

WEB SCRAPING. COMMENT ETRE PROTEGES CONTRE LA COLLECTE AUTOMATIQUE DE DONNEES

Mihai MALAIRAU¹,
Denis REDKO¹,
Sandu RAȘ^{1*}

¹Universit e Technique de Moldavie, Facult e Ordinateurs, Informatique et Micro electronique, D epartement G enie Logiciel et Automatique, Groupe FI-191, Chișinău, R epublique de Moldavie

*Auteur correspondant : Sandu Raș, ras.sandu@isa.utm.md

R esum e : La transformation automatique des ressources Web dans un format sp ecifique consiste   extraire des donn ees web ou web scraping. L'extraction des donn ees Web se fait   l'aide des langages de programmation backend, en acc edant au site Web avec un client http et en extrayant les donn ees en adressant les balises, les classes, les identifiants du document qui d ecrit la page. Plusieurs fois, le web scraping est effectu e   des fins d'analyse et de collecte d'informations   partir de plusieurs sources en un seul endroit. Le but principal de cet article  tait de familiariser et d'expliquer ce qu'est le scraping Web, comment il est utilis e, les techniques, quels objectifs et comment les administrateurs de sites Web peuvent  tre prot eg es contre la collecte automatique de donn ees.

Mots-cl es : extraction de donn ees, analyse HTML, structures de donn ees, demande GET, automatisation, headless browser.

Introduction

Avec l'av enement des applications Internet et Web, le besoin de transformer les informations des pages HTML en formats plus pratiques est apparu, ce qui permet une gestion plus flexible. En r eponse   ce besoin, une technologie de grattage Web a vu le jour. Au fil du temps, la communaut e des d eveloppeurs, les d eveloppeurs Web ont cr e de nombreux outils, biblioth eqes, packages qui permettent un grattage Web plus facile en utilisant l'API de ces outils.

Le Web scraping a trouv e son application dans la recherche de certaines informations, dans l'indexation de pages web, l'analyse et le suivi des donn ees, il a  galement trouv e son application dans la lutte contre la concurrence des entreprises, il peut  tre utilis e par les utilisateurs pour capturer des offres plus rentables, analyser plus de magasins Internet, etc.

Web Scraping

L'extraction de donn ees Web est le processus de transformation automatique des ressources Web en un format structur e sp ecifique. Par exemple, si une collection de pages Web HTML d ecrit des d etails sur diff erentes soci etes (noms, emplacements, etc.), l'extraction de donn ees Web signifierait transformer ce format HTML natif en structures de donn ees traitables par ordinateur, telles que des entr ees dans des tables de base de donn ees relationnelle.

Le but de l'extraction de donn ees Web est de rendre les donn ees Web disponibles pour les  tapes de manipulation ou d'int egration ult erieures.

Historique

Alors que le Web prolif erait dans les ann ees 1990, les chercheurs dans le domaine de l'informatique d'horizons divers (bases de donn ees, syst emes, intelligence artificielle, r ecup eration d'informations, etc.) ont r ealis e que la capacit e d'int egrer des donn ees provenant de sources h et erog enes donnerait naissance   une grande vari ete d'applications attrayantes, telles que les assistants d'achat qui comparent les produits sur plusieurs sites de vente au d etail.

De nombreux chercheurs qui ont étudié les formulations traditionnelles du problème d'intégration de données ont tourné leur attention vers l'intégration de données Web. Cette attention a révélé de nombreux nouveaux défis. L'extraction de données est rapidement devenue l'un des principaux défis à relever.

Les chercheurs n'ont tout simplement pas pu prouver leurs algorithmes d'intégration de données Web de manière convaincante avant d'avoir développé des moyens systématiques d'accéder automatiquement à un grand nombre de documents Web, puis d'extraire des données structurées à partir des formats natifs de ces documents. .

La première approche pour extraire des données Web consistait simplement à coder la récupération d'URL et à extraire les données nécessaires dans les langages de programmation conventionnels. En effet, de nombreuses applications d'intégration de données Web continuent d'utiliser cette approche aujourd'hui. Cependant, les programmes d'extraction de données mis en œuvre de cette manière ont tendance à être relativement importants, ce qui rend difficile leur conception, leur débogage, leur réutilisation et leur maintenance.

