

УДК 004.9

ФАЛЬТИНА Е.В., студентка гр. ПИм-221 (КузГТУ)
Научный руководитель БУЙНАЯ Е.В., к.э.н, доцент (КузГТУ)
г. Кемерово

РЕШЕНИЕ ПРОБЛЕМЫ ДУБЛЕЙ В СПРАВОЧНИКАХ БАЗЫ ДАННЫХ «1С: БУХГАЛТЕРИЯ» С ПОМОЩЬЮ МАТЕМАТИЧЕСКОГО АЛГОРИТМА РАСЧЕТА КОСИНУСНОЙ ДИСТАНЦИИ

В любой без исключения организации при работе в программах обязательно происходит заполнение справочников. Справочники — это прикладные объекты конфигурации, позволяющие хранить в информационной базе данные, имеющие одинаковую структуру и списочный характер [1]. При этом если в организации отсутствует жесткое регулирование такого пополнения, то в ней часто возникает проблема дублей. При этом в базе также можно встретить перестановки слов и их сокращения, при этом самые разнообразные. Из-за всего этого список приходит в неустойчивое состояние, что приводит к производным сложностям учета: пересортице, отрицательным остаткам, избыточной инвентаризации.

Как следствие, очень важно систематизировать данные и исправить все ошибки, чтобы не потерять прибыль из-за проведения операций с неверными или ошибочными данными. В связи с этим весьма актуально решение проблем хаоса в справочниках при занесении первичных данных.

В ходе работы со справочниками были выявлены следующие проблемы:

- перестановка слов в наименовании («гвозди плоские» и «плоские гвозди»);
- излишняя информация (исходит из желания точнее описать сущность предмета);
- сокращения наименований (например, «пл. гвозди»);
- копирование лишних символов при переносе информации из других систем (например, перенос строки);
- числовые ошибки (например, вместо 250 гр. пишут 25 гр.);
- орфографические ошибки в словах (например, «плоские гвозди»).

Если не решать данные проблемы, то в конечном итоге придётся столкнуться со следующими последствиями:

- сложность прочтения данных, введенных другим работником;
- наличие нескольких карточек с похожими названиями, а значит, и непонимание того, какую именно карточку использовать при поступлении/реализации товара;
- пересортица в базе по нескольким карточкам, при которой также неясно, какую карточку выбрать при списании;
- сложность при синхронизации с другими учетными системами.

Для решения данных проблем существует множество методов. Все их можно разделить на административные и инженерные. К административным методам относятся:

- ввод единых классификаторов;
- разработка и внедрение инструкций по ведению справочников;
- увольнение всех сотрудников и ввод информации самостоятельно (что долго и мешает другим делам);
- использование бумажных справочников (это неудобно и не технологично).

К инженерным методам относятся:

- ввод через сканеры (покупка доп. оборудования);
- загрузка через файлы обмена, почту;
- ввод с помощью математических методов и расчетов.

Нами предполагается разработка типа обработки, решающего выявленные проблемы на основании математических алгоритмов. В качестве исходных данных для разрабатываемой программы будут использованы записи справочников номенклатуры и контрагентов конфигурации «1С: Бухгалтерия»; их структура представлена в таблицах 1 и 2. Основная логика программы будет содержаться в Python. Также будет настроена интеграция между конфигурацией «1С: Бухгалтерия» и приложением на Python, так как в системе 1С необходимо будет вызывать функции из Python, а в основной программе — использовать записи из базы данных. Для этого будут использоваться встроенные библиотеки Python.

Таблица 1. Структура данных справочника "Номенклатура"

Реквизит	Тип
Наименование	Строка (250)
Вид номенклатуры	СправочникСсылка.ВидНоменклатуры
Единица измерения	СправочникСсылка.ЕдиницаИзмерения
Артикул	Число (250)
Цена реализации	Число (250)
Номенклатурная группа	СправочникСсылка.ГруппаНоменклатуры

Таблица 2. Структура данных справочника "Контрагенты"

Реквизит	Тип
Наименование	Строка (250)
Полное наименование	Строка (250)
Вид контрагента	ПеречислениеСсылка.ВидКонтрагента
ИНН	Число (12)
КПП	Число (9)
Страна регистрации	Строка (250)

В результате работы приложения в качестве выходных данных в базе будут храниться вектора слов (двоичные числа), словосочетаний и предложений, а также число, называемое косинусной дистанцией.

