

Очевидно, что данная настройка не является самой оптимальной, так как значения углов, измеренные гироскопом и акселерометром, немного отличаются от действительных, однако она позволяет достаточно быстро стабилизировать положение квадрокоптера, тем самым решить поставленную задачу.

Подобная настройка с небольшими корректировками может быть использована для X-образных квадрокоптеров со схожими габаритами и техническими характеристиками.

ЛИТЕРАТУРА

1. MPU-6000 and MPU-6050 Register Map and Descriptions Revision 4.2 [Электронный ресурс]. – URL: <https://www.invensense.com/wp-content/uploads/2015/02/MPU-6000-Register-Map1.pdf> (дата обращения 18.11.2018).

2. Соммер У. Программирование микроконтроллерных плат Arduino/Freduino. – СПб.: БХВ-Петербург, 2012. – 256 с.

3. Петин В. А. Проекты с использованием контроллера Arduino – 2-е изд., перераб. и доп. – Санкт-Петербург: БХВ-Петербург, 2015. – 462 с.

4. Ревич, Ю. В. Занимательная электроника – 3-е изд. – Санкт-Петербург: БХВ-Петербург, 2016. – 576 с.

АНАЛИЗ МНОГОМЕРНЫХ ДАННЫХ ДЛЯ ОПРЕДЕЛЕНИЯ ГРУППЫ РИСКА СЕРДЕЧНО-СОСУДИСТЫХ ЗАБОЛЕВАНИЙ

П.А. Зяблицев

(г. Томск, Томский политехнический университет)

e-mail: paz4@tpu.ru

ANALYSIS OF MULTIDIMENSIONAL DATA TO DETERMINE THE RISK GROUP OF CARDIOVASCULAR DISEASES

P.A. Zyablitsev

(Tomsk, Tomsk Polytechnic University)

Abstract: The paper is devoted to research a total risk of cardiovascular diseases. This problem is actual, because prediction of such diseases can save many lives. The implementation of the OLAP technology was considered as one of the stages of data analysis.

Keywords: OLAP processing, total risk, myocardial infarction, Pivot tables, data analysis, multidimensional data, data warehouse.

Введение. В настоящее время существует несколько способов определения риска возникновения сердечно сосудистых заболеваний. Первая группа методов - это обследование в медицинских учреждениях, но стоит отметить что мало кто из нас обратится в поликлинику при отсутствии боли или явного дискомфорта, а ишемическая болезнь сердца может проходить без каких-либо признаков. Другие методы анализа риска основаны на эмпирических данных проспективных исследований за большими группами людей. Благодаря таким исследованиям было обосновано понятие суммарного риска и разработана таблица оценки риска сердечно-сосудистых заболеваний SCORE. Однако на данный момент данная таблица имеет много недостатков и важной задачей является создание системы оценки группы риска сердечно-сосудистых заболеваний с высокой точностью. Для решения данной задачи было решено применить методы интеллектуального анализа данных.

Интеллектуальный анализ данных. Интеллектуальный анализ данных – это совокупность математических моделей, численных методов, программных средств и информационных технологий, обеспечивающих обнаружение в эмпирических данных доступной для интерпретации информации и синтез на основе этой информации ранее неизвестных, нетривиальных и практически полезных для достижения определенных целей знаний. [1]

Процесс интеллектуального анализа данных состоит из следующих этапов:

1. Сбор данных
2. Подготовка данных (фильтрация, дополнение, кодирование)
3. Использование методов анализ данных
4. Верификация результата (проверка полученных закономерностей и моделей)
5. Применение полученной модели для прогнозирования.

Рассмотрим каждый этап более подробно:

Первый этап подразумевает собой сбор данных различного формата из различных источников: структурированных (базы данных) и не структурированных (социальные сети, текстовые файлы, веб-сайты). Эти данные объединяются в витрины данных или хранилища данных, с которыми в дальнейшем мы уже можем работать. Даже если у нас есть реляционная база данных и данные из других источников нас не интересуют рекомендуется перенести информацию из БД в хранилище данных, так как аналитические запросы к оперативной БД будут занимать слишком много серверного времени, блокирую таблицы.

Этап подготовки данных для анализа является крайне важным, и большая ошибка относиться к нему небрежно. Так как если мы имеем данные низкого качества на входе, то, вероятнее всего, и результат будет такого же качества. Под качеством данных подразумевается их полнота, точность, своевременность и возможность интерпретации. На данном этапе необходимо изучить данные на предмет пропуска значений, дублирования, шумов и выбросов. Для улучшения качества данных следует исключить объекты с пропущенными значениями из обработки, убрать дублирование, исключить данные с крайними значениями. Этот этап занимает много времени и сил, но его необходимость неоспорима.

