

Оценка моделей

Виктор Владимирович Китов

МГУ им.Ломоносова, ф-т ВМиК, кафедра ММП.

I семестр 2015 г.

Матрица ошибок (confusion matrix)


Матрица ошибок $M = \{m_{ij}\}_{i,j=1}^C$ показывает количества объектов, реально принадлежащих классу ω_i , но отнесенных к ω_j .

		Прогнозный класс				
		1	2	...	C	
Истинный класс	1	[n_{11}	n_{12}		
	2		n_{21}	n_{22}		
	⋮				⋮	
	C					n_{CC}
]				

Диагональные элементы соответствуют правильным классификациям, а внедиагональные - неправильным.

Пример визуализации матрицы ошибок

Пример визуализации матрицы ошибок



- Видно, что ошибки сконцентрированы на разделении классов 1 и 2.
- Классы 1, 2 можно объединить в один класс «1+2», решить 6-то классовую задачу, а потом для всех объектов, отнесенных к «1+2», разделять их на классы 1 и 2 отдельным классификатором.

Случай 2х классов

Матрица ошибок:

		Прогноз	
		+	-
Правильный класс	+	TP (true positives)	FN (false negatives)
	-	FP (false positives)	TN (true negatives)

P и N - число наблюдений положительного и отрицательного класса.

$$\begin{aligned}
 P &= TP + FN, & N &= TN + FP, \\
 \hat{P} &= TP + FP, & \hat{N} &= FN + TN
 \end{aligned}$$

Меры качества

Точность (accuracy):	$\frac{TP+TN}{P+N}$
Доля ошибок (error rate):	$1-\text{accuracy}=\frac{FP+FN}{P+N}$
FPR (ложная тревога):	$\frac{FP}{N}$
TPR (вероятность обнаружения):	$\frac{TP}{P}$
Точность (precision):	$\frac{TP}{\hat{P}} = \frac{TP}{TP+FP}$
Полнота (recall):	$\frac{TP}{P}$
F-мера:	$\frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}}$
взвешенная F-мера:	$\frac{1}{\frac{\beta^2}{1+\beta^2} \frac{1}{\text{Precision}} + \frac{1}{1+\beta^2} \frac{1}{\text{Recall}}}$

Разделимость и надежность

- **Разделимость (discriminability)** измеряет правильность соотнесения классов
 - например, все ранее перечисленные меры: доля ошибок, точность, полнота, и т.д.
- **Надежность (reliability)** измеряет правильность соотнесения вероятностей классов
 - Правдоподобие (что объект x_i принадлежит классу y_i , $i = 1, 2, \dots, N$):

$$\prod_{i=1}^N \hat{p}(y_i|x_i)$$

- Brier score:

$$\frac{1}{N} \sum_{n=1}^N \sum_{c=1}^C (\mathbb{I}[x_n \in \omega_c] - \hat{p}(\omega_c|x_n))^2$$

- Пример хорошей разделимости, но плохой надежности.

Содержание

1 ROC кривые

Байесовское решающее правило

- Обозначение: $\hat{\omega}_j$ означает, что «прогноз равен классу ω_j »
- Матрица цены:

	Прогноз	
	$\hat{\omega}_1$	$\hat{\omega}_2$
Правильный класс	ω_1	0
	ω_2	λ_2
		0

- λ_1, λ_2 -цена неправильной классификации класса ω_1 и ω_2 соответственно.

Байесовское решающее правило

- Цена прогноза $\hat{\omega}_1$:
 $L(\hat{\omega}_1) = \lambda_2 p(\omega_2|x) = \lambda_2 p(\omega_2)p(x|\omega_2)/p(x)$
- Цена прогноза $\hat{\omega}_2$:
 $L(\hat{\omega}_2) = \lambda_1 p(\omega_1|x) = \lambda_1 p(\omega_1)p(x|\omega_1)/p(x)$
- *Байесовское правило* минимизирует ожидаемую цену:

$$\hat{\omega}^* = \arg \min_{\hat{\omega}} L(\hat{\omega})$$

- Оно эквивалентно:
 $\hat{\omega}^* = \hat{\omega}_1 \Leftrightarrow \lambda_2 p(\omega_2)p(x|\omega_2) < \lambda_1 p(\omega_1)p(x|\omega_1) \Leftrightarrow$

$$\frac{p(x|\omega_1)}{p(x|\omega_2)} > \frac{\lambda_2 p(\omega_2)}{\lambda_1 p(\omega_1)} = \mu$$

