

Модификация схемы VM25 с помощью генетического алгоритма.

С.П. Воробьев, М.Б. Хорошко, ЮРГТУ (НПИ), Новочеркасск

Быстро растущее информационное пространство объединенных вычислительных сетей порождает новые потребности в обработке, представлении и особенно в поиске данных. На первое место выходит критерий релевантности, который позволяет при его корректном использовании повысить эффективность информационного поиска. Существует достаточно большое количество схем и моделей для решения задачи поиска, одной из которых является VM25.

Схема взвешивания Окари VM25, была разработана как способ построения вероятностной модели, чувствительной к частоте термина и длине документа, но не использующей большого количества дополнительных параметров. В соответствии с ней каждый документ d получает оценку по запросу q , определяемой следующей формулой:

$$Score_{d,q} = \sum_{t \in q} w_{q,t} * w_{d,t}$$

где

$$w_{q,t} = \ln \left(\frac{N - f_t + 0.5}{tf_{q,t} + 0.5} \right) * tf_{q,t}$$

$$w_{d,t} = \frac{(k_1 + 1)f_{d,t}}{K_d + tf_{d,t}}$$

$$K_d = k_1((1 - b) + b \frac{W_d}{W_A})$$

Переменная k_1 — это положительный параметр настройки, с помощью которого производится калибровка частоты термина. Переменная b — еще один параметр настройки ($0 \leq b \leq 1$), определяющий нормировку по длине документа. Рекомендуемые значения k_1 и b - параметры, равны 1.2 и 0.75 соответственно; W_d и W_A - длина документа и средняя длина документа.

Для подбора параметров надстройки будем использовать следующий генетический алгоритм, который получает на вход количество коэффициентов (n) используемых в модели и возвращает подобранные коэффициенты. Общий алгоритм выглядит следующим образом:

- 1) Создается начальная популяция. Случайным образом из диапазона коэффициентов от C_{min} до C_{max} (диапазон устанавливается для каждого алгоритма), подбираем k_n наборов коэффициентов и переводим их в двоичный вид.
- 2) Вычисляем приспособленность хромосом. Оцениваем ошибку, для каждого набора коэффициентов.
- 3) Выбираем двух родителей с наименьшей ошибкой для операции скрещивания.
- 4) Выбор хромосом для операции мутации.
- 5) Оценка приспособленности нового набора коэффициентов.
- 6) Если ошибка n_1 - набора больше заданной ошибки ε_{enter} , то переходим к пункту 3, иначе пункт 7.
- 7) Полученный набор коэффициентов, который минимизирует ошибку, возвращается в модель поиска.

Рассмотрены более детально основные аспекты:

- Все коэффициенты генерируются изначально случайным образом по равномерному закону при ограничении сверху и снизу. Затем переводятся в двоичный вид, чтобы можно было применять операции скрещивания и мутации.
- Ошибка оценивается по следующей формуле:

$$\varepsilon = \sum_{i=0}^n (r(d_i, q_i) - score(d_i, q_i))^2$$

Где, $r(d_i, q_i)$ – средняя оценка документа d_i экспертами, по запросу q_i . $score(d_i, q_i)$ – полученная релевантность документа d_i , по запросу q_i .

В ходе экспериментов получены оптимальные операции скрещивания и мутации.

Операция отбора. После проведения ряда экспериментов, было выявлено, что для более быстрого получения максимума целевой функции отбор хромосом должен осуществляться по следующему принципу. Для операции скрещивания берется два самых лучших хромосома, и случайным образом N_{kr} хромосом.

Для операции мутации берется два хромосома с самой низкой приспособленностью и N_{mut} хромосом.

Операция скрещивания. Для выбора оптимальной операции скрещивания, был проведен ряд экспериментов с различными методами. В результате определилось два оптимальных метода показанные на рисунке 1. Для проверки эффективности случайным образом делалась выборка запросов от одного до ста. В качестве параметра определяющего оптимальность, бралась средняя оценка релевантности выдачи по данным запросам. Во время эксперимента отключались другие операции. Таким образом функция достигает максимума при скрещивании методом «расчески» и очень близко при скрещивании «пополам» (рисунок 2). Решено оставить оба варианта в алгоритме и эксперименты доказали эффективность выбранного способа (рисунок 1). По различным запросам метод расчески достигает максимальной точки по одному набору запросов, метод пополам по двум, а использование двух методов по четырем.




