

目次

記号表	page x
まえがき	xiii
1 Boolean retrieval	1
1.1 情報検索問題の例	3
1.2 逆インデックス構築の最初の試み	6
1.3 ブールクエリーの処理	10
1.4 拡張されたブールモデル対ランク付けされた検索	14
1.5 引用文献と参考図書	16
2 用語語彙とポスティングリスト	18
2.1 文書輪郭と文字列解読	18
2.2 用語の語彙を決定する	21
2.3 スキップポインターによる高速なポスティングリストの共通集 合操作	32
2.4 位置的ポスティングと句クエリー	35
2.5 引用文献と参考図書	41
3 辞書と寛容な検索	43
3.1 辞書検索の構成	43
3.2 ワイルドカード検索	45
3.3 スペル修正	49
3.4 音声上の修正	56
3.5 引用文献と参考図書	57
4 インデックスの構築	59
4.1 ハードウェア概説	60
4.2 ブロックソートインデキシング	61
4.3 単一パスインメモリインデキシング	64
4.4 分散インデキシング	66

4.5	動的インデキシング	69
4.6	他のタイプのインデックスについて	72
4.7	引用文献と参考図書	75
5	<i>Index compression</i>	77
5.1	検索システムにおける用語の統計的性格	78
5.2	辞書の圧縮	82
5.3	ポスティングファイルの圧縮	86
5.4	引用文献と参考図書	96
6	点数付け, 語重みづけ, ベクトル空間モデル	98
6.1	パラメーター及びゾーンインデックス	98
6.2	語頻度と重みづけ	104
6.3	点数付けのベクトル空間モデル	107
6.4	改良型 tf-idf 関数	113
6.5	引用文献と参考図書	118
7	完全な検索システムでの計算スコア	119
7.1	効果的なスコアリングとランキング	119
7.2	情報検索システムのコンポーネント	127
7.3	ベクトル空間スコアリングとクエリ演算子の相互作用	131
7.4	引用文献と参考図書	132
8	情報検索の評価	134
8.1	情報検索システムの評価	135
8.2	一般的に使われているテスト集合	136
8.3	順位なし検索集合の評価	137
8.4	順位つき検索結果の評価	140
8.5	妥当性の評価	146
8.6	さらに広い観点から: システムの質とユーザーの実用性	149
8.7	検索結果のスニペット	152
8.8	引用文献と参考図書	154
9	<i>Relevance feedback and query expansion</i>	157
9.1	Relevance feedback and pseudo relevance feedback	158
9.2	Global methods for query reformulation	168
9.3	References and further reading	172
10	<i>XML 検索</i>	173
10.1	基本的な XML 概念	175
10.2	XML 検索のチャレンジ	178
10.3	XML 検索のベクトル空間モデル	183
10.4	XML 検索の評価	187

目次	vii
10.5 テキスト中心対データ中心の XML 検索	191
10.6 引用文献と参考図書	193
11 確率的情報検索	195
11.1 基本的な確率論のレビュー	196
11.2 確率ランキング原理	197
11.3 バイナリ独立モデル	198
11.4 評価といくつかの拡張	205
11.5 引用文献と参考図書	209
12 検索のための言語モデル	211
12.1 言語モデル	211
12.2 クエリ尤度モデル	216
12.3 情報検索における言語モデル手法と他の手法との対比	222
12.4 拡張言語モデル手法	223
12.5 引用文献と参考図書	224
13 テキストの分類とナイーブベイズ	226
13.1 テキスト分類問題	229
13.2 ナイーブベイズテキスト分類	231
13.3 ベルヌーイモデル	235
13.4 ナイーブベイズの性質	237
13.5 特徴選択	243
13.6 テキスト分類の評価	250
13.7 引用文献と参考図書	257
14 ベクトル空間分類	259
14.1 文書の表現とベクトル空間での関係性の指標	260
14.2 ロッキオ分類	262
14.3 k 最近傍法	266
14.4 線形分類器 対 非線形分類器	270
14.5 クラス数が 2 より多い分類	274
14.6 バイアス-バリエーション・トレードオフ	276
14.7 引用文献と参考図書	283
15 支持ベクトル機械と文書の機械学習	286
15.1 支持ベクトル機械 - 線形的に分離可能な場合	286
15.2 支持ベクトルモデルへの拡張	292
15.3 テキスト文書の分類における問題	299
15.4 アドホック情報検索での機械学習手法	304
15.5 引用文献と参考図書	308
16 平坦クラスタ化	311