Для применения математических методов с входными данными необходимо поработать, т.е. сделать предобработку. Она заключается в следующем:

- необходимо удалить все междометия («в», «на» и т.д.);
- нужно удалить точки, запятые, двоеточия, т.е. все спецсимволы («*», «,» и т.д.);
- привести существительные к «начальной» форме (т.е. перевести в именительный падеж);
- привести все слова к нижнему регистру;
- произвести обратную транслитерацию слов (т.е. перевести все слова на русский).

После такой работы с данными необходимо выделить в них признаки. Признаки — это некоторые свойства класса-объекта, его характерные черты, уникально выделяющие его среди других классов-объектов. Признаками слов являются биплеты или триплеты. Биплет — это обычное разбиение слова на последовательности по две буквы с шагом смещения в один символ; триплет — всё то же самое, но здесь последовательность имеет по три буквы.

Однако для того, чтобы применять математические методы, необходимо будет также закодировать слова — то есть, в этом случае, представить их в виде чисел. Для этого удобно использовать гистограммы, так как для программистов гистограмма — это вектор. По своей сути гистограмма — графическое представление данных, содержащее информацию о том, сколько и каких событий случилось за определенный интервал. На ней по горизонтали откладывается номер биплета, а по вертикали — количество таких биплетов в предложении/слове.

Для такого рода работы первоначально нужно будет составить словарь гистограммы. Для этого можно вывести все возможные комбинации биплетов русского языка. Так, если исключить из алфавита ненужные нам экзотические буквы «Ъ» и «Ь», останется 31 буква. Всего получится 31×31 комбинаций — 961. Это значительное количество, которое можно попробовать уменьшить.

С целью уменьшения количества комбинаций можно использовать словарь и найти на основе его текста частоту появления каждого биплета. Так, если частота очень большая, то этот биплет будет отнесен к групповому биплету, т.е. биплету, который очень часто встречается в тексте. Частоты посчитаем так: количество раз появления биплета во всем тексте поделим на общее количество биплетов в тексте.

Появление в предложении биплета, частота появления которого очень высока, приводит к малому уменьшению информационной энтропии сообщения. Информационная энтропия — это мера непредсказуемости появления какого-

либо символа первичного алфавита. В свою очередь, первичный алфавит — это набор букв или, в данном случае, биплетов, которыми мы можем оперировать.

Следовательно, мы можем попробовать сгруппировать биплеты с большой частотой появления в один общий сводный биплет. На гистограмме такие биплеты будут «занимать» ровно одну позицию по координате X. В итоге у нас получится N биплетов — это и будет словарь.

Благодаря всему вышеперечисленному мы, имея некоторое предложение, можем посчитать количество биплетов в нем. В массиве длиной N, где каждая позиция соответствует отдельному биплету из словаря, проставим количество биплетов в предложении на позициях биплетов в гистограмме. В итоге мы получим гистограмму предложения. Эта гистограмма зависит не от порядка слов и биплетов, а только от конечного набора последних в предложении. На рисунке 1 представлен пример; числа, которые можно видеть на схеме, — это количество появления биплетов в проверяемом предложении.



Рисунок 1. Слово, представленное в виде вектора

После преобразования данных в нужную нам форму можно наконец применить математические методы. Наиболее удобно в данном случае будет использовать косинусную дистанцию между векторами.

Косинусное подобие — метрика, используемая для определения сходства между двумя векторами. Она вычисляется как косинус угла между двумя векторами и может принимать значения от -1 до 1 . Значение 1 означает полное сходство, а значение -1 — полное несходство.

Косинусная дистанция (расстояние) получается, когда мы из единицы вычитаем косинусное подобие. В этом случае ситуация противоположна приведённой выше: чем меньше показатель, тем лучше.

$$1 - \frac{\mathbf{A} \cdot \mathbf{B}}{\|\mathbf{A}\| \|\mathbf{B}\|} = 1 - \frac{\sum_{i=1}^n A_i B_i}{\sqrt{\sum_{i=1}^n A_i^2} \sqrt{\sum_{i=1}^n B_i^2}}$$

Рисунок 2. Формула расчета косинусной дистанции (где A и B — векторы слов, $\|\mathbf{A}\|$ и $\|\mathbf{B}\|$ — их длина, а n — количество элементов массива, соответствующих вектору)

По формуле, показанной на рисунке 2, рассчитываем расстояние между двумя словами (предложениями), представленными в виде векторов. Чем меньше это расстояние, тем одно слово (предложение) ближе ко второму по смыслу.

