

Markus Hövener, Head of SEO

SCREAMING FROG SEO SPIDER: ADVANCED

API-ANBINDUNG

GA und GSC

- > Es gibt einige Systeme, die über API erreichbar sind:
 - > Google Search Console
 - > Google Analytics
 - > Link-Datenbanken: Ahrefs, Majestic, Moz
(jeweils kostenpflichtig, außer Moz)

Status

The screenshot shows the SEO Spider interface with the following status information:

- Google Analytics:** Progress: 0%, Errors: 0, Disconnected
- Google Search Console:** Progress: 100%, Errors: 0, Connected
- Majestic:** Progress: 100%, Errors: 0, Connected
- Ahrefs:** Progress: 0%, Errors: 0, Disconnected
- Mozscape:** Progress: 0%, Errors: 0, Disconnected

A large blue banner at the top center reads "100% müssen es sein!"

LINK-DATENBANKEN

Link-Datenbanken

> Zuerst Verbindung herstellen

The screenshot shows the MAJESTIC account interface. At the top, there's a navigation bar with links for Tools, Support, and Plans & Pricing. Below that, the MAJESTIC logo is displayed with a starburst graphic. The main section is titled "Account". A navigation bar at the bottom includes links for Home, Verified Domains, Bucket, Downloads, Reports, and API. The "API" link is highlighted with a dropdown menu open, showing "7LD G" as the access token. The main content area is titled "Application Authorised" and contains the message: "You have granted 'Screaming Frog SEO Spider' access to your subscription resources." It also instructs the user to enter the token "7LD G" when prompted for an access token.


Application Authorised

You have granted '**Screaming Frog SEO Spider**' access to your subscription resources.

Simply enter **7LD G** when you are asked for your 'access token'.

This token will only work with '**Screaming Frog SEO Spider**' and remember you can revoke access at anytime from the [OpenApps](#) page.

