

Ts.S. HOVHANNISYAN, S.A. SIRADEGHYAN, R.G. KIRAKOSSIAN, M.K. PERTOSYAN

ESTIMATING THE ACCURACY OF ANOMALY DETECTION IN TELECOMMUNICATION NETWORKS BY THE MACHINE LEARNING SYSTEM

Anomaly detection in telecommunication networks is becoming more and more important. This is because of the increase in the number of unauthorized access attempts and attacks to stop the operation. The paper assesses the accuracy of anomaly detection in telecommunication networks by machine learning.

Keywords: telecommunication network, anomaly detection, machine learning, support vector machine, artificial intelligence, monitoring.

UDC 681.3

S.W. PICKL, G.T. KIRAKOSSIAN, A.V. GHULYAN

DEVELOPING COMPLEX INTELLIGENT SYSTEMS FOR DECISION SUPPORT IN HEALTHCARE

Medical information doubles in volume every five years, and physicians practicing in the rapidly changing field of diabetes are challenged to remain current with medical literature, research, guidelines and best practices. In this paper, we propose a way to expand the accessibility and usability of medical evidence to improve patient outcomes across the field of diabetes.

Keywords: personalized medicine, technology platform IBM Watson, decision support, cloud services.

Introduction. Today, the global healthcare industry is redefining itself to reduce costs and more efficiently manage its resources while improving patient care. To deliver that strategy, healthcare organizations are becoming more data driven, defining their data as a very strategic asset, and putting their processes and systems to access and analyze the right data and derive actionable results. Global Research centers publish innovative findings in peer-reviewed journals, which the most common medium doctors use to gather new medical information. Nevertheless, keeping up with the medical literature can take as many as 160 hours a week. It's not surprising that only about 20 percent of the knowledge that clinicians use today is evidence-based.

The ability to analyze a wide volume and variety of content and data is a key to that strategy, not only from traditional sources such as electronic medical records (EMRs), doctors' notes, healthcare operational systems, but also from nontraditional sources such as social media and public health records.

One of the top challenges for information technology leaders in healthcare is aligning technology capabilities with the needs of the organization, regulatory requirements and wants of the patient. That is a driving tremendous interest in data analysis [3].

Recognizing the unique data analysis and data management challenges of healthcare providers, IBM Corporation has put a major focus on IBM Watson Health [1, 2], which uses cognitive technology to help transform the way in which organizations care for patients.

We propose a way to expand the accessibility and usability of medical evidence to improve patient outcomes across the field of diabetes based on IBM cloud solutions. We try to find a technology solution that could provide personalized diagnosis and treatment suggestions for individual patients.

Methodology and Approach. The Retrieve and Rank (R&R) [4] service on the Watson Developer Cloud is a great tool that enables enhancement of standard search implementations with natural language and machine learning capabilities. R&R is really 2 services bolted together. Retrieve is Apache Solr [5] in the cloud and offers all the rich feature set of Solr. There are 2 visible enhancements: 1) a custom query builder optimized for natural language search and 2) a set of algorithms to score semantic relationships between a given query and a Solr document which get fed into the Rank portion of R&R. The ranker is a learning to rank algorithm designed to re-rank objects in a list based on their relevance to some objective.

For implementation of the solution based on the R&R service, we will follow a process to optimize the content, configure a solr cluster, build a ground truth, train a ranker, and run a set of experiments to evaluate our configuration and the custom feature.

Configure Solr

- Create a Retrieve and Rank service in Bluemix and capture your credentials.
- Create a new Solr cluster and capture the Solr Cluster ID <sc3689b816_2b07_4548_96a9_a9e52a063bf1>.
- Upload configuration to Solr to capture the following documents with metadata:
 - id - Unique identifier for the document;
 - source - The original source document;
 - doc_type - What type of section this is e.g. cause. This will become relevant for our custom feature;
 - topic - The section header;
 - text_description – The body content of the document.
- Now we have a working solr cluster on Bluemix

Process to optimize the content

Machine learning-based applications are only as good as the data that power them. The following section details how to format content for Solr.

