

Прикладные задачи анализа данных

Функции ошибки / функционалы качества

Дьяконов А.Г.

**Московский государственный университет
имени М.В. Ломоносова (Москва, Россия)**



Задача

Дано

Найти

Критерий

**Построить алгоритм легко!
Чтобы улучшить... надо уметь оценивать.**

Метрики

- **функции ошибки**
- **функционалы качества**

Функции ошибки / функционалы качества

Пожалуй, **самое главное**, при решении задачи...


а что такое решение!

В анализе данных:


- **формализация ответа (формат)**
- **как ответ оценивается (критерий качества)**

Случай из практики: задача про траектории зрачка
(задача с 3 классами, а не с двумя)

Задача регрессии



Задача регрессии




Будем дальше пытаться всё решать в классе констант

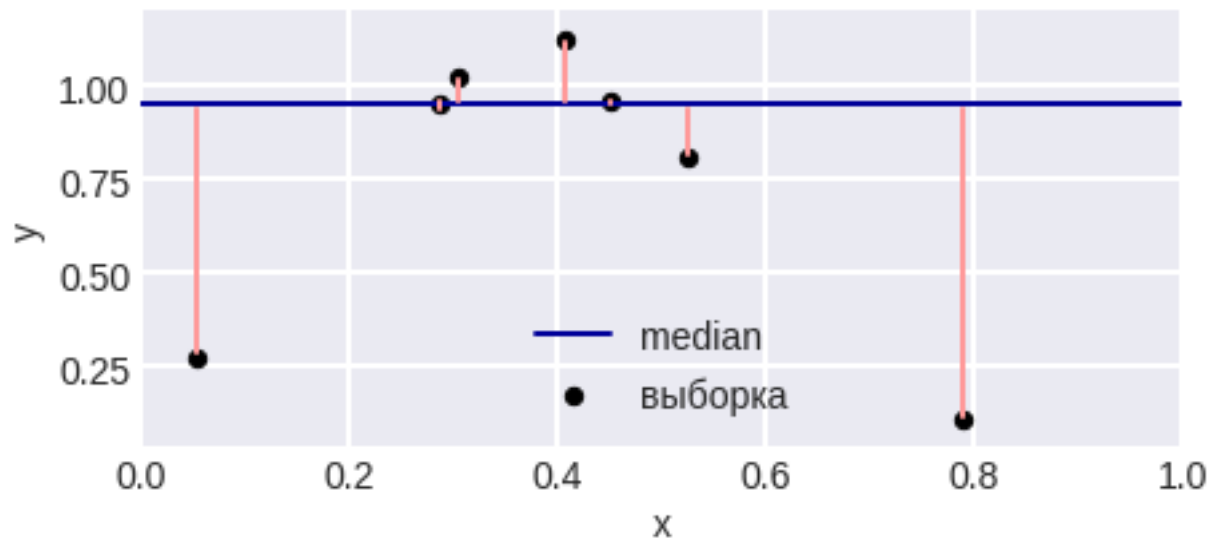
1. Простейшее решение

2. Примерно это и происходит в листьях обобщённых деревьев

3. Раскрывает природу функционалов



Средний модуль отклонения – Mean Absolute Error (MAE), Mean Absolute Deviation (MAD)



$$MAE = \frac{1}{q} \sum_{i=1}^q |a_i - y_i|$$

Напоминание:

$$\frac{1}{q} \sum_{i=1}^q |a - y_i| \rightarrow \min$$

$$a = \text{median}(\{y_i\}_{i=1}^q)$$

Это открывает смысл решений!

Средний модуль отклонения

Способы использования тайных знаний:


- **медиана, вместо усреднения, в ансамбле**
- **округление ответа (если целевой вектор целочисленный)**

Средний квадрат отклонения ~ Mean Squared Error (MSE)

$$MSE = \frac{1}{q} \sum_{i=1}^q |a_i - y_i|^2$$

$$\frac{1}{q} \sum_{i=1}^q |a - y_i|^2 \rightarrow \min$$

$$a = \frac{1}{q} \sum_{i=1}^q y_i$$



Root Mean Squared Error (RMSE)
или **Root Mean Square Deviation (RMSD)**

$$RMSE = \sqrt{\frac{1}{q} \sum_{i=1}^q |a_i - y_i|^2}$$

Средний квадрат отклонения ~ Mean Squared Error (MSE)

Способы использования тайных знаний

- ничего не делать (в RF, GBM и т.д. всё равно усредняют)
 - метод НСКО – классическая регрессия!

Обобщения

$$\sqrt[p]{\frac{1}{q} \sum_{i=1}^q w_i |\varphi(a_i) - \varphi(y_i)|^p}$$

Рецепты

1. Преобразование целевого вектора $\varphi(y)$
2. Веса \sim вероятности появления объектов в сэмплировании
3. В случае нетривиальных p – прямая настройка


Прямая настройка – пример

$$F(\underbrace{B}_{\text{стандартная оптимизация}} \cdot \underbrace{C_c}_{\text{простое РР}}) \rightarrow \min_c$$


Как в задаче CrowdFlower (выбор порогов)

Есть обобщения, где берётся медиана, а не усреднение!

Про нетривиальные p



Как точка минимума зависит от степени



Symmetric mean absolute percentage error (SMAPE or sMAPE)

$$\mu = \frac{2}{q} \sum_{i=1}^q \frac{|y_i - a_i|}{y_i + a_i} = 100\% \cdot \frac{1}{q} \sum_{i=1}^q \frac{|y_i - a_i|}{(y_i + a_i)/2}$$