На третьем этапе мы используем методы анализа данных. Это может быть машинное обучение, применение деревьев решений, искусственных нейронных сетей, корреляционный и регрессионный анализ, многомерный анализ данных (технология OLAP) и многие другие. После этого этапа мы получаем модель, которая прогнозирует значение на основе исходных данных или распределяет данные на категории, классы или кластеры.

На этапе проверки мы определяем достаточную ли прогнозную точность имеет наша модель и удовлетворяет ли нашим ожиданиям.

И на последнем этапе мы используем нашу модель уже непосредственно для наших целей, будь то улучшение бизнес процесса, прогнозирование заболевания или предсказание природных катастроф.

Применение методов анализа для выявления риска возникновения сердечно-сосудистых заболеваний. На первом этапе мы имеем данные из Томского регистра острого инфаркта миокарда, которые ведется с 1984 года (всего учтено около 50 000 случаев, в том числе более 25 000 подтвержденных случаев острого инфаркта миокарда). Данные представляют собой файлы Excel с данными о больных. Всего имеется более 50 тысяч записей с более чем 100 различными параметрами.

Наиболее важный и трудоемкий этап – это подготовка данных. Наш исходный файл Excel представляет собой список пациентов и большое количество их параметров (209 столбцов в таблице). Для построения хранилища данных нам нужны не все параметры, этой таблицы, а лишь те, которые позволят вычислять суммарный риск возникновения серьезных сердечно-сосудистых случаев, а также смерти от сердечно-сосудистых заболеваний. Некоторые подмножества столбцов требуют свертки в отдельные атрибуты. Полезные данные из таблицы Excel будут перенесены в таблицу реляционной БД, так как в дальнейшем с ней проще работать с помощью запросов SQL и далее на основе этой таблицы создавать хранилище данных.

Из 209 проанализированных столбцов были выбраны 12, а именно: ID пациента, ID случая, социальное положение, возраст, стенокардия, артериальная гипертензия, сахарный диабет, курение, приступ произошел во время, индекс массы тела, фермент сыворотки крови, дата смерти.

Для переноса полезных данных из таблицы Excel в БД необходимо создать пакет переноса данных. С помощью SQL Server Data Tools for Visual Studio 2012 создается проект пакета переноса данных SSIS (SQL Server Integration Services).

Данные являются достаточно сырыми после переноса. Например, в файле Excel нет как такого столбца как возраст, но есть год рождения и дата приема, на основании которых мы можем определить возраст. Помимо этого, нужно провести работу по форматированию всех параметров к нужным типам данных (в исходном файле типы самые разные и не соответствуют нашим задачам).

После этого можно создавать хранилище данных по схеме звезда, это необходимо для дальнейшего анализа данных с помощью технологии OLAP. Структура хранилища представлена на рисунке 1.

