволюционисты;
- байесовцы;
- аналогисты.

Общие рассуждения

Интеллект и разум

Интеллект


- Это способность воспринимать информацию и сохранять ее в качестве знания для построения адаптивного поведения в среде или контексте.
- Основная задача - “проложить путь” к “мишени” указанной механизмами целеполагания

и

Разумность

- Восприятие
 - Целеполагание
 - Построение алгоритма действия для достижения цели
-

Ford Mark 1 - система управления огнем (ВМС США)



Интеллектуальные свойства

- Принимал данные о курсах и положении кораблей, а также метеоданные
 - Проводил баллистические вычисления
 - Выдавал параметры стрельбы на орудия
-

Отличие машинного обучения от обычного программирования

Обычное программирование

- Главная задача программиста - самому в ручную прописать все правила, которыми будет руководствоваться система в своем поведении и отладить их.

Машинное обучение

- на основании имеющихся данных(примеров решения данной задачи) подобрать метод обучения и подходящий алгоритм, обучить его и проверить на тестовых данных. То есть машина сама напишет себе программу по примерам из данных.
-


Намеки на базовые ПОНЯТИЯ

Типы задач и методы обучения

На примерах


Распознавание цифр относят к задаче **классификации обучение с учителем**. То есть имеем тренировочный набор рукописных цифр, в котором каждая цифра соответствует своему классу и роль учителя заключается в том, что он соотнес каждому изображению цифры ее класс.

Программа генерации лиц представляет собой отработку метода анализа принципиальных компонент (**РСА**) **обучения без учителя** на чем-то наборе студенческих фотографий. То есть автор “скормил” компьютеру набор фото студентов и попросил его разложить их самому по 80ти “полочкам”. Первое что бросилось в глаза методу - цвет футболки.



CRISP-DM

Стандартизованный
жизненный цикл систем
интеллектуальной
обработки данных



Какие бы задачи не решались методами машинного обучения, они проходят через 3 стадии:

- представление;
- оценка;
- оптимизация

Оптимизационный метод “градиентный спуск” оценивает данные представленные моделью по косвенной “функции ошибок” и выдает информацию о том, как изменить модель так, чтобы функция ошибок спустилась в тот минимум, который нас устроит.


Школы познания

Стадии Браге, Кеплера и Ньютона



Тихо Браге

значительную часть
жизни собирал
астрономические
данные достаточной
точности о движении
планет




Кеплер находит
математические
закономерности в
данных Браге




Ньютон на основании
найденных Кеплером
закономерностей
выводит известный
аксиоматический базис

Основные методы: обратная дедукция и решающие деревья



Коннекционисты


Перцептрон



Эта школа
вдохновляется данными
о том как работает мозг.
Как он строит знание в
реальных условиях

Многослойный Перцептрон

Нейронная сеть хранит знание в связях между нейронами




Обратное распространение ошибки



Increase b

Increase w_i
in proportion to a_i


Change a_i
in proportion to w_i




Основной метод построения знания в нейронных сетях, позволяющий на основе знания о том, как сильно ошиблась модель перестраивать все веса модели начиная с выходного



Эволюционисты



Эволюция, как метод получения нового знания берет свои истоки из наблюдений за развитием живого. В частности за тем, как человек сам стал влиять на развитие организмов его окружающих. Агрокультура издавна отбирала растения с самыми вкусными плодами, овец - с самой длинной шерстью. Одомашненные кошки, собаки, рыбки, кролики, попугаи и прочее также следствие эволюции с рукотворным отбором.



Эволюционисты рассматривают программы (алгоритм), как набор обращений к подпрограммам. Для решения конкретной задачи они создают популяции программ и оценивают их способность к решению данной задачи с помощью **функции приспособленности**. Отобрав лучшие версии программ они “скрещивают” их в случайных местах вызовов подпрограмм и таким образом получают новую популяцию для следующей эпохи отбора.



DISTRIBUTED
EVOLUTIONARY
ALGORITHMS IN
PYTHON

Сильнейшей стороной эволюционных алгоритмов является широчайший охват “пространства гипотез”, в котором каждая версия алгоритма прорабатывает свою версию ответа. Также следует отметить взаимосвязь эволюции и коннекционизма. Эволюционный рост ассоциативных зон коры головного мозга основан на нейронном обучении в сенсорных зонах - без этого он был бы бесполезен. Эволюция усиливает в потомках те свойства, что в наибольшей мере помогли предкам выжить и размножиться..

Байесианцы

Naïve Bayes Classifier

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



Thomas Bayes
1702 - 1761

Томас Байес(1702-1761) - британский математик, священник, член лондонского королевского общества. Сформулировал правило обновления уровня доверия к гипотезе при получении новых свидетельств. Сама теорема была опубликована Лапласом спустя 10 лет после смерти Байеса, т. к. он посчитал ее недостойной публикации, но к счастью оставил ее в своих записях.



Проиллюстрируем работу теоремы на примере диагностики заболеваний.

Известно:

Тест на болезнь дает верный результат в 99% случаях заболеваний и дает ложноположительный результат в 1% случаев.

$P(A)$ Распространенность заболевания - 0,1% среди всего населения (приорная вероятность)

$P(B|A)$ - вероятность положительного теста при болезни


$P(B)$ - вероятность положительного срабатывания теста =
 $[P(A)*P(B|A)+P(-A)*P(B|-A)]$

Тогда

$P(A|B)$ - вероятность болезни в случае положительного теста составит примерно 9%.

Неочевидность результата объясняется игрой вероятностей - из 1000 человек будет болен 1 и тест это покажет (на 99%), но так же тест даст ложноположительное срабатывание для 10 человек, т.е. в результате тест из 1000 раз сработает 11 и только 1 из них будет болен, что и соответствует вероятности в 9%

Аналогисты





Рассуждения по аналогии - древнейший метод построения знания. Первое упоминание относят к Аристотелю и его закону подобия “если две вещи схожи, мысль об одной из них будет склонна вызывать мысль о другой.”

Метод ближайших соседей





Джон Сноу — серьёзная вспышка эпидемии холеры, случившаяся в 1854 году в Лондоне. Событие вошло в историю благодаря методичным действиям доктора Джона Сноу выявившего источник эпидемии — загрязнённую воду из водозабной колонки. Исследование Сноу послужило толчком к развитию эпидемиологии и совершенствованию систем водоснабжения и канализации.





Метод опорных векторов созданный Владимиром Вапником сотрудником Bell Labs в 1994м году решает задачу разделения классов “проводя аналогии” и секущие гиперплоскости из $n+1$ мерного пространства

VK.COM/AISNZ



school of ai

СНЕЖИНСК