16.1 情報検索でのクラスター化	312
16.2 問題記述	316
16.3 クラスター化の評価	317
16.4 K 平均法	321
16.5 モデル基盤クラスター化	327
16.6 引用文献と参考図書	332
17 階層的クラスター化	335
17.1 階層的集塊性クラスター化	336
17.2 単一リンクと完全リンククラスター化	339
17.3 グループ平均集塊クラスター化	345
17.4 重心クラスター化	346
17.5 階層的集塊クラスター化の最適性	348
17.6 分割可能クラスター化	351
17.7 クラスターラベル付け	351
17.8 実装ノート	353
17.9 引用文献と参考図書	355
18 行列の分解と潜在意味インデキシング	357
18.1 線形代数の復習	357
18.2 用語—文書行列と特異値分解	361
18.3 低階数近似	363
18.4 潜在意味インデキシング	366
18.5 引用文献と参考図書	371
19 ウェブ検索の基礎	372
19.1 背景と歴史	372
19.2 ウェブの特徴	374
19.3 経済モデルとしての宣伝	380
19.4 サーチのユーザー体験	382
19.5 インデックスのサイズと推定	384
19.6 近複製とシングリング	388
19.7 引用文献と参考図書	392
20 ウェブのクローリングとインデックス化	393
20.1 概説	393
20.2 クローリング	394
20.3 インデックスを分散化する	403
20.4 接続サーバー	405
20.5 引用文献と参考図書	407
21 リンク解析	409
21.1 グラフとしてのウェブの世界	410

目次	ix
21.2 PageRank	412
21.3 ハブと権威者	421
21.4 引用文献と参考図書	427
参考文献	429
索引	456

記号表

記号	ページ	意味
γ	89	γ コード
γ	229	分類, あるいは, クラスタ関数: $\gamma(d)$ は d のクラス, あるいは, クラスタ
Γ	229	第 13 章および第 14 章の監督付き学習法 (supervised learning method) : $\Gamma(\mathbb{D})$ は, トレーニング集合 \mathbb{D} から学んだ分類関数 γ である.
λ	358	固有値 (eigenvalue)
$\bar{\mu}(\cdot)$	262	(ロッキオ (Rocchio) 分類での) 1 つのクラス, あるいは, (K -平均と重心クラスタリングでの) 1 つのクラスタの重心 (centroid)
Φ	103	トレーニング例 (training example)
σ	361	特異値 (singular value)
$\Theta(\cdot)$	10	アルゴリズムの計算複雑度のきっちりとした限界 (tight bound)
ω, ω_k	318	クラスタリング中のクラスタ
Ω	318	クラスタリング, あるいは, クラスタの集合 $\{\omega_1, \dots, \omega_K\}$
$\arg \max_x f(x)$	159	f が最大値に達するような x の値
$\arg \min_x f(x)$	159	f が最小値に達するような x の値
c, c_j	229	分類におけるクラス, あるいは, カテゴリー
cf_t	81	用語 t のコレクション中の頻度 (その用語が, 文書コレクション中に現れる総数)
\mathbb{C}	229	すべてのクラスの集合 $\{c_1, \dots, c_J\}$
C	240	\mathbb{C} の要素を値とするランダム変数
C	357	用語-文書行列 (term-document matrix)
d	4	コレクション D の d 番目の文書のインデックス
d	63	文書 (document)
\vec{d}, \vec{q}	158	文書ベクトル, クエリーベクトル
D	316	すべての文書からなる集合 $\{d_1, \dots, d_N\}$
D_c	262	クラス c にある文書集合

