

(19) 日本国特許庁(JP)

(12) 特 許 公 報(B2)

(11) 特許番号

特許第4828091号

(P4828091)

(45) 発行日 平成23年11月30日(2011.11.30)

(24) 登録日 平成23年9月22日(2011.9.22)

(51) Int.Cl.

F I

G 0 6 F 17/30 (2006.01)

G 0 6 F 17/30 2 1 0 D

G 0 6 F 17/30 1 7 0 A

G 0 6 F 17/30 3 5 0 C

請求項の数 10 (全 25 頁)

(21) 出願番号 特願2004-30629 (P2004-30629)
 (22) 出願日 平成16年2月6日(2004.2.6)
 (65) 公開番号 特開2004-288168 (P2004-288168A)
 (43) 公開日 平成16年10月14日(2004.10.14)
 審査請求日 平成19年2月6日(2007.2.6)
 (31) 優先権主張番号 特願2003-105867 (P2003-105867)
 (32) 優先日 平成15年3月5日(2003.3.5)
 (33) 優先権主張国 日本国(JP)

(73) 特許権者 398038580
 ヒューレット・パッカード・カンパニー
 HEWLETT-PACKARD COMPANY
 アメリカ合衆国カリフォルニア州パロアル
 ト ハノーバー・ストリート 3000
 (74) 代理人 110000039
 特許業務法人アイ・ピー・エス
 (72) 発明者 川谷 隆彦
 東京都杉並区高井戸東3丁目29番21号
 日本ヒューレット・パッカード株式会社
 内

審査官 岩間 直純

最終頁に続く

(54) 【発明の名称】 クラスタリング方法プログラム及び装置

(57) 【特許請求の範囲】

【請求項 1】

コンピュータに入力された 1 つ以上の文書セグメントを持つ複数の文書から成る入力文書集合を、それぞれ 1 つ以上の文書を含む 1 つ以上のクラスターにクラスタリングする前記コンピュータに実行させる方法であって、

前記コンピュータに、

(a) 入力文書集合において、用語それぞれが出現する文書の数(用語頻度)と、前記用語それぞれが含まれる文書に含まれる(共起する)用語が出現する文書の数とに基づいて、その m 成分 U_{0m} として、用語 m の用語頻度を含み、その m n 成分 U_{0mn} として、用語 m と用語 n とが共起する文書の数を含む文書頻度行列 U_0 を求めるステップと、

(b) いずれのクラスターにも含まれていない文書(残存文書)の集合の中から、着目クラスターの形成のために用いられる文書を選択し、前記選択された文書(種文書)を用いて、初期状態の処理対象となる前記クラスター(着目クラスター)を作成するステップと、

(c) 前記入力文書集合 D に含まれる文書 D_r それぞれの式 1 により表される共起行列 S_r であって、 m n 成分が式 2 により表される共起行列 S_r を求めるステップと、

【数 1】

$$S^r = \sum_{y=1}^{Y_r} d_{ry} d_{ry}^T \quad (1)$$

【数 2】

$$S^r_{mn} = \sum_{y=1}^{Y_r} d_{rym} d_{ryn} \quad (2)$$

10

ただし、出現する用語の集合は $\{w_1, \dots, w_M\}$ で与えられ、文書集合 D は R 個の文書を含み、文書 D_r は、 r 番目の文書であり、文書 D_r は、 Y_r 個の文を含み、 D_{ry} は、 y 番目の文であり、 d_{ry} は、 y 番目の文の 2 値の文ベクトルであって、 $d_{ry} = (d_{ry1}, \dots, d_{ryM})^T$ であり、 T はベクトルの転置を示し、 d_{rym} は、 m 番目の用語の有無を示し、

(d) 前記着目クラスターに含まれる文書集合 D の共起行列 S^r から、その mn 成分が式 3 により表される行列 T を求めるステップと、

20

【数 3】

$$T_{mn} = \prod_{r=1}^R S^r_{mn} \quad (3)$$

$$S^r_{mn} > 0$$

ただし、 T_{mn} は、行列 T の mn 成分であり、

(e) 前記求められた行列 T から、以下の通りに文書集合 D の共有共起行列 TA または QA を求めるステップと、

30

$TA_{mn} = T_{mn} : U_{0mn} = A$ のとき、

$TA_{mn} = 0 : U_{0mn} \neq A$ 以外のとき、

ただし、 TA_{mn} は、共有共起行列 TA の mn 成分であり、または、

$QA_{mn} = \log(TA_{mn}) : TA_{mn} > 1$ のとき、

$QA_{mn} = 0 : TA_{mn} \leq 1$ 以外のとき、

ただし、 QA_{mn} は、共有共起行列 QA の mn 成分であり、

A は、着目クラスターに含まれる R 個の文書の内、共通の文を含む文書の数であり、

(f) 前記入力文書集合に含まれる全ての文書の前記着目クラスターに対する文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を、式 4 により求めるステップと、