Sur la base de cette expérience, les chercheurs ont rapidement remarqué que les programmes d'extraction de données Web écrits dans des programmes conventionnels ont de nombreux modèles logiciels courants. Cette observation a conduit à des efforts pour encapsuler ces modèles, soit en tant que bibliothèques réutilisables pour les langues existantes, soit en tant que primitives dans des langues spécialisées pour l'extraction de données Web. Par exemple, de nombreux programmes d'extraction Web ont un comportement d'exploration, comme « analyser un document HTML pour trouver tous ses hyperliens ; puis récupérez toutes les URL nouvellement découvertes et répétez ou "soumettez plusieurs fois un formulaire Web, en reliant à chaque fois l'un des paramètres d'entrée à l'une des valeurs".

Pour faciliter la construction de robots d'exploration Web, ce comportement peut être codé comme un ensemble de fonctions / classes dans une bibliothèque ou comme éléments primitifs dans un langage de récupération de données Web spécialisé.

Utilisation

Le scraping web se fait en exécutant un programme, écrit dans un langage de programmation backend. Bien que cela ne puisse pas être fait par de simples utilisateurs, il existe des ressources, des services et des applications qui offrent aux utilisateurs simples les privilèges de cette technologie.

À l'aide de nodeJS, une plate-forme logicielle basée sur le moteur V8 qui transforme JavaScript d'un langage hautement spécialisé en un langage à usage général, et des packages dans le gestionnaire de packages npm - cheerio - l'implémentation rapide et flexible de la base jQuery conçue spécifiquement pour serveur, axios - client http pour les navigateurs et nodeJS, le web scraping est très facile.

Le programme fait une requête get sur la page utm.md, extrait les dernières nouvelles et les place dans un fichier qui peut ensuite être importé dans un autre programme.

```
const Axios = require("axios").default;
const cheerio = require("cheerio");
const fsPromise = require("fs").promises;
const baseUrl = "https://utm.md/";
const axios = Axios.create({
  baseUrl,
  method: "GET"
});
(async () => {
  let news = [];
  const { data } = await axios.get();
  const $ = cheerio.load(data);
  const h3 = $(".entry-title");
```

```
for (let i = 0; i < h3.length; i++) {  
  news.push(h3[i].children[0].data);  
}  
await fsPromise.writeFile(  
  `./noutati_UTM.json`,  
  JSON.stringify(news, null, 2),  
  "utf8"  
);  
})();
```

Les données collectées sont écrites dans un fichier JSON et peuvent ensuite être manipulées et facilement gérées, et grâce au format JSON, elles peuvent être utilisées par n'importe quel langage de programmation de serveur.

```
[  
  "UTM va beneficia de expertiza a 3 profesori din SUA prin intermediul programului  
  Fullbright Specialist.",  
  "Studenta FCIM, Diana MARUSIC: exemplu de perseverență la „Mold SEF”",  
  "„MOLD SEF” – 2020",  
  "Studiu de politici publice: Securitatea energetică a RM în contextul funcționării pieței  
  concurențiale",  
  "UTM a dat start cursurilor de pregătire pentru BAC",  
  "STAFF SELECTION CONTEST for international credit mobility within ERASMUS +  
  Programme at Slovak University of Agriculture in Nitra",  
  "HOTĂRÂREA ȘEDINȚEI CONSILIULUI DE ADMINISTRAȚIE NR. 12 DIN 10  
  februarie 2020",  
  "HOTĂRÂREA ȘEDINȚEI CONSILIULUI DE ADMINISTRAȚIE NR. 11 DIN 27  
  IANUARIE 2020",  
  "STUDENT SELECTION CONTEST FOR ICM WITHIN ERASMUS+ PROGRAMME  
  AT Slovak University of Agriculture in Nitra, Slovakia",  
  "INVITATION – lectures on nanobiotechnology from researchers at the Royal Institute  
  of Technology and Joint Research Center of the EC"  
]
```

Sécurité

Certains sites Web utilisent des méthodes pour empêcher le grattage Web, tels que la détection et le blocage de l'exploration (visualisation) par des robots sur leurs pages. En réponse à cela, il existe des systèmes de grattage Web qui reposent sur l'utilisation de méthodes d'analyse DOM, de vision par ordinateur et de traitement du langage naturel pour simuler la visualisation humaine afin de fournir la collection de contenu de page Web pour une analyse hors ligne.

