

Монотонные классификаторы для задач медицинской диагностики

Швец Михаил

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

Научный руководитель ст.н.с ВЦ РАН, д.ф.-м.н.
К. В. Воронцов

Группа 174, 1 июля 2015

- Предложить вычислительно эффективные методы отбора признаков и объектов для монотонных классификаторов
- Применить разработанные методы к задаче диагностики заболеваний по электрокардиосигналу

Определения и обозначения

$\mathbb{X} = \{x_1, \dots, x_m\}$, $y : \mathbb{X} \rightarrow Y = \{-, +\}$.

Множество признаков $P = \{p_1, \dots, p_t\}$, где
 $p_j : \mathbb{X} \rightarrow E_j$. $\forall j : E_j = \{0, \dots, n - 1\}$.

Пространство $W = E_1 \times E_2 \times \dots \times E_t$.

$\alpha \in W$ предшествует $\beta \in W$ ($\alpha \preceq \beta$) по множеству $Q \subseteq P$,
если $\forall p_j \in Q$ выполнено $p_j(\alpha) \leq p_j(\beta)$.

Пара $x_i, x_k \in \mathbb{X}$, $y_i = -1$ и $y_k = +1$, является **монотонной** по
 $Q \subseteq P$, если $x_i \preceq x_k$, и **дефектной**, если $x_k \preceq x_i$.

\mathbb{X} – **монотонная** по $Q \subseteq P$, если в \mathbb{X} нет дефектных пар.

Монотонный классификатор – функция $f : W \mapsto Y$,
удовлетворяющая условиям монотонности
 $\forall u, v \in W : u \preceq v$ по множеству $Q \subseteq P \longrightarrow f(u) \leq f(v)$



О вычислительной сложности задач (А. Зухба)

Теорема 1

Задача выбора признаков так, чтобы монотонных пар было не менее m , а дефектных не более d , является NP-трудной.

Теорема 2

Задача выбора признаков так, чтобы монотонных пар было не менее m , а признаков не менее q , является NP-трудной.

Теорема 3

Задача выбора признаков так, чтобы дефектных пар было не более d , а признаков не более q , является NP-трудной.

Теорема 4

Задача выбора объектов так, чтобы монотонных пар было не менее m , а дефектных не более d , является NP-трудной.

Отбор признаков

Определение критерия

Сортирующий критерий – функция $g : P \rightarrow \mathbb{R}$. Признаки упорядочиваются $p_{j_1} \dots p_{j_t}$ так, что $g(p_{j_1}) > g(p_{j_2}) > \dots > g(p_{j_t})$. При фиксированном k , выбор признаков проводится по правилу $Q = \{p_{j_1} \dots p_{j_k}\}$.

Средняя частота и встречаемость признака

$$F_j(y) = \frac{\sum_{x_i \in \mathbb{X}} p_j(x_i)[y_i=y]}{\sum_{x_i \in \mathbb{X}} [y_i=y]}; \quad B_j(y, \theta) = \frac{\sum_{x_i \in \mathbb{X}} [p_j(x_i) \geq \theta][y_i=y]}{\sum_{x_i \in \mathbb{X}} [y_i=y]}$$

Используемые критерии

$$g_{F+}(p_j) = F_j(+) \quad g_{B+}(p_j) = B_j(+)$$

$$g_{dif(F)}(p_j) = F_j(+) - F_j(-) \quad g_{dif(B)}(p_j) = B_j(+) - B_j(-)$$

$$g_{|dif(F)|}(p_j) = |F_j(+) - F_j(-)| \quad g_{|dif(B)|}(p_j) = |B_j(+) - B_j(-)|$$

а также $g_{NB}(p_j) = b_j$, b_j – веса линейного классификатора.



Отбор объектов (монотонизация выборки)

Количество дефектных пар, в которых участвует объект

$$L_i = \{x_k \in \mathbb{X} : y_i \neq y_k, (x_i, x_k) - \text{дефектная пара}\}.$$

Удаление минимального числа объектов

Задача получения подвыборки максимальной мощности, в которой отсутствуют дефектные пары, является полиномиальной по количеству объектов.