40

【数 4】

$$com_q(D', P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M Q^A_{mn} S^P_{mn}}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M (Q^A_{mn})^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M (S^P_{mn})^2}} \quad (4)$$

ただし、式 4 において、 D' は、最初にこのステップが実行されるときには、入力文書集合 D であり、これ以外ときには残存文書の集合であり、

50

S P は、任意の文書 P の共起行列であり、共有共起行列 Q A を、共有共起行列 T A に置換することにより、文書共通度 $c o m t (D', P, T A)$ を得ることができ、

(g) 前記着目クラスターとの前記文書共通度 $c o m t (D', P, T A)$ または $c o m q (D', P, Q A)$ の値が、予め決められた範囲の値となる文書を、この着目クラスターに帰属させるステップと、

(h) 前記(c) ~ (g) のステップを実行しても、前記着目クラスターに帰属する文書の数が増えなくなるまで、前記(c) ~ (g) のステップを繰り返すステップと、

(i) 前記クラスターそれぞれに対して、前記文書共通度 $c o m t (D', P, T A)$ または $c o m q (D', P, Q A)$ が、予め決められた値を示す文書の数が増えるか、または、前記クラスターの数が増えなくなるまで、前記(b) ~ (h) を実行しても、前記クラスターの数が増えなくなるまで、前記(b) ~ (h) を繰り返すステップと、

(j) 前記文書それぞれの前記クラスターに対する文書共通度 $c o m t (D', P, T A)$ または $c o m q (D', P, Q A)$ に基づいて、前記文書それぞれが帰属するクラスターを決定するステップと

を実行させる方法。

【請求項 2】

前記(b) 初期状態の着目クラスターを作成するステップが、

(b - 1) 前記残存文書の集合の前記共有共起行列 T A または Q A を求めるステップと、

(b - 2) 前記残存文書の集合の前記共有共起行列 T A または Q A を用いて、近隣文書の数が増える1つの文書を、前記着目クラスターの種文書として選択するステップであって、前記近隣文書それぞれは、前記1つの文書との間で、予め決められた値よりも高い類似度を有するステップと、

(b - 3) 前記種文書と、前記残存文書それぞれの文書セグメントベクトルに基づいて、前記残存文書の内、前記種文書との間の類似度の値が、予め決められた値よりも高いと判断された文書とを含む前記着目クラスターを作成するステップと

をさらに含む請求項 1 に記載の方法。

【請求項 3】

前記(g) 着目クラスターに帰属させるステップが、

(g - 1) 前記着目クラスターについて、共有共起行列 T A または Q A と、文書頻度行列 U とを求めさせるステップと、

(g - 2) 前記入力文書集合の文書頻度行列 U 0 と、その成分が U_{mm} , U_{mn} と表される前記着目クラスターの文書頻度行列 U とに基づいて、式 5, 6 で表され、用語 m それぞれおよび用語対 mn それぞれの前記着目クラスターに対する特有度 v_{mm} , v_{mn} を求めさせるステップと、

【数 5】

$$v_{mm} = c' / (U^0_{mm} / U_{mm}) \quad (5)$$

【数 6】

$$v_{mn} = c' / (U^0_{mn} / U_{mn}) \quad (6)$$

10

20

30

40

50

ただし、式 5 , 6 は、前記入力文書集合の文書頻度行列 U_0 において、成分 U_{0mm} , U_{0mn} が 0 以外の値をとる用語 m および用語対 mn に対して適用され、式 5 , 6 において、 c' は、 U_{0mm} / U_{mm} の平均値であり、

(g - 3) 前記特有度 v_{mm} , v_{mn} と、予め決められた重み決定関数 $f(x)$ とから、用語 m の重み $z_{mm} (= f(v_{mm}))$ および用語対 mn の重み $z_{mn} (= f(v_{mn}))$ を求めさせるステップと、

(g - 4) 前記求められた重み z_{mm} , z_{mn} と、共有共起行列 TA または QA とから、式 8 または式 9 で表される前記入力文書集合に含まれる文書 P それぞれの文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を求めさせ、

【数 7】

10

$$com_t(D, P; Q^A) = \frac{\sum_{m=1}^M z_{mm} Q^A_{mm} S^P_{mm}}{\sqrt{\sum_{m=1}^M z_{mm} (Q^A_{mm})^2} \sqrt{\sum_{m=1}^M z_{mm} (S^P_{mm})^2}} \quad (7)$$

【数 8】

$$com_q(D, P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M z_{mn} Q^A_{mn} S^P_{mn}}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M z_{mn} (Q^A_{mn})^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M z_{mn} (S^P_{mn})^2}} \quad (8)$$

20

ただし、式 7 , 8 において、共有共起行列 QA を、共有共起行列 TA に置換することにより、文書共通度 $com_t(D', P, TA)$ を得ることができ、

(g - 5) 予め決められた値以上の前記文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を示す文書を、前記着目クラスターに帰属させるステップとをさらに含む請求項 1 または 2 に記載の方法。

