

Морфологический подход к синтезу метрических классификаторов и его реализация методом отыскания минимального разреза графа соседства для обучающей выборки*

Ю. В. Визильтер, В. С. Горбацевич
viz@gosnias.ru, gvs@gosnias.ru

Предложен и обоснован морфологический подход к синтезу классификаторов в задаче обучения с учителем, предполагающий решение двух последовательных подзадач — переразметки обучающей выборки и оптимальной корректной интерполяции (расширения) решающего правила. Доказана проективность морфологических операторов машинного обучения. Показано, что классы морфологических классификаторов и алгоритмов обучения образуют систему вложенных классов возрастающей сложности в смысле Пытьева и могут быть использованы для структурной минимизации риска переобучения. Показано, что для случая двухклассовой классификации метод минимального разреза графов позволяет отыскивать глобальный оптимум введенного критерия качества классификации.

Введение

Непосредственным толчком к разработке предлагаемого подхода послужило изучение работы [1], в которой (как и в [2]) распознающие алгоритмы (классификаторы) анализируются, будучи представлены лишь векторами решений на объектах обучающей выборки. Для перехода от анализа к синтезу необходимо дополнительно опереться на *принцип компактности* [3],[4], заключающийся в том, что соседние объекты выборки должны с большей вероятностью принадлежать к одному классу. Основанные на этом предположении алгоритмы будем называть *метрическими классификаторами*. Предлагается рассматривать задачу синтеза метрического классификатора как задачу *оптимальной сегментации* (labeling) точек обучающей выборки, а «форму» и «сложность» классификаторов трактовать в терминах «формы» и «сложности» изображений (образованных метками классов на точках выборки), то есть в терминах *математической морфологии*.

Основными источниками используемых далее морфологических конструкций и идей являются: *теория форм* М.Павель [5], *математическая морфология* Серра [6], *теория морфологического анализа* Пытьева [7] а также *критериальная проективная морфология* [8]. Для алгоритмической реализации процедур синтеза метрических классификаторов предлагается использовать технику построения минимальных разрезов графов [9]—[13], применяя ее к графикам соседства элементов обучающей выборки.

Задача обучения с учителем

Пусть даны пространство объектов \mathcal{A} , конечное множество классов $C = \{c_1, \dots, c_l\}$, и известно разбиение объектов по классам $c_{\mathcal{A}}(a) : a \in \mathcal{A} \mapsto c \in C$. Обозначение $c_{\mathcal{A}}$ указывает на то, что функция определена на \mathcal{A} .

Работа выполнена при финансовой поддержке РФФИ, проекты № 11-08-01114-а, 11-08-01039-а.

Производится описание объектов из \mathcal{A} дескрипторами из *пространства описаний (признаков)* \mathcal{X} : $x_{\mathcal{A}}(a) : a \in \mathcal{A} \mapsto x \in \mathcal{X}$. Случайным образом формируется конечная *выборка объектов* $A \subseteq \mathcal{A}$, $\|A\| < +\infty$ и соответствующая *выборка описаний* $X \subseteq \mathcal{X}$, $\|X\| < +\infty$. Каждому значению x ставится в соответствие класс c породившего его объекта $c_X(x) : x_{\mathcal{A}}(a) \in X \mapsto c_{\mathcal{A}}(a) \in C$. По *обучающей выборке* c_X требуется построить такой *распознавающий алгоритм* или *классификатор* $f_{\mathcal{X}}(x) : x \in \mathcal{X} \mapsto c \in C$, который обеспечивает *наилучшее разбиение* \mathcal{X} на классы из C .

«Наилучшее разбиение» определим при помощи *тестовой выборки* $c'_Y(x) : x \in Y \mapsto c \in C$, $Y \subseteq \mathcal{X}$, $Y \cap X = \emptyset$, $\|Y\| < +\infty$, и *критерия эмпирического риска* на выборке Y :

$$J_Y(f_{\mathcal{X}}) = d_H(f_Y, c'_Y)/\|Y\|,$$

$$d_H(f_Y, c'_Y) = \sum_{x \in Y} 1(f(x) \neq c'(x)),$$

где $1(true) = 1$, $1(false) = 0$, $\|Y\| = \sum_{x \in Y} 1$.