α -монотонизация

- ① Упорядочим объекты класса $y = -1$: $x_{i_1}, x_{i_2} \dots x_s \dots$, по убыванию $|L_i|$: $|L_{i_1}| > \dots > |L_{i_s}| > 0 = |L_{i_{s+1}}| = \dots$;
- ② удалим из выборки первые s' объектов $\{x_{i_1} \dots x_{i_{s'}}\}$, где s' выбрано из условия $s' \leq \alpha s < s' + 1$;
- ③ удалим эти объекты также из всех множеств L_i ;
- ④ удалим из выборки все объекты x_i класса $y = +1$, у которых $|L_i| > 0$.



Монотонный классификатор ближайшего соседа

Верхняя и нижняя тень объекта $x_i \in \mathbb{X}$

$$M_i^+ = \{a \in W : x_i \preceq a\} \quad M_i^- = \{a \in W : a \preceq x_i\}$$

Расстояние до тени

$$\rho(u, M_i) = \min_{a \in M_i} \rho(u, a), \text{ где } \rho(u, a) - \text{манхэттенское расстояние}$$

Лемма (о вычислении расстояния до тени)

Расстояния от объекта $u \in W$ до верхней и нижней теней объекта $x_i \in \mathbb{X}$ вычисляются по следующим формулам:

$$\rho(u, M_i^-) = \sum_{p_j \in Q} [p_j(u) - p_j(x_i)]_+,$$

$$\rho(u, M_i^+) = \sum_{p_j \in Q} [p_j(x_i) - p_j(u)]_+.$$

Результирующая функция

Монотонный классификатор ближайшего соседа

$$x_k = \arg \min_{x_i \in \mathbb{X}} \rho(u, M_i) - \text{близайший к объекту } u \in W$$

$$f(u) = y_k$$

Непрерывный аналог результирующей функции

$$\tilde{f}(u) = \begin{cases} f(u), & \rho_- = 0 \text{ или } \rho_+ = 0 \\ \frac{\rho_- - \rho_+}{\rho_- + \rho_+}, & \text{иначе.} \end{cases}$$

Здесь $\rho_y = \min_{y_i=y} \rho(u, M_i)$. Такая дискриминантная функция нужна для более точного вычисления значения AUC.

Утверждение

Функция \tilde{f} является монотонной.

Классификатор ближайшего соседа с M-функцией расстояния (Г. Махина)

M-расстояние

$r : W \times \mathbb{X} \rightarrow E_N$, где $N = (nt)^2 + nt + 1$, задаваемая правилом
 $r(u, x_i) = nt\rho(u, M_i) + (nk - \rho(u, x))$.

Утверждение (о сохранении монотонности M-функции)

Для любых $u, v \in W$, таких что $u \preceq v$, выполнено

$$\forall x_i \in \mathbb{X}(y_i = +1) : r(u, x_i) \geq r(v, x_i)$$

$$\forall x_i \in \mathbb{X}(y_i = -1) : r(u, x_i) \leq r(v, x_i)$$

Теорема

При использовании метода ближайшего соседа с M-функцией расстояния получаемая функция является монотонной.

Композиция моделей

Взвешенное голосование

$$a(x) = F(b_1(x), \dots, b_K(x)),$$

$$F(b_1(x), \dots, b_K(x)) = \sum_{k=1}^K w_k b_k(x)$$

Выбор весов

$w_k = 1$ – простое голосование

$w_k = q^{k-1}$ – члены геометрической прогрессии

Утверждение

Если функция $b_1(x)$ монотонна на множестве признаков Q_1 , а функция $b_2(x)$ монотонна на множестве признаков Q_2 , то их линейная комбинация с неотрицательными весами w_1 и w_2 , $w_1 b_1(x) + w_2 b_2(x)$, монотонна на множестве признаков $Q_1 \cup Q_2$.


Данные [Успенский]

- Данные о 14 болезнях.
- Признаковое описание получено с помощью технологии информационного анализа электрокардиосигналов.

Сравнение моделей


- Функционал качества – AUC.
- Скользящий контроль по 10 блокам, 40 запусков.