【請求項 4】

前記 (j) 前記文書それぞれが帰属するクラスターを決定するステップが、
複数の前記クラスターに含まれる文書が示す話題が重複するときに、冗長なクラスターがあると判断し、前記冗長なクラスターを除去させて、文書それぞれが帰属するクラスターを決定し直させるために、

30

(j - 1) 全てのクラスターと全ての文書との文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を求めさせるステップと、

(j - 2) 前記求められた全てのクラスターと全ての文書との文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ が、前記着目クラスターについては予め決められた値よりも大きくなり、これ以外のクラスターのいずれについても前記予め決められた値よりも小さくなる文書の数、前記クラスターそれぞれの重要度として求めさせるステップと、

40

(j - 3) 前記重要度の値が、予め決められた値よりも小さいクラスターが 1 つあったときには、そのクラスターを、冗長なクラスターとして除去させ、重要度の値が、予め決められた値よりも小さいクラスターが複数あったときには、最小の重要度を示すクラスターを、冗長なクラスターとして除去させ、

(j - 4) 前記除去されたクラスターに帰属していた文書それぞれを、前記除去されたクラスターに帰属していた文書それぞれと、除去されたクラスター以外のクラスターとの文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ に基づいて、除去されたクラスター以外のクラスターのいずれかに帰属させるステップと

を含むステップをさらに含む請求項 1 ~ 3 のいずれかに記載の方法。

【請求項 5】

50

前記クラスタリングは、再帰的に行われ、前記再帰的に行われるクラスタリングそれぞれは、その直前のクラスタリングにより得られたクラスターに属する文書集合を前記入力文書集合とする

請求項 1 ～ 4 のいずれかに記載の方法。

【請求項 6】

コンピュータに入力された 1 つ以上の文書セグメントを持つ複数の文書から成る入力文書集合を、それぞれ 1 つ以上の文書を含む 1 つ以上のクラスターにクラスタリングするために、

(a) 入力文書集合において、用語それぞれが出現する文書の数 (用語頻度) と、前記用語それぞれが含まれる文書に含まれる (共起する) 用語が出現する文書の数とに基づいて、その m 成分 U_{0m} として、用語 m の用語頻度を含み、その n 成分 U_{0n} として、用語 m と用語 n とが共起する文書の数を含む文書頻度行列 U_0 を求めるステップと、

10

(b) いずれのクラスターにも含まれていない文書 (残存文書) の集合の中から、着目クラスターの形成のために用いられる文書を選択し、前記選択された文書 (種文書) を用いて、初期状態の処理対象となる前記クラスター (着目クラスター) を作成するステップと、

(c) 前記入力文書集合 D に含まれる文書 D_r それぞれの式 1 により表される共起行列 S_r であって、 m n 成分が式 2 により表される共起行列 S_r を求めるステップと、

【数 9】

20

$$S_r = \sum_{y=1}^{Y_r} d_{ry} d_{ry}^T \quad (1)$$

【数 10】

$$S_{r_{mn}} = \sum_{y=1}^{Y_r} d_{rym} d_{ryn} \quad (2)$$

30

ただし、出現する用語の集合は $\{w_1, \dots, w_M\}$ で与えられ、文書集合 D は R 個の文書を含み、文書 D_r は、 r 番目の文書であり、文書 D_r は、 Y_r 個の文を含み、 D_{ry} は、 y 番目の文であり、 d_{ry} は、 y 番目の文の 2 値の文ベクトルであって、 $d_{ry} = (d_{ry1}, \dots, d_{ryM})^T$ であり、 T はベクトルの転置を示し、 d_{rym} は、 m 番目の用語の有無を示し、

(d) 前記着目クラスターに含まれる文書集合 D の共起行列 S_r から、その m n 成分が式 3 により表される行列 T を求めるステップと、

【数 11】

40

$$T_{mn} = \prod_{r=1}^R S_{r_{mn}} \quad (3)$$

$$S_{r_{mn}} > 0$$

ただし、 T_{mn} は、行列 T の m n 成分であり、

(e) 前記求められた行列 T から、以下の通りに文書集合 D の共有共起行列 TA または QA を求めるステップと、

$TA_{mn} = T_{mn} : U_{0mn} \quad A$ のとき、

50

$T A_{mn} = 0$: $U 0_{mn}$ A 以外のとき、

ただし、 $T A_{mn}$ は、共有共起行列 $T A$ の mn 成分であり、または、

$Q A_{mn} = \log(T A_{mn})$: $T A_{mn} > 1$ のとき、

$Q A_{mn} = 0$: $T A_{mn} > 1$ 以外のとき、

ただし、 $Q A_{mn}$ は、共有共起行列 $Q A$ の mn 成分であり、

A は、着目クラスターに含まれる R 個の文書の内、共通の文を含む文書の数であり、

(f) 前記入力文書集合に含まれる全ての文書の前記着目クラスターに対する文書共通度 $comt(D', P, T A)$ または $comq(D', P, Q A)$ を、式 4 により求めるステップと、