Здесь *расстояние Хэмминга* d_H имеет смысл числа ошибок классификации на тестовой выборке Y . Отсюда *критерий среднего ожидаемого эмпирического риска* имеет вид

$$J_{\mathcal{X}}(f_{\mathcal{X}}) = E_{Y \subseteq \mathcal{X}}\{J_Y(f_{\mathcal{X}})\},$$

где $E_{Y \subseteq \mathcal{X}}\{\cdot\}$ — математическое ожидание по всем возможным выборкам $Y \subseteq \mathcal{X}$.

Таким образом, задача построения *оператора оптимального синтеза* θ , заключается в минимизации критерия $J_{\mathcal{X}}(f_{\mathcal{X}}) = J_{\mathcal{X}}(\theta_{C_X})$:

$$\theta : c_X \in \Omega_X \mapsto f_{\mathcal{X}} \in \Omega_{\mathcal{X}},$$

$$\theta : \arg \min_{\theta} \{J_{\mathcal{X}}(\theta'_{C_X})\}. \quad (1)$$

Здесь Ω_X и $\Omega_{\mathcal{X}}$ — множества всех возможных разбиений X и \mathcal{X} по классам из C .

Как правило, от задачи синтеза (1) сразу переходят к задаче обучения классификаторов заданного класса при помощи *обучающего правила* известного типа:

$$\theta \in \Theta : c_X \in \Omega_X \mapsto f_{\mathcal{X}} \in F_{\mathcal{X}} \subseteq \Omega_{\mathcal{X}},$$

$$\theta = \arg \min_{\theta' \in \Theta} \{J_Y(\theta' c_X)\}, \quad (2)$$

где $F_{\mathcal{X}}$ — класс классификаторов, Θ — класс алгоритмов обучения для $F_{\mathcal{X}}$ на выборках $X \subseteq \mathcal{X}$.

Кроме того, вместо недоступного критерия $J_{\mathcal{X}}(f_{\mathcal{X}})$, на практике используется критерий *наблюдаемого эмпирического риска* $J_X(\theta_{c_X})$, который имеет глобальный минимум при $f_X \equiv c_X$, непригодный для неизвестной тестовой выборки Y . Этой проблеме посвящена *теория оценки и контроля переобучения* [2]. Здесь риск оценивается по обучающей выборке, но сложность решающего правила искусственно ограничивается. Для этого вводится понятие *сложности класса классификаторов* $Q(F_{\mathcal{X}})$, а точнее *сложности класса классификаторов* $Q(F_{\mathcal{X}})$. Соответственно вместо (2) решается задача *задача минимизации наблюдаемого риска с регуляризацией по сложности класса обучаемого классификатора*:

$$\begin{aligned} \theta &\in \Theta : c_X \in \Omega_X \mapsto f_{\mathcal{X}} \in F_{\mathcal{X}} \subseteq \Omega_{\mathcal{X}}, \\ \theta &= \arg \min_{\theta' \in \Theta} \{J_X(\theta' c_X) + \alpha Q(F_{\mathcal{X}})\}, \end{aligned} \quad (3)$$

где $\alpha \geq 0$ — параметр регуляризации.

Решение задачи (3) сводится к следующему («*метод структурной минимизации риска*»). Пусть в рамках некоторого суперкласса $\mathbf{F}_{\mathcal{X}}$ определена последовательность вложенных классов классификаторов *нарастающей сложности*:

$$\begin{aligned} F_{\mathcal{X}}^0 \subseteq F_{\mathcal{X}}^1 \subseteq \dots \subseteq F_{\mathcal{X}}^j \subseteq \mathbf{F}_{\mathcal{X}} \subseteq \Omega_{\mathcal{X}} : \\ Q(F_{\mathcal{X}}^0) \leq Q(F_{\mathcal{X}}^1) \leq \dots \leq Q(F_{\mathcal{X}}^j) \leq \dots \end{aligned} \quad (4)$$

Тогда задача (3) последовательно решается для $F_{\mathcal{X}}^j$, $j = 0, 1, 2, \dots$, пока значения критерия не перестанут улучшаться. Значение α подбирается *методом кросс-валидации с валидационной выборкой* $Z \subseteq \mathcal{X}$, $Y \cap X = \emptyset$, $\|Z\| < +\infty$.