Metriken auswählen



Tab „Link Metrics“

	Address	Status Code	Title 1	Majestic Referring Domains - URL (http + https URL)
1	http://www.mba-fernstudium.de/	200	Fernstudium: MBA-Studium berufsbegleitend in Deutschland	24
2	http://www.mba-fernstudium.de/spezialisierung/mba-bildungsmanagement.html	200	MBA-Fernstudium: Bildungsmanagement	2
3	http://www.mba-fernstudium.de/spezialisierung/index.html	200	MBA Fernstudium - Master of Business Administration	2
4	http://www.mba-fernstudium.de/datenschutz/	200	Datenschutzerklärung	2
5	http://www.mba-fernstudium.de/spezialisierung/mba-gesundheitsmanagement-sozialmana...	200	MBA Fernstudium: Gesundheitsmanagement, Sozialmanagement	1
6	http://www.mba-fernstudium.de/links/	200	MBA Fernstudium - Links - Index	1
7	http://www.mba-fernstudium.de/faq/mba-ohne-bachelor.html	200	MBA ohne Bachelor	1
8	http://www.mba-fernstudium.de/spezialisierung/mba-tourismusmanagement.html	200	MBA Fernstudium: Tourismusmanagement	1
9	http://www.mba-fernstudium.de/faq/mba-berufsbegleitend.html	200	MBA berufsbegleitend	1
10	http://www.mba-fernstudium.de/ueber-uns/	200	Über MBA Fernstudium	1
11	http://www.mba-fernstudium.de/spezialisierung/mba-marketing.html	200	MBA Fernstudium: Marketing	1
12	http://www.mba-fernstudium.de/spezialisierung/mba-produktionsmanagement.html	200	MBA Fernstudium: Produktionsmanagement	1
13	http://www.mba-fernstudium.de/spezialisierung/mba-controlling.html	200	MBA-Fernstudium: Controlling	1
14	http://www.mba-fernstudium.de/spezialisierung/mba-logistikmanagement.html	200	MBA Fernstudium: Logistikmanagement	1
15	http://www.mba-fernstudium.de/faq/mba-gehalt.html	200	MBA-Gehalt	1
16	http://www.mba-fernstudium.de/kontakt.html	200	Fernstudium & MBA - So kontaktieren Sie uns!	2
17	http://www.mba-fernstudium.de/spezialisierung/mba-health-care-management.html	200	MBA Fernstudium: Health Care Management	1
18	http://www.mba-fernstudium.de/spezialisierung/mba-finanzmanagement.html	200	MBA Fernstudium: Finanzmanagement	1
19	http://www.mba-fernstudium.de/spezialisierung/mba-human-resource.html	200	MBA Fernstudium: Human Resource Management/Personalmanagement	1
20	http://www.mba-fernstudium.de/spezialisierung/mba-insurance-management.html	200	MBA Fernstudium Insurance Management	1
21	http://www.mba-fernstudium.de/faq/mba-stipendium.html	200	MBA-Stipendium	1
22	http://www.mba-fernstudium.de/spezialisierung/mba-sportmanagement.html	200	MBA Fernstudium: Sportmanagement	1
23	http://www.mba-fernstudium.de/faq/index.html	200	MBA-Fernstudium: Informationen	1
24	http://www.mba-fernstudium.de/spezialisierung/mba-general-management.html	200	MBA Fernstudium: General Management	1
25	http://www.mba-fernstudium.de/links/jobboersen.html	200	MBA-Fernstudium - Links - Jobbörsen	2
26	http://www.mba-fernstudium.de/faq/mba-verbundstudium.html	200	MBA-Verbundstudium	2
27	http://www.mba-fernstudium.de/links/institutionen.html	200	MBA Fernstudium - Links - Institutionen und Einrichtungen	2
28	http://www.mba-fernstudium.de/faq/mba-fernstudium-kosten.html	200	MBA-Fernstudium Kosten	2
29	http://www.mba-fernstudium.de/links/index.html	200	MBA Fernstudium - Links - Index	2
30	http://www.mba-fernstudium.de/faq/mba-berufserfahrung.html	200	MBA ohne Berufserfahrung	2
31	http://www.mba-fernstudium.de/faq/mba-ohne-studium.html	200	MBA ohne Studium	2
32	http://www.mba-fernstudium.de/links/fernschulen.html	200	MBA Fernstudium - Links - Fernschulen	2
33	http://www.mba-fernstudium.de/faq/mba-executive.html	200	Executive MBA-Fernstudium	2
34	http://www.mba-fernstudium.de/links/portale.html	200	MBA Fernstudium - Links - Portale	2
35	http://www.mba-fernstudium.de/links/ratgeber.html	200	MBA Fernstudium - Links - Ratgeber	2
36	http://www.mba-fernstudium.de/links/plattformen.html	200	MBA Fernstudium - Links - Plattformen	2
37	http://www.mba-fernstudium.de/links/foren.html	200	MBA Fernstudium - Links - Foren	2
38	http://www.mba-fernstudium.de/faq/mba-fernstudium-ranking.html	200	MBA-Fernstudium Ranking	2

Direkter Sprung in die Link-Datenbank

Wofür braucht man das?

- > Content Audit:
 - > Welche Seiten einer Website sind gut verlinkt?
- > Massen-Checks:
 - > Wie gut sind 10.000 konkrete Seiten/Websites verlinkt?

GOOGLE SEARCH CONSOLE UND GOOGLE ANALYTICS

Daten, Daten, Daten

- > GA und GSC: Quelle realer Nutzerdaten
- > Auch (und vor allem): Erfolgsmetriken (Conversions ...)
- > Beide Quellen können im Frog angezapft werden:
Configuration > API Access
- > Konfiguration recht einfach

Ergebnisse ...

> ... in den Tabs „Analytics“ bzw. „Search Console“

Status	Clicks	Impressions	CTR	Position
	172	4590	0,0375	16,15
	0	6	0,0000	38,67
9	661	0,0136	44,44	
0	57	0,0000	16,68	
0	5	0,0000	45,00	
	0	268	0,0000	54,40
	0	3	0,0000	39,67
	11	1104	0,0100	31,07
5	95	0,0526	17,93	
3	106	0,0283	49,25	
0	101	0,0000	62,15	
0	56	0,0000	41,93	
0	97	0,0000	12,52	
1	167	0,0060	19,75	
0	33	0,0000	17,18	
4	572	0,0070	44,76	
1	18	0,0556	36,22	
0	71	0,0000	87,65	

Diagnose: Analytics

Filter	Was tun?
Sessions Above 0	Seite hatte mind. eine Session (Positivfall)
Bounce Rate Above 70%	Hohe Bounce Rate (muss nicht schlimm sein)
No GA Data	Keine Daten für diese URL erfasst (also: niemand hat diese Seite im Zeitraum besucht)
Non-indexable with GA Data	Seite hat Sessions, ist aber eigentlich nicht indexierbar (kann auf Probleme hinweisen)
Orphan URLs	Siehe Orphans

Diagnose: Google Search Console

Filter	Was tun?	Es gibt URLs mit 0 Klicks und >0 Impressionen: Beide Filter zeigen die nicht an
Clicks Above 0	Seite hatte mind. einen Klick (Positivfall)	
No GSC Data	Keine Daten für diese URL erfasst (also: keine Klicks, keine Impressionen)	
Non-indexable with GSC Data	Seite hat Klicks, ist aber eigentlich nicht indexierbar (kann auf Probleme hinweisen)	
Orphan URLs	Siehe Orphans	

Wofür braucht man das?