【数 12】

$$comq(D', P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M Q_{mn}^A S_{mn}^P}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M (Q_{mn}^A)^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M (S_{mn}^P)^2}} \quad (4)$$

ただし、式 4 において、 D' は、最初にこのステップが実行されるときには、入力文書集合 D であり、これ以外のときには残存文書の集合であり、 S^P は、任意の文書 P の共起行列であり、共有共起行列 $Q A$ を、共有共起行列 $T A$ に置換することにより、文書共通度 $comt(D', P, T A)$ を得ることができ、

(g) 前記着目クラスターとの前記文書共通度 $comt(D', P, T A)$ または $comq(D', P, Q A)$ の値が、予め決められた範囲の値となる文書を、この着目クラスターに帰属させるステップと、

(h) 前記 (c) ~ (g) のステップを実行しても、前記着目クラスターに帰属する文書の数が増えなくなるまで、前記 (c) ~ (g) のステップを繰り返すステップと、

(i) 前記クラスターそれぞれに対して、前記文書共通度 $comt(D', P, T A)$ または $comq(D', P, Q A)$ が、予め決められた値を示す文書の数が増えるか、または、前記クラスターの数が増えなくなるまで、前記 (b) ~ (h) を実行しても、前記クラスターの数が増えなくなるまで、前記 (b) ~ (h) を繰り返すステップと、

(j) 前記文書それぞれの前記クラスターに対する文書共通度 $comt(D', P, T A)$ または $comq(D', P, Q A)$ に基づいて、前記文書それぞれが帰属するクラスターを決定するステップと

をコンピュータに実行させるためのプログラム。

【請求項 7】

前記 (b) 初期状態の着目クラスターを作成するステップは、前記コンピュータに、

(b-1) 前記残存文書の集合の前記共有共起行列 $T A$ または $Q A$ を求めさせるステップと、

(b-2) 前記残存文書の集合の前記共有共起行列 $T A$ または $Q A$ を用いて、近隣文書の数が増える 1 つの文書を、前記着目クラスターの種文書として選択させるステップであって、前記近隣文書それぞれは、前記 1 つの文書との間で、予め決められた値よりも高い類似度を有するステップと、

(b-3) 前記種文書と、前記残存文書それぞれの文書セグメントベクトルに基づいて、前記残存文書の内、前記種文書との間の類似度の値が、予め決められた値よりも高いと判断された文書を含む前記着目クラスターを作成させるステップと

をさらに含む請求項 6 に記載のプログラム。

【請求項 8】

前記 (g) 着目クラスターに帰属させるステップは、前記コンピュータに、

(g-1) 前記着目クラスターについて、共有共起行列 $T A$ または $Q A$ と、文書頻度行列 U とを求めさせるステップと、

10

20

30

40

50

(g - 2) 前記入力文書集合の文書頻度行列 U^0 と、その成分が U_{mm} , U_{mn} と表される前記着目クラスターの文書頻度行列 U とに基づいて、式 5, 6 で表され、用語 m それぞれおよび用語対 mn それぞれの前記着目クラスターに対する特有度 v_{mm} , v_{mn} を求めさせるステップと、
【数 13】

$$v_{mm} = c' / (U^0_{mm} / U_{mm}) \quad (5)$$

10

【数 14】

$$v_{mn} = c' / (U^0_{mn} / U_{mn}) \quad (6)$$

ただし、式 5, 6 は、前記入力文書集合の文書頻度行列 U^0 において、成分 U^0_{mm} , U^0_{mn} が 0 以外の値をとる用語 m および用語対 mn に対して適用され、式 5, 6 において、 c' は、 U^0_{mm} / U_{mm} の平均値であり、

20

(g - 3) 前記特有度 v_{mm} , v_{mn} と、予め決められた重み決定関数 $f(x)$ とから、用語 m の重み $z_{mm} (= f(v_{mm}))$ および用語対 mn の重み $z_{mn} (= f(v_{mn}))$ を求めさせるステップと、

(g - 4) 前記求められた重み z_{mm} , z_{mn} と、共有共起行列 TA または QA とから、式 8 または式 9 で表される前記入力文書集合に含まれる文書 P それぞれの文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を求めさせ、

【数 15】

$$com_t(D, P; Q^A) = \frac{\sum_{m=1}^M z_{mm} Q^A_{mm} S^P_{mm}}{\sqrt{\sum_{m=1}^M z_{mm} (Q^A_{mm})^2} \sqrt{\sum_{m=1}^M z_{mm} (S^P_{mm})^2}} \quad (7)$$

30

【数 16】

$$com_q(D, P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M z_{mn} Q^A_{mn} S^P_{mn}}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M z_{mn} (Q^A_{mn})^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M z_{mn} (S^P_{mn})^2}} \quad (8)$$

40

ただし、式 7, 8 において、共有共起行列 QA を、共有共起行列 TA に置換することにより、文書共通度 $com_t(D', P, TA)$ を得ることができ、