Морфологический подход к синтезу классификаторов

Рассмотрим поход к машинному обучению, направленный непосредственно на решение задачи (1). Решение (1) предлагается отыскивать в виде композиции решений подзадач:

$$\theta_{\alpha} = \delta_{\alpha} \psi_{\alpha}, \quad (5)$$

где ψ_{α} — оператор (процедура) *синтеза оптимального отклика классификатора на обучающей выборке X с учетом его сложности (локальной некомпактности)*

$$\psi_{\alpha} : c_X \in \Omega_X \mapsto f_X \in \Omega_X,$$

$$\psi_{\alpha} = \arg \min_{\psi'} \{J_X(\psi' c_X) + \alpha Q_X(\psi' c_X)\}; \quad (6)$$

δ_{α} — оператор (процедура) *оптимальной корректирующей интерполяции (расширения)* классификатора

f_X на \mathcal{X} с учетом сложности получаемого классификатора $f_{\mathcal{X}}$:

$$\delta_{\alpha} : f_X \in \Omega_X \mapsto f_{\mathcal{X}} \in \Omega_{\mathcal{X}},$$

$$\delta_{\alpha} = \arg \min_{\delta'} \{J_{NN}(\delta' f_X) + \beta Q(\delta' f_X)\}; \quad (7)$$

Здесь

$$J_{NN}(\delta f_X) = \begin{cases} +\infty, & \text{если } \exists x \in X : \delta f_X(x) \neq f_X(x); \\ d_H(\delta f_X(X), \delta^{NN} f_X(X)) - & \text{иначе,} \end{cases}$$

d_H — расстояние Хэмминга; δ^{NN} — оператор интерполяции, соответствующий *правилу ближайшего соседа* (Nearest Neighbor).

Как решается в рамках такого подхода проблема переобучения? Ответ связан с областью *критериальной морфологии* [8], где доказано следующее

Утверждение 1. *Если* ψ_{α} — морфологический фильтр

$$\psi_{\alpha} A = \arg \min_B \{J(A, B) + \alpha Q(B)\};$$

где A — исходный образ, B — выходной образ, $J(A, B)$ — критерий ошибки аппроксимации, $Q(B)$ — критерий сложности образа B , $\alpha \geq 0$ — параметр регуляризации, и критерий $J(A, B)$ обладает свойствами метрики. **То**

- 1) оператор ψ_{α} является проектором: $\psi_{\alpha}^2 = \psi_{\alpha}$;
- 2) проектор ψ_{α} определяет систему вложенных классов, монотонную по параметру α : $\alpha \geq \beta \Rightarrow \psi_{\beta} \psi_{\alpha} = \psi_{\alpha}$.

Поскольку в задаче (1) функционал J имеет вид расстояния Хэмминга, из Утверждения 1 следует, что θ_{α} (5) является *алгебраическим проектором*:

$$\theta_{\alpha}^2 = \theta_{\alpha} \Rightarrow \forall x \in X : \theta_{\alpha} f_X(x) = f_X(x) \quad (8)$$

Кроме того, из Утверждения 1 следует, что на основе θ_{α} образуется система вложенных классов решающих правил, монотонная относительно α :

$$\forall \alpha \geq \beta \Rightarrow F_{\mathcal{X}}^{\alpha} \subseteq F_{\mathcal{X}}^{\beta} : Q(F_{\mathcal{X}}^{\alpha}) \leq Q(F_{\mathcal{X}}^{\beta}), \quad (9)$$

где $F_{\mathcal{X}}^{\alpha} = \{f_X(x) : \theta_{\alpha} f_X(x) = f_X(x)\}$ — множество классификаторов (разбиений), стабильное относительно проектора θ_{α} . В морфологиях изображений такая система вложенных проективных классов рассматривается как множество Пытьевских «форм» нарастающей сложности. В задаче синтеза классификаторов последовательность «форм» может быть использована для решения проблемы переобучения методом минимизации структурного риска. Необходимо лишь определить $Q_X(f_X)$ как критерий компактности.