- > Typische Fragestellungen:
 - > Habe ich Seiten mit vielen Klicks und hoher Klicktiefe?
(Dann: interne Verlinkung verbessern)
 - > Welche meiner Seiten haben keine/wenig Besucher?
(Prüfen: Kann ich die Seiten optimieren? Oder sperren?)

SEARCH

Search

- > Hilfreiches Feature:
Configuration > Custom > Search
- > Man kann nach bestimmten Sachen im HTML-Code suchen:
 - > Positiv (kommt vor)
 - > Negativ (kommt nicht vor)

Beispiel

Custom Search

Search the source code of internal HTML pages. The results can be seen in the **Custom** Tab. See our [User Guide](#) for examples.

Filter 1 Contains mailto:

Filter 2 Does Not Contain canonical

Filter 3 Contains

Filter 4 Contains

Filter 5 Contains

Filter 6 Contains

Filter 7 Contains

Filter 8 Contains

Filter 9 Contains

Filter 10 Contains

Wichtig

- > Filter müssen **vor einem Crawl** definiert werden
- > Es können max. **10 Filter** definiert werden
- > Theoretisch kann man auch mithilfe von regulären Ausdrücken suchen:
 - > <https://docs.oracle.com/javase/8/docs/api/java/util/regex/Pattern.html>
- > Wer das nicht macht: Groß-/Kleinschreibung wird ignoriert („MAILTO“ und „mailto“ liefern dieselben Ergebnisse)

Ergebnis

	Address	Occurrences	Content	Status Code	
1	http://www.spiegel.de/netzwelt/netzpolitik/cyber-security-cluster-bonn-bsi-bundeswehr-und-telekom-gruenden-verein-a-1237842.html	1	text/html; charset=UTF-8	200	OK
2	http://www.spiegel.de/plus/was-sind-das-fuer-menschen-die-gender-studies-studieren-a-00000000-0002-0001-0000-000159826640	2	text/html; charset=utf-8	200	OK
3	http://www.spiegel.de/wirtschaft/service/versicherung-check-fuer-haftpflicht-hausrat-berufsunfaehigkeit-a-960380.html	1	text/html; charset=UTF-8	200	OK
4	http://www.spiegel.de/reise/europa/kirchen-in-europa-das-sind-die-schoensten-a-1227628.html	1	text/html; charset=UTF-8	200	OK
5	http://www.spiegel.de/intervalfasten-wie-die-diaet-funktioniert-a-00000000-0002-0001-0000-000160707735	2	text/html; charset=utf-8	200	OK
6	http://www.spiegel.de/einestages/anti-suffragetten-in-england-frauenwahlrechts-gegner-a-1086519.html	1	text/html; charset=UTF-8	200	OK

Wofür braucht man das?

- > Beispiele:
 - > Fehlt ein bestimmter Code in einigen Seiten? („UA-123456“)
 - > Fehlt ein bestimmtes Tag in einigen Seiten?
 - > ...

Aber...

- > „Search“ liefert nur, wie oft etwas in Seiten vorkommt
- > Keine Möglichkeit, sich dann z. B. auch die Tags anzeigen zu lassen
- > Dann braucht man...

EXTRACTION

Extraction


- > Extrem hilfreiches Feature:
Configuration > Custom > Extraction
- > Man sucht nach bestimmten Stellen und extrahiert Daten
- > 10 Extraction-Filter möglich (losgelöst von den Such-Filtern)

Techie-Mode an!

