

# 20章「全文検索の高速化」

(Namazu)

中島康彦

## §20. 1 検索の手法

「手作業で作成したキーワード」による検索

- ▶ キーワード作成が繁雑, 類擬語が膨大／不統一
- ▶ 利用時には高速, キーワードの体系が不明

「文書そのもの」に対する全文検索

- ▶ システムを作るのは簡単
- ▶ 利用時には低速, キーワード作成者による擾乱がない

「自動生成したインデックス」による検索

- ▶ 一度, インデックス生成の仕組みを作れば, あとは簡単
- ▶ 利用時には高速, インデックスと類擬語のバランスが必要

## §20. 2 インデックス検索までの流れ

インデックスを作成する。

- ▶ 文書の内容から種類を推測する。  
File-MMagic

- ▶ 種類に応じて文書をテキストファイルに変換する。  
word,excel,pdfなど ⇒ text形式

- ▶ 文書を「わかち書き」にする。(形態素解析)  

```
% echo "本日は晴天なり" | kakasi -w  
本日 は 晴天 なり
```

```
% cd ~/Html/ml00-x.archive  
% mknmz -k [0-9]*  
% ls
```

検索する。

```
% namazu 検索式 .
```

---

## §20. 3 WEBとの連携

.namazurcの作成

```
% vi .namazurc  
Index .  
Template .  
Replace /usr0/majordomo/lists/ml00-x.archive/  
        http://i.econ.kyoto-u.ac.jp/~xxxx/ml00-x.archive/  
Logging on  
Lang ja
```

namazu.cgiの作成

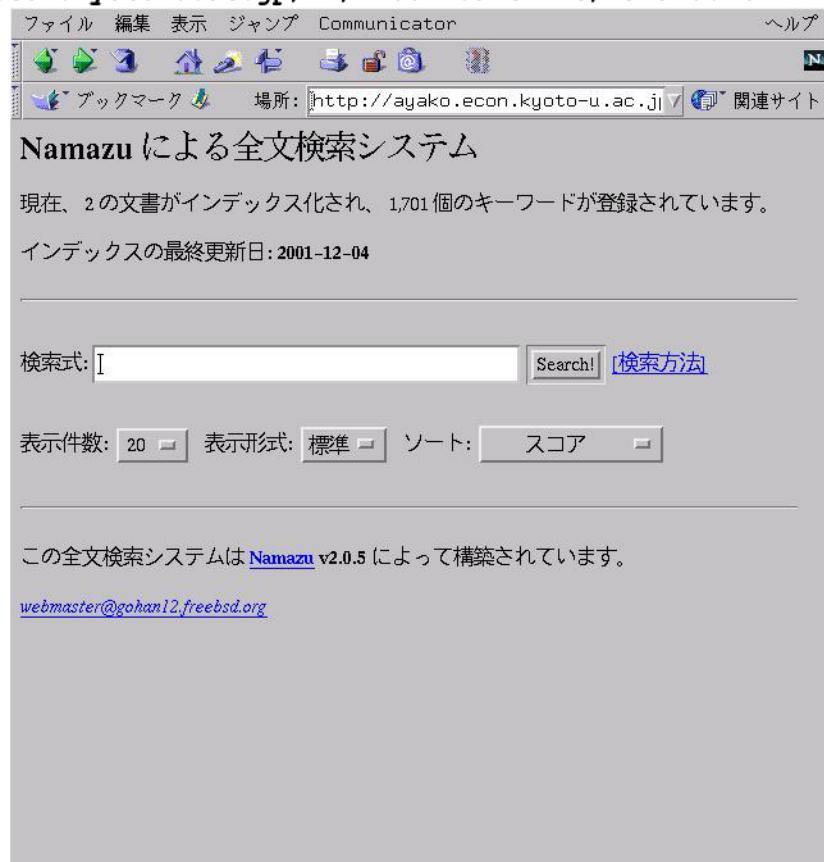
```
% cp /usr/local/libexec/namazu.cgi .
```

namazu.htmlの作成

```
% cat NMZ.head.ja NMZ.foot.ja  
| sed -e "s/{cgi}/namazu.cgi/" > namazu.html
```

