



Деревья решений (decision trees)



Деревья решений

- Следующие три раздела посвящены методам на основе деревьев.
- Три основных метода:
 - Деревья решений (decision trees)
 - Случайные леса (random forests)
 - Расширяемые деревья (boosted trees)



Деревья решений

- Все эти три метода основаны на базовом алгоритме деревьев решений.
- Мы пройдем все три метода, каждый в своём разделе курса, и в самом конце уже будут проверочные упражнения.



Деревья решений

История



Деревья решений

- Хотя базовые деревья решений использовались для принятия решений уже очень длительное время, статистические деревья решений были разработаны относительно недавно.
- Обратите внимание, это разные вещи.




Деревья решений

- Общий термин “дерево решений” можно описать как схему, отображающую выбор решения:



Деревья решений

- Общий термин “дерево решений” можно описать как схему, отображающую выбор решения:





Деревья решений

- Обучение деревьев решений – это статистическое моделирование с применением деревьев, где решения в каждом узле принимаются на основе некоторого условия (некоторой метрики).
- Давайте рассмотрим шаги, которые привели к возможности создавать предсказания на основе деревьев.




Деревья решений

- В двух словах – деревья решений и похожие методы разбивают данные на части на основе информации, содержащейся в признаках.
- Это значит, что нам нужно математическое определение термина информация, и способность измерить её.



Деревья решений


- Клод Шеннон считается отцом теории информации.
- В 1948 году в журнале Bell System Technical Journal опубликовал работу “Математическая теория коммуникаций”.





Деревья решений

- Работал в разных сферах:
 - Проектирование микросхем
 - Криптография
 - Носимые компьютеры
 - Искусственный интеллект






Деревья решений

- Способность измерить информацию станет важна, когда мы рассмотрим математические основы построения деревьев решений.
- Мы займёмся этим позже, а пока посмотрим на этапы развития деревьев решений.



Деревья решений

- 1963: Морган, Санквист - первая публикация регрессионного алгоритма деревьев





Деревья решений


- 1963: piecewise-constant regression tree





Деревья решений


- 1963: piecewise-constant regression tree





Деревья решений


- 1963: piecewise-constant regression tree





Деревья решений


- 1963: piecewise-constant regression tree





Деревья решений

- 1963: piecewise-constant regression tree





$X < 1$



Деревья решений



- 1963: piecewise-constant regression tree





Деревья решений



- 1963: piecewise-constant regression tree





Деревья решений

- 1963: piecewise-constant regression tree





Деревья решений

- В статье 1963 года разбиения в каждом узле дерева основывались на “загрязнении узла” (node impurity), которое по сути определялось как метрика ошибки:

$$\phi(t) = \sum_{i \in t} (y_i - \bar{y})^2$$



Деревья решений

- 1972: Роберт Мессенджер и Льюис Манделл публикуют первый алгоритм классификации с применением деревьев.
- Условие разделения в узлах было названо “Theta Automatic Interaction Detection” (THAID)



Деревья решений

- 1972: Роберт Мессенджер и Льюис Манделл публикуют первый алгоритм классификации с применением деревьев.
- Условие разделения в узлах было названо “Theta Automatic Interaction Detection” (THAID)
- 1980: Гордон Кисс публикует развитие алгоритма CHAID – Chi-square automatic interaction detection.



Деревья решений

- 1970-е годы: Лео Брейман и Чарльз Стоун из Беркли, Джером Фридман и Ричард Ольшен из Стэнфорда начали разработку алгоритмов CART – Classification and Regression tree.




Деревья решений

- 1970-е годы: Лео Брейман и Чарльз Стоун из Беркли, Джером Фридман и Ричард Ольшен из Стэнфорда начали разработку алгоритмов CART – Classification and Regression tree.
- 1984: Они опубликовали книгу по алгоритмам CART, включая детали реализации на компьютере.
- Методы на основе CART стали стандартом (и в Scikit-Learn!)



Деревья решений

- В книге CART были предложены многие концепции:
 - Кросс-валидация деревьев
 - Усечение деревьев (pruning)
 - Суррогатные разбиения
 - Оценки важности переменных
 - Поиск линейных разделений





Деревья решений

- 1986: Джон Росс Квинлан разработал алгоритм деревьев решений ID3 на основе метрики “gain ratio”.
- 1990-е: улучшения ID3 – C4.5 (всё ещё популярен)
- 2000-е: выпущена оптимизированная коммерческая версия C5.0 с различными улучшениями.



