

情報検索サービス

第1回資料

オリエンテーションと講義

聖徳大学司書補講習
2008年8月29日、9月1日
江草由佳
国立教育政策研究所
yuka@nier.go.jp

テキスト・参考書

- テキスト
 - 情報科学技術協会編「CD-ROM版情報検索の演習 新訂版」日外アソシエーツ 2003年 ¥2,200
– 演習で使うので必ず毎回持参すること！
- 参考書
 - 原田智子編著「三訂情報検索演習」樹村房 2006年10月 ¥1,900

4

5

6

7

8

9

今回のおしながき

- オリエンテーション
 - 講義の目的・内容
 - テキスト・参考書
 - スケジュール(予定)
 - 講義のWebサイトとE-mail
 - USBメモリ利用のすすめ
- 講義内容
 - 情報検索とは
 - 情報検索の理論
 - 論理演算子(AND, OR, NOT)
 - トランケーション(前方一致、中間任意、中間一致)
 - 情報検索の評価方箇
 - データベース検索スキルを身につける

- 積された大量情報の中から、必要な情報を迅速、的確に検索するための知識を習得する。
- また、各種情報メディアによる検索の特徴と検索システムの構造を理解する。
- 情報検索のプロセスや検索結果の評価方法についても学習する。
- オンデスク検索およびインターネットによる情報検索を実際に演習することにより、検索スキルを習得する。

データベース検索スキルを身につける

3

スケジュール(予定)

- (注)進捗状況により多少前後します
- 9:00～10:30(90分)
 - オリエンテーション、情報検索とは
 - CD-ROM検索の準備と使い方
 - 10:40～12:10(90分)
 - 新聞記事情報の検索
 - NDL-O PAC, Webcat, cnii
 - 13:00～14:10(70分)
 - 人物情報検索
 - 試験勉強
 - 14:20～15:30(70分)
 - 雑誌情報検索
 - 総合演習、質疑応答
 - 15:40～17:00(80分)
 - 試験
 - 質疑応答
 - 16:40～17:00(20分)
 - 質疑応答

5

6

7

8

9

講義ホームページ利用方法 (次回以降の演習準備)

- 講義ホームページ閲覧 + お気に入り追加
 - 1. Internet Explore を起動
 - “スタート”→“全てのプログラム”→“Internet Explore”
 - 2. “アドレス”に以下を入力、“Enter”キー
 - <http://momiji.mimoza.jp/lecture/2008/ir-seitoku/>
 - 3. “お気に入り”→“お気に入りに追加”→“OK”
 - 講義資料取り寄せ(ダウンロード)方法
 - 1. リンクの部分の上のマウスボタンをクリック
 - 2. “対象をファイルに保存”を選ぶ
 - 3. (USBメモリ等の場所を選び,) “保存”ボタンをクリックする
 - 4. (印刷したい人は)印刷

7

8

9

講義・演習の目的・内容

- 積された大量情報の中から、必要な情報を迅速、的確に検索するための知識を習得する。
- また、各種情報メディアによる検索の特徴と検索システムの構造を理解する。
- 情報検索のプロセスや検索結果の評価方法についても学習する。
- オンデスク検索およびインターネットによる情報検索を実際に演習することにより、検索スキルを習得する。

データベース検索スキルを身につける

3

講義のWebサイトとE-mail

- 講義のWebサイト
 - <http://momiji.mimoza.jp/lecture/2008/ir-seitoku/>
 - 講義の資料がある
 - 講義の開始時にお気に入りに追加+講義資料のダウンロードをすること
- 講義時間外の質問はE-mailで！ yuka@nier.go.jp

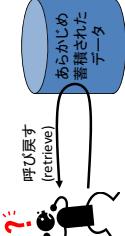
6

7

8

9

1. 情報検索とは

- **情報検索**
 - IR: Information (storage and retrieval)
 - 情報(information)を呼び戻すこと(retrieval)
 - 元はinformation storage and retrieval 情報の蓄積と検索
 - 1950年にムニアーズ(Calvin N. Mooers)が初めて定義
 - 1960年代に広く使われるようになる
 - search: データベース検索では、これも「検索」と訳す
- 