(g - 5) 予め決められた値以上の前記文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を示す文書を、前記着目クラスターに帰属させるステップとをさらに含む請求項 6 または 7 に記載のプログラム。

【請求項 9】

前記 (j) 前記文書それぞれが帰属するクラスターを決定するステップは、前記コンピュータに、

複数の前記クラスターに含まれる文書が示す話題が重複するときに、冗長なクラスター

50

があると判断し、前記冗長なクラスターを除去させて、文書それぞれが帰属するクラスターを決定し直させるために、

(j - 1) 全てのクラスターと全ての文書との文書共通度 $c o m t (D', P, T A)$ または $c o m q (D', P, Q A)$ を求めさせるステップと、

(j - 2) 前記求められた全てのクラスターと全ての文書との文書共通度 $c o m t (D', P, T A)$ または $c o m q (D', P, Q A)$ が、前記着目クラスターについては予め決められた値よりも大きくなり、これ以外のクラスターのいずれについても前記予め決められた値よりも小さくなる文書の数、前記クラスターそれぞれの重要度として求めさせるステップと、

(j - 3) 前記重要度の値が、予め決められた値よりも小さいクラスターが1つあったときには、そのクラスターを、冗長なクラスターとして除去させ、重要度の値が、予め決められた値よりも小さいクラスターが複数あったときには、最小の重要度を示すクラスターを、冗長なクラスターとして除去させ、

(j - 4) 前記除去されたクラスターに帰属していた文書それぞれを、前記除去されたクラスターに帰属していた文書それぞれと、除去されたクラスター以外のクラスターとの文書共通度 $c o m t (D', P, T A)$ または $c o m q (D', P, Q A)$ に基づいて、除去されたクラスター以外のクラスターのいずれかに帰属させるステップと

を含むステップをさらに含む請求項6～8のいずれかに記載のプログラム。

【請求項10】

1つ以上の文書セグメントを持つ複数の文書から成る入力文書集合を、それぞれ1つ以上の文書を含む1つ以上のクラスターにクラスタリングする装置であって、

(a) 入力文書集合において、用語それぞれが出現する文書の数(用語頻度)と、前記用語それぞれが含まれる文書に含まれる(共起する)用語が出現する文書の数とに基づいて、その $m n$ 成分 $U 0 m n$ として、用語 m の用語頻度を含み、その $m n$ 成分 $U 0 m n$ として、用語 m と用語 n とが共起する文書の数を含む文書頻度行列 $U 0$ を求める手段と、

(b) いずれのクラスターにも含まれていない文書(残存文書)の集合の中から、着目クラスターの形成のために用いられる文書を選択し、前記選択された文書(種文書)を用いて、初期状態の処理対象となる前記クラスター(着目クラスター)を作成する手段と、

(c) 前記入力文書集合 D に含まれる文書 $D r$ それぞれの式1により表される共起行列 $S r$ であって、 $m n$ 成分が式2により表される共起行列 $S r$ を求める手段と、

【数17】

$$S^r = \sum_{y=1}^{Y_r} d_{ry} d_{ry}^T \quad (1)$$

【数18】

$$S^r_{mn} = \sum_{y=1}^{Y_r} d_{rym} d_{ryn} \quad (2)$$

ただし、出現する用語の集合は $\{w_1, \dots, w_M\}$ で与えられ、文書集合 D は R 個の文書を含み、文書 $D r$ は、 r 番目の文書であり、文書 $D r$ は、 Y_r 個の文を含み、 $D r y$ は、 y 番目の文であり、 d_{ry} は、 y 番目の文の2値の文ベクトルであって、 $d_{ry} = (d_{ry1}, \dots, d_{ryM})^T$ であり、 T はベクトルの転置を示し、 d_{rym} は、 m 番目の用語の有無を示し、

(d) 前記着目クラスターに含まれる文書集合 D の共起行列 $S r$ から、その $m n$ 成分が

式 3 により表される行列 T を求める手段と、

【数 19】

$$\begin{aligned} T_{mn} &= \prod_{r=1}^R S^r_{mn} \\ S^r_{mn} &> 0 \end{aligned} \quad (3)$$

ただし、 T_{mn} は、行列 T の mn 成分であり、

(e) 前記求められた行列 T から、以下の通りに文書集合 D の共有共起行列 TA または QA を求める手段と、

$TA_{mn} = T_{mn} : U_{0mn} \text{ A のとき、}$

$TA_{mn} = 0 : U_{0mn} \text{ A 以外 のとき、}$

ただし、 TA_{mn} は、共有共起行列 TA の mn 成分であり、または、

$QA_{mn} = \log(TA_{mn}) : TA_{mn} > 1 \text{ のとき、}$

$QA_{mn} = 0 : TA_{mn} > 1 \text{ 以外 のとき、}$

ただし、 QA_{mn} は、共有共起行列 QA の mn 成分であり、

A は、着目クラスターに含まれる R 個の文書の内、共通の文を含む文書の数であり、

(f) 前記入力文書集合に含まれる全ての文書の前記着目クラスターに対する文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ を、式 4 により求める手段と、