Деревья решений

- Многие улучшения основного алгоритма были перенесены на другие методы с применением деревьев – случайные леса и расширяемые деревья.
- Давайте посмотрим на фундаментальную идею деревьев решений!



Деревья решений

Терминология





Деревья решений

- Для начала обсудим различные термины, которые встречаются при обсуждении деревьев...



Деревья решений


- Вспомним наше простое дерево:





Деревья решений


- Вспомним наше простое дерево:





Деревья решений


- Разбиение (splitting):





Деревья решений


- Разбиение (splitting):





Деревья решений


- Узлы (nodes):





Деревья решений


- Корневой узел (root node):





Деревья решений


- Листовые / конечные узлы (leaf / terminal nodes):





Деревья решений


- Родительские/дочерние узлы (parent/children nodes):





Деревья решений


- Родительские/дочерние узлы (parent/children nodes):





Деревья решений


- Родительские/дочерние узлы (parent/children nodes):





Деревья решений


- Ветви / поддеревья (tree branches / sub trees):





Деревья решений


- Усечение (pruning)





Деревья решений


- Усечение (pruning)





Деревья решений

- Далее мы перейдём к построению дерева!





Деревья решений

Gini impurity



Деревья решений

- Прежде чем мы узнаем, как при построении деревьев выбираются критерии разбиения, давайте взглянем на наиболее часто используемую метрику измерения информации для деревьев решений – gini impurity (загрязнение Джини, индекс Джини, примесь Джини).



Деревья решений

- Метрика “gini impurity” измеряет, насколько информация в наборе данных является чистой (“pure”).
- С точки зрения задач классификации, мы можем воспринимать это как однородность классов.
- Посмотрим как это выглядит на простейшем примере двух классов...



Деревья решений

- Метрика “gini impurity” для классификации
 - Для набора классов C и заданного набора данных Q :

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Метрика “gini impurity” для классификации
 - Для набора классов C и заданного набора данных Q , p_c это вероятность класса c .

$$p_c = \frac{1}{N_Q} \sum_{x \in Q} \mathbb{1}(y_{class} = c)$$


$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Метрика “gini impurity” для классификации

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$






Деревья решений

- Метрика “gini impurity” для классификации

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$






Деревья решений

- Метрика “gini impurity” для классификации

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$






Деревья решений

- Метрика “gini impurity” для классификации

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$

Класс “красный”
 $(2/4)(1 - 2/4) = 0.25$






Деревья решений

- Метрика “gini impurity” для классификации

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Класс “красный”
 $(2/4)(1 - 2/4) = 0.25$


Класс “синий”
 $(2/4)(1 - 2/4) = 0.25$



Деревья решений

- Метрика “gini impurity” для классификации

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Класс “красный”
 $(2/4)(1 - 2/4) = 0.25$



Класс “синий”
 $(2/4)(1 - 2/4) = 0.25$




Gini Impurity
 $0.25 + 0.25 = 0.5$



Деревья решений

- Данные более чистые (меньше “impurity”)

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Класс “красный”
 $(1/4)(1 - 1/4) = 0.1875$



Класс “синий”
 $(3/4)(1 - 3/4) = 0.1875$




Gini Impurity
 $0.1875 + 0.1875 = 0.375$



Деревья решений

- Данные полностью чистые (нулевой “impurity”)

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Класс “красный”
 $(0/4)(1 - 0/4) = 0$



Класс “синий”
 $(4/4)(1 - 4/4) = 0$



Gini Impurity
 $0 + 0 = 0$



Деревья решений

- Если цель дерева решений в том, чтобы отделить классы друг от друга, то мы можем выполнять разбиения данных на основе метрики gini impurity.
- Мы хотим минимизировать gini impurity на листьях.
- Если на листьях gini impurity минимально, то это будет означать, что мы удачно разделили классы.



Деревья решений

- В следующей лекции мы построим пример применения *gini impurity*, вычисляя его на основе набора данных.
- Далее мы рассмотрим различные типы разбиения признаков и определения того, какой признак будет корневым узлом.



Деревья решений

Gini impurity в деревьях – часть 1



Деревья решений

- Начнём разбираться в том, как лучше выбрать порядок узлов и как выполнять разбиение внутри дерева.
- Для начала посмотрим, как построить дерево на основе некоторого набора данных, используя метрику gini impurity.



Деревья решений

- Начиная строить дерево, нам нужно выбрать признак, который будет использоваться для корневого узла.
- Мы можем применить метрику gini impurity для сравнения информации, содержащейся внутри признаков в наборе данных.
- Рассмотрим этот момент подробнее...