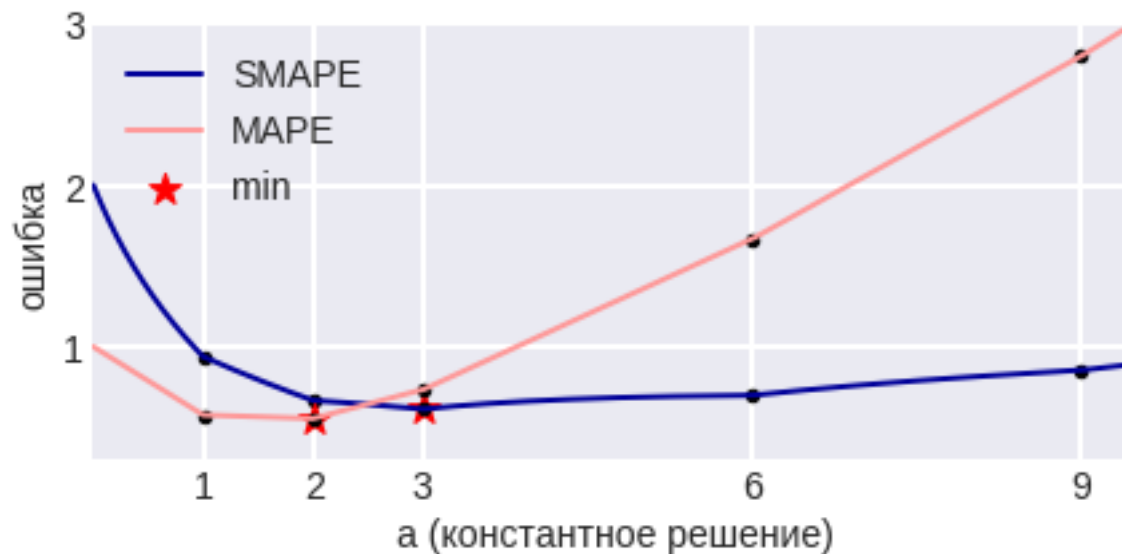
Когда надо интерпретировать погрешность как проценты

- плохо, если есть нули (и отрицательные значения)

Mean Absolute Percent Error (MAPE)


$$100\% \cdot \frac{1}{q} \sum_{i=1}^q \frac{|y_i - a_i|}{|y_i|}$$

Symmetric mean absolute percentage error (SMAPE or sMAPE)




Чтостораживает в этом графике?

Symmetric mean absolute percentage error (SMAPE or sMAPE)



Масштаб!



PMAD

$$PMAD = \frac{\frac{1}{q} \sum_{i=1}^q |y_i - a_i|}{\sum_{i=1}^q |y_i|}$$

Меры на сравнении с бенчмарком

Классная идея:

сделать простой алгоритм и смотреть ошибку относительно его.

$$r_i = e_i / e'_i$$

Mean Relative Absolute Error (MRAE)

$$MRAE = \frac{1}{q} \sum_{i=1}^q |r_i|$$

Меры на сравнении с бенчмарком

а можно так...

$$REL_MAE = \frac{\sum_{i=1}^q |y_i - a_i|}{\sum_{i=1}^q |y_i - a'_i|}$$

или Percent Better

$$PB(MAE) = \frac{1}{q} \sum_{i=1}^q I[|y_i - a_i| < |y_i - a'_i|]$$

Как выбрать бенчмарк в задачах прогнозирования?

Нормированные ошибки

Не зависят от шкалы...

$$q_t = \frac{e_t}{\frac{1}{q-1} \sum_{i=2}^q |y_i - y_{i-1}|}$$

Mean Absolute Scaled Error




$$MASE = \frac{1}{q} \sum_{i=1}^q |q_i|$$

Какие ещё бывают функционалы в регрессии?

С точностью до порога

$$\frac{1}{q} \sum_{i=1}^q I[|y_i - a_i| < \varepsilon]$$

(это функционал качества) был в задаче **Dunnhumby**




**Минимизация графика ошибки
(на вертикали)**

**Мы всегда его минимизируем – не
только здесь!**


Несимметричные функции потерь

$$\frac{1}{q} \sum_{i=1}^q \begin{cases} g(|y_i - a_i|), & y_i < a_i, \\ h(|y_i - a_i|), & y_i \geq a_i, \end{cases}$$



Зачем нужны такие функции?

Несимметричные функции потерь



$$\frac{1}{q} \sum_{i=1}^q \begin{cases} k_2 |y_i - a_i|, & y_i < a_i, \\ k_1 |y_i - a_i|, & y_i \geq a_i, \end{cases}$$

Совет


Функции ошибок иногда и классные признаки...

Пример: в Casualty придумываем бенчмарки (восстановление одной переменной по другой),
признаки – их относительные ошибки,
т.к. абсолютные брать нельзя

Почему?

Совет


Аналогично во многих задачах с сигналами...