【数 20】

$$com_q(D', P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M Q^A_{mn} S^P_{mn}}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M (Q^A_{mn})^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M (S^P_{mn})^2}} \quad (4)$$

ただし、式 4 において、 D' は、最初にこのステップが実行されるときには、入力文書集合 D であり、これ以外ときには残存文書の集合であり、 S^P は、任意の文書 P の共起行列であり、共有共起行列 QA を、共有共起行列 TA に置換することにより、文書共通度 $com_t(D', P, TA)$ を得ることができ、

(g) 前記着目クラスターとの前記文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ の値が、予め決められた範囲の値となる文書を、この着目クラスターに帰属させる手段と、

(h) 前記 (c) ~ (g) の手段を実行しても、前記着目クラスターに帰属する文書の数が増えなくなるまで、前記 (c) ~ (g) の手段を繰り返す手段と、

(i) 前記クラスターそれぞれに対して、前記文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ が、予め決められた値を示す文書の数が増えるか、または、前記クラスターの数が増えなくなるまで、前記 (b) ~ (h) を実行しても、前記クラスターの数が増えなくなるまで、前記 (b) ~ (h) を繰り返す手段と、

(j) 前記文書それぞれの前記クラスターに対する文書共通度 $com_t(D', P, TA)$ または $com_q(D', P, QA)$ に基づいて、前記文書それぞれが帰属するクラスターを決定する手段と

を有する装置。

【発明の詳細な説明】

【技術分野】

【0001】

本発明は文書のクラスタリングをはじめとする自然言語処理に関するものであり、前記処

理の高性能化を図ることによって文書からの情報の抽出を容易にするものである。

【背景技術】

【0002】

文書クラスタリングは入力された文書群を文書の内容、即ち話題によって幾つかのグループに分割する技術である。クラスタリング技術は古くから研究されてきており、これまでに考案された方法についてはC. D. ManningとH. Schutzeによって著されたFoundations of Statistical Natural Language Processing (The MIT Press、1999年)に体系的に紹介されている。まず、クラスタリングは、各文書が各クラスターに帰属する確率を求めるソフトクラスタリング、各クラスターに帰属するか否かを求めるハードクラスタリングに大別される。後者については、さらに、階層的な手法と非階層的な手法とに分類される。階層的な手法は、さらにボトムアップのアプローチとトップダウンのアプローチに分けられる。前者では、初期状態として各文書をクラスターの核とし、最も近いクラスター同士をマージするという処理を繰り返す。これにより文書集合は木構造で表現されるようになる。クラスター間の近さの尺度、即ち類似度を図る方法として単一リンク法、完全リンク法、グループ平均法が知られている。これらは何れも2文書間の類似度をもとに算出されるものである。後者では、全文書が1つのクラスターに属するという状態から出発し、例えばひとつのクラスター中のあらゆる文書対の中で最も低い類似度が閾値以下の場合、そのクラスターを分割するという処理を繰り返す。

10

【0003】

非階層的な手法では、予め指定された数のクラスターが何らかの基準を満たすように作成される。よく知られている方法の例を以下に示す。

20

ステップ1: 指定されたクラスター数の文書をランダムに選択して各クラスターの中心とするステップ、

ステップ2: 各文書について各クラスター中心との近さを求め、各文書を最も近いクラスターに帰属させるステップ、

ステップ3: 各クラスターに帰属する文書ベクトルの平均により各クラスターの中心を求めるステップ、

ステップ4: ステップ2)の処理を実行し、各文書の帰属するクラスターに変化がなければ終了、そうでなければステップ3へいくステップ、からなる方法である。

【非特許文献1】X. Liu, Y. Gong, W. Xu and S. Zhu. Document Clustering with Cluster Refinement and Model Selection Capabilities. In Proceedings of the 25th Annual International ACM-SIGIR Conference on Research and Development in Information Retrieval, pp.191-198. Tampere, Finland, August, 2002.

30

【発明の開示】

【発明が解決しようとする課題】

【0004】

従来の文書クラスタリング技術は3つの大きな問題を抱えている。ひとつは求められるクラスターの数の問題である。文書クラスタリングでは求められるクラスターの数は入力された文書集合中の文書が述べている話題の数と同じでなければならない。前述のようにボトムアップの階層的なクラスタリング処理では、各クラスターは一つの文書から成る状態から出発し、最も近いクラスター同士をマージする処理を繰り返して最後は全文書が一つのクラスターに属することになる。従って、話題の数と同じ数のクラスターを得るにはクラスターのマージを打ち切ることが必要となる。これは、クラスターのマージ処理において類似度が閾値以下のクラスター対についてはマージを行わないようにすることにより実現可能である。しかしながら、実際には上述の閾値を如何に決めるかが難しい問題となっている。閾値が不適切であれば正しい数のクラスターは得られない。同様にトップダウンのクラスタリング処理では、ひとつのクラスター中のあらゆる文書対の中で最も低い類似度が閾値以上の場合にはクラスターの分割は行わないようにすれば、原理的には話題の数と同じ数のクラスターが得られる筈である。