Рис. 1. Операции скрещивания




Рис. 2. Методы скрещивания. При скрещивании «расчетской» биты с двух коэффициентов меняются через один. При скрещивании методом пополам, берется половину бит с первого коэффициента и вторую половину со второго коэффициента.

Операция мутации. Для определения оптимальной мутации, был проведен эксперимент, где оценивалась средняя релевантность документов выданных системой при отключенных других механизмах. В результате эксперимента выяснилось, что мутация достигает максимума при вероятности мутирования бита равной 40%. График зависимости результатов поиска от вероятности мутирования показан на рисунке 3.




Рис. 3. Зависимость результатов поиска от вероятности мутирования бита

Для проведения эксперимента, было создано две базы запросов – документов. Первая база используется для обучения алгоритма, вторая для оценки. Тестовые коллекции были предоставлены организацией РОМИП, брались две коллекции:

- псевдослучайная выборка сайтов из домена narod.ru объемом 728 000 документов.
- набор, содержащий новостные сообщения из 25 источников и охватывающий 3 временных интервала (около 31 500 документов).

Были сформированы запросы трех типов:

- информационные запросы,
- навигационные запросы,
- транзакционные запросы.

Всего сформировано около 5 000 запросов в равных соотношениях.

Эксперимент. Реализуем модель *OkapiBM25* и ее модификацию, где в качестве параметров надстройки будут выступать подобранные значения с помощью генетического алгоритма. Сравниваются полученные метрики оценки для двух систем по 30 запросам.

Полнота (recall) вычисляется как отношение найденных релевантных документов к общему количеству релевантных документов:

Полнота характеризует способность системы находить нужные пользователю документы, но не учитывает количество нерелевантных документов, выдаваемых пользователю. Полнота показана на рисунке 4.




Рис.4. Полнота

Среднее значение полноты: $BM=0,173$, $GA=0,241$. GA показывает лучшую полноту, в среднем на 40%, т.е. пользователь получит на 40% больше релевантных документов.

Точность (precision) вычисляется как отношение найденных релевантных документов к общему количеству найденных документов. Точность характеризует способность системы выдавать в списке результатов только релевантные документы. Точность алгоритмов показана на рисунке 5.




Рис.5. Точность

Среднее значение точности: $BM=0,167$, $GA=0,217$. GA показывает точность, выше на 30%, т.е. больше вероятность, что пользователь получит только релевантные документы на свой запрос.

Аккуратность (accuracy) вычисляется как отношение правильно принятых системой решений к общему числу решений. Аккуратность алгоритмов показана на рисунке 6.




Рис.6. Аккуратность

Среднее значение аккуратности: $BM=0,832$, $GA=0,873$. GA обладает более лучшей аккуратностью на 5%, т.е. система принимает больше правильных решений.

Ошибка (*error*) вычисляется как отношение неправильно принятых системой решений к общему числу решений. Ошибка алгоритмов полказана на рисунке 7.




Рис.7. Ошибка

Среднее значение ошибки: BM=0,167, GA=0,150. GA обладает меньшей ошибкой на 10%, т.е. системой на 10% меньше принято неправильных решений.

F-мера (*F*) часто используется как единая метрика, объединяющая метрики полноты и точности в одну метрику. *F*-мера для данного запроса вычисляется по формуле:

$$F = \frac{2}{\frac{1}{\text{precision}} + \frac{1}{\text{recall}}}$$

Отметим основные свойства:

- $0 \leq F \leq 1$
- если $\text{recall} = 0$ или $\text{precision} = 0$, то $F = 0$
- если $\text{recall} = \text{precision}$, то $F = \text{recall} = \text{precision}$
- $\min(\text{recall}, \text{precision}) \leq F \leq \frac{r+p}{2}$

F-мера алгоритмов полказана на рисунке 8.




Рис.8. *F*-мера

Среднее значение *f*-мера: BM=0,17, GA=0,24. GA на 40% позволяет улучшить данную метрика, т.е. в среднем GA выдает лучше результаты на 40%.

Таким образом, модификация с генетическим алгоритмом позволяет улучшить базовую модель в среднем на 40%, т.е. пользователь получит на свой ответ больше релевантных документов на 40%, вероятность того что на запрос будут только релевантные ответы на 30%, на 5% системой принято больше правильных решений, на 10% меньше не правильных.

Литература

1. Sparck Jones, Karen, S. Walker. A probabilistic model of information retrieval. б.м. : IP&M, 2000.
2. Маннинг, Кристофер Д. Введение в информационный поиск. М. : Вильямс, 2011.