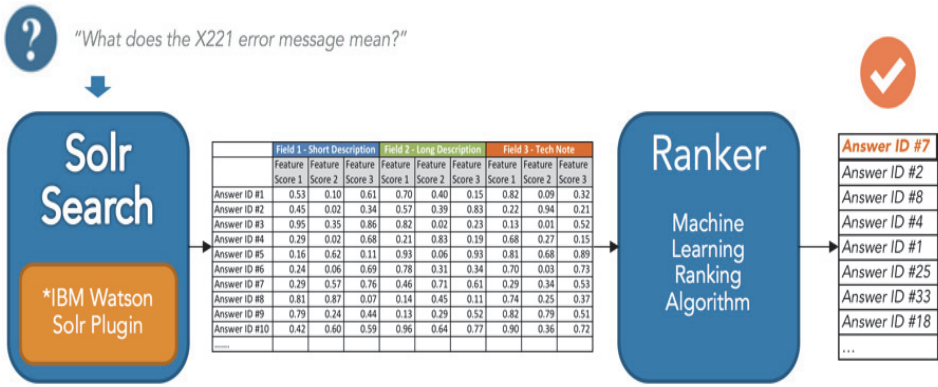
The Watson Document Conversion service allows to convert and segment HTML, word and pdf documents. When you tell the document conversion service how to segment the HTML documents, each segment is called an answer unit. The configuration associated with my document conversion call requests “answer units” but you could also ask for normalized html or text. The “selector tags” are h1 and h2. This will combine any deeper child tags like h3’s into the answer unit with its parent. This was important for the particular format of these source documents.

Once the answer units are returned by document conversion you can loop through them and write the extracted content to the relevant solr fields. Finally, we need to set our doc_type field so we create basic logic in the addDocumentFields function to identify this type.

We have not done any optimization yet.


Build a Ground Truth and Train the Ranker

If machine learning can be defined as a set of techniques to make predictions from data where the performance of those predictions improves with experience, then ground truth is the experience. In the case of Retrieve and Rank, ground truth comprises examples of input questions and output documents with associated relevance labels. A perfect answer should get a high relevance score and a bad answer, a low score. Once we have our topic/id mappings extracted, we simply remove any topics that don’t represent a question (i.e. don’t start with How, What, Can) and add a relevance label. Relevance is normally represented on some scale e.g. 1–5 where 5 is a perfect answer and 1 is poor. All documents with no label are given 0 by default and they are discarded. Ground truth is then segmented into train sets (70%) and test sets (30%) that allow us to teach and evaluate our model. Then we use R&R to train our ranker.



Custom Features and Natural Language Processing

The features that are native to Retrieve are query-document scorers as they compare lexical overlap between a query and document. The first stage in the question answer pipeline was called question analysis. We are going to build a custom query-document scorer here. In question analysis one of the key tasks was to identify the lexical answer type (LAT) which refers to the term in the question that indicates what entity type should be returned as the answer. For example the LAT in “What is the capital of California” is *capital* and the system should further generalize that to *capital city* such that the system knows to return a city as its answer.



That improvement would look something like in the above figure where the x axis represents time and the y axis represents some average relevance metric.

In our case, we will create a Natural Language Classifier (NLC) service in Bluemix and train NLC to classify the LAT as represented by the intent of an end-user question for the most common question types we would anticipate in the application. The question types we’ll use are:

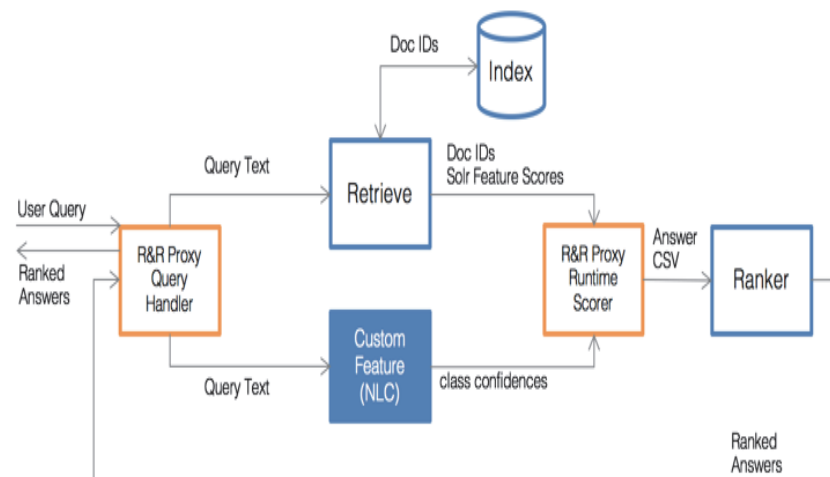
- Definition - What is Diabetes?
- Cause - What causes Diabetes?