6

7

8

9

USBメモリ利用のすすめ

- USBメモリの利用をすすめます
 - USBメモリであればなんでもよい
 - 講義の資料、課題の保存のため
 - 保存したファイルは再起動すると消去されるため他の講義でも利用可能
 - さまざまなファイルの保存に利用できる
- USBメモリとはデータを保存するメディア
 - FDよりも大容量、安定している
 - 金額1,000円前後～
 - USBメモリの使い方
 - http://momiji.mimoza.jp/lecture/2007/QA/#usb
 - USBメモリのはしご方
 - <http://momiji.mimoza.jp/lecture/2007/QA/#usb-exit>

6

7

8

9

retriever(レトリーバー):
獲得をねがうに訓練された強大

第1回資料

第1回資料

第1回資料

情報検索の理論(1) — p.19

- コンピュータ検索では論理演算の概念が基本
- データベース全体から合致するものを検索し
 - 論理積、論理和、論理差の集合の概念をもちいて、広げたり、狭めたりして検索
- 論理演算
 - トランケーション

p.19
参考書のページ数を表す

10

第1回資料

情報検索の理論(1) — p.19

- 論理演算
 - 論理積(AND)、論理和(OR)、論理差(NOT)
 - 論理演算子
 - 説明ではAND, OR, NOTを使うが、演算子の書き方はシステムによって様々である。

— 説明ではAND, OR, NOTを使うが、演算子の書き方はシステムによって様々である。

論理積 A AND B

論理和 A OR B

論理差 A NOT B

論理積の例：教育 and 情報

- 「教育」と「情報」の両方を含む
- 高等学校「情報」教員養成におけるメディア・リテラシー教育
- 情報教育に関する問題—高等学校の情報関係科の履修の経験による検討
- 高校生のコンピュータに対する意識調査
- 高等学校教員免許状取得の現状と課題—教科「情報」の免許状の取得
- 高校普通教科「情報」とスキル教育
- 高校生の情報活用に関する日中比較
- 高校教育の多様化—高等学校現場からの報告
- デジタルメディア利用教授不安の減少と高校生のコンピュータ不安

p.19
参考書のページ数を表す

13

第1回資料

情報検索の理論(2) — p.19

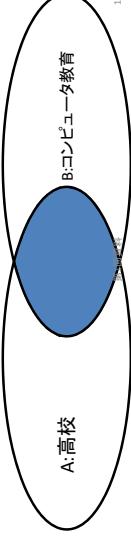
- (1)論理演算子 — p.19
- 論理積(AND) — p.20

— Aという検索語を持つ情報の集合とBという検索語をもつ集合の両方を含む部分を検索すること

— 情報を絞り込んでいくときに有用

— 例：「高校におけるコンピュータ教育」

— 検索式："高校 AND コンピュータ教育"



12

情報検索の理論(3) — p.19

- (1)論理演算子 — p.19
- 論理和(OR) — p.20

— Aという検索語を持つ情報の集合とBという検索語のいずれか一方の検索語をもつ集合部分と、両方をもつ集合部分全てを検索すること

— 同義語などの検索に有用

— 例：「高校におけるコンピュータ教育」

— 検索式："高校 OR 高等学校"



14

論理和の例：高校 or 高等学校

「高校」が「高等学校」のどちらかを含む、
高等学校「情報」教員養成におけるメディア・リテラシー教
育

情報教育による問題—高等学校の情報関係科の履修の経験による検討

高校生のコンピュータに対する意識調査

高等学校教員免許状取得の現状と課題—教科「情報」の免許状の取得

高校普通教科「情報」とスキル教育

高校生の情報活用に関する日中比較

高校教育の多様化—高等学校現場からの報告

デジタルメディア利用教授不安の減少と高校生のコンピュータ不安

高校
高等学校

第1回資料

15

情報検索の理論(2) — p.19

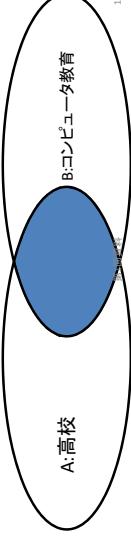
- (1)論理演算子 — p.19
- 論理積(AND) — p.20

— Aという検索語をもつ集合の両方を含む部分を検索すること

— 情報を絞り込んでいくときに有用

— 例：「高校におけるコンピュータ教育」

— 検索式："高校 AND コンピュータ教育"



