

Оценка объема выборки в задачах логистической регрессии

А. П. Мотренко

Научный руководитель: В. В. Стрижов
Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

13 июня 2012

- 1 Введение
- 2 Постановка задачи классификации
- 3 Выбор признаков
- 4 Многоклассовая классификация
- 5 Оценка объема выборки
- 6 Вычислительный эксперимент
- 7 Результаты

Работа посвящена прогнозу вероятности принадлежности пациента к одному из нескольких неупорядоченных классов:

A_1 Больные, перенесшие инфаркт.

A_2 Больные, находящиеся в состоянии инфаркта.

A_3 Пациенты, имеющие предрасположенность к инфаркту.

B_1 , B_2 Здоровые пациенты двух типов.

Решается задача оценки параметров функции регрессии и выбора признаков при многоклассовой классификации.

Для каждого пациента измеряются концентрации белков K, L, N, \dots , абсорбированных на поверхности кровяных телец:

		K	L	...	N
A_1	001	x_{11}	x_{12}	...	x_{1n}
A_1	002	x_{21}	x_{22}	...	x_{2n}
...
A_3	i	x_{i1}	x_{i2}	...	x_{in}
A_3	$i + 1$	$x_{(i+1)1}$	$x_{(i+1)2}$...	$x_{(i+1)n}$
...

Требуется, имея набор признаков $\mathbf{x}_i = [x_{i1} x_{i2} \dots x_{in}]$ определить, к какой из четырех групп A_1, A_3, B_1, B_2 относится пациент.

Чтобы перейти от задачи многоклассового прогнозирования к двуклассовой задаче, рассмотрим всевозможные пары групп:

$$A_1 \ A_3$$

$$A_1 \ B_1$$

$$A_1 \ B_2$$

$$A_3 \ B_1$$

$$A_3 \ B_2$$

$$B_1 \ B_2$$

Задача классификации решается для каждой пары групп.

Дана выборка $D = \{\mathbf{x}_i, y_i\}, i = 1, \dots, m$, где
 $y_i \in \{0, 1\}$ — объект,
 $\mathbf{x}_i \in \mathbb{R}^n$ — описание объекта.

Разделение выборки на классы осуществляется с помощью логистической регрессии.

Предполагается, что $\mathbf{y} = [y_1, \dots, y_m]^T$ — случайный вектор с независимыми компонентами $y_i \sim \mathcal{B}(\theta_i)$. Определим θ_i как

$$\theta_i = \frac{1}{1 + \exp(-\mathbf{x}_i^T \mathbf{w})} = f(\mathbf{x}_i^T \mathbf{w}),$$

где \mathbf{w} — вектор параметров логистической регрессии.

Алгоритм классификации имеет вид

$$a(\mathbf{x}) = \text{sign}(f(\mathbf{x}, \mathbf{w}) - c_0),$$


где c_0 — пороговое значение (cut-off) функции регрессии.

$\mathcal{I} = \{1, 2, \dots, m\}$ — множество индексов объектов,

$\mathcal{I} = \mathcal{L} \sqcup \mathcal{T}$, \mathcal{L} — обучающее подмножество, \mathcal{T} — тестовое.

Параметры \mathbf{w} оцениваются на подвыборке $D_{\mathcal{L}}$, а качество прогноза вычисляется на подвыборке $D_{\mathcal{T}}$.

Для оценки качества прогноза используется площадь AUC под кривой ROC (area under curve).



где

TPR — доля правильно классифицированных в пользу заданного класса объектов

FPR — доля ошибочно классифицированных в пользу данного класса объектов выборки.

Отрезок $[(0,0),(1,1)]$ соответствует отказу от принятия решения в пользу какого-нибудь из классов.

Стоимость полного обследования одного пациента составляет 3400 евро. Уменьшение числа измеряемых признаков позволит:

1. Сократить расходы на обследование пациента.
2. Увеличить количество пациентов в выборке.

Выбор признаков осуществляется полным перебором.

Оптимальный набор $\hat{\mathcal{A}}$ определяется как

$$\hat{\mathcal{A}} = \arg \max_{\mathcal{A} \subseteq \mathcal{I}} \text{AUC}(\mathcal{A}) \text{ при условии } |\mathcal{A}| = \text{const},$$

где $\mathcal{A} \subseteq \mathcal{J} = \{1, 2, \dots, n\}$ — некоторое подмножество индексов признаков.