Монотонные пары




Предположение о хорошей монотонности выборки выполняется.
С ростом размерности количество пар быстро убывает.

Дефектные пары




Дефектных пар существенно меньше, чем монотонных.

Сравнение сортирующих критериев



Высокое качество классификации на небольших размерностях.

Качество классификации. М-функция



Изменение параметра монотонизации

| | | α | | | | |
|-----|------------------|----------|-------|-------|-------|-------|
| | | 0,1 | 0,3 | 0,5 | 0,7 | 0,9 |
| ВДЭ | чувствительность | 93,86 | 84,01 | 77,17 | 70,92 | 66,08 |
| | специфичность | 42,10 | 64,36 | 76,07 | 83,13 | 86,32 |
| ГБЭ | чувствительность | 97,49 | 93,50 | 90,32 | 88,38 | 87,07 |
| | специфичность | 51,99 | 72,03 | 81,84 | 85,43 | 87,11 |
| ЖКЭ | чувствительность | 95,81 | 93,67 | 92,92 | 91,90 | 89,65 |
| | специфичность | 80,83 | 87,81 | 88,96 | 90,72 | 92,84 |
| ИБЭ | чувствительность | 97,51 | 94,50 | 92,79 | 92,08 | 90,81 |
| | специфичность | 61,77 | 78,35 | 83,75 | 85,14 | 87,77 |
| МКЭ | чувствительность | 96,02 | 90,42 | 86,07 | 82,66 | 80,06 |
| | специфичность | 50,64 | 76,05 | 81,97 | 85,31 | 87,67 |
| ММЭ | чувствительность | 95,54 | 87,77 | 82,27 | 79,53 | 76,58 |
| | специфичность | 41,41 | 74,04 | 82,90 | 86,58 | 88,80 |
| СДЭ | чувствительность | 98,02 | 94,29 | 91,50 | 90,09 | 88,76 |
| | специфичность | 33,96 | 74,53 | 84,44 | 87,90 | 89,62 |
| УЩЭ | чувствительность | 97,34 | 91,72 | 88,34 | 85,73 | 83,56 |
| | специфичность | 35,30 | 74,61 | 82,92 | 88,03 | 89,96 |

С ростом α чувствительность падает, специфичность растет.

Сравнение результатов

| | ВДЭ | ГБЭ | ЖКЭ | ИБЭ | МКЭ | ММЭ | СДЭ |
|-----------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Monotonic | 87,26 | 97,29 | 98,67 | 97,99 | 95,47 | 93,67 | 96,68 |
| M_func | 86,55 | 96,87 | 98,03 | 97,91 | 94,86 | 91,51 | 96,01 |
| logReg | 87,62 | 96,91 | 99,00 | 98,21 | 95,11 | 93,52 | 97,08 |
| Syndr | 86,35 | 96,60 | 98,90 | 97,84 | 95,17 | 93,37 | 96,66 |
| | УЩЭ | ХГЭ | ХХЭ | ЭА | ЭАП | ЭАХ | ЯБЭ |
| Monotonic | 95,67 | 95,65 | 95,56 | 90,75 | 95,78 | 91,82 | 94,63 |
| M_func | 94,84 | 93,38 | 94,59 | 88,87 | 95,59 | 91,59 | 94,22 |
| logReg | 95,75 | 95,22 | 95,07 | 90,04 | 96,62 | 92,42 | 94,69 |
| Syndr | 95,17 | 94,77 | 95,51 | 89,27 | 96,59 | 91,90 | 94,67 |

- Исследованы различные способы отбора объектов и признаков для монотонного классификатора ближайшего соседа.
- Предложены жадные методы решения NP-трудных задач.
- Выполнена программная реализация и проведены численные эксперименты, показывающие применимость исследуемых моделей к задаче медицинской диагностики.

Направление развития работы:

- Предложение внутреннего критерия качества на основании количества монотонных и дефектных пар для стратегии пошагового добавления и удаления объектов и признаков.
- Развитие идеи композиции монотонных классификаторов, построение аналога синдромного алгоритма.