40

【0005】

50

しかしながら、この場合にも閾値をどのように決めるかが難しい問題となっている。また、非階層的なクラスタリングでは、ユーザーは与えられた文書集合を何個のクラスターに分割するかの情報を事前に入力することを求められる。しかしながら、クラスター数の情報は入力文書集合の事前の知識なしには正確に与えることは不可能である。このように入力文書集合から正しい数のクラスターを得ることは難しい問題となっている。非階層的なクラスタリングでクラスター数を正しく推測する試みもなされており、性能は向上しているが完璧ではない（非特許文献1）。

【0006】

2番目の問題はクラスタリングにおける精度の問題である。これは、ひとつのクラスターに属する文書が同じ話題を述べているかどうかの問題である。クラスタリング処理では、通常は文書は、各成分が文書中に現れる各用語の有無、もしくは出現頻度で与えられるベクトルで表現され、2つのクラスター間の類似度は、異なるクラスターに属する文書対の余弦類似度をもとに、ある文書とクラスター間の類似度はその文書のベクトルとそのクラスターに属する文書の平均ベクトルとの間の距離（例えばユークリッド距離）をもとに求められていた。従来のクラスタリング処理では、上記の余弦類似度やユークリッド距離を求めるときに、どのような用語がそのクラスターに重要なのかを検証することなく、各文書で得られたベクトルをそのまま用いることが多かった。そのため、各クラスターに本質的でない情報を表す用語や用語対の存在がクラスタリングの精度に影響を及ぼした。

【0007】

3番目の問題は話題の階層性の抽出である。通常、話題には階層性が存在する。例えば“イラク戦争”という話題を例にとると、“イラク戦争”に関連するニュース記事の中には様々な下位の話題が存在する。例えば、“サダムフセイン”、“国連による大量破壊兵器の査察”、“ブッシュ大統領の態度”、“フランス、ドイツ、ロシアの反対”などが挙げられる。従って、実際のクラスタリングにおいては、ニュース記事の集合全体に対してクラスタリングを行い、その結果として得られるであろう“イラク戦争”に関するニュース記事の集合に対してサブクラスタリングを行って下位の話題に対応する文書のグループが得られるようになることが望まれる。しかしながら、現状の技術では、前述のように、各話題に対応したクラスターを正しく求め、各文書を正しいクラスターにアサインすることは難しかったので、サブクラスタリングも難しい課題として残されていた。

【課題を解決するための手段】

【0008】

先ず、階層化を伴わないフラットなクラスタリングを考える。文書クラスタリングは各文書が記述する話題によって文書をグループ化するものであるから、ひとつのクラスターに属する文書（クラスター文書集合と呼ぶ）は同じ話題について述べている筈である。従って、クラスター文書集合は何らかの共通性を有する筈である。また、各話題にはその話題には多く出現し、他の話題にはあまり出現しない話題特有の用語や用語対が存在する筈である。従って、各クラスターには用語や用語対の出現傾向に違いが存在する筈である。このようなことから、本発明ではクラスタリングの精度を高めるために、クラスタリングの過程で、

A)：着目クラスター文書集合の共通情報を抽出し、この共通情報との近さにより各文書の着目クラスターに対する近さ（文書共通度）を求める。

B)：着目クラスターに特有でない用語や用語対を検出し、上記文書共通度の算出においてはそれらの影響を排除する。

という手段を導入する。

【0009】

従来の階層的な処理では、クラスターのマージや分割が頻繁に繰り返される。また、従来の非階層的な処理では、クラスターのメンバーがやはり頻繁に入れ替わる。このような状況では各クラスターの共通情報、クラスターに非特有用語や用語対の検出には無理がある。そこで、本発明ではクラスタリングの全体の手順として以下を採用する。

【0010】

ステップ1：最初の繰り返しにおいては全文書から、2回目以降の繰り返しにおいては、その時点で存在するどのクラスターに対しても文書共通度が一定値以下の文書の中から、クラスターの種の候補となる文書を検出する。

ステップ2：先ず、クラスターの種の各候補文書について、全文書との類似度を求め一定値以上の類似度を有する文書を抽出する。その文書数が最も大きくなる候補文書をクラスターの種とし、その文書集合によりクラスターを形成する。

ステップ3：その時点でのクラスター文書集合と各文書との間で文書共通度を求め、一定値以上の文書共通度を有する文書をそのクラスターに一時的に帰属させることによりクラスターを成長させる。クラスターに一時的に属する文書数が一定になればステップ4へ移行する。そうでなければ本ステップを繰り返す。