Оценка компактности и минимизация сложности классификаторов

Для каждого $x \in X \subseteq \mathcal{X}$ определим систему вложенных окрестностей $O_k(x) \subseteq X$,

$k = 1, \dots, \|X\| - 1$, состоящих из k ближайших соседей. Принцип компактности предполагает, что близкие соседи должны с большей вероятностью принадлежать к одному классу. Введем локальную меру k -некомпактности f_X :

$$Q_k(x, f_X) = q_H(O_k(x)) / \|O_k(x)\|;$$

$$q_H(O_k(x)) = \sum_{y \in O_k(x)} 1(f_X(x) \neq f_X(y)), \quad (10)$$

и глобальную меру k -некомпактности f_X :

$$Q_X^k(f_X) = Q_H(X, f_X) / \|X\|,$$

$$Q_H(X, f_X) = \sum_{x \in X} Q_k(x, f_X). \quad (11)$$

Значение $Q_X^k(f_X)$ (11) характеризует эмпирическую оценку вероятности того, что один из k ближайших соседей в разбиении $f_X(x)$ будет отнесен к другому классу. При любых фиксированных k и X усложнению классификатора f_X соответствует нарастание меры k -некомпактности $Q_X^k(f_X)$. Кроме того, как показано в [11], при увеличении параметра k в (11) преимущество получают более простые и «гладкие» разделяющие поверхности.

С учетом (11) задача (6) сводится к известной задаче оценивания параметров скрытой Марковской модели [14], для которой существует эффективное приближенное решение методом нахождения максимального потока / минимального разреза графа. Для случая двух классов метод разрезания графа может давать точное оптимальное решение. Алгоритм нахождения минимального разреза на графе с двумя терминальными вершинами позволяет минимизировать функционал энергии вида:

$$E(T) = E_0 + \sum_{i=1..N} E_i(t_i) + \sum_{(i,j) \in V} E_{ij}(t_i, t_j), \quad (12)$$

где N — число нетерминальных вершин графа; $T = \langle t_1, \dots, t_N \rangle$, $t_1, \dots, t_N \in \{0, 1\}$ — метки ассоциирования нетерминальных вершин с терминальными; $E_i(0), E_i(1) \in \{0, 1\}$ — унарные потенциалы; $E_{ij}(t_i, t_j)$ — парные потенциалы $E_{ij}(0, 0), E_{ij}(0, 1), E_{ij}(1, 0), E_{ij}(1, 1)$; V — подмножество пар индексов, задающее соседство на T .

Энергия (12) субмодулярна [13], если $\forall (i, j) \in V$:

$$E_{ij}(0, 0) + E_{ij}(1, 1) \leq E_{ij}(0, 1) + E_{ij}(1, 0). \quad (13)$$

Для субмодулярной энергии (12)–(13) метод минимального разрезания графа [9], [12] гарантирует нахождение точного минимума [10], [13].

Для задачи синтеза двухклассового классификатора (6), (11) примем: $C = \{0, 1\}$, $N = \|X\|$, $T = \langle f_X(x_1), \dots, f_X(x_N) \rangle$, $E_i(x) = 1(f_X(x) \neq c_X(x))$, $E_{ij}(t_i, t_j) = 1(f_X(x_i) \neq f_X(x_j))$, $V = \{(i, j) : j \in O_k(x_i)\}$. Легко убедиться, что соответствующая энергия (12) будет субмодулярной, а значит, метод действительно порождает α -семейства проекторов из Утверждения 1.