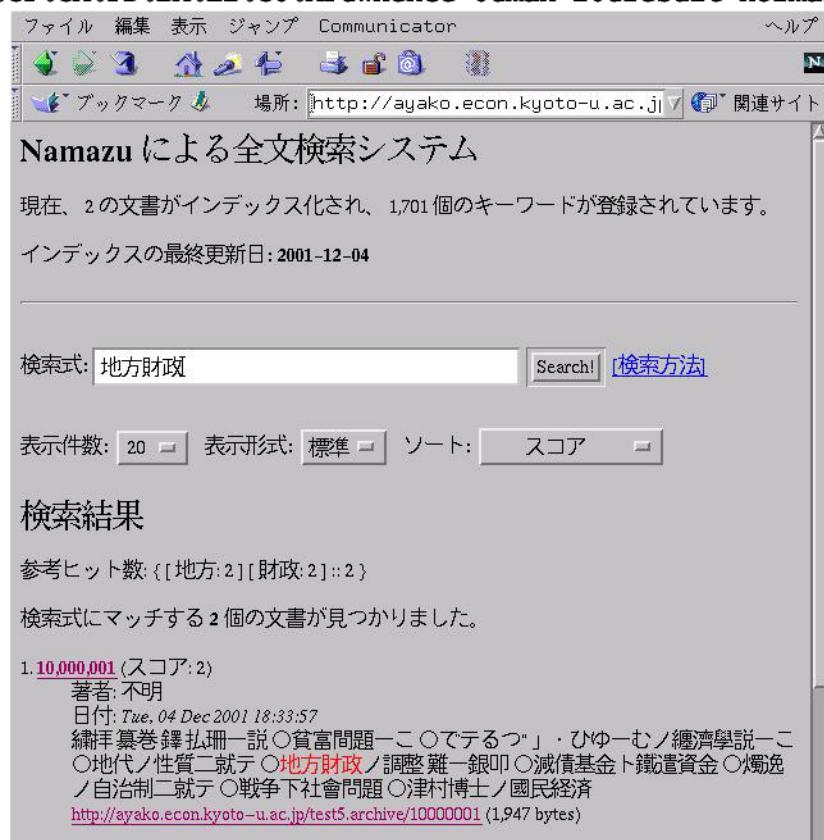
## §20. 4 各自のホームページを表示してみる

<http://i.econ.kyoto-u.ac.jp/~x/ml00-x.archive/namazu.html>



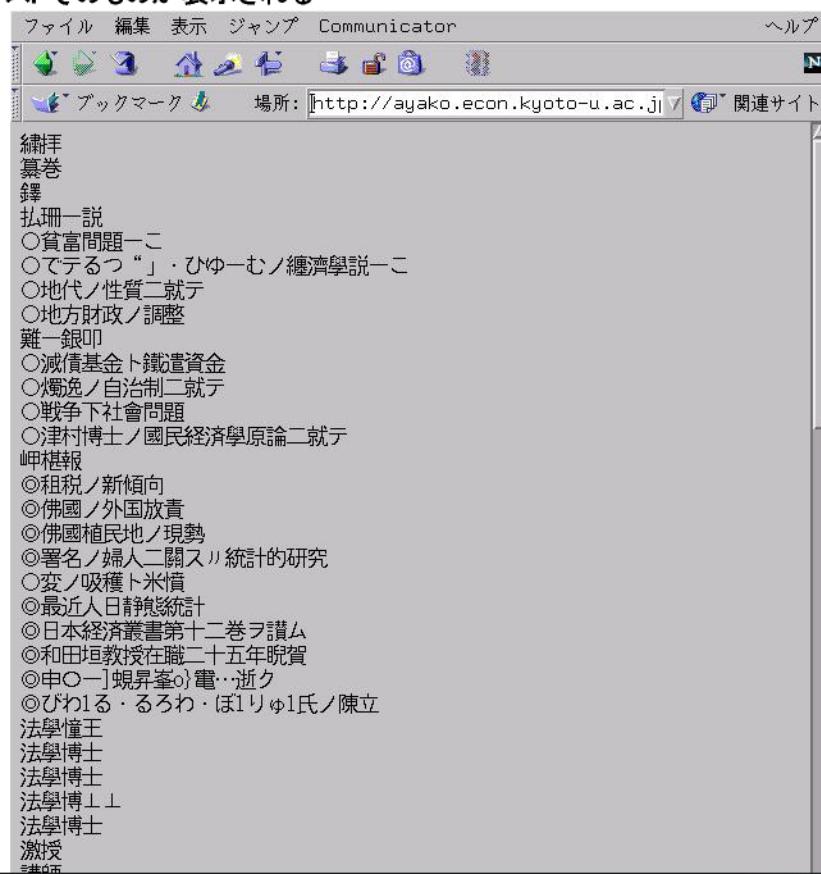
## §20. 5 前回の経済論叢データベースのOCR結果を使用した例

<http://i.econ.kyoto-u.ac.jp/test4.archive/namazu.cgi?query=%C3%CF%CA%FD%BA%E2%C0%AF&whence=0&max=20&result=normal&sort=score>



## §20. 6 検索結果の表示

OCR変換テキストそのものが表示される



## §20. 7 速度の比較

Pentium-III 700MHz / RAID5 40MB/s

6898個のテキストファイル(合計3M行, 168Mバイト)から、「景気循環」を検索した場合

逐次全文検索

▶ 検索 ... 12分

Namazuによるインデックス検索

▶ インデックス作成 ... 220分  
▶ 検索 ... 1秒未満

## §20. 8 OCR結果との正しい連携

インデックス生成対象 … 認識誤りを含むテキスト

表示対象 … TIFF画像ファイル

この先は宿題。成果をレポートに替えててもよい。

---

## §20. 9 最近できること

画像から透明テキスト付きPDFを生成

- ▶ そのままNamazuに入力可
- ▶ ただし、それだけではタイトル・著者名がわからない
- ▶ `pdftotext -enc EUC-JP "xxx.pdf"` により、`xxx.txt`を生成し、インデックスファイルと組み合わせる。

## §20. 10 経済論叢データベース(現在)

<http://www.econ.kyoto-u.ac.jp/ronsov/>

The screenshot shows a Mozilla Firefox browser window with the URL <http://www.econ.kyoto-u.ac.jp/ronsov/> in the address bar. The page title is "経済学研究科 経済論叢データベース". Below the title, it says "文書数 7,433 キーワード数 