


Спес на РОМИП'2007

Максаков Алексей
bruzz@yandex.ru


Дорожка Web поиска

- Традиционная оценка релевантности (Lucene)
- Словарный морфологический анализ
- Цель: сравнить “базовый” подход с представленными на РОМИП

Коллекция km.ru




Коллекция Vu.web



Причины

- Традиционная оценка весов слов (tfidf)
- Нет оценки близости (в документе) слов из запроса
- Нет эвристического дополнения запросов (прилагательные -> существительные, расшифровка понятий)

Метод опорных векторов (SVM)



минимизировать $\frac{1}{2} \alpha^T \cdot \alpha + C_{light} \sum_i \xi_i$

при $c_i (\alpha \cdot x_i + b) \geq 1 - \xi_i, \forall i = 1 \dots n$

$\xi_i \geq 0, \forall i = 1 \dots n$ (1)

Задача сводится к задаче квадратичной оптимизации:

$$t_{об} = O(mn^{1,7})$$

максимизировать $\sum_i \lambda_i - \frac{1}{2} \sum_{i,j} \lambda_i \lambda_j c_i c_j (x_i \cdot x_j)$

при $\sum_i c_i \lambda_i = 0$

$0 \leq \lambda_i \leq C, \forall i = 1 \dots n$

Structural SVM

минимизировать $\frac{1}{2} \alpha^T \cdot \alpha + C \xi$

$$C_{light} = \frac{C}{n}$$

$$\forall c \in \{0,1\}^n : \frac{1}{n} \alpha^T \sum_{i=1}^n c_i d_i x_i \geq \frac{1}{n} \sum_{i=1}^n c_i - \xi \quad (2)$$

$$\frac{1}{n} \sum_{i=1}^n c_i$$

макс.доля ошибок
обучения

Эквивалентно решению
исх.задачи (1) при

$$\xi^* = \frac{1}{n} \sum_{i=1}^n \xi_i^*$$

SVM-perf

T. Joachims (KDD, август 2006): Training Linear SVMs in Linear Time

Алгоритм Cutting Plane находит следующее решение задачи (2):

$$(a, \xi + \varepsilon) \quad C_{light} = \frac{1}{\text{avg}_i \|x_i\|} \quad C_{perf} = \frac{n}{\text{avg}_i \|x_i\|}$$

Вычислительная сложность обучения: $O(sn)$

1 шаг итерации: $O(sn)$ операций, где $s=|V|$ *коэффициент разреженности матрицы $V \times D$, n -число примеров

Число итераций: $\max \left\{ \frac{2}{\varepsilon}, \frac{8C \max_{i=1..n} \|x_i\|}{\varepsilon^2} \right\}$ (на практике 20-90)

Сравнение времени обучения

$|V|=80000$, $|D|=5200$: $t_{об}(SVM-perf) > 2,5t_{об}(SVM-light)$

$|V| > 250000$, $|D|=29700$ (15-90 итераций):



Предстоит выяснить

- Изменится ли качество классификации при применении `svm_perf` (всегда ли достаточно $\varepsilon = 0,001$)?
- Имеют ли “право на жизнь” более простые алгоритмы, в том числе и при решении иерархической задачи классификации?

Спасибо за внимание