**Признак – не только коэффициенты в приближении,
но и ошибка приближения!**

~ отклонение от типичного поведения


Задача классификации



Обычная точность – Accuracy, Mean Consequential Error

$$MCE = \frac{1}{q} \sum_{i=1}^q I[a_i = y_i]$$

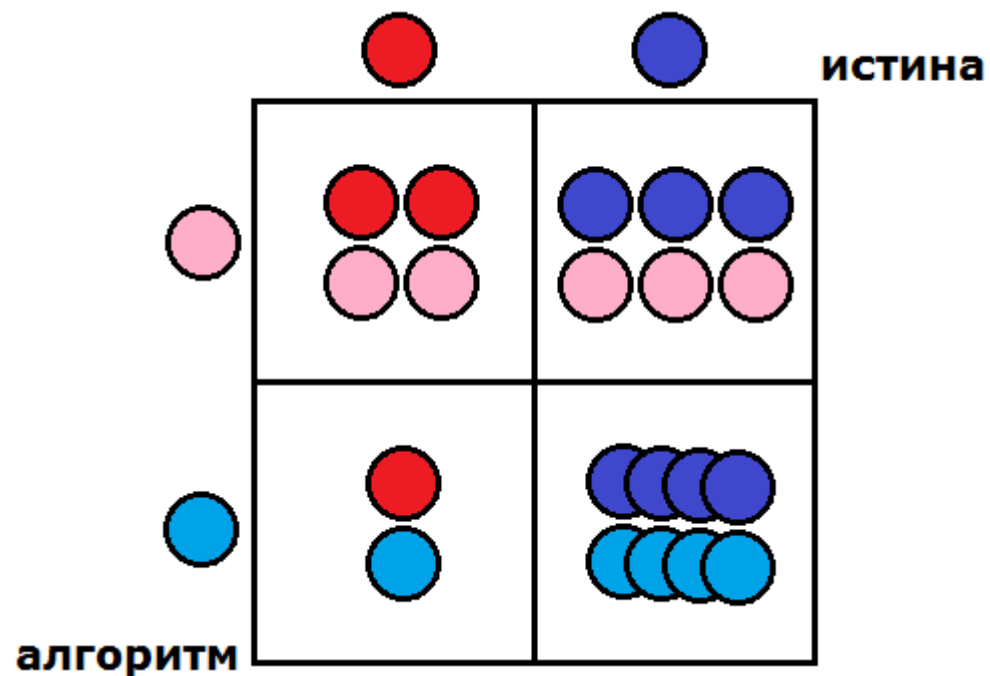

- первое, что приходит в голову
- не учитывает разную мощность классов



$y = [0, 0, 0, 0, 1, 0, 0, 0, 0, 0, 0, 0, 0, 1, 0, 0, 0, 0]$

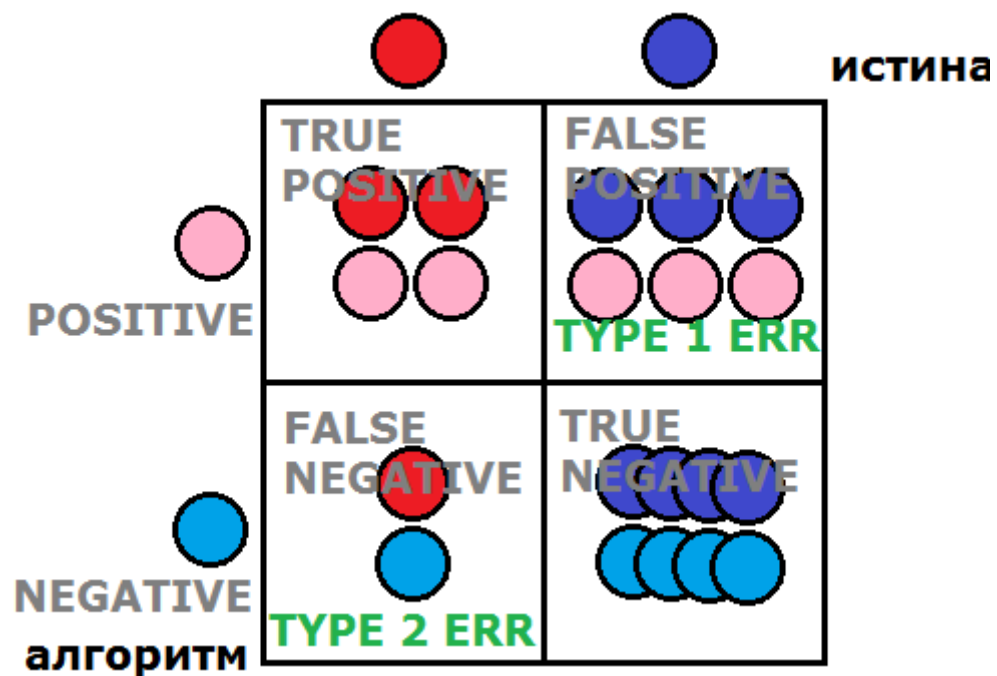

Выгодно выдавать решение – константу 0!

Задача классификации с двумя классами



Confusion Matrix

Задача классификации с двумя классами



Как запомнить названия ошибок

1 рода – не учил, но **сдал** (= знает по мнению экзаменатора)

2 рода – **учил**, но не сдал (= не знает по мнению экзаменатора)




Ошибка 1 рода




Ошибка 2 рода

Точность Accuracy

$$ACC = \frac{TP+TN}{ALL}$$





Полнота (Sensitivity, True Positive Rate, Recall, Hit Rate)





TPR = TP / сколько правда 1

Specificity (True Negative Rate)




FPR = 1 – Specificity

Точность (Precision, Positive Predictive Value)




False Positive Rate (FPR, fall-out, false alarm rate)



FPR = FP / сколько правда 0

F₁ score



$$\frac{2}{\frac{1}{TP/(TP+FP)} + \frac{1}{TP/(TP+FN)}} = \frac{2TP}{2TP + FP + FN}$$

F_β score

$$\frac{1}{\frac{\alpha}{P} + \frac{1-\alpha}{R}} = \frac{PR}{\alpha R + (1-\alpha)P} = \frac{1}{\alpha} \frac{PR}{R + \left(\frac{1}{\alpha} - 1\right)P}$$

$$\beta^2 = \left(\frac{1}{\alpha} - 1\right)$$

$$F_\beta = (1 + \beta^2) \frac{PR}{R + \beta^2 P}$$

Задача бинарной классификации

Теперь выдаём оценку принадлежности к классу 1

$$y \in \{0, 1\}$$

$$a \in [0, 1]$$

Log Loss

В задаче классификации с двумя непересекающимися классами (0, 1), когда ответ **вероятность** (?) принадлежности к классу 1


$$LOGLOSS = -\frac{1}{q} \sum_{i=1}^q (y_i \log a_i + (1 - y_i) \log(1 - a_i))$$

На что похоже?

Так понятнее...

$$-\begin{cases} \log a_i, & y_i = 1, \\ \log(1 - a_i), & y_i = 0. \end{cases}$$

Нельзя ошибаться!



Log Loss

В задаче классификации с двумя непересекающимися классами (0, 1), когда ответ **вероятность** (?) принадлежности к классу 1

$$\text{LOGLOSS} = -\frac{1}{q} \sum_{i=1}^q (y_i \log a_i + (1 - y_i) \log(1 - a_i))$$

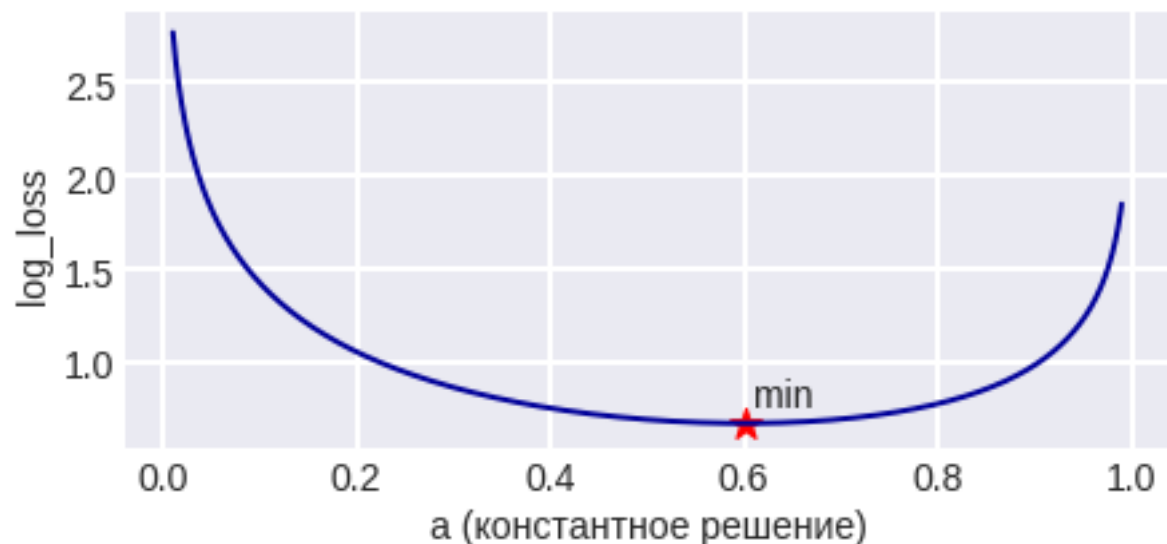
На что похоже?