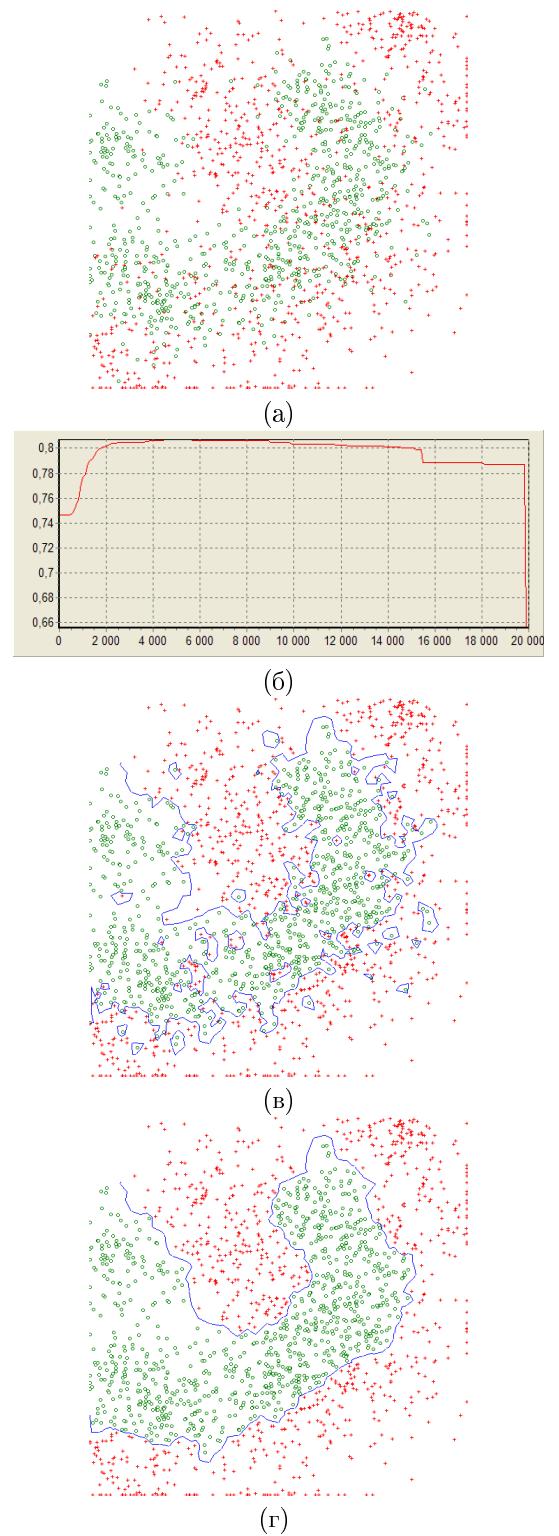


Рис. 1. Пример морфологического обучения: а) обучающая выборка; б) зависимость вероятности распознавания от параметра α ; в) переразметка выборки при $\alpha = 1000$ (переобучение); г) $\alpha = 4500$ (оптимум).

Моделирование процедур морфологического синтеза классификаторов

Для наглядности моделировались двумерные данные. Выборка формировалась на основе сме-

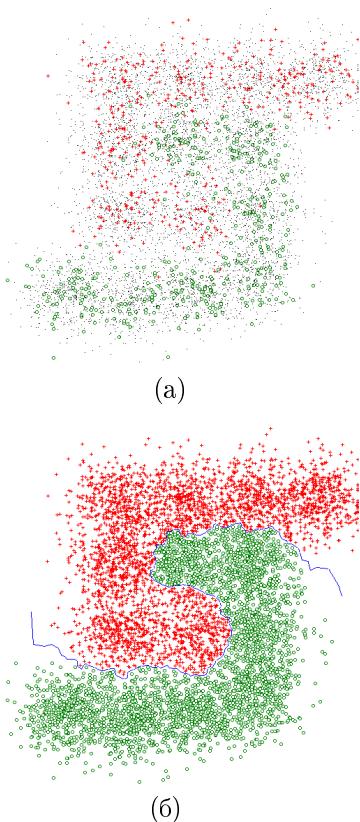


Рис. 2. Пример обучения на частично (на 10%) размеченной обучающей выборке. Показаны: а) обучающая выборка; б) результат переразметки выборки.