Деревья решений

- Метрика “gini impurity” для классификации
 - Для набора классов C и заданного набора данных Q :

$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Метрика “gini impurity” для классификации
 - Для набора классов C и заданного набора данных Q , p_c это вероятность класса c .

$$p_c = \frac{1}{N_Q} \sum_{x \in Q} \mathbb{1}(y_{class} = c) \quad G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Метрика “gini impurity” для классификации
 - Для набора классов C и заданного набора данных Q , p_c это вероятность класса c .

$$p_c = \frac{1}{N_Q} \sum_{x \in Q} \mathbb{1}(y_{class} = c)$$

$$G(Q) = \sum_{c \in C} p_c (1 - p_c)$$



Деревья решений

- Рассмотрим следующий набор данных:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No



Деревья решений

- Попробуем спрогнозировать – спам или нет:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No

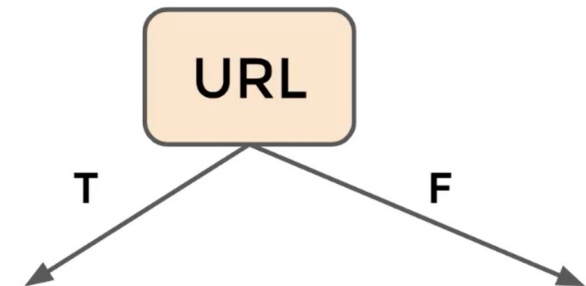
URL



Деревья решений

- Является ли письмо спамом, если в нём есть URL:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No

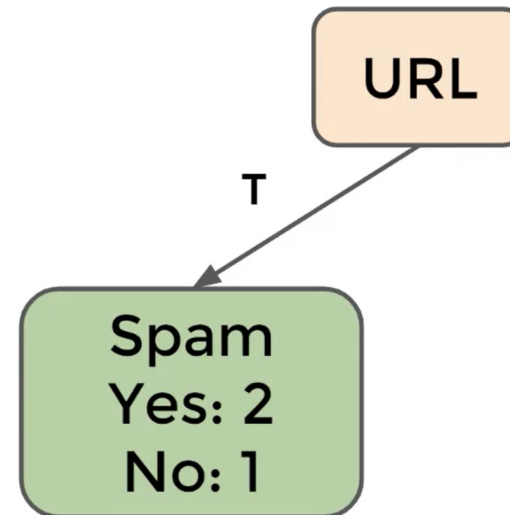




Деревья решений

- Является ли письмо спамом, если в нём есть URL:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No






Деревья решений

- Является ли письмо спамом, если в нём есть URL:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No






Деревья решений

- Является ли письмо спамом, если в нём есть URL:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No






Деревья решений

- Вспомним формулу gini impurity:

X - URL Link	Y-Spam
Yes	Yes
Yes	Yes
No	No
No	No
No	Yes
No	No
Yes	No




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Пусть “спам” и “не-спам” будут классами C
- Левый листовой узел:
 $(\frac{2}{3})(1 - \frac{2}{3})$




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Пусть “спам” и “не-спам” будут классами C
- Левый листовый узел:

$$\left(\frac{2}{3}\right)\left(1 - \frac{2}{3}\right) + \left(\frac{1}{3}\right)\left(1 - \frac{1}{3}\right)$$



$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$




Деревья решений

- Пусть “спам” и “не-спам” будут классами C
- Левый листовый узел:

$$\left(\frac{2}{3}\right)\left(1-\frac{2}{3}\right) + \left(\frac{1}{3}\right)\left(1-\frac{1}{3}\right)$$

$$\text{Gini}=0.44$$



$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Пусть “спам” и “не-спам” будут классами C
- Левый листовой узел:


$$\left(\frac{2}{3}\right)\left(1-\frac{2}{3}\right) + \left(\frac{1}{3}\right)\left(1-\frac{1}{3}\right)$$

$$\text{Gini}=0.44$$

- Правый листовой узел:

$$\left(\frac{1}{4}\right)\left(1-\frac{1}{4}\right) + \left(\frac{3}{4}\right)\left(1-\frac{3}{4}\right)$$

$$\text{Gini}=0.375$$




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Итак, для признака URL метрика gini impurity:
- Левый лист: Gini=0.44
- Правый лист: Gini=0.375




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Всего писем: $(2+1) + (1+3) = 7$
- Левый лист: $Gini=0.44$
- Правый лист: $Gini=0.375$




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Всего писем: $(2+1) + (1+3) = 7$
- Левый лист: $Gini=0.44$
- Правый лист: $Gini=0.375$
- Писем слева: 3
- Писем справа: 4




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Всего писем: $(2+1) + (1+3) = 7$
- Левый лист: $Gini=0.44$
- Правый лист: $Gini=0.375$
- Писем слева: 3
- Писем справа: 4
- $(3/7)*0.44+(4/7)*0.375$
- Gini Impurity = 0.403




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Gini Impurity для признака URL равна 0.403




$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Gini Impurity для признака URL равна 0.403
- А если несколько признаков?