Вспоминаем...

$$\Pi = \prod_{i=1}^n \pi_p(x_i) = p^m (1-p)^{n-m} \sim$$

$$\frac{1}{n} (m \log p + (n-m) \log(1-p))$$

Log Loss – Оптимальная константа



$$-\frac{1}{q} \sum_{i=1}^q (y_i \log a + (1 - y_i) \log(1 - a)) \rightarrow \min_a$$

$$-\frac{q_1}{q} \log a - \frac{q_0}{q} \log(1 - a) \rightarrow \min_a$$

$$a = \frac{q_1}{q}$$

Интерпретация константного решения

Посчитаем матожидание ошибки –

у нас один (*i*-й) объект, который с вероятностью p принадлежит классу 1.

$$-p \log(a_i) - (1-p) \log(1-a_i)$$

Минимизируем это выражение:

$$\frac{p}{a_i} - \frac{1-p}{1-a_i} = 0$$

$$a_i = p$$

О чудо!

Но так не всегда...

Вот почему используют `log_loss`

Log Loss

В каких пределах варьируется \log_loss ?

Какие недостатки \log_loss ?

Log Loss

В каких пределах варьируется \log_loss ?

$$[0, -p \log p - (1-p) \log(1-p)]$$

**Если логарифм по основанию 2, то на сбалансированной выборке
это $[0, 1]$**

Какие недостатки \log_loss ?

Его значение неинтерпретируемы...

Задача классификации $\{0,1\}$ с ответами на $[0,1]$

Реальный случай

Пусть ошибка:

$$|y_i - a_i| \cdot \begin{cases} 0.8, & y_i = 1, \\ 0.2, & y_i = 0, \end{cases} (*)$$

где $y_i \in \{0,1\}$ – верная классификация i -го объекта,
 $a_i \in [0,1]$ – ответ нашего алгоритма.


Заказчик: важно получать значения из отрезка $[0,1]$
и интерпретировать как вероятности принадлежности к классу 1

Вычисление матожидания ошибки

Пусть i -й объект принадлежит к классу 1 с вероятностью p

Посчитаем матожидание нашей ошибки:

$$\begin{aligned} & 0.8 | 1 - a_i | p + 0.2 | a_i | (1 - p) = \\ & = 0.8p - 0.8pa_i + 0.2a_i - 0.2pa_i = \\ & = 0.8p - (p - 0.2)a_i \end{aligned}$$



Вычисление матожидания ошибки

$$0.8p - (p - 0.2)a_i \rightarrow \min$$

Оптимальное решение

(которое минимизирует матожидание ошибки)


$$a_i = \begin{cases} 0, & p < 0.2, \\ 1, & p \geq 0.2. \end{cases}$$

**Функционал (*) вынуждает нас
выдавать значения из множества {0,1}.**

В чём ошибка заказчика, как исправить?

Неправильный выбор функционала

**Интересно... матожидание ошибки (при оптимальном решении)
в зависимости от p .**




ROC и AUC ROC

Функционал зависит не от конкретных значений, а от их порядка


id	оценка	класс
1	0.5	0
2	0.1	0
3	0.2	0
4	0.6	1
5	0.2	1
6	0.3	1
7	0.0	0

id	оценка	класс
4	0.6	1
1	0.5	0
6	0.3	1
3	0.2	0
5	0.2	1
2	0.1	0
7	0.0	0

id	> 0.25	класс
4	1	1
1	1	0
6	1	1
3	0	0
5	0	1
2	0	0
7	0	0



ROC и AUC ROC



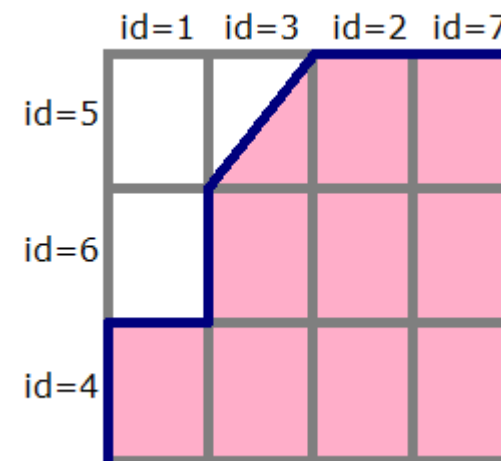
наилучший ($AUC=1$), случайный ($AUC \sim 0.5$) и наихудший ($AUC=0$) алгоритма

Смысл AUC

AUC ~ число правильно отсортированных пар (на рис. «кирпичики»)

Это сложно объяснить заказчику!

$$AUC = \frac{\sum_{i=1}^q \sum_{j=1}^q I[y_i < y_j] I[a_i < a_j]}{\sum_{i=1}^q \sum_{j=1}^q I[y_i < y_j]}$$



Чем хороша эта запись?

Что неправильно (требуется пояснения) в формуле?

Смысл AUC

AUC ~ число правильно отсортированных пар (на рис. «кирпичики»)

Это сложно объяснить заказчику!

$$AUC = \frac{\sum_{i=1}^q \sum_{j=1}^q I[y_i < y_j] I[a_i < a_j]}{\sum_{i=1}^q \sum_{j=1}^q I[y_i < y_j]}$$

Чем хороша эта запись?

Можно обобщить, например, на регрессию.

$$I[a_i < a_j] = \begin{cases} 1, & a_i < a_j, \\ 1/2, & a_i = a_j, \\ 0, & a_i > a_j. \end{cases}$$

Настройка RF/GBM на AUC ROC

Случай из жизни (Интернет-математика)




классификация → классификация пар



Можно дублировать,

Можно брать разности/отношения.

AUC ROC



	1	0	истина
1			
0			
алгоритм			




001010 00101

AUC – не всегда ступеньки!

GINI

В простейшем случае


$$GINI = 2 \cdot AUC - 1$$



Немного сбивает с толку разница масштабов $0.9 \rightarrow 0.8$

AUC ROC


Если задаться распределениями классов (на ответах алгоритма) и получать оценку AUC ROC



Для оценки AUC ROC маленькие выборки не подходят!