Les sites Web peuvent utiliser différents mécanismes pour détecter un grattoir / araignée d'un utilisateur normal. Certaines de ces méthodes sont répertoriées ci-dessous :

1. Trafic inhabituel / taux de téléchargement élevé, en particulier à partir d'un seul client / ou d'une seule adresse IP dans un court laps de temps.
2. Tâches répétitives effectuées sur le site Web - sur la base de l'hypothèse qu'un utilisateur humain n'exécute pas les mêmes tâches répétitives tout le temps.
3. Détection par les pots de miel - ce sont généralement des liens qui ne sont pas visibles pour un utilisateur normal, mais uniquement pour une araignée. Lorsqu'un grattoir / araignée essaie d'accéder au lien, les alarmes sont déclenchées.

Pour éviter le blocage, les scrapers Web doivent effectuer des actions sur le site aussi près que possible du comportement de l'utilisateur. Par conséquent, vous devez périodiquement faire pivoter les adresses IP, changer d'agent utilisateur et définir la vitesse de compression Web sur optimale et entre les appels pour créer des actions aléatoires sur le site qui ne provoqueront pas de suspicion.

Conclusion

Cet article parle de l'extraction de données Web, qui s'est développée avec le développement des technologies de l'information. L'extraction de données Web est utilisée avec de bonnes pensées ainsi qu'avec de mauvaises pensées sans prendre en compte le respect du droit d'auteur. Pour cela, différents langages de programmation sont utilisés qui permettent la transformation des données en des formats plus flexibles et plus faciles à utiliser, le plus souvent c'est du *JSON*. Différentes méthodes qui détectent l'action de raclage sont utilisées pour se protéger contre l'extraction malveillante de données.

Comme Internet s'est développé de façon astronomique et que les entreprises sont devenues de plus en plus dépendantes des données, il est désormais indispensable d'avoir accès aux dernières données sur chaque sujet. Les données sont devenues la base de tous les processus décisionnels, que ce soit une entreprise ou une organisation à but non lucratif. Par conséquent, le web scraping a trouvé ses applications dans tous les efforts des notes de l'époque contemporaine. En outre, il devient de plus en plus clair que ceux qui utiliseront l'outil de grattage Web de manière créative et avancée auront une longueur d'avance sur les autres et gagneront un avantage concurrentiel.

Bien qu'il existe des méthodes qui protégeraient l'extraction automatique des données, elles n'ont qu'un effet de ralentissement, car davantage de code est nécessaire et la vitesse de collecte des données est nécessaire.

Nous remercions: Mme Daniela Istrati, lecteur universitaire au Département Génie Logiciel et Automatique, Université Technique de Moldova, pour l'aide à l'élaboration de cet article

Bibliographie

1. Shaumik Daityari, *Protect Your Site Against Web Scraping*, <https://blog.jscrambler.com/protect-your-site-against-web-scraping/>, accédé le 18/02/2020
2. ScrapeHero, *How to prevent getting blocked while scraping*, <https://www.scrapehero.com/how-to-prevent-getting-blacklisted-while-scraping/>, accésat accédé le 18/02/2020
3. Nicholas Kushmerick, *Languages for Web Data Extraction*, https://link.springer.com/referenceworkentry/10.1007%2F978-0-387-39940-9_1156, accédé le 18/02/2020
4. Jeffrey Neuburger, *QVC Sues Shopping App for Web Scraping That Allegedly Triggered Site Outage*, <https://newmedialaw.proskauer.com/2014/12/05/qvc-sues-shopping-app-for-web-scraping-that-allegedly-triggered-site-outage>, accédé le 18/02/2020
5. Adler, Kenneth A. ,*Controversy Surrounds 'Screen Scrapers': Software Helps Users Access Web Sites But Activity by Competitors Comes Under Scrutiny*, <https://corporate.findlaw.com/law-library/controversy-surrounds-screen-scrapers-software-helps-users.html>, accédé le 18/02/2020