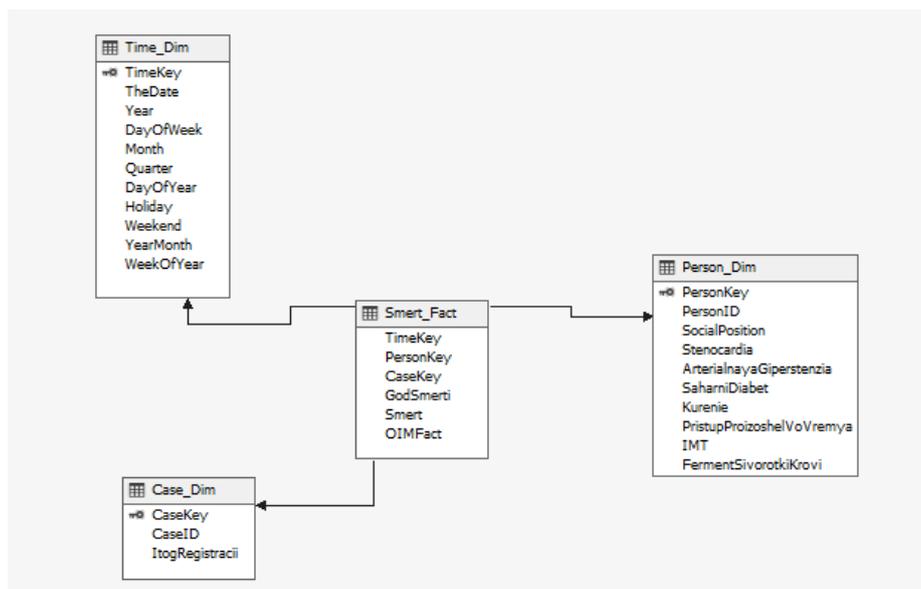


Рисунок 1. Структура хранилища данных

После создания хранилища данных в SQL Server нужно заполнить его данными из нашей БД. Для этого будем использовать пакет по переносу данных из нашей БД в хранилище данных. Таким образом после запуска пакета наше хранилище данных заполнится. Можно приступать к созданию “куба данных”.

Создание куба будет происходить с помощью ПО «SQL Server Data Tools», с помощью которого мы создавали пакеты SSIS. Только теперь в создании проекта нам нужно выбрать “Проект интеллектуального анализа данных и многомерных данных служб Analysis Services”.

Создание такого куба данных позволяет получать быстрые отчеты по различным выборкам, это позволит понять и проанализировать зависимости между различными параметрами.

На данном этапе интеллектуальный анализ не завершен, планируется применить методы машинного обучения для предсказания сердечно-сосудистых заболеваний. Тем не менее применение технологии OLAP позволяет произвести предварительный анализ данных и сравнение всех возможных вариантов. Результат такого рода работы представлен в таблицах 1, 2.

Таблица 1 – зависимость смертей от социального положения и стенокардии.

Число Smart Fact	стенокардия			Общий итог
	есть	нет	неизвестно	
социальное положение				
рабочий квалифицированного труда	175	422	155	752
рабочий не квалифицированного труда	44	125	53	222
водитель транспорта	51	129	28	208

служащий	71	79	38	188
предприниматель	7	5	9	21
безработный	208	755	841	1804
пенсионер	5144	2745	3448	11337
инвалид труда	542	212	84	838
инвалид ВОВ	15	9	2	26
учащийся		1	1	2
военнослужащий		1	3	4
неизвестно	217	345	175	737
Общий итог	6474	4828	4837	16139

Таблица 2 – зависимость смертей от возраста, пола и курения.

Число Smert Fact	мужчина				мужчина Итог	женщина				женщина Итог	Общий итог
	курит	не курит	курил ранее	неизвестно		курит	не курит	курил ранее	неизвестно		
60	139	43	30	99	311	6	49	2	41	98	409
61	107	47	35	126	315	6	65	2	41	114	429
62	122	42	35	103	302	7	71	2	43	123	425
63	111	33	38	100	282	5	71	3	54	133	415
64	100	42	35	104	281	7	84	1	38	130	411
65	99	41	57	97	294	14	89	2	54	159	453
66	107	51	35	104	297	11	130	4	25	170	467
67	100	50	36	87	273	9	103	4	51	167	440
68	78	65	31	75	249	5	117	2	71	195	444
69	89	55	44	78	266	11	117	4	59	191	457
Общий итог	1052	469	376	973	2870	81	896	26	477	1480	4350

Закключение. В результате выполнения данной работы было спроектировано хранилище данных для последующей обработки этих данных технологией OLAP. Данные из громоздких и неудобных для обработки файлов Excel были перенесены в хранилище данных со всеми необходимыми конвертациями. Был создан «OLAP-куб», который позволяет получать отчеты о всех зависимостях между атрибутами в режиме реального времени. Данная работа является одним из важнейших этапов по созданию системы оценки группы риска сердечно-сосудистых заболеваний. Данный этап имеет практическую пользу для аналитиков. Эксперт может проверять различные теории в режиме реального времени, все данные можно вращать и получать необходимые «срезы» и «разрезы». Благодаря созданию «куба» появляется возможность проанализировать данные РОИМ Томской области и на основании этих данных сделать вывод о наиболее опасных факторах риска и их сочетаниях.

ЛИТЕРАТУРА

1. Дюк В., Самойленко А. Data Mining: учебный курс (+CD-ROM). 2001 г. Издательство: Питер. Серия: Учебный курс. – 368 с.
2. Введение в многомерный анализ. [Электронный ресурс]. – URL: <https://habrahabr.ru/post/126810/> (Дата обращения 11.10.18г.)
3. Difference Between Data Mining and OLAP. [Электронный ресурс]. – URL: <http://www.differencebetween.com/difference-between-data-mining-and-vs-olap> (Дата обращения 15.09.18г)