В пользовательском режиме программы 1С форма реализованной обработки будет выглядеть так, как представлено на рисунке 3, то есть под полем ввода наименования будет выпадающий список со всеми схожими значениями из базы, а справа от них — рассчитанная косинусная дистанция.

Рисунок 3. Макет приложения

В ходе воплощения проекта нами также был реализован контрольный пример на маленькой выборке, необходимый для выявления недочетов на начальном этапе разработки. Для этого были взяты следующие данные: вводимая строка – «Гвозди, в коробке.», строка из базы – «Белые болты в коробке». Сначала происходила предобработка введенной строки — так, как это было описано выше (см. рис. 4).

```
Гвозди, в коробке.
Переведенное слово:
['Гвозди,', 'в', 'коробке.']
Строка без междометий:
Гвозди, коробке.
Строка без спецсимволов:
Гвозди коробке
Строка в именительном падеже:
гвоздь коробка
Строка в нижнем регистре:
гвоздь коробка
Итоговая строка:
гвоздь коробка
```

Рисунок 4. Предобработка введенной строки

Далее производилось построение гистограмм по данным, после чего все полученные результаты были выведены в виде отчета в соответствии с рисунком 5. Слева в отчете представлена гистограмма введенной строки (на оси абсцисс откладываются уникальные буквы в словосочетании, а на оси ординат – их количество в словах). Справа выводится гистограмма строки из базы, а также рассчитанная косинусная дистанция.

По гистограммам данного отчета и по расчету дистанции можно наглядно наблюдать схожесть фраз. Здесь мы видим, что строки «Гвозди, в коробке.» и «Белые болты в коробке» по графику схожи, но по рассчитанной косинусной

дистанции имеют значительное в данном случае расстояние – 0,7 (напомним, что чем меньше это число, тем лучше).

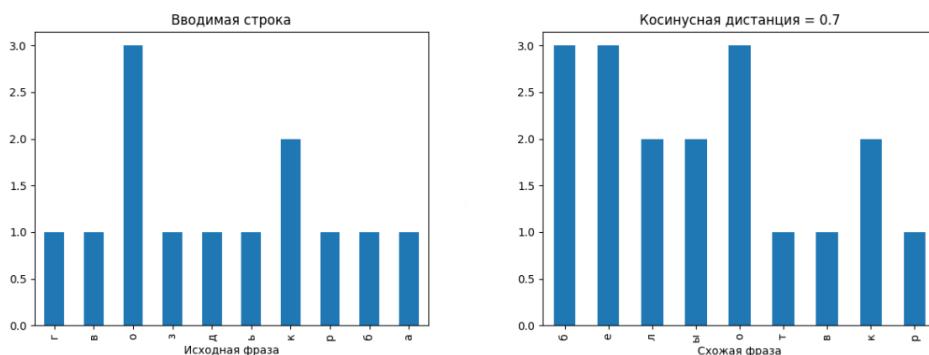


Рисунок 5. Внутренний отчет

Таким образом, с помощью рассмотренного метода можно решить проблему одинаковых слов, занесенных в справочники по-разному; например, одно может быть добавлено полностью, другое с сокращениями, а третье на английском языке и т.д., хотя при этом все они подразумевают один и тот же объект. Подобный способ облегчит работу с программой и поможет исправить ошибки в базе. В перспективе планируется адаптация данной разработки под большую выборку, тестирование на реальных данных, а также внедрение метода в различные организации для производственной эксплуатации.

Список литературы:

1. Архитектура платформы 1С:Предприятие. Справочники [Электронный ресурс]. – Режим доступа <https://v8.1c.ru/platforma/spravochniki/> (дата обращения: 31.01.2024)
2. 1C-RarusTechDay 2023 — 6-я открытая техническая конференция для специалистов 1С // 1С-Рарус URL: (<https://rarus.ru/events/20230720-1c-rarustechday-2023-587081/>, б.д.) (дата обращения: 30.07.2023).
3. Как подключиться к 1С из Python и реализовать обмен данными // Статьи URL: https://dzen.ru/a/XtPGLCpP_TCSfohn (дата обращения: 30.08.2023).
4. Г.И.Фалин, А.И.Фалин. О гистограмме и её свойствах. Математика в профильной школе. ФРАКТАЛ, 2013, №1, стр.44-62
5. Кристиан С. Пероне, «Машинное обучение:: косинусное сходство векторных пространственных моделей (часть III)» в Terra Incognita.