- Symptom - What are the symptoms of Diabetes?
- Complications - What are complications associated with Diabetes?
- Diagnosis - How is Diabetes diagnosed?
- Treatment - How is Diabetes treated?
- Prevention - How do I prevent Diabetes?

The key to training a classifier is to provide examples of variations in how a question type could be asked.

In our query-document scorer, we need to compare the LAT identified by NLC to the document returned by solr so that we can return a definition for a definition question, symptoms for a symptom question etc. We could use NLC to classify sections of documents as well, but in our case we can use the structure of the documents to simplify this process. Each document in our NIDDK dataset has section titles called “*What is **” “*What causes **” “*What are the symptoms of **” and so on.

The solution diagram is presented below:



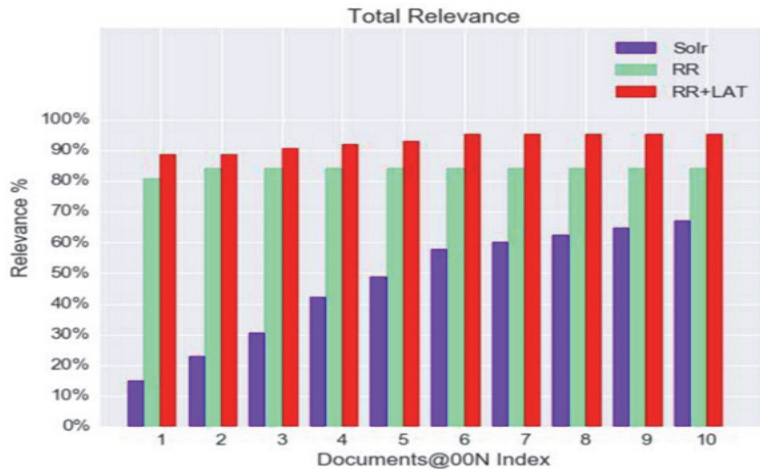
Results of Experiments

We used clinical practice guidelines of US. It’s a small dataset of about 40 documents on topics related to diabetes.

The main purpose of the experiment is to check the efficiency of the developed methodology and tools for the following scenarios:

- Using the features of Apache Solr configuration (Solr).
- Training the Ranker (RR).
- Custom Features Implementation (RR+LAT).

The result of our experiments are presented below:



Conclusion. Usage of IBM Watson allows using the unstructured data like texts and efficiently training systems for getting recommendations and suggestions for patients/doctors. We show that the proposed approach and technological solution allows achieving ~90% relevance to our questions in small datasets.

REFERENCES

1. <http://www.ibm.com/cloud-computing/bluemix/>
2. <http://www.ibm.com/watson/>
3. <https://www.hpcwire.com/2016/05/09/healthcare-professionals-get-cognitive-sooner-watson-health-financed-ibm/>
4. http://www.ibm.com/watson/developercloud/doc/retrieve-rank/ranker_tooling.shtml
5. <http://lucene.apache.org/solr/>