Дискриминативные решающие правила

- Правило, основанное на дискриминантных ф-циях:
 - соотнести x классу $\omega_1 \iff g_1(x) - g_2(x) > \mu$
 - соотнести x классу $\omega_1 \iff g_1(x)/g_2(x) > \mu$ (для $g_1(x) > 0, g_2(x) > 0$)
- Правило, основанное на вероятностях:
 - соотнести x классу $\omega_1 \iff P(\omega_1|x) > \mu$

ROC кривая

- ROC кривая - зависимость вероятности обнаружения положительного класса (TPR) от вероятности ложной тревоги (FPR) для различных μ .
- Если μ уменьшается, алгоритм чаще выбирает ω_1 и
 - TPR= $1 - \varepsilon_1$ возрастает
 - FPR= ε_2 также возрастает
- Диагональ соответствует случайной классификации ω_1 и ω_2 с вероятностями μ и $1 - \mu$.
- Характеризует качество классификации для различных значений μ .
 - более выпуклые вверх кривые лучше

Изо-линии цены

- Обозначим $\varepsilon_1, \varepsilon_2$ - вероятности ошибиться на классе ω_1 и ω_2 соответственно.
- $1 - \varepsilon_1 = TPR$, $\varepsilon_2 = FPR$
- Ожидаемые потери


$$L = \lambda_2 p(\omega_2) \varepsilon_2 + \lambda_1 p(\omega_1) \varepsilon_1 = \lambda_2 p(\omega_2) \varepsilon_2 - \lambda_1 p(\omega_1) (1 - \varepsilon_1) + \lambda_1 p(\omega_1)$$

- Изо-линия потерь:


$$(1 - \varepsilon_1) = \frac{\lambda_2 p(\omega_2)}{\lambda_1 p(\omega_1)} \varepsilon_2 + \frac{\lambda_1 p(\omega_1) - L}{\lambda_1 p(\omega_1)}$$

- В оптимальной точке изо-линия касается ROC-кривой с тангенсом угла наклона $\frac{\lambda_2 p(\omega_2)}{\lambda_1 p(\omega_1)}$

Сравнение классификаторов по ROC кривой



Сравнение классификаторов по ROC кривой



Как сравнивать различные классификаторы?

Критерий AUC

- AUC - площадь под ROC-кривой:
 - глобальная характеристика качества
 - $AUC \in [0, 1]$
 - $AUC=0.5$ - эквивалент случайного угадывания
 - $AUC=1$ - безошибочное распознавание.
 - равна вероятности того, что для случайных $x_1 \in \omega_1$ и $x_2 \in \omega_2$ будет выполнено: $g_{\omega_1}(x_1) > g_{\omega_2}(x_2)$

LC index

- LC index - применение методики к байесовскому решающему правилу:
 - Отмасштабируем λ_1 и λ_2 так, что $\lambda_1 + \lambda_2 = 1$
 - определим $\lambda_1 = \lambda$, $\lambda_2 = 1 - \lambda$
 - для каждого $\lambda \in [0, 1]$ рассчитаем
$$L(\lambda) = \begin{cases} +1, & \text{если 1й классификатор лучше} \\ -1, & \text{если 2й классификатор лучше} \end{cases}$$
 - определим плотность вероятности λ : $p(\lambda)$ (например, треугольник)
 - выбираем 1-й классификатор $\iff \int_0^1 L(\lambda)p(\lambda)d\lambda > 0$.

Распределение вероятности ошибки

- Пусть e - вероятность ошибки на новом объекте.
- Цель - найти распределение вероятности e
 - знаем, что на отложенной выборке объема n было k ошибок.

Вероятность сделать k ошибок на выборке объема n :

$$p(k|e, n) = \binom{n}{k} e^k (1 - e)^{n-k}$$

Тогда

$$p(e|k, n) = \frac{p(e, k|n)}{p(k|n)} = \frac{p(k|e, n)p(e|n)}{\int p(k|n)p(e|n)de}$$

Полагая априорное распределение $p(e|n) \equiv \text{const}$, получим

$$p(e|k, n) = \frac{p(k|e, n)}{\int p(k|n)de} \propto e^k (1 - e)^{n-k}$$

Распределение вероятности ошибки

Поскольку бета-распределение имеет вид

$$Be(x|\alpha, \beta) = [\Gamma(\alpha + \beta)/(\Gamma(\alpha)\Gamma(\beta))]x^{\alpha-1}(1-x)^{\beta-1}, \text{ то}$$

$$p(e|k, n) \sim Be(k + 1, n - k + 1)$$

Бета-распределение:

$$\xi \sim Be(\alpha, \beta) \Rightarrow \mathbb{E}[\xi] = \frac{\alpha}{\alpha + \beta}, \text{ Var}[\xi] = \frac{\alpha\beta}{(\alpha + \beta)^2(\alpha + \beta + 1)}$$

