

ЛИНЕЙНАЯ КЛАССИФИКАЦИЯ

Логистическая регрессия

ЛИТЕРАТУРА



Бинарный линейный классификатор

Дана обучающая выборка


$$X_N = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}, \quad \mathbf{x}_i \in \mathbf{R}^p, y_i \in \{-1, +1\}$$

Цель: каждый новый входной вектор \mathbf{x} отнести к одному из двух классов – положительному «+1» или отрицательному «-1»

$$\hat{y} = \hat{y}(\mathbf{x}, \mathbf{w}) = \text{sign} \left(w_0 + \sum_{j=1}^p w_j x_j \right) = \text{sign}(\mathbf{w}^\top \mathbf{x}),$$

$$\mathbf{x} = (1, x_1, \dots, x_p)$$

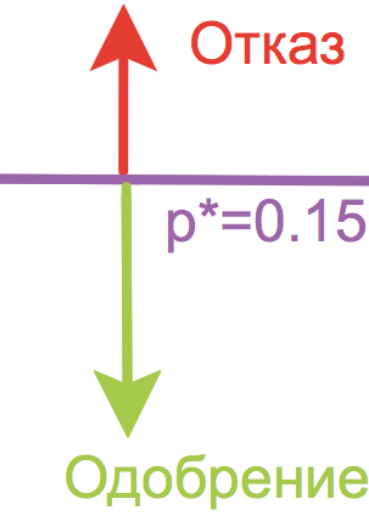
Линейная модель классификации



Логистическая регрессия как линейный классификатор

- Логистическая регрессия прогнозирует вероятность p_+ отнесения примера x к классу "+1".
- Пример: банковский скоринг


Клиент	Вероятность невозврата
Mike	0.78
Jack	0.45
Larry	0.13
Kate	0.06
William	0.03
Jessica	0.02



Логистическая регрессия

$$p_+ = \sigma(z) = \frac{1}{1 + \exp(-z)}$$

где $z = \mathbf{w}^T \mathbf{x} = w_0 + \sum_{j=1}^p w_j x_j$



Функция потерь (ошибок классификации)

- Доля неправильных ответов:

- $E(W) = \frac{1}{N} \sum_{i=1}^N [y_i \neq \hat{y}_i] = \frac{1}{N} \sum_{i=1}^N [\text{sign}(w^\top \mathbf{x}_i) \neq y_i]$


- $E(W) = \frac{1}{N} \sum_{i=1}^N [y_i (w^\top \mathbf{x}_i) < 0]$

- $M_i = y_i (w^\top \mathbf{x}_i)$ - отступ

- $L(M) = [M < 0]$ – пороговая функция

Верхняя оценка

$$L(M) \leq \tilde{L}(M) = \log_2(1 + \exp(-M))$$



Логистическая функция потерь

- $ERR(w) = \sum_{i=1}^N \log_2 (1 + \exp(-y_i(w^\top x_i)))$

С учетом L2-регуляризации:

- $ERR(w) = \sum_{i=1}^N \log_2 (1 + \exp(-y_i(w^\top x_i))) + \frac{1}{\lambda} \sum_{j=1}^p w_j^2$

Использование полиномиальных признаков для нелинейного разделения


Полиномиальными признаками до степени d для двух переменных x_1 и x_2 мы называем следующие:

$$\{x_1^d, x_1^{d-1}x_2, \dots, x_2^d\} = \{x_1^i x_2^j\}_{i+j=d, i, j \in \mathbb{N}}$$

Например, для $d = 3$ это будут следующие признаки:

$$1, x_1, x_2, x_1^2, x_1 x_2, x_2^2, x_1^3, x_1^2 x_2, x_1 x_2^2, x_2^3$$

Пример нелинейного разделения классов



Confusion matrix (матрица ошибок классификации)

	$y = 1$	$y = 0$
$\hat{y} = 1$	True Positive (TP)	False Positive (FP)
$\hat{y} = 0$	False Negative (FN)	True Negative (TN)

Здесь \hat{y} — это ответ алгоритма на объекте, а y — истинная метка класса на этом объекте.

Таким образом, ошибки классификации бывают двух видов: False Negative (FN) и False Positive (FP).

Метрики качества классификации

- Доля правильных ответов: $accuracy = \frac{TP + TN}{TP + TN + FP + FN}$

Малоинформативна в задачах с неравными классами.

Пример. Допустим, мы хотим оценить работу спам-фильтра почты. У нас есть 100 не-спам писем, 90 из которых наш классификатор определил верно, и 10 спам-писем, 5 из которых классификатор также определил верно. Тогда ассурасу:

$$accuracy = \frac{5 + 90}{5 + 90 + 10 + 5} = 0.864$$

Если мы просто будем предсказывать все письма как не-спам, то получим более высокую ассурасу

$$accuracy = \frac{0 + 100}{0 + 100 + 0 + 10} = 0.909$$

Метрики качества классификации

- precision (точность) и recall (полнота).

$$precision = \frac{TP}{TP + FP} \qquad recall = \frac{TP}{TP + FN}$$

Precision показывает долю объектов, названных классификатором положительными и при этом действительно являющимися положительными, а recall показывает, какую долю объектов положительного класса из всех объектов положительного класса нашел алгоритм.


Precision не позволяет записывать все объекты в один класс, так как в этом случае растет значение FP. Recall демонстрирует способность алгоритма обнаруживать данный класс вообще, а precision — способность отличать этот класс от других классов.

AUC-ROC – площадь под кривой ошибок

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

TPR - это полнота, а FPR показывает, какую долю из объектов отрицательного класса алгоритм предсказал неверно.



Кривая ошибок или **ROC-кривая** – графическая характеристика качества бинарного классификатора, зависимость доли верных положительных классификаций от доли ложных положительных классификаций при варьировании порога решающего правила.

AUC-ROC – площадь под кривой ошибок

В идеальном случае, когда классификатор не делает ошибок ($FPR = 0$, $TPR = 1$), площадь под кривой, равна 1; в противном случае, когда классификатор случайно выдает вероятности классов, $AUC-ROC = 0.5$. Каждая точка на графике соответствует выбору некоторого порога вероятности, разделяющего положительный и отрицательный класс.

Площадь под кривой в данном случае показывает качество алгоритма (больше — лучше), кроме этого, важной является крутизна самой кривой — мы хотим максимизировать TPR , минимизируя FPR , а значит, наша кривая в идеале должна стремиться к точке $(0,1)$.

Критерий AUC-ROC устойчив к несбалансированным классам и может быть интерпретирован как вероятность того, что случайно выбранный положительный объект будет иметь более высокую вероятность быть положительно определенным данным классификатором, чем случайно выбранный отрицательный объект.

Чувствительность и специфичность

- Наряду с FPR и TPR при оценке качества классификации используют также понятия *чувствительности* и *специфичности*, которые изменяются в интервале $[0, 1]$:
- *чувствительность* алгоритма совпадает с TPR (долей положительных объектов, правильно классифицированных алгоритмом);
- *специфичность* алгоритма определяется как $1 - \text{FPR}$ (это доля отрицательных объектов, правильно классифицированных алгоритмом).
- Модель с высокой чувствительностью чаще дает истинный результат при наличии положительного исхода (хорошо обнаруживает положительные примеры). Наоборот, модель с высокой специфичностью чаще дает истинный результат при наличии отрицательного исхода (хорошо обнаруживает отрицательные примеры).