Для объекта \mathbf{x}_{m+1} построим таблицу

	A_1	A_3	B_1	B_2
A_1	—	0	0	1
A_3	1	—	1	1
B_1	1	0	—	0
B_2	0	0	1	—

Присвоим классам A_1, A_3, B_1, B_2 номера 1, 2, 3, 4. Тогда

$$\text{class}(\mathbf{x}_{m+1}) = \arg \max_{l \in \{1, \dots, 4\}} \sum_{k=1}^4 a_{lk}(\mathbf{x}_{m+1}),$$

где $a_{lk}(\mathbf{x}) \in \{0, 1\}$, $l, k \in \{1, \dots, 4\}$ — результат классификации между парой классов (l, k) .


Использование $K = 3$ оптимальных наборов.

Вероятность можно оценивать, используя K оптимальных наборов для каждого класса.


	A_1	A_3	B_1	B_2
A_1	—	0, 1, 0	0, 0, 0	1, 1, 0
...



	A_1	A_3	B_1	B_2
A_1	—	0	0	1
...




a.




b.

- a. Количество появлений каждого признака в $K = 5$ лучших наборов для какой-либо пары классов.
- b. По горизонтали — наборы признаков, вошедшие в $K = 5$ лучших для какой-либо пары классов. Цветом обозначено значение AUC, соответствующее набору.



a.



b.

- а. Количество неправильно классифицированных при многоклассовой классификации пациентов каждого класса.
- б. Количество правильно классифицированных пациентов каждого класса при выполнении двуклассовой классификации между всевозможными парами.

1. Метод доверительных интервалов.
2. Метод оценки объема выборки в логистической регрессии.
3. Метод скользящего контроля.
4. Сравнение плотностей распределения параметров модели на различных подвыборках.

Пусть $D = \{(x_i, y_i)\}, i \in \mathcal{I} = \{1, \dots, m\}$.

$$\bar{x} = \frac{1}{2} \sum_{i=1}^m x_i.$$

При известных μ и σ случайная величина имеет распределение

$$Z = \frac{\bar{x} - \mu}{\sigma} \sqrt{m} = \frac{E}{\sigma} \sqrt{m} \sim \mathcal{N}(0, 1).$$

Получаем

$$m^* = \left(\frac{z_{\alpha/2}\sigma}{E} \right)^2,$$

где $P\{|Z| \geq z_{\alpha/2}\} = \alpha$.

Предполагается, что

1. $x_i \sim \mathcal{N}(\mu, \sigma^2)$.
2. Значения μ и σ^2 известны.

Более вероятно, что

$$x_i \sim \begin{cases} \mathcal{N}(\mu_1, \sigma_1^2), & \text{с вероятностью } p_i; \\ \mathcal{N}(\mu_2, \sigma_2^2), & \text{с вероятностью } 1 - p_i. \end{cases}$$

Фиксируем множество индексов признаков \mathcal{A} и индекс $j \notin \mathcal{A}$.

$$H_0 : w_j = 0 \rightarrow \mathbf{w}_{\mathcal{A}}, \quad H_1 : w_j \neq 0 \rightarrow \mathbf{w}_{\mathcal{A}^*}, \text{ где } \mathcal{A}^* = \mathcal{A} \bigcup \{j\}.$$

Оценим вектор $\boldsymbol{\theta}$ параметров бернуlliевского распределения:

$$H_0 : \boldsymbol{\theta} = f(X_{\mathcal{A}}^T \mathbf{w}_{\mathcal{A}}), \quad H_1 : \boldsymbol{\theta} = f(X_{\mathcal{A}^*}^T \mathbf{w}_{\mathcal{A}^*}).$$

Важно лишь пороговое значение функции регрессии c_0 , поэтому выберем в качестве тестовой статистики


$$Z = \frac{\hat{p} - p_0}{\sqrt{p_0 c_0 / m}}, \quad \hat{p} = \frac{1}{m} \sum_{i=1}^m y_i$$

где \hat{p} — ОМП для параметра p , $c_0 = 1 - p_0$ — пороговое значение функции регрессии.

Тогда

$$m^* = \frac{p_0 c_0 \left(z_{1-\alpha/2} + z_{1-\beta} \sqrt{\frac{p_1 c_1}{p_0 c_0}} \right)^2}{(p_1 - p_0)^2}.$$

Результаты метода доверительных интервалов и метода для логистической регрессии




Метод доверительных интервалов: $m^* \sim 10^5$.


Метод для логистической регрессии: $m^* \sim 10^3$.

Введем величину

$$\text{RS}(m) = \frac{\text{AUC}(\mathcal{A}, D_{\mathcal{T}(m)})}{\text{AUC}(\mathcal{A}, D_{\mathcal{L}(m)})}.$$



Вывод: $m^* \geq 30$.