$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$



Деревья решений

- Нам нужно разобрать ещё несколько вопросов:
 - Несколько признаков
 - Непрерывные признаки
 - Мульти-категориальные признаки
- Мы можем применить *gini impurity* для каждого из этих случаев, чтобы найти наилучший корневой узел и наилучшие параметры разбиения для листьев.



Деревья решений

Gini impurity в деревьях – часть 2



Деревья решений

- Ранее мы узнали, как вычислять gini impurity для бинарного категориального признака (состоящего только из двух категорий).
- Нам нужно разобрать ещё несколько вопросов:
 - Непрерывные признаки
 - Мульти-категориальные признаки ($N > 2$)
 - Как выбрать корневой узел



Деревья решений

- Представим себе непрерывный признак:

X - Words in Email	Y-Spam
10	Yes
40	No
20	Yes
50	No
30	No



Деревья решений

- Вычислим метрику gini impurity

X - Words in Email	Y-Spam
10	Yes
40	No
20	Yes
50	No
30	No



Деревья решений

- Сначала отсортируем данные

X - Words in Email	Y-Spam
10	Yes
40	No
20	Yes
50	No
30	No



Деревья решений

- Вычислим возможные значения для разделения

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

Words $\leq$ N



Деревья решений

- Возьмём средние значения “между” строками

X - Words in Email		Y-Spam
15	10	Yes
25	20	Yes
35	30	No
45	40	No
	50	No

Words $\leq N$



Деревья решений

- Вычислим gini impurity для каждого разбиения

Words ≤ 15

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No



Деревья решений

- Вычислим gini impurity для каждого разбиения

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