- > Es gibt drei Möglichkeiten, zu definieren, was man wo extrahieren möchte:
 - > Reguläre Ausdrücke
 - > CSSPath
 - > XPath

Ein Beispiel: Reguläre Ausdrücke

> Produktdetailseiten bei obi.de



Artikelbeschreibung ▾ Lieferinformationen ▾ Bewertungen (0) ▾

Artikelbeschreibung

Art.Nr. 1224278



(0)

Produkt bewerten

Im HTML-Code

- > <p class="article-number text-bold" tm-data="ads.description-text.article-number.p">Art.Nr. 1224278</p>
- > Um etwas zu extrahieren, brauche ich etwas
 - > davor: >Art.Nr.
 - > dahinter: </p>
- > Alles zwischen diesen beiden Markern soll extrahiert werden!

Regulären Ausdruck erzeugen

- > Regulärer Ausdruck:
>Art.Nr. (.+?)</p>

Extract selected elements of internal HTML pages. See our [User Guide](#) for examples. The results can be seen in the **Custom Tab** in the **Extraction filter**.



Regulärer Ausdruck unter der Lupe

- > Am Anfang soll „>Art.Nr.“ stehen
- > Am Ende soll „</p>“ stehen
- > Alles dazwischen soll extrahiert werden

```
>Art.Nr. (.+?)</p>
```

Und dann?

Filter: Extraction		Export			
	Address	Status Code	Status	Artikelnummer 1	
1	https://www.obi.de/schneeschieber/offner-aluminium-schaufel-mit-holzstiel/p/1224278	200	OK	1224278	

Alternative: XPath

- > Nicht gerade intuitiv
- > Möglichkeit, nach bestimmten Tags/Attributen zu suchen

Im HTML-Code

- > <strong itemprop="price" tm-data="ads.price.strong">19,99
- > Der XPath-Ausdruck dafür:
//strong[@itemprop='price']

Anlegen

The screenshot shows the 'Anlegen' (Create) screen in the Screaming Frog SEO Spider tool. On the left, there is a list of extractors:

- Preis (Extractor 1): XPath //strong[@itemprop='price']
- Extractor 3: Inactive
- Extractor 4: Inactive
- Extractor 5: Inactive

To the right of the extractors is a dropdown menu titled 'Extract Text' with the following options:

- Extract Inner HTML
- Extract HTML Element
- Extract Text
- Function Value

A green checkmark icon is positioned next to the 'Extract Text' option, indicating it is selected.

Das Ergebnis

Filter: Extraction		Export				
	Address	Status Code	Status	Artikelnummer 1	Preis 1	
1	https://www.obi.de/schneeschieber/offner-aluminium-schaufel-mit-holzstiel/p/1224278	200	OK	1224278	19,99	

XPath für Nicht-XPath-Kundige

Cheat Sheet:
XPath für Nicht-XPath-Kundige

Ich möchte...	So mache ich das mit XPath
Ich möchte den Inhalt eines Attributs (z. B. die Meta Description)	Schreibeweise: <code>//tag[@name="wert1"]/@name</code>
HTML-Code: <code><tag attribut1="wert1" attribut2="wert2"></code>	Beispiel: <code><meta name="description" content="Das will ich!"></code>
Ich möchte den Inhalt eines von <tag> und </tag> umschlossenen Tags	Schreibeweise: <code>//tag</code>
HTML-Code: <code><tag>Inhalt</tag></code>	Beispiel: <code><h1>Das will ich!</h1></code>
Ich möchte den Inhalt eines von <tag> und </tag> umschlossenen Tags, das durch ein bestimmtes Attribut gekennzeichnet ist	Schreibeweise: <code>//tag[@attribut="wert"]</code>
HTML-Code: <code><tag attribut="wert">Inhalt</tag></code>	Beispiel: <code><h1 hell="hell">Das will ich!</h1></code>

Wenn es mehrere passende Objekte gibt, kann man über [index] auf das jeweilige Objekt zugreifen

Schreibeweise:
XPath-Ausdruck[index]

Beispiel:

```
<ul>
  <li>Link 1</li>
  <li>Link 2</li>
</ul>
```

XPath:

```
//ul/li[1] liefert „Link1“
//ul/li[2] liefert „Link2“
```


Ich möchte ein bestimmtes Element, das von anderen Elementen umschlossen ist

Schreibeweise:
`/element1/element2/element3/...`

Beispiel:

```
/html/head/meta[@name="description"]/@content
```

Liefert den Wert des content-Attributs eines Meta-Tags, bei dem das Attribut `name` „description“ entspricht. Das Meta-Tag wird vom <head>-Tag und dieses wiederum vom <html>-Tag umschlossen.



Wofür braucht man das?