Ա.Վ. ՊԻԿԼ, Գ.Տ. ԿԻՐԱԿՈՍՅԱՆ, Ա.Վ. ՂՈՒԼՅԱՆ

ԱՌՈՂՋԱՊԱՀՈՒԹՅԱՆ ՈԼՈՐՏՈՒՄ ՈՐՈՇՈՒՄՆԵՐԻ ԿԱՅԱՑՄԱՆՆ ԱԶԱԿՑՄԱՆ ՀԱՄԱԼԻՐ ԻՆՏԵԼԵԿՏՈՒԱԼ ՀԱՄԱԿԱՐԳԵՐԻ ՆԱԽԱԳԾՈՒՄ

Բժշկական տեղեկատվության ծավալը յուրաքանչյուր հինգ տարում կրկնապատկվում է, և շաքարախտ հիվանդության արագ փոփոխվող ոլորտում աշխատող բժիշկները կանգնած են բժշկական գրականությանը, գիտական հետազոտություններին, ղեկավար ցուցումներին և առաջավոր փորձին իրազեկ լինելու խնդրի առաջ: Հոդվածում առաջարկվում է շաքարախտ հիվանդության բնագավառում բժշկական ցուցումների հասանելիության և օգտագործման հարմարավետության ընդլայնման ուղիներ՝ հիվանդների բուժման արդյունքների բարելավման համար:

Առանցքային բառեր. անհատական բժշկություն, IMB Watson տեխնոլոգիական հարթակ, որոշումների կայացման աջակցում, ամպային ծառայություններ:

С.В. ПИКЛ, Г.Т. КИРАКОСЯН, А.В. ГУЛЯН

**РАЗРАБОТКА КОМПЛЕКСНЫХ ИНТЕЛЛЕКТУАЛЬНЫХ СИСТЕМ
СОДЕЙСТВИЯ ПРИНЯТИЮ РЕШЕНИЙ В ОБЛАСТИ
ЗДРАВООХРАНЕНИЯ**

Медицинская информация удваивается в объеме каждые пять лет, и врачи, практикующие в быстро меняющейся области диабета, сталкиваются с проблемой быть в курсе новой медицинской литературы, научных исследований, руководящих указаний и передовой практики. В данной работе предлагаются пути расширения доступности и удобства использования медицинских указаний для улучшения результатов лечения пациентов по всей области диабета.

Ключевые слова: индивидуальная медицина, технологическая платформа IBM Watson, поддержка принятия решений, облачные услуги.

ՀՏԴ 371.214

Գ.Ձ. ԱՃԵՄՅԱՆ, Է.Հ. ՀՈՎՀԱՆՆԻՍՅԱՆ

**ԹԵՍՏԱՅԻՆ ԱՌԱՋԱԴՐԱՆՔԻ ԿԱՏԱՐՄԱՆ ՏԵՎՈՂՈՒԹՅԱՆ
ՍԱՀՄԱՆՄԱՆ ՄԵԹՈԴ**

Դիտարկվում է գիտելիքների ստուգման համար կիրառվող յուրաքանչյուր թեստային առաջադրանքի կատարման տևողության ընտրության ազդեցությունը պատասխանի ճշտության վրա: Առաջարկվում է թեստային առաջադրանքի հարցադրման և պատասխանի համար առավելագույն ժամանակի հաշվարկման նոր մոտեցում:

Առանցքային բաներ. գիտելիքների ստուգում, առաջադրանքի տևողություն, կատարման ժամանակի ընտրություն:

Ներածություն: Ներկայումս գիտելիքների ստուգման և գնահատման ամենաընդունելի և օբյեկտիվ ձևերից մեկը դրա իրականացումն է թեստային առաջադրանքների կիրառմամբ: Թեստավորման եղանակով ուսանողների գիտելիքների ճշգրիտ և օբյեկտիվ գնահատման համար անհրաժեշտ է հաշվի առնել յուրաքանչյուր թեստային առաջադրանքի կատարման տևողությունը: Թեստավորում իրականացնող համակարգերում գիտելիքների ստուգում և գնահատում իրականացնելիս, ելնելով խնդրի դրվածքից, վիճակագրական տվյալներից, փորձագիտական գնահատականից, սահմանվում կամ դասավանդողի կողմից հիմնականում ընտրվում է առաջադրանքներին պատասխանելու ընդհանուր ժամանակը, և թեստ հանձնողի ընտրությանն է մնում, թե նա ինչպես կբաշխի այդ ժամանակը առաջադրանքների կատարման միջև: Նմանատիպ շատ համակարգերում ժամանակային բաղադրիչն ազդում է գնահատման արդյունքի