

検索の仕組み



検索の仕組み

- 検索方法の種類

- 逐次検索 (Sequential Search)
 - 索引検索 (Index Search)



3

逐次検索

- 文書（レコード）を先頭から順に見て、検索語との一致を探す
 - 例
 - 本を最初のページから調べる
 - ブラウザのページ内の検索
 - Word, PDF の文章内の検索
 - 簡単だがデータの量が多いと時間がかかる



4

第一册·新上常青树乐谱汇编

私が新入会員を説いていた理由

13

逐次検索の例



検索の仕組み

索引検索

- あらかじめキーワードの索引を作つておく
- 例
 - 本の巻末の索引を調べる
 - OPAC
 - Googleなどの検索エンジン
- データ量が多くても検索時間は変わらない



7

本の索引

Tron 56
tsr-van 94
U
Ulrich's Periodicals Directory 126
Uniferm Card 5
UNIX 56
URL (Uniform Resource Locator) 65
USB (Universal Serial Bus) 63
W
WAN (Wide Area Network) 64
Web 66
検索エンジン 70
サービス 71
情報発信 73
Web 2.0 76
Web of Science 97
Web 検索技術 72
Webcat 108
Webcat Plus 24, 108
Web サイト 131
Wiki 75
Wikisource 75, 133

ア
アクセス権限 145, 160
アクセス制御 142, 143, 145
アグリゲータ 53, 111, 112
圧縮方式 59
イ
医学情報 122
医学中央蔵誌 3, 100, 123
医学用語シーラス 14
意匠制度 202
一次情報 49
データベース 82, 83
一次資料 8
医中誌 Web 100
インターネット 64
歴史 64
イングリュー 41
インバット・ファクター 36
インターネット、ビブリオストリックスを参照
引用
Web 情報の 133
著作物の 208



p. 001

吾輩は猫である。
名前はまだ無い。
どこで生れたか
とんと見当が
つかぬ。

p. 005

吾輩は人間と同居
して彼等を観察
すればするほど、
彼等は我儘な
ものだと断言
せざるを得ない
ようになった。



観察 005, 120, ...
同居 005, 120, ...
台所 004
断言 005
人間 003, 005, ...
吾輩 001, 002, 005, ...
我儘 005, 032, ...
猶予 002, 081, ...

索引検索の例



Google 日本

Google 検索 | I'm Feeling Lucky

連携関連: 日本の猫スピット 473 ページをストリートビューで探しよ。

iGoogle 広告掲載 ビジネス メール Googleについて Google.com in English

10

索引検索の例



検索対象
○大妻女子大学
□他大学蔵書 (NDL)

資料区分
□図書
○一和図書
□洋図書
□記録
□和文書
□洋文書
□AV資料
□オンラインDB

検索条件
夏目漱石
AND
著者名に「夏」の語を含む
出版社・出版者

検索オプション
出典年:
言語:
媒体種別:
配架場所:
並び順:
一覧表示件数: 20


索引ファイル

- 索引語 (キーワード) の抽出
 - 対象レコード (文書、ページ) から検索の手がかり (語、句) を取り出す
 - レコード (ページ) 番号をつける
 - 索引語を 50 音順、ABC 順に並べる
- 検索
 - 語句が一致するものを探す
 - 該当レコード (ページ) を取り出す



12

検索の仕組み



索引語の抽出



- 昔は人手で抽出
- 今はコンピュータが自動抽出
 - 英語は単語がスペースで区切られているので簡単
 - 日本語は単語の区切りがない
 - 形態素解析法
 - バイグラム法

索引語の抽出 (英語)



- 単語がスペースで区切られている

資料番号: 201833
標題: Information Retrieval in Chemistry and Chemical Patent Law

「Information」 「Retrieval」 「in」 「Chemistry」 「and」
「Chemical」 「Patent」 「Law」

15

索引語の抽出 (日本語)



- 形態素解析法
 - 文法解析と辞書を使って単語を区切る

資料番号: 98170
標題: インターネット時代の化学文献とデータベースの活用法

- まず助詞などで語句を切り出す
 - 「インターネット時代」「化学文献」「データベース」「活用法」
- カタカナの部分は単語として切り出す
 - 「インターネット」「時代」
- 次に語句から辞書を使って単語を取り出す
 - 「化学文献」→「化学」「文献」

16

索引語の抽出 (日本語)



- バイグラム (bigram) 法
 - 1 文字ずつずらしながら、2 文字のペアを機械的に索引

資料番号: 98170
標題: インターネット時代の化学文献とデータベースの活用法

「イン」 「ンタ」 「ター」 「一ネ」 「ネッ」 「ット」
「ト時」 「時代」 「代化」 「化学」 「学文」 「文献」
「献と」 「とデ」 「デー」 「ータ」 「タベ」 「ベー」
「ース」 「スの」 「の活」 「活用」 「用法」

17

形態素解析とバイグラム



- 形態素解析
 - 検索結果にノイズが少ない
 - 切り出しのための辞書の整備が必要
 - 検索エンジンなどで用いられる
 - Google, Yahoo!