15

Words ≤ 15

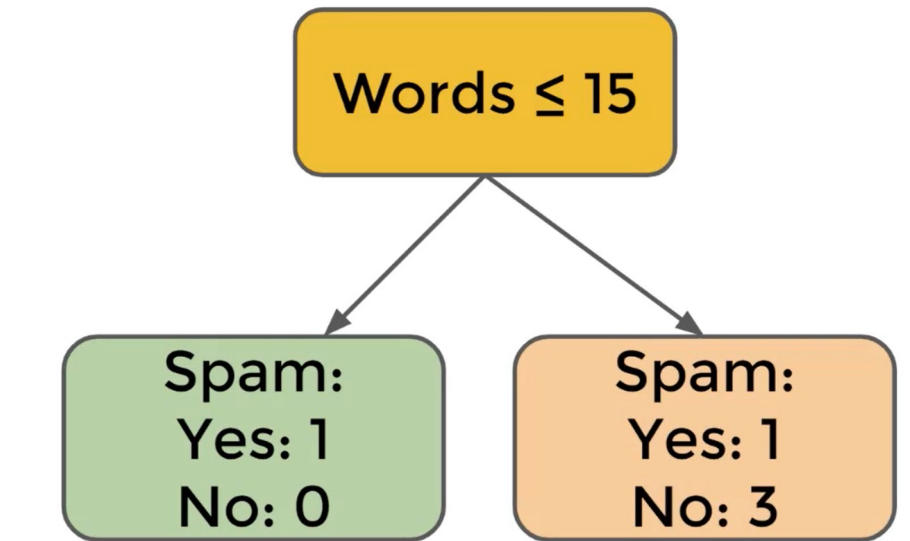


Деревья решений

- Вычислим gini impurity для каждого разбиения

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

15



$$G(Q) = \sum_{c \in C} p_c(1 - p_c)$$

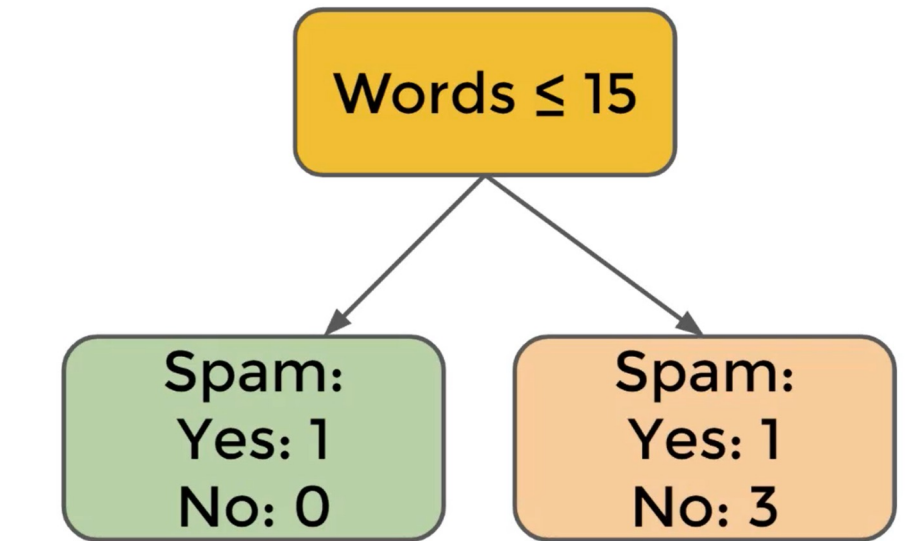


Деревья решений

- Вычислим gini impurity для каждого разбиения

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

15



$$G(Q) = \left(\frac{1}{5}\right)(0+0) + \left(\frac{4}{5}\right)\left(\left(\frac{1}{4}\right)\left(1-\frac{1}{4}\right) + \left(\frac{3}{4}\right)\left(1-\frac{3}{4}\right)\right)$$

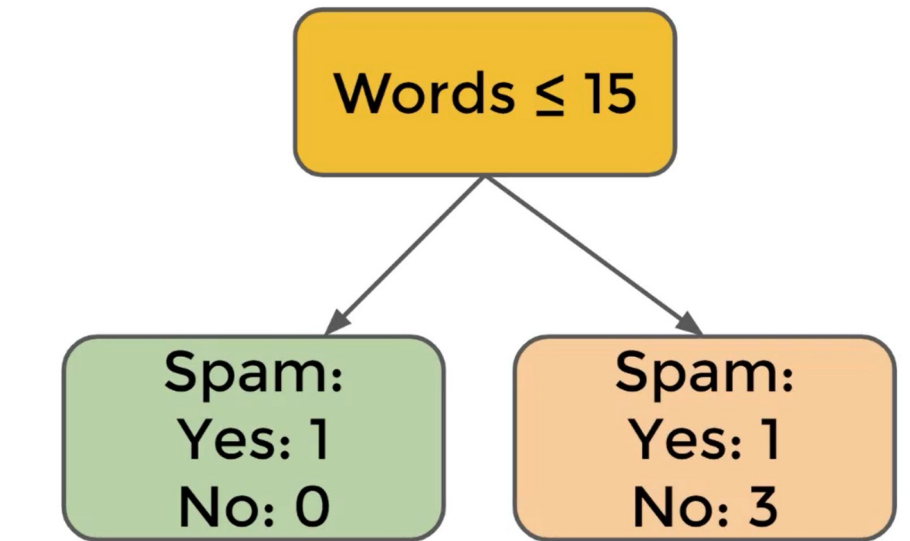


Деревья решений

- Вычислим gini impurity для каждого разбиения

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

15



$$\begin{aligned} G(Q) &= \left(\frac{1}{5}\right)(0+0) + \left(\frac{4}{5}\right)\left(\left(\frac{1}{4}\right)(1-\frac{1}{4}) + \left(\frac{3}{4}\right)(1-\frac{3}{4})\right) \\ &= 0.3 \end{aligned}$$



Деревья решений

- Вычислим gini impurity для каждого разбиения

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

15

Gini=0.3



Деревья решений

- Вычислим gini impurity для каждого разбиения

X - Words in Email		Y-Spam	
15	10	Yes	Gini=0.3
25	20	Yes	Gini=0
35	30	No	Gini=0.26
45	40	No	Gini=0.4
	50	No	



Деревья решений

- Выбираем наименьший gini impurity

X - Words in Email		Y-Spam	
15	10	Yes	Gini=0.3
25	20	Yes	Gini=0
35	30	No	Gini=0.26
45	40	No	Gini=0.4
	50	No	

Orange arrows point from the 'Gini' values to the 'Gini=0' value, which is highlighted with a large orange arrow.