- > Typische Fälle:
 - > Wettbewerbs-Beobachtung ☺ (Vorsicht!)
 - > Relaunch: Alte auf neue Produktseiten umleiten
 - > Endkontrolle: Gibt es überall einen Text?
 - > Bestandsaufnahme: Welche Texte gibt es wo?
 - > ...

XML-SITEMAPS


XML-Sitemaps

- > Wichtig für einige Diagnose-Schritte beim Frog
- > ... und auch für die neue Google Search Console
- > Also: unbedingt nutzen!

Anforderungen

- > Alle URLs in XML-Sitemaps:
 - > HTTP-Code 200
 - > URL = Canonical-Tag
 - > Nicht per robots.txt gesperrt
 - > Nicht per Robots-Meta-Tag „noindex“ gesperrt
- > Gesamtanforderungen:
 - > Dateigröße max. 50 MB
 - > Maximal 50.000 URLs pro Sitemap

Warum wichtig?



Also ...

- > Ideal: Crawl laufen lassen und mit XML-Sitemaps abgleichen
- > Sicherstellen:
 - > Die XML-Sitemaps müssen den Regeln genügen
- > Dann prüfen:
 - > Gibt es relevante URLs, die in der XML-Sitemap fehlen? (nicht so schlimm)
 - > Gibt es URLs, die in der XML-Sitemap vorkommen, aber beim Crawl fehlen? (deutlich schlimmer!)

Einstellungen

- > Configuration > Spider > Basic
- > Option „Crawl Linked XML Sitemaps“ auswählen
- > Unter „Crawl these Sitemaps“ URLs aller Sitemaps angeben
- > Crawl durchlaufen lassen, „Crawl Analysis“ nicht vergessen
- > Alle Informationen im Tab „Sitemaps“

Dann: Prüfen

Filter	Was tun?
URLs in Sitemap	Positivfall (keine Implikation)
URLs not in Sitemap	Prüfen: sind das wichtige Seiten? Falls ja: in XML-Sitemap aufnehmen
Orphan URLs	Später mehr dazu
Non-indexable URLs in Sitemap	Sollte es keine geben (404, robots.txt ...)
URLs in multiple Sitemaps	Unschön (sollte vermieden werden)
XML Sitemap with over 50k URLs	Technische Vorgabe verletzt
XML Sitemap over 50MB	Technische Vorgabe verletzt

ORPHANS

Was sind Orphans?

- > Unbekannte Seiten:
 - > Nicht im Crawl aufzufinden (also intern nicht verlinkt)
 - > Nicht in XML-Sitemaps vorhanden
 - > Sind aber im Index, haben evtl. Traffic
- > Passiert das oft?
 - > Eher nein
 - > Oft Seiten, die bei einem Relaunch vergessen wurden

Wie kann der Crawler die entdecken?

- > Verbindung mit Google Analytics oder Search Console nötig:
 - > Gibt es Seiten mit organischem Traffic?
- > Also:
 - > Verbindung herstellen (GA oder GSC)
 - > Option „Crawl New URLs Discovered in ...“ auswählen
 - > Crawl durchlaufen lassen, „Crawl Analysis“ nicht vergessen
- > Und dann:
 - > Reports > Orphan Pages

URL REWRITING

Warum?

> Klassischer Fall:

<https://www.schnullireich.de/babykleidung-mit-namen/16/halstuch-mit-namen-rosa-biene/libelle>

<https://www.schnullireich.de/babykleidung-mit-namen/16/halstuch-mit-namen-rosa-biene/libelle?c=10>

<https://www.schnullireich.de/babykleidung-mit-namen/16/halstuch-mit-namen-rosa-biene/libelle?c=8>


- > Produktdetailseiten kanonisieren auf die URL ohne „c“
- > Crawler muss alle Dubbletten laden, kein Mehrwert

Also...

- > Irrelevante URL-Parameter können aus URLs entfernt werden
- > Zur Erinnerung: URL-Parameter:
 - > ...?parameter1=wert¶meter2=wert2
- > Vorteil:
 - > Schnellerer Crawl
 - > Gleiches Verhalten wie Google (siehe nächste Folie)


Google Search Console

- > Korrespondiert mit Report „URL-Parameter“
- > Auch hier können Parameter als irrelevant markiert werden




Eintragen


> Configuration > URL Rewriting



Testen



Komplexeres ist möglich...



Wichtig!

> Das Ersetzen/Umschreiben passiert nur im Frog!

DAS WAR'S MIT TEIL 3