18

検索の仕組み

形態素解析とバイグラム

- バイグラム
 - システムが簡単・安価
 - 辞書がいらない
 - 断片的な単語で検索できる
 - ノイズがある
 - 「京都」を検索しようとすると「東京都」もヒットする
 - 「タイ」を検索しようとすると「スタイル」もヒットする
 - 社内文書など小規模なシステムでよく用いられる
 - OPAC, NDL-OPAC、新聞記事データベース

19



http://kge.de


プール演算

- 論理演算、集合演算ともいう
- 集合間の
 - 積 AND
 - 和 OR
 - 差 NOT
 - を求める
- 情報検索で用いる

21



AND 検索



22



Google の検索オプション




Google の AND



検索の仕組み

OR 検索



25

Google の OR

Google

検索オプション

検索するキーワード

すべてのキーワードを含む:

語順も含め完全一致:

いずれかのキーワードを含む:

語順

含まれないキーワード:

語順の範囲:

+Yoda 森林 風景 納屋 地図 ニュース ショッピング Gmail もっと見る +


Google 滞辺 OR 滞邊 OR 滞邊

検索



26

NOT 検索



27

Google の NOT

Google

検索オプション

検索するキーワード

すべてのキーワードを含む:

語順も含め完全一致:

いずれかのキーワードを含む:

語順

含まれないキーワード:

語順の範囲:

+Yoda 森林 風景 納屋 地図 ニュース ショッピング Gmail もっと見る +

Google 滞辺 -滯邊 -滯邊



検索の仕組み (AND)

資料番号: 98170
標題: インターネット時代の化学文献とデータベースの活用法

索引語	件数	レコードリスト
インターネット	253	... 50405, 52183, 60031, 64521, ...
インターネット	3862	... 50937, 64742, 68451, 69227, 69228, 85258, 89866, 92454, 94765, 98170, 103220, ...
インターネット	28	... 67940, 54697, 54336, ...
データ	3301	... 84161, 84594, 85258, 85850, 90102, 93397, 95151, 89150, 98168, 98170, 98175, 98572, 101090, ...
データベース	485	... 53219, 54083, 77305, 83210, 98170, 100351, 123087, ...
データマイニング	71	... 83943, 88541, 88630, 100455, ...

29

近接演算

- 語と語のあいだの距離を調べて検索する
 - 距離が近いほど適合性が高い
- 通常、2つの語が続いていることを指定
 - Google では「完全一致」と呼ぶ



検索の仕組み

Google の近接演算 (フレーズ)

Google 検索 開発 記者 他国 ニュース ショッピング Gmail もっと見る

ログイン

検索オプション

検索するキーワード
すべてのキーワードを含む:

該当も含め完全一致: ソメイヨンの起源

いずれかのキーワードを含む:
含めないキーワード:
該当の範囲: Google "ソメイヨンの起源"

検索

約 53,200 件 (0.18 秒)



検索の仕組み (近接)


• 単語間の距離をはかって、適合性を見る

資料番号: 98170
標題: インターネット時代の化学文献とデータベースの活用法

1 2 3 4 5 6

索引語	件数	レコードリスト
インターナル	253	... 50405-7, 52183-12, 60031-3, 64521-5, ...
インターネット	3862	... 50937-1, 64742-8, 68451-8, 69227-17, 69228-6, 85259-2, 89966-10, 92454-7, 94755-8, 98170-1, 103220 ...
インターネ	28	... 67940-2, 54697-10, 54336-18, ...
データ	3301	... 84161-9, 84594-1, 85258-7, 85850-6, 90102-13, 93397-15, 95151-18, 89150-4, 98168-4, 98170-5, 98175-8, 98572-13, 101090-2, ...
データベース	485	... 53219-8, 54083-7, 77305-11, 83210-5, 98170-5, 100351-8, 123087-9, ...
データマイニング	71	... 83943-17, 88541-3, 88630-2, 100455-9, ...

32



検索フィールド

• 検索する項目のこと

- タイトル
- 著者名
- 件名(統制語)
- フリーワード(タイトル、著者名などすべて)



検索フィールド

詳細検索 ?

キーワード	<input type="text"/>	
And	タイトル	<input type="text"/>
And	著者	<input type="text"/>
And	出版者	<input type="text"/>
And	件名	<input type="text"/>
And	ISBN	<input type="text"/>
And	分類	<input type="text"/>
And	選択してください	<input type="text"/>

著者名・件名典則検索 各種番号・コード NDLC NDC

広範囲検索(ノイズ多め)(日中韓) フレーズ検索(欧文) ?

34