си гауссовых распределений. При построении графа соседства использовался алгоритм триангуляции Делоне с динамическим кэшированием [15]. Разрезы графов вычислялись при помощи библиотеки [16], что обеспечило время обучения не более 1 секунды. На Рис.1. показан пример морфологического обучения с учителем. Обучающая выборка содержала 1000 объектов двух классов. Приведена полученная методом Монте-Карло зависимость вероятности правильного распознавания от параметра α . На Рис.2 показан пример обучения по частично размеченнной выборке – т.н. semi-supervised learning (размечено 10% из 10000 объектов).

Заключение

Предложенный подход к машинному обучению назван «морфологическим» в силу его алгоритмического и методического соответствия известному морфологическому подходу к анализу изображений. Дальнейшие работы в рамках предложенного подхода должны быть связаны с исследованием его поведения на многомерных модельных и реальных данных, связанных с задачами распознавания сложных образов.

Литература

- [1] Воронцов К. В. Комбинаторная теория надёжности обучения по прецедентам. Диссертация на соискание ученой степени доктора физико-математических наук. ВЦ им. А. А. Дородницына РАН, Москва, 2010.
- [2] Вапник В. Н. Восстановление зависимостей по эмпирическим данным. — Москва: Наука, 1979.
- [3] Айзерман М. А., Браверман Э. М., Розонэр Л. И. Метод потенциальных функций в теории обучения машин — Москва: Наука, 1970 — 314 с.
- [4] Хачай М. Ю. Топологический подход к выводу условий равномерной по классу событий сходимости частот к вероятностям // Интеллектуализация обработки информации: 8-я международная конференция (ИОИ-8), Кипр, г. Пафос, 2010 г.: Сборник докладов, Москва: МАКС Пресс, , 2010, С. 91–94.
- [5] Pavel M. Fundamentals of Pattern Recognition // Marcel Dekker. Inc., New York, 1989.
- [6] Serra J. Image Analysis and Mathematical Morphology // Academic Press, London, 1982.
- [7] Пытьев Ю. П., Чуличков А. И. Методы морфологического анализа изображений // Москва: Физматлит, 2010 — 336 с.
- [8] Визильтер Ю. В. Обобщенная проективная морфология. // Компьютерная оптика — 2008. — Т. 32, № 4. — С. 384–399
- [9] L. Ford, D. Fulkerson. Flows in Networks // Princeton University Press, 1962.
- [10] D. Greig, B. Porteous, A. Seheult. Exact maximum a posteriori estimation for binary images // Journal of the Royal Statistical Society 1989. — Vol. 51, No. 2. — Pp. 271–279.
- [11] Y. Boykov, V. Kolmogorov. Computing geodesics and minimal surfaces via graph cuts // In Proc. IEEE International Conf. Computer Vision (ICCV) 2003. — Pp. 26–33.
- [12] Y. Boykov, V. Kolmogorov. An experimental comparison of min-cut/max-flow algorithms for energy minimization in vision // IEEE Trans. Pattern Analysis and Machine Intelligence (PAMI) 2004. — Vol. 26, No. 9. — Pp. 1124–1137.
- [13] V. Kolmogorov, R. Zabih. What energy functions can be minimized via graph cuts? // IEEE Trans. Pattern Analysis and Machine Intelligence (PAMI) 2004. — Vol. 26, No. 2. — Pp. 147–159.
- [14] Geman S., Geman D. Stochastic relaxation, Gibbs distributions, the Bayesian restoration of images // IEEE Trans. Pattern Analysis and Machine Intelligence 1984. — No. 6. — Pp. 721–741.
- [15] Скворцов А. В. Обзор алгоритмов построения триангуляции Делоне // Вычислительные методы и программирование 2002. — Т. 3. — С. 14–39.
- [16] Y. Boykov, V. Kolmogorov. MAXFLOW - software for computing mincut/maxflow in a graph. V. 3.01. — <http://www.cs.ucl.ac.uk/staff/V.Kolmogorov/software.html>