12

情報検索の理論(8) — p.20

- (3)トランケーション — p.21

— トランケーション

— 検索語を入力する場合に、語の一部が任意であるように指定して検索すること

— 指定方法としては、大きく分けて2種類ある

— 任意の部分を指定する方法(マスク文字を使用)
• 決まっている位置を指定する方法
→ 図書館？

ここはなんでもいい(任意) ここ(前方)は「図書館」と
と指定する方法
任意の部分の特殊文字という
のことをマスク文字といふ
決まっていいますよと
指定する方法

第1回資料

18

情報検索の理論(4) — p.20

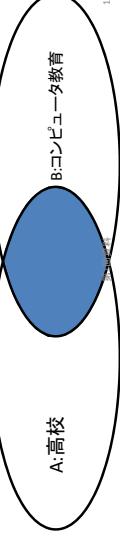
- (1)論理演算子 — p.20
- 論理差(NOT) — p.20

— Aという検索語を持つ情報の集合からBという検索語をもつ集合部分を除いた部分を検索すること

— 複数の言語で書かれていることはすぐないので、ロシア語文獻を抜くといった検索に有効

— 例：「トラック事故以外の自動車事故」

— 検索式："自動車事故 NOT トラック事故"



16

第1回資料

17

マスク文字

- マスク文字(ワイルドカード)
 - 任意文字とする部分に使用する入力文字
 - マスク(mask):覆い隠すから由来
 - マスク文字はシステムによって異なる
- 以下は説明で使用
 - ? : 文字以上、何文字でもよい
 - # : 文字または一文字
 - ! : ちょうど一文字



19

情報検索の理論(10) — p.20 (3)ランクーション — p.21

2)後方一致検索 — p.22

- 検索語の後方を一致させる検索
- 検索語の始まりを任意文字に指定する方検索
- 例)
 - ? 情報
 - ? 情報 /

p.?は
参考書のページ数
を表す

22

情報検索結果の評価(1) — p.23

- 検索結果の評価
 - 検索終了後、求める情報が適切に検索できているか、検索漏れはやノイズがないかどうかをチェックする
 - 検索漏れ
 - 本来必要な情報でデータベースに存在するにもかかわらず検索されなかつた情報
 - ノイズ
 - そのテーマに不要な情報が入り込んで検索された情報

p.?は
参考書のページ数
を表す

23

一致指定文字*

- 一致指定文字*
 - 一致する部分がどこかを示す特殊文字
 - 一致指定文字はシステムによって異なる
- 以下は説明で使用
 - / : ここから始まる、もしくは、ここで終わる



19

情報検索の理論(11) — p.20 (3)ランクーション — p.21

3)中間任意検索 — p.23

- 検索語の途中を任意文字に指定する検索
- 例)
 - 情報 ? システム ⇒ 情報システム、情報管理システム、情報検索システム
 - ログン ⇒ ログイン、ログオン
 - WOMIN ⇒ WOMAN,WOMEN
- ・ 単数形、複数形が同時に検索できる
- GRAY ⇒ GREY,GRAY
 - ・ 英米綴りの違いを同時に検索できる

p.?は
参考書のページ数
を表す

23

情報検索結果の評価(2) — p.23

- 再現率(recall ratio)
 - データベースに含致する適合情報のうち、どれだけ適合情報が検索されたかという割合を表す
 - 検索漏れの程度を表す指標となる
- 精度(precision ratio)(適合率(relevance ratio))
 - データベース全体の適合率を実際に調べるのは不可能なため、普通、正確にはつからない
 - 精度が高まれば、検索結果の情報全體のうち、どれだけ適合情報が検索されたかという割合を表す。
 - ノイズの程度を表す指標となる
 - 検索結果から容易に計算可能な指標となる
- 双方とも下がるという関係にある