AUC ROC


Если задаться распределениями классов (на ответах алгоритма) и получать оценку AUC ROC



AUC ROC


- + в задачах, где важен порядок
- + учитывает разную мощность классов
- + не важны значения, важен порядок
- + можно использовать для оценки признаков

- «завышает» качество
- оценивает не конкретный классификатор, а регрессию
 - сложно объяснить заказчику
- не путать классификацию и регрессию



Полностью бинарный случай

Если «вдруг» $a \in \{0,1\}^q$, $y \in \{0,1\}^q$, $F = AUC$?! (Сбербанк)



Из рисунка

$$\begin{aligned}
 AUC &= (1 + TPR - FPR) / 2 = \\
 &= \frac{1}{2} \left[1 + \frac{TP}{TP + FN} - \frac{FP}{FP + TN} \right]
 \end{aligned}$$

	1	0	y
1	TP	FP	
0	FN	TN	
A			

$$\begin{aligned}
 &= \frac{1}{2} \left[1 + \frac{\|a \cdot y\|}{\|y\|} - \frac{\|a \cdot \bar{y}\|}{\|\bar{y}\|} \right] = \\
 &= \frac{1}{2} \left[\frac{\|a \cdot y\|}{\|y\|} + \frac{\|\bar{a} \cdot \bar{y}\|}{\|\bar{y}\|} \right]
 \end{aligned}$$

т.е. это точность с оглядкой на мощности классов...

$$TPR - FPR \rightarrow \max$$


Полностью бинарный случай

$$\frac{1}{2} \left[\frac{\|a \cdot y\|}{\|y\|} + \frac{\|\bar{a} \cdot \bar{y}\|}{\|\bar{y}\|} \right]$$

– примитивная точность (Accuracy, не Precision),
если мощности классов совпадают.


А если выровнять мощности (**как?**),
то можно смотреть на точность...

Маленький AUC не всегда плохо...



В каких случаях хороша такая ROC-кривая?

Маленький AUC не всегда плохо...




11010010110...011010100000100000

**Мы не можем хорошо решить задачу классификации,
но можем хорошо отделить часть объектов одного класса**

Пример: клиенты, которые не купят билет
(чтобы предложить его им со скидкой)

Ещё примеры кривых... «полнота-точность»



id	оценка	класс
1	0.5	0
2	0.1	0
3	0.2	0
4	0.6	1
5	0.2	1
6	0.3	1
7	0.0	0

id	оценка	класс
4	0.6	1
1	0.5	0
6	0.3	1
3	0.2	0
5	0.2	1
2	0.1	0
7	0.0	0

id	> 0.25	класс
4	1	1
1	1	0
6	1	1
3	0	0
5	0	1
2	0	0
7	0	0

Максимизация AUC ROC

- замена индикаторных функций на дифференцируемые
- использование смысла функционала (переход к парам)
 - ансамблирование с ранговой деформацией

ДЗ Пройти тест goo.gl/93qkum

Совет

Ищите матожидание!

Пробуйте константные решения.

Многоклассовая задача

Hamming Loss


**Число ошибок в векторе
классификаций**

$$HL(\tilde{a}, \tilde{y}) = \frac{\|\tilde{a} \oplus \tilde{y}\|}{l}$$

Log Loss

$$LOGLOSS = -\frac{1}{q} \sum_{i=1}^q \sum_{j=1}^l y_j \log a_j$$

Полнота и т.п. – всё что придумывается со строками матрицы



Полнота и т.п. – по строкам или столбцам



Это множества – и можно усреднять функции сходства множеств

Как использовать на практике (LSHTC)

- Решающее правило с отсечкой:

$$\alpha_{ij} = \begin{cases} 1, & \gamma_{ij} \geq \min(c, \max(\{\gamma_{ij}\}_{j=1}^l)), \\ 0, & \text{иначе.} \end{cases}$$

- Решать задачу по вертикали / по горизонтали

Функционал в LSHTC




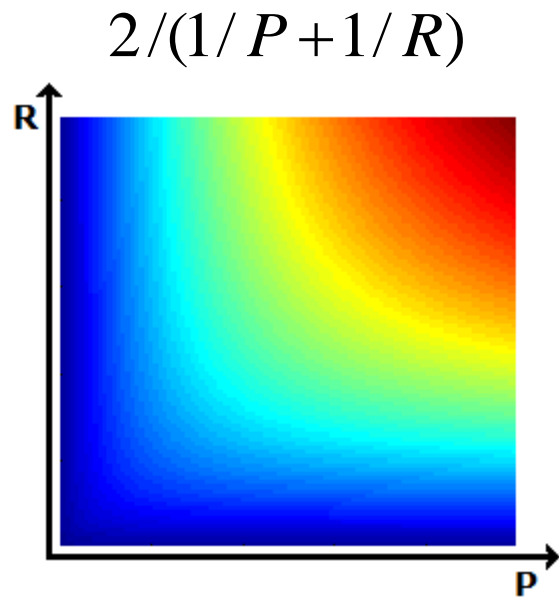
$$\tilde{F} = \frac{2\tilde{P}\tilde{R}}{\tilde{P} + \tilde{R}}$$

$$\tilde{P} = \frac{1}{l} \sum_{j=1}^l \frac{TP_j}{TP_j + FP_j}$$

$$\tilde{R} = \frac{1}{l} \sum_{j=1}^l \frac{TP_j}{TP_j + FN_j}$$

Id	Predicted
1,12	35 200
2,54	55
3,11	
4,1 7	101
...	

Почему используется F-мера



Очень полезно «чувствовать функции»

Пример из жизни: лайки

L	D	
+100	0	Совсем хорошо
+10	0	Хорошо
+1	-0	Мало статистики, но нет минусов
+2	-1	Есть минусы
+10	-9	Много минусов
+100	-100	Неоднозначно
+1	-1	Мало статистики
+9	-10	Много плюсов
+1	-2	Мало плюсов
0	-1	Нет плюсов

Как придумать один признак на базе двух?

