



Universidade Federal de Pernambuco
Centro de Informática

Graduação em Ciência da Computação

Extraindo Estrutura de Entidades na Web com Pouca Supervisão

Lucas Almeida Pereira de Lima

Proposta de Trabalho de Graduação

Orientador: Prof. Luciano de Andrade Barbosa

Recife
Setembro de 2016

Resumo

A World Wide Web contém uma quantidade vasta de dados de variados domínios, e.g., imóveis, carros e produtos. Uma parte desses dados exhibe uma estrutura definida representando entidades com seus atributos e respectivos valores. A obtenção de dados de entidades estruturadas pode ser útil, por exemplo, para melhoria dos resultados de busca de engenhos de busca e tomada de decisão apoiada em dados. Essa estrutura encontra-se normalmente de forma implícita, acessível apenas através de páginas HTML. O objetivo desse trabalho é desenvolver um extrator que com pouca supervisão seja capaz de extrair dados estruturados de entidades em páginas web (apartamentos, televisores etc) de diversos sites em um certo domínio.

Palavras-chave: recuperação de informação, extração de dados, extração de entidades, dados estruturados, coleta de dados, web

Abstract

The World Wide Web contains a vast amount of data from a diverse set of domains, e.g., real estate, cars and products. A significant amount of this data exhibits a defined structure representing entities and their attributes and respective values. Data of web structured entities can be used, for instance, to improve search engine results, and for data-driven analytics. This structure is usually implicit, accessible only through HTML pages. The main goal of this work is to develop a semi-supervised extractor, capable of extracting structured data from entities in web pages (apartments, TVs etc).

Keywords: information retrieval, data extraction, entity extraction, structure data, data collection, web

Sumário

1	Contexto	1
2	Objetivo	2
3	Cronograma	3
4	Possíveis Avaliadores	4
5	Assinaturas	5

CAPÍTULO 1

Contexto

A World Wide Web é uma grande fonte de dados estruturados [1]. O processamento de dados estruturados de páginas web possibilita diversos benefícios, como visualização mais adequada da informação, buscas mais precisas e tomada de decisões apoiada em dados. Para processar esses dados, é preciso primeiramente extraí-los. A dificuldade da tarefa de extração de dados é dependente da forma como os dados se apresentam. Quando há uma estrutura bem definida, como em sistemas de bancos de dados, a extração pode ser feita de forma simples e precisa. Por outro lado, extrair informações de texto livre é difícil visto que não há estrutura bem definida. Como grande parte da informação da Web se apresenta de forma semi-estruturada, é possível obter uma certa estrutura através da árvore HTML e de objetos como listas e tabelas. Por outro lado, HTML é uma linguagem para objetos a serem exibidos na tela, e não para o consumo de programas de extração de dados [2].

Dessa forma, há um grande interesse em, dado um conjunto de páginas web, extrair a informação semi-estruturada relevante e transformá-la em uma “base de dados” estruturada [3]. Muitas vezes, a informação exibida em sites é gerada automaticamente através de programas que transformam a informação disponível em um banco de dados em uma página HTML. Com isso, para um mesmo site, é comum que haja um template, i.e, uma certa estrutura regular que define a forma como a informação é exibida na página [4].

Uma abordagem simples para extração de dados estruturados consiste em analisar páginas de um dado site para identificar características específicas desse site (como caminho na árvore DOM e atributos do HTML) para extração. Essa estratégia é capaz de alcançar uma boa acurácia, porém, precisa de um grande esforço manual para repetir o processo em muitos sites, além do custo de manter os extratores atualizados quando ocorrem mudanças na estrutura. Dessa forma, deseja-se neste trabalho criar para um determinado domínio um extrator único para extrair dados estruturados de vários sites [5][6][7][8][9][10]. O grande desafio de desempenhar essa tarefa decorre da grande variedade na forma de exibição de conteúdo encontrada entre sites, até mesmo dentro de um mesmo domínio.


CAPÍTULO 2

Objetivo

O objetivo principal desse trabalho é a criação de um extrator semi-supervisionado para dados estruturados em páginas HTML em determinado domínio, que seja efetivo para uma quantidade extensa de sites. Como estudo de caso será feita a extração de dados estruturados de entidades do domínio de imóveis.

CAPÍTULO 3

Cronograma



CAPÍTULO 4

Possíveis Avaliadores

São possíveis avaliadores do trabalho a ser produzido conforme especificado nesta proposta:

- Bernadette Farias Lóscio
- Ana Carolina Salgado

CAPÍTULO 5

Assinaturas

Lucas Almeida Pereira de Lima
Aluno

Luciano de Andrade Barbosa
Orientador

Referências Bibliográficas

- [1] N. Dalvi, A. Machanavajjhala, and B. Pang, “An analysis of structured data on the web,” *Proc. VLDB Endow.*, vol. 5, pp. 680–691, Mar. 2012.
- [2] T. Weninger and J. Han, “Information network analysis and extraction on the world wide web,” *Proceedings of the 2013 International Conference on World Wide Web (WWW 2013)*, May 2013.
- [3] M. J. Cafarella, A. Halevy, and J. Madhavan, “Structured data on the web,” *Commun. ACM*, vol. 54, pp. 72–79, Feb. 2011.
- [4] H. G.-M. Arvind Arasu, “Extracting structured data from web pages,” in *Proceedings of the 2003 ACM SIGMOD International Conference on Management of Data*, Association for Computing Machinery, Inc., June 2003.
- [5] L. Barbosa and G. Ferreira, *Extracting Records and Posts from Forum Pages with Limited Supervision*, pp. 233–240. Cham: Springer International Publishing, 2015.
- [6] B. Liu, R. Grossman, and Y. Zhai, “Mining data records in web pages,” in *Proceedings of the Ninth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, KDD ’03, (New York, NY, USA), pp. 601–606, ACM, 2003.
- [7] T. Weninger, T. J. Johnston, and J. Han, “The parallel path framework for entity discovery on the web,” *ACM Trans. Web*, vol. 7, pp. 16:1–16:29, Sept. 2013.
- [8] T. Furche, G. Gottlob, G. Grasso, X. Guo, G. Orsi, C. Schallhart, and C. Wang, “Diadem: Thousands of websites to a single database,” *Proc. VLDB Endow.*, vol. 7, pp. 1845–1856, Oct. 2014.
- [9] D. Qiu, L. Barbosa, X. L. Dong, Y. Shen, and D. Srivastava, “Dexter: Large-scale discovery and extraction of product specifications on the web,” *Proc. VLDB Endow.*, vol. 8, pp. 2194–2205, Sept. 2015.
- [10] M. J. Cafarella, A. Halevy, D. Z. Wang, E. Wu, and Y. Zhang, “Webtables: Exploring the power of tables on the web,” *Proc. VLDB Endow.*, vol. 1, pp. 538–549, Aug. 2008.