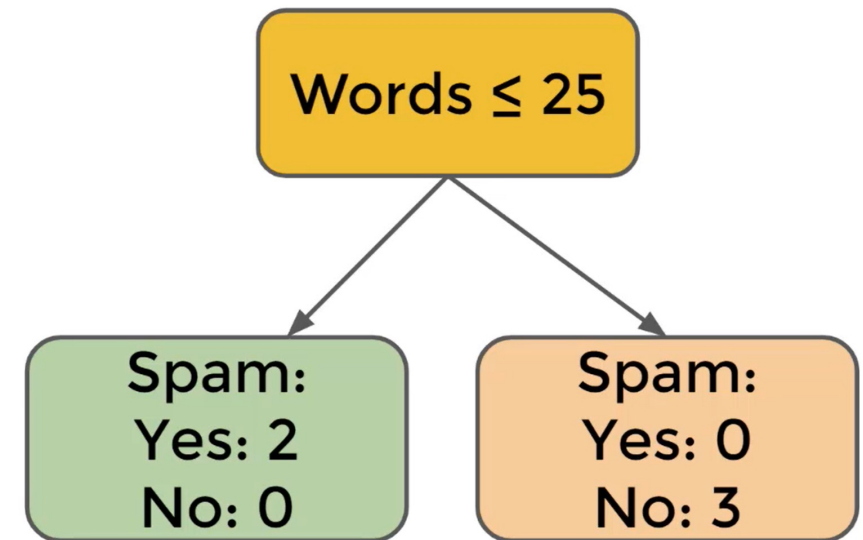


Деревья решений

- Это значение будет разделителем для узла

X - Words in Email	Y-Spam
10	Yes
20	Yes
30	No
40	No
50	No

25



$$G(Q) = 0$$



Деревья решений

- Мы вычислили gini impurity для следующих случаев:
 - Бинарные признаки
 - Непрерывные признаки
- Далее давайте вычислим эту метрику для мульти-категориальных признаков



Деревья решений

- Мульти-категориальный признак:

X - Sender	Y-Spam
Abe	Yes
Bob	Yes
Claire	No
Abe	No
Bob	No



Деревья решений

- Вычислим gini impurity для всех комбинаций


X - Sender	Y-Spam
Abe	Yes
Bob	Yes
Claire	No
Abe	No
Bob	No



Деревья решений

- Вычислим gini impurity для всех комбинаций

X - Sender	Y-Spam
Abe	Yes
Bob	Yes
Claire	No
Abe	No
Bob	No






Деревья решений

- Вычислим gini impurity для всех комбинаций

X - Sender	Y-Spam
Abe	Yes
Bob	Yes
Claire	No
Abe	No
Bob	No






Деревья решений

- Вычислим gini impurity для всех комбинаций

X - Sender	Y-Spam
Abe	Yes
Bob	Yes
Claire	No
Abe	No
Bob	No






Деревья решений

- Вычислим gini impurity для всех комбинаций

X - Sender	Y-Spam
Abe	Yes
Bob	Yes
Claire	No
Abe	No
Bob	No





Деревья решений

- Теперь мы умеем вычислить gini impurity для различных типов признаков.
- Но как выбрать признак для корневого узла, когда признаков несколько?
- Нужно вычислить gini impurity для каждого признака, выбрать тот где метрика наименьшая, и взять его первым.




Деревья решений

- Мы хотим минимизировать gini impurity на листьях.
- Оставляем листья, когда impurity меньше некоторого порогового значения.
- Выполняем разбиение только в тех случаях, когда impurity больше некоторого порогового значения.



Деревья решений

- Слишком большое дерево (“overfitted”):






-
- The diagram shows a hierarchical tree structure. At the top is a single orange node. This node branches into two orange nodes. The left orange node branches into two orange nodes, and the right orange node branches into two orange nodes. The leftmost orange node branches into two green nodes. The rightmost orange node branches into two green nodes. The two green nodes under the leftmost orange node are enclosed in a red rounded rectangle. The two green nodes under the rightmost orange node are also enclosed in a red rounded rectangle.



Деревья решений


- Добавляем порог уменьшения для gini impurity:





Деревья решений


- Ещё мы можем установить максимальную глубину





Деревья решений


- Ещё мы можем установить максимальную глубину





Деревья решений

- Ещё мы можем установить максимальную глубину





Деревья решений

- Посмотрим различные гиперпараметры во время написания кода!



Деревья решений

Пишем код – часть 1 - данные



Деревья решений

Пишем код – часть 2 - модель