Очень полезно «чувствовать функции»

Пример из жизни: лайки

L	D	$\frac{(L - D)}{\sqrt{ L + D }}$
+100	0	10.0000
+10	0	3.1623
+1	-0	1.0000
+2	-1	0.5774
+10	-9	0.2294
+100	-100	0
+1	-1	0
+9	-10	-0.2294
+1	-2	-0.5774
0	-1	-1.0000

Оценка результатов поиска/рекомендаций



Задача с бинарной релевантностью

$$x_1 \prec x_2 \prec \dots \prec x_q$$

$y_i = 1$ – релевантный объект

$y_i = 0$ – нерелевантный объект

Задача ранжирования

Целевой признак может быть бинарным, но это не задача классификации

Precision at n

Точность на первых n элементах

$$p @ n = \frac{y_1 + \dots + y_n}{n}$$

Average Precision at n

Средняя точность на первых n элементах

$$ap @ n = \sum_{k=1}^n \frac{P(k)}{\min(n, m)}$$

m – мощность множества релевантных объектов
(товаров, документов)

n – сколько рекомендаций будет учитываться

$$P(k) = \begin{cases} p @ k, & y_k = 1, \\ 0, & y_k = 0, \end{cases}$$

y_i – бинарное значение релевантности

Average Precision at n

Примеры (три релевантных объекта):

$$0 \prec 0 \prec 0$$

$$ap @ 3 = \frac{1}{3} [0 + 0 + 0]$$

$$0 \prec 0 \prec 1$$

$$ap @ 3 = \frac{1}{3} \left[0 + 0 + \frac{1}{3} \right]$$

$$0 \prec 1 \prec 1$$

$$ap @ 3 = \frac{1}{3} \left[0 + \frac{1}{2} + \frac{2}{3} \right]$$

$$1 \prec 0 \prec 0$$

$$ap @ 3 = \frac{1}{3} \left[\frac{1}{1} + 0 + 0 \right]$$

$$0 \prec 0 \prec 1 \prec 1 \prec 1$$

$$ap @ 5 = \frac{1}{3} \left[0 + 0 + \frac{1}{3} + \frac{2}{4} + \frac{3}{5} \right]$$

$$1 \prec 1 \prec 1 \prec 0 \prec 0$$

$$ap @ 5 = \frac{1}{3} \left[\frac{1}{1} + \frac{2}{2} + \frac{3}{3} + 0 + 0 \right]$$

Mean Average Precision

– усреднение $ap@n$ по всем пользователям

Concordant – Discordant ratio

$$\frac{|\{(i, j) \mid y_i > y_j, 1 \leq i < j \leq n\}|}{|\{i \mid y_i = 1\}| \cdot |\{j \mid y_j = 0\}|}$$

Упорядочили: E, D, C, B, A (по убыванию релевантности)

На самом деле: B, E – релевантные

Пары «нерелевантный» – «релевантный»:

BA

EA

BC

EC

BD

ED

Качество упорядочивания: 4 / (2 + 4)

Что ещё может встретиться... в задачах рекомендации

$$\frac{1}{|Z|} \sum_{z \in Z} \frac{|\{x_1, \dots, x_{h(z)}\} \cap \{x'_1, \dots, x'_{h(z)}\}|}{h(z)}$$

x_1, \dots, x_n – **упорядоченный** список ответов

x'_1, \dots, x'_m – **все релевантные**

$$Z \subseteq \{1, 2, \dots, n\}$$

$$Z = \{5, 10, 15, 20, 25, 30\}$$

когда логично применить?

Рекомендации



Новинка
Ritmix RH-126M, Black Green наушники

[К сравнению](#) [В избранное](#) [Поделиться](#)

Цвет: черный, зеленый



Тип: Наушники
 Модель: 15119162
 Тип соединения: Проводные
 Вид наушников: Вставные (внутриканальные), Спортивные
 Конструкция наушников: Динамические, С микрофоном
[Перейти к описанию](#)



Рекомендуем также



от 115 ₽
 Ritmix RH-120M наушники
[Все варианты](#)



от 282 ₽
 Ritmix RH-180M наушники
[Все варианты](#)



289 ₽
 Ritmix RH-158, Dark Venge наушники
[В корзину](#)



от 145 ₽
 Ritmix RH-125 наушники
[Все варианты](#)



183 ₽
 Ritmix RH-115M Luminous наушники
[В корзину](#)



от 220 ₽
 Ritmix RH-150M наушники
[Все варианты](#)



709 ₽
 Бестаркий и чувства
[В корзину](#)



1 032 ₽
 Ritmix RH-567M Gaming игровые наушники
[В корзину](#)



934 ₽
 Ritmix RH-565M Gaming игровые наушники
[В корзину](#)



65 ₽
 Ritmix RH-011 наушники
[Все варианты](#)



47 ₽
 Ritmix RH-004 наушники
[Все варианты](#)



65 ₽
 Ritmix RH-011, Black наушники
[В корзину](#)



45 ₽
 Ritmix RH-003 наушники
[Все варианты](#)



4 790 ₽
 Ritmix REK-615 электронная книга
[В корзину](#)



1 199 ₽
 Ritmix RCH-108 WH автомобильный держатель
[В корзину](#)

Mean Reciprocal Rank (MRR)

– это усреднение Reciprocal rank (RR) по всем ранжированиям, который сделал алгоритм.

$$RR = \frac{1}{\arg \min_i y_i}$$

Часто оптимизируют именно его!

Классические функционалы в поиске

Случай небинарной релевантности

Выдали i документов/товаров/..., а их ценность (релевантность):

$$y_1, \dots, y_q$$

Cumulative Gain at n

$$CG@n = y_1 + \dots + y_n$$

Discounted Cumulative Gain at n

$$DCG@n = \sum_{i=1}^n \frac{2^{y_i} - 1}{\log_2(i+1)}$$

Ещё вариант:

$$DCG@n = y_1 + \sum_{i=2}^n \frac{y_i}{\log_2(i)} = y_1 + y_2 + \frac{y_3}{\log_2 3} + \dots + \frac{y_n}{\log_2 n}$$

Цена ошибок за неправильное ранжирование

$$\frac{1}{\log_2(1+1)} - \frac{1}{\log_2(1+2)} \approx 0.37$$

$$\frac{1}{\log_2(1+10)} - \frac{1}{\log_2(1+11)} \approx 0.01$$

$$\frac{1}{\log_2(1+10)} - \frac{1}{\log_2(1+20)} \approx 0.06$$

Normalized DCG

$$nDCG = \frac{DCG}{IDCG}$$

IDCG = ideal DCG

для того, чтобы не было зависимости от длины выдачи

Ещё подход к сравнению порядков:

Пусть алгоритм выдал

$$x_1 \prec x_2 \prec \dots \prec x_q$$

Правильный порядок

$$x_{i_1} \prec x_{i_2} \prec \dots \prec x_{i_q}$$

Надо сравнить:

$$(1, 2, \dots, q)$$

$$(i_1, i_2, \dots, i_q)$$

Ранговые корреляции...