\mathbb{D}	229	第 13 章から第 15 章のすべてのラベル付き文書集合 $\{\langle d_1, c_1 \rangle, \dots, \langle d_N, c_N \rangle\}$
df_t	105	用語 t の文書頻度 (コレクション中でその用語が現れる文書の全数)
H	90	エントロピー (entropy)
H_M	92	M 番目の調和数 (M th harmonic number)
$I(X; Y)$	244	ランダム変数 X と Y の相互情報 (mutual information)
idf_t	106	用語 t の逆文書頻度 (inverse document frequency)
J	229	クラスの数
k	260	集合からの上位 k 個の要素. 例えば, kNN での k 個の最近傍, 上位 k 個の検索された文書, 語彙 V からの上位 k 個の選択された特徴
k	48	k 個の文字列
K	316	クラスターの数
L_d	207	文書 d の長さ (トークン数でみたとき)
L_a	234	トークン数でみたときのテスト文書 (あるいはアプリケーションの文書) の長さ
L_{ave}	62	トークン数でみたときの文書の平均長
M	4	語彙のサイズ ($ V $)
M_a	234	テスト文書 (または, アプリケーション文書) の語彙のサイズ
M_{ave}	70	コレクション中の文書での語彙の平均サイズ
M_d	211	文書 d の言語モデル
N	4	検索, あるいは, トレーニング用のコレクション中の文書数
N_c	232	クラス c 中の文書数
$N(\omega)$	268	イベント ω の発生数
$O(\cdot)$	10	アルゴリズムの計算複雑度の上界 (upper bound)
$O(\cdot)$	197	イベントの発生確率
P	138	精度 (precision)
$P(\cdot)$	196	確率 (probability)
P	413	遷移確率行列 (transition probability matrix)
q	51	クエリー
R	138	再現率 (recall)
s_i	51	文字列 (string)
s_i	100	ゾーン得点に対するブール値 (boolean values for zone scoring) ? ? ? ? ? ? ? ? ?
$\text{sim}(d_1, d_2)$	108	文書 d_1, d_2 の類似度得点
T	38	文書コレクション中の全トークン数
T_{ct}	232	クラス c の文書の中の語 t の発生数
t	4	語彙 V のなかの t 番目の用語のインデックス
t	54	語彙の中の用語
$tf_{t,d}$	105	文書 d での用語 t の用語頻度 (d での t の全発生数)

U_t	238	(用語 t があれば) 値 0, (t がなければ) 値 1 を取るランダム変数
V	185	コレクション (a.k.a. レキシコン) 中の用語 $\{t_1, \dots, t_M\}$ の語彙
$\vec{v}(d)$	108	長さで正規化された文書ベクトル
$\vec{V}(d)$	108	長さで正規化されていない文書 d のベクトル
$wf_{t,d}$	112	文書 d での用語 t の重さ
w	100	重さ (例えば, ゾーンや用語の重さ)
$\vec{w}^T \vec{x} = b$	262	超平面 (hyperplane); \vec{w} はこの長平面の法線ベクトル (normal vector) で w_i は \vec{w} の要素 i
\vec{x}	198	用語接続ベクトル (term incidence vector) $\vec{x} = (x_1, \dots, x_M)$; もっと一般的には, 文書特徴表現 (document feature representation)
X	238	語彙 V の値を取るランダム変数 (例えば, 文書中与えられた k の位置で)
\mathbb{X}	229	テキスト分類での文書空間
$ x $	123	x の絶対値 (absolute value)
$ A $	54	集合の要素数 (set cardinality): 集合 A の要素の数
$ S $	358	正方行列 S の行列式 (determinant)
$ s_i $	51	文字列 s_i の文字数
$ \vec{x} $	123	ベクトル \vec{x} の長さ
$ \vec{x} - \vec{y} $	116	\vec{x} と \vec{y} のユークリッド距離 (Euclidean distance) (つまり, $(\vec{x} - \vec{y})$ の長さ)