1,149,415 [検索方法]". There are search fields for "検索式:" and "件数:" (set to 20), and dropdown menus for "形式:" (set to 標準) and "ソート:" (set to スコア). A "Search!" button is also present. The main content area displays a table of 20 entries, each with a ID number, author, and title. The table is scrollable. The right side of the page contains two text blocks: "ここにPDFが表示されます." and "画像から作成したPDFについては、文字認識誤りを含むテキスト情報が埋め込まれていることがあります。検索結果中に不適切な文字が混入し得る点は御了承下さい。" Below these is another text block: "50年を経過しない本文については表示できません。原本の入手方法については、経済学会に直接お問い合わせ下さい。". At the bottom of the page, there is a footer with icons for back, forward, search, and other browser functions.

ID	著者	題名
10171209	赤岡功	〈追憶文〉冬嶺孤松秀
10171208	岸田民樹	〈追憶文〉降旗武彦先
10171207	村木正義	予防原則と費用効果か
10171206	杉浦勉	イギリス行財政改革に
10171205	陳力闘	リスク回避、契約からの
10171204	松山一紀	会社人間の閉塞感
10171203	近藤文男	シャープの対米輸出マ
10171202		故 降旗武彦名誉教授追
10171201		哀辞
10171105	伊藤宣広	D. H. ロバートソン
10171104	劉哈衝	保護関税政策の国際政
10171103	中村隆之	ハロッド "An Essay in
10171102	菅原康歩	ユーロ債市場の形成と
10171101	近藤文男	シャープの対米輸出マ
10170508		経済論叢 第169巻・第
10170507	田中秀夫 川名雄	『研究ノート』アダム
10170506	坂本雅則	門鎖的所有権下における

今日はここまで