Ещё подход к оценке ранжирования

Известны вероятности того, что объект является релевантным

$$p_i = p(x_i)$$

~ пользователь выберет ссылку

Expected reciprocal rank (ERR)

$$ERR @ n = \frac{1}{n} \sum_{k=1}^n \frac{1}{k} p_k \prod_{i < k} (1 - p_i)$$

Как интерпретировать?

Quadratic Weighted Kappa

**показывает согласованность порядков,
когда ответы «мера релевантности»**

$y = 1\ 1\ 1\ 2\ 2\ 3\ 3\ 3$ # правильный ответ

$a = 1\ 1\ 2\ 1\ 3\ 2\ 3\ 3$ # наш ответ

0.6666667

$a = 1\ 1\ 1\ 2\ 2\ 3\ 3\ 3$ # наш ответ

1

$a = 3\ 3\ 3\ 2\ 2\ 1\ 1\ 1$ # наш ответ

-1

Quadratic Weighted Kappa

```
E = table(y) %*% t(table(a))
O = table(y,a)
E = E/sum(E)*sum(O)
n = length(unique(y))
W = (matrix(1:n,nr=n,nc=n) -
matrix(1:n,nr=n,nc=n,byrow = TRUE))**2/(n-1)**2
kappa = 1-sum(W*O)/sum(W*E)
```

ответы

```
a = 1 1 2 1 3 2 3 3
y = 1 1 1 2 2 3 3 3
```

матрица ответов

```
O =
  a
y   1 2 3
  1 2 1 0
  2 1 0 1
  3 0 1 2
```

веса

```
W =
      [,1] [,2] [,3]
[1,] 0.00 0.25 1.00
[2,] 0.25 0.00 0.25
[3,] 1.00 0.25 0.00
```

Внешнее произведение сумм

```
E =
  a
y   1 2 3
  1 9 6 9
  2 6 4 6
  3 9 6 9
```


Нормировка

```
E =
  a
y   1 2 3
  1 1.125 0.75 1.125
  2 0.750 0.50 0.750
  3 1.125 0.75 1.125
```

Редакторское расстояние

Операции

- добавление к кластеру
- создание кластера с одним объектом
- удаление из кластера
- удаление кластера с одним объектом



```

1 2 3;4 5;6
1 2 3; 4 5 [delC]
2 3; 4 5 [del]
2 3; 4 5; 1 [insC]
2 3; 4 5 6; 1 [ins]
    
```

	2 3	4 5 6	1
1 2 3	1	6	2
4 5	4	1	3
6	3	2	2

Редакторское расстояние

- Плохо заносить не в тот кластер (целых две операции на перенос)
 - Плохо создавать неправильный кластер


⇒ осторожный алгоритм



- Многое зависит от операций...


Задача с «неклассическим целевым вектором»

Надо предсказывать не значение,
а интервал $[a, b]$



Как измерить качество?

Задача с интервальным целевым вектором



Интервал – это множество!

Коэффициент Жаккара (Jaccard)

$$\frac{|A \cap B|}{|A \cup B|}$$

коэффициент Шимкевича-Симпсона (Szymkiewicz, Simpson)

$$\frac{|A \cap B|}{\min(|A|, |B|)}$$

коэффициент Браун-Бланке (Braun-Blanquet)

$$\frac{|A \cap B|}{\max(|A|, |B|)}$$

См. википедию «Коэффициент сходства» для переноса идеи Колмогорова об обобщённом среднем...

Вариации на тему усреднения...

**коэффициент Сёренсена
(Sørensen)**

$$\frac{2|A \cap B|}{|A| + |B|}$$

**коэффициент Кульчинского
(Kulczynsky)**

$$\frac{|A \cap B|}{2} \frac{1}{1/|A| + 1/|B|}$$

коэффициент Отиаи (Ochiai)

$$\frac{|A \cap B|}{\sqrt{|A| \cdot |B|}}$$

Меры включения


$$\frac{\frac{|A \cap B|}{|A|}}{\frac{|A \cap B|}{2|A| - |A \cap B|}}$$

$$\frac{\frac{|A \cap B|}{|B|}}{\frac{|A \cap B|}{2|B| - |A \cap B|}}$$

Как решать задачи с интервалами? Потом вернёмся...


Упражнение №1.

Рассматривается задача классификации на два класса. На рисунке показаны объекты в пространстве ответов двух алгоритмов. Вычислить AUC ROC для алгоритмов.



Упражнение №1 - Решение


1. Смотрим проекции на оси – ответы алгоритмов




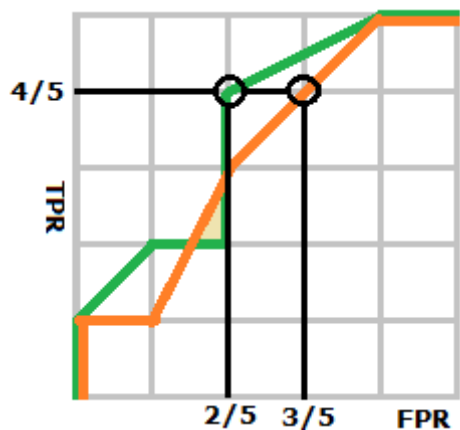
Первый алгоритм:




Второй алгоритм:



2. По проекциям строим ROC - кривые:



3. Вычисляем площади под ROC - кривыми:






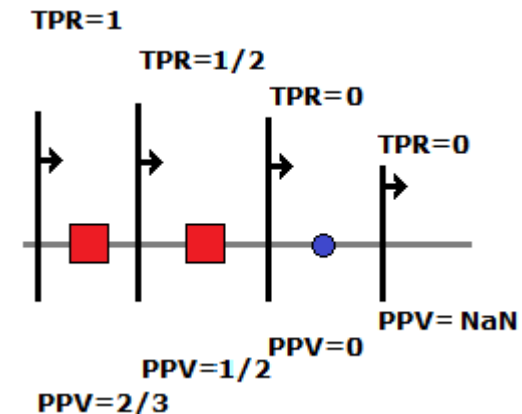


16/25
17.5/25

Упражнение №2.

Какие значения F_1 -меры могут быть у классификатора в задаче с двумя непересекающимися классами и тремя объектами?

Упражнение №2 – Решение.

Можно честно рассмотреть все возможные случаи:



Упражнение №2 - Решение.

Получаем, что F1-мера – среднее гармоническое чисел из пар
 $(1, 1), (1/2, 1), (2/3, 1), (1/3, 1), (1/2, 1/2), (0, 0)$

Все возможные значения F1-меры:

$1, 0.8, 2/3, 0.5, 0$

Но можно быстрее догадаться до ответа...