24

情報検索の理論(9) — p.20 (3)ランクーション — p.21

1)前方一致検索

- 検索語の前方が一致する検索
- 検索語の末尾を任意文字に指定する検索
- 大抵どのシステムにもある
- 例)
 - 情報?
-/情報
 - CAT# ⇒ CAT,CATS,CATV
 - ・ 猫を検索したいときによいが、CATVまで検索されてしまう
 - DISC ⇒ DISK,DISC
 - ・ 英米綴りの違いを同時に検索できる

p.?は
参考書のページ数
を表す

21

情報検索の理論(12) — p.20 (3)ランクーション — p.21

4)中間一致検索

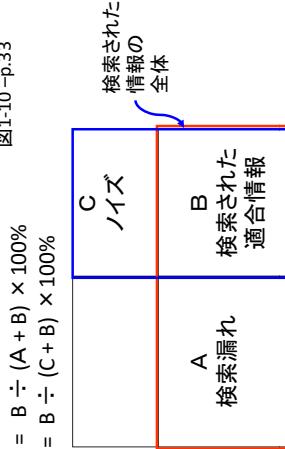
- 検索語の中間が一致する検索
- 検索語の両端を任意文字に指定する検索
- インターネットの検索エンジンでは中間一致していることが多い
- 一般に3文字以下の略字ではノイズを招くので、ランクーションを使わず、完全一致させたほうがよい、例)
- ?情報? ⇒ 情報、交通情報、情報システム

p.?は
参考書のページ数
を表す

24

情報検索結果の評価(3) — p.23

$$\text{再現率 } R = \frac{B}{A+B} \times 100\%$$
$$\text{精度 } P = \frac{B}{C+B} \times 100\%$$



25

27

情報検索結果の評価(4) -p.23

- 例) 10件の文献を出力、10件全部が適合文献、データベース全体には100件の適合文書が存在
- 精度: $10/10 \times 100 = 100\%$
- 再現率: $10/100 \times 100 = 10\%$
残りの90%が検索漏れ
- 例) 50件の文献を出力、30件が適合文献
データベース全体には70件適合文書が存在
- 精度: $30/50 \times 100 = 60\%$
- ノイズは40%
- 再現率: $30/70 \times 100 = 43\%$
- 検索漏れは57%

第1回資料 28

データベースの起源 -27p.

- 1950年代
- 米国国防総省が戦力に関する情報を保管、集中管理するためコンピュータを使ったライフレリーを開発
- データの基地(data base)から由来
- 例) 50件の文献を出力、30件が適合文献
データベース全体には70件適合文書が存在
- 精度: $30/50 \times 100 = 60\%$
- 再現率: $30/70 \times 100 = 43\%$
- 検索漏れは57%

第1回資料 29

データベースの定義(1) -p.28

- 著作権法二条十の三-p.28
 - 論文、数値、図形その他の情報の集合物であつて、それらの情報を電子計算機用いて検索することができるようになつて構成したもの
 - 日本工業規格(JIS) -p.28
 - 適用業務分野で使用するデータの集まりであつて、データの特性とそれに応する実態の間の関係とを記述した概念的な構造によつて編成されたもの(X0017)
 - 特定の規則に従つて電子的な形式で、一か所に蓄積されたデータの集合であつて、コンピュータでアクセス可能なものの(X0807)

第1回資料 30

データベースの定義(2) -28p. -日本のデータベースの特徴--

- データベースとは”コンピュータを用いて検索できる”ことが重要である。情報が電子メディアに蓄積され、コンピュータ、携帯情報端末(PDA)、地上波テレビ端末などを使用して検索できる状態になっている。
- データや情報がコンピュータ処理できるように体系的に整理され、統合化・構造化されて蓄積・保存されており、必要な情報だけを部分的に取り出せる。
蓄積情報の検索や更新が容易に行えるよう、効率化を図ったものである

一方、ヨーロッパにおけるデータベースの定義では、コンピュータを使用するかしないか、電子的であるかどうかについては特に規定していない

31

32

第1回 演習課題: 論理演算ヒトランケーション

- 第1回 演習課題を行い、提出しなさい
- 第1回 演習課題は講義Webサイトにもあります。
- 学籍番号、名前、提出日を忘れないこと
- この課題のねらい:
 - 論理演算ヒトランケーション機能を使った検索式を組み立てることができるようになる。
 - 論理演算子の書き方やマスク文字が、システムによって異なることを体験する。

31

32