В выборку были добавлены два новых объекта.
Положение разделяющей гиперплоскости определяется выражением

$$\mathbf{x}^T \mathbf{w} = \ln \left(\frac{c_0}{1 - c_0} \right).$$

Сравнение плотностей распределения параметров

Для оценки сходства функций плотности $p_1(\mathbf{w})$ и $p_2(\mathbf{w})$ воспользуемся расстоянием Кулльбака-Лейблера

$$D_{KL}(p_1, p_2) = \int_{\mathbf{w} \in \mathcal{W}} p_1(\mathbf{w}) \ln \frac{p_1(\mathbf{w})}{p_2(\mathbf{w})} d\mathbf{w}.$$

Плотность вероятности появления данных есть

$$p(y|\mathbf{x}, \mathbf{w}, f_{\mathcal{A}}) \equiv p(D|\mathbf{w}, f_{\mathcal{A}}) = \prod_{i=1}^m \theta_i^{y_i} (1 - \theta_i)^{1-y_i}.$$

Пусть также $\mathbf{w} \sim \mathcal{N}(\mathbf{w}_0, \sigma^2 I_{|\mathcal{A}|})$, и его плотность имеет вид

$$p(\mathbf{w}|f_{\mathcal{A}}, \alpha) = \left(\frac{\alpha}{2\pi} \right)^{\frac{|\mathcal{A}|}{2}} \exp\left(-\frac{1}{2}(\mathbf{w} - \mathbf{w}_0)^T \alpha I(\mathbf{w} - \mathbf{w}_0)\right),$$

где $\alpha^{-1} = \sigma^2$,

$I_{|\mathcal{A}|}$ — единичная матрица размерности $|\mathcal{A}|$.

Для нахождения $p(\mathbf{w}|D, \alpha, f_{\mathcal{A}})$, воспользуемся формулой Байеса

$$p(\mathbf{w}|D, \alpha, f_{\mathcal{A}}) = \frac{p(D|\mathbf{w}, f_{\mathcal{A}})p(\mathbf{w}|\alpha, f_{\mathcal{A}})}{p(D|\alpha, f_{\mathcal{A}})},$$

где $p(D|\mathbf{w}, f_{\mathcal{A}})$ — правдоподобие данных,
 $p(\mathbf{w}|\alpha, f_{\mathcal{A}})$ — вероятностные плотности параметров модели,


$$p(D|\alpha, f_{\mathcal{A}}) = \int p(D|\mathbf{w}, f_{\mathcal{A}})p(\mathbf{w}|\alpha, f_{\mathcal{A}})d\mathbf{w}.$$

Тогда


$$\begin{aligned} p(\mathbf{w}|D, f_{\mathcal{A}}) &= \frac{p(y|\mathbf{x}, \mathbf{w}, f_{\mathcal{A}})p(\mathbf{w}|f_{\mathcal{A}}, \alpha)}{Z(\alpha)} = \\ &= \frac{\alpha^{\frac{|\mathcal{A}|}{2}}}{(2\pi)^{\frac{|\mathcal{A}|}{2}} Z(\alpha)} \exp\left(-\frac{1}{2}(\mathbf{w} - \mathbf{w}_0)^T \alpha I(\mathbf{w} - \mathbf{w}_0)\right) \prod_{i=1}^m \theta_i^{y_i} (1 - \theta_i)^{1-y_i}, \end{aligned}$$

где $Z(\alpha)$ — нормировочный множитель.

Оценка объема выборки с помощью расстояния Кулльбака-Лейблера



a.



b.

а. Усредненное еклидово расстояние между параметрами модели

$$\|\mathbf{w}_m - \mathbf{w}_{m+1}\| = \sqrt{\sum_{i=1}^{|\mathcal{A}|} (w_i^m - w_i^{m+1})^2},$$

б. Усредненное расстояние Кулльбака-Лейблера.
Вывод: $m^* \geq 30$.

- ① Предложен алгоритм выбора признаков для многоклассовой классификации
- ② Найдены оптимальные наборы признаков для выборки пациентов с инфарктом миокарда

Публикации:

- ① Мотренко А.П., Многоклассовый прогноз вероятности наступления инфаркта и оценка объема выборки // JMLDA, декабрь 2011
- ② Мотренко А.П., Стрижов В.В., Многоклассовый прогноз вероятности наступления инфаркта // Известия Тульского государственного университета, март 2012
- ③ Предложен метод оценки объема выборки, основанный на исследовании пространства параметров модели.

Публикация:

Мотренко А.П. Оценка необходимого объема выборки пациентов при прогнозировании сердечно-сосудистых заболеваний // JMLDA, май 2012.