Упражнение №3

Вычислить $ap@k$:

$ap@5(\text{actual} = [1, 2, 3], \text{predict} = [1, 4, 5, 2, 6, 3])$

$ap@3(\text{actual} = [1, 2, 3], \text{predict} = [1, 4, 5, 2, 6, 3])$

$ap@3(\text{actual} = [1], \text{predict} = [1, 2, 3, 4, 5, 6])$

$ap@3(\text{actual} = [1, 3], \text{predict} = [1, 2, 3, 4, 5, 6])$

$ap@2(\text{actual} = [1, 3], \text{predict} = [1, 2, 3, 4, 5, 6])$

Упражнение №3

Решение:

$$\text{ap@5}(\text{actual} = [1, 2, 3], \text{predict} = [1, 4, 5, 2, 6, 3]) = 0.5$$

$$\text{ap@3}(\text{actual} = [1, 2, 3], \text{predict} = [1, 4, 5, 2, 6, 3]) = 1/3$$

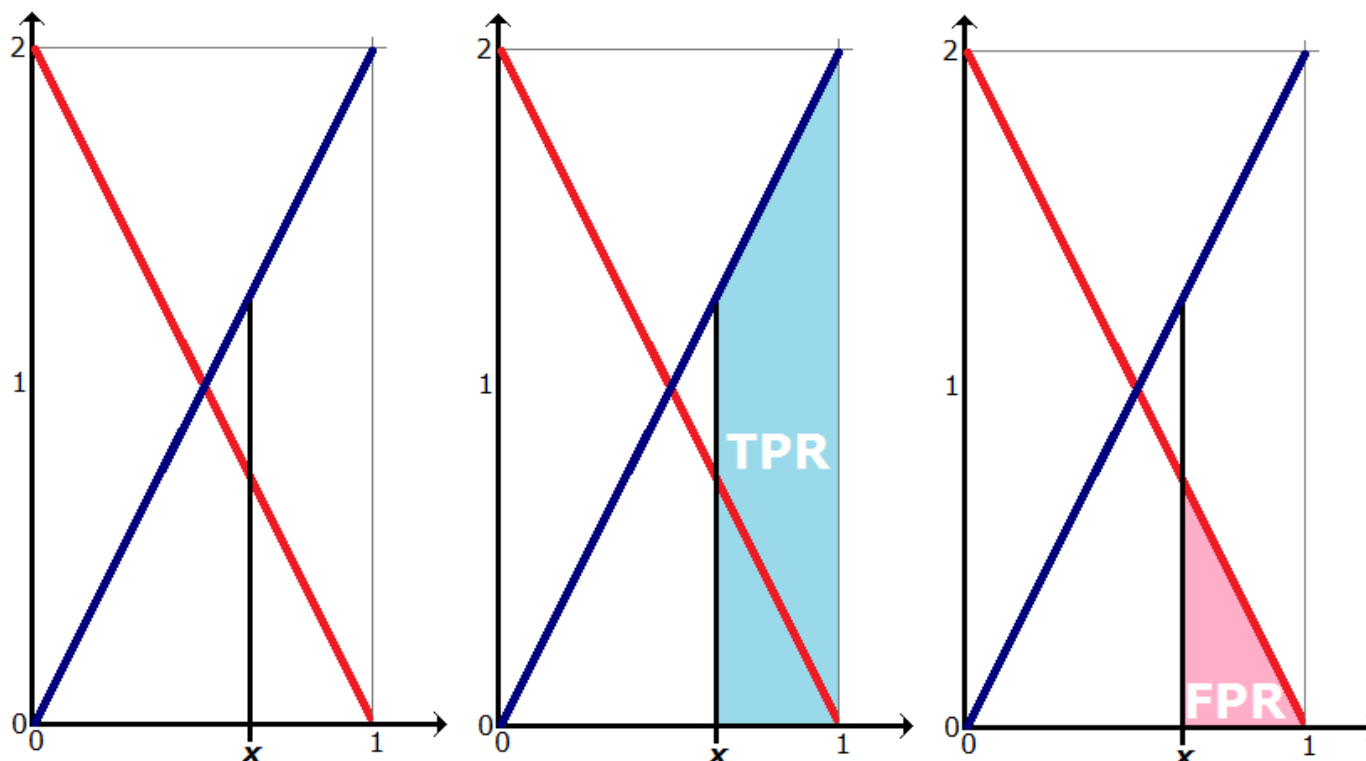
$$\text{ap@3}(\text{actual} = [1], \text{predict} = [1, 2, 3, 4, 5, 6]) = 1$$

$$\text{ap@3}(\text{actual} = [1, 3], \text{predict} = [1, 2, 3, 4, 5, 6]) = 5/6$$

$$\text{ap@2}(\text{actual} = [1, 3], \text{predict} = [1, 2, 3, 4, 5, 6]) = 1/2$$

Упражнение №4

На ответах алгоритма $a(x) \in [0, 1]$ объекты класса 0 распределены с плотностью $p_0(a) = 2 - 2a$, а объекты класса 1 – с плотностью $p_1(a) = 2a$. Построить ROC-кривую и вычислить площадь под ней.



Упражнение №4

Решение

$$\text{TPR}(x) = 1 - \frac{1}{2} x 2x = 1 - x^2$$

$$\text{FPR}(x) = \frac{1}{2} (1 - x)(2 - 2x) = (1 - x)^2$$

Площадь под параметрической кривой

$$\int_1^0 \text{TPR}(x) \cdot \text{FPR}'(x) dx = 2 \int_0^1 (1 - x^2)(1 - x) dx$$

или

$$\text{TPR} = 2\sqrt{\text{FPR}} - \text{FPR}.$$

$$\int_0^1 (2\sqrt{t} - t) dt = \frac{5}{6} \approx 0.83.$$

Литература

Tom Fawcett An introduction to ROC analysis // Pattern Recognition Letters Volume 27 Issue 8, 2006, P. 861-874.

<https://ccrma.stanford.edu/workshops/mir2009/references/ROCintro.pdf>

Стрижов В.В. Функция ошибки в задачах восстановления регрессии // Заводская лаборатория, 2013, 79(5): 65-73.

<http://strijov.com/papers/Strijov2012ErrorFn.pdf>

К.Д. Маннинг, П. Рагхаван, Х. Шютце «Введение в информационный поиск» // . — Вильямс, 2011.