ステップ4：終了条件を満たせばステップ5へ移行する。そうでなければステップ1に戻って続行する。

ステップ5：各文書について各クラスターへの文書共通度を求め、文書共通度が一定値以上のクラスターに帰属させる。

ステップ6：1つの話題に2つ以上のクラスターが対応していないかどうかを検出する。そのようなクラスターがあれば冗長なクラスターとして削除し、各文書の帰属するクラスターを求めなおす。

【0011】

上記のクラスタリング手順において、前記A)の共通情報を用いる文書共通度の算出、及びB)の着目クラスターに特有でない用語や用語対の検出はステップ3と5において行われることになる。A)については、その時点での着目クラスターに一時的に帰属している文書から共通情報を抽出することになる。共通情報の抽出と利用は特願2002-326157で述べられている方法を援用することができる。基本的な考え方は次の通りである。いま、着目クラスターがR個の文書から成るものとし、各文書から一つずつ文を取り出してR個の文からなる文の組を作ったとする。このような文の組は各文書の文の数の積通り存在することになる。ここでは、着目する文の組において、R個の文のうちのA個以上の文に現れる用語を共通用語、共通用語で構成された文を共通文と呼ぶこととする。A個以上の文書に出現する用語はいずれかの文の組において共通用語となる。ここで、全ての文の組で共通文を作り、共通文の集合を構成したとする。このような共通文の集合は着目クラスターの共通の話題の内容を示すものと考えられる。従って、各文書と共通文集合との間で何らかの手段で類似度を求め、文書共通度とすると、それは各文書の着目クラスターの共通話題への近さを表わすことになる。

【0012】

さらに、各文書と共通文集合との間の類似度ではA個以上の文書に出現する用語を含む文書のみがゼロでない類似度を有する。ここで、Aを A_1 、または A_2 ($A_1 > A_2$) に設定した場合を考えてみる。明らかに A_1 個以上の文書に出現する用語の方が A_2 個以上の文書に出現する用語よりも着目クラスターにおける共通性は高い。従って、Aを A_2 に設定した場合、 A_1 に設定した場合に比べてより共通性の低い用語のみを含む文書もゼロでない類似度を有することになる。また、 A_1 個以上の文書に出現する用語の何れかを含む文書の本数は A_2 個以上の文書に出現する用語の何れかを含む文書の本数よりも少ない。従って、このような類似度をステップ3と5に適用すると、Aを大きな値に設定した場合、クラスターは話題の揃った少数の文書で構成され、反対にAを小さな値に設定した場合、クラスターは広範な話題を含むより多数の文書で構成されるようになる。本発明ではAの値によりクラスターの話題の揃い方を制御する。

【0013】

またB)の着目クラスターに特有でない用語や用語対の検出は次のような考え方で行うものである。種文書が話題iの着目クラスターの成長の過程を考える。話題iを述べている文書数は、文書集合全体には c_0 個、着目クラスターの文書集合にはc個存在したとする。また、用語mを含む文書数は、文書集合全体では U_{mm}^0 個、着目クラスターの文書集合では U_{mm} 個存在したとする。用語mが話題iの特有用語の時には用語mは話題iの文書に多く現れるの

10

20

30

40

50

で、

【 0 0 1 4 】

【 数 5 】

$$U_{mm}^0 / U_{mm} \approx c_0 / c$$

【 0 0 1 5 】

となり、非特有の時には話題*i*以外の話題の文書にも現れるので、

【 0 0 1 6 】

【 数 6 】

$$U_{mm}^0 / U_{mm} > c_0 / c$$

10

【 0 0 1 7 】

となる筈である。従って、 c_0 / c を適当な方法で求めることができれば用語*m*が話題*i*に特有か否かを判断することができる。 U_{mm}^0 / U_{mm} を用語*m*の文書頻度比と呼ぶことにすると、本発明では、着目クラスターの文書集合において最も頻度の高い一定個の用語のうち、文書頻度比の値の小さな一定個は話題*i*の特有用語とみなし、これらの用語の文書頻度比の平均*c'*を c_0 / c の推測値とした。結局、 c' をパラメータとして

【 0 0 1 8 】

【 数 7 】

$$U_{mm}^0 / U_{mm} > \alpha c'$$

20

【 0 0 1 9 】

を満たす用語*m*は話題*i*には特有用語ではないと判断できる。

同様に、用語*m*、*n*を含む文書数は、文書集合全体では U_{mn}^0 個、着目クラスターの文書集合では U_{mn} 個存在したとして、

【 0 0 2 0 】

【 数 8 】

$$U_{mn}^0 / U_{mn} > \alpha c'$$

【 0 0 2 1 】

30

を満たす用語対*m*、*n*は話題*i*には特有用語対ではないと判断できる。

文書共通度は着目クラスターに本質的でない用語や用語対の影響を受けにくくするためには、話題*i*には特有ではないと判断された用語、用語対は、各文書と着目クラスターの文書集合との文書共通度の算出に用いないようにすればよい。もしくは、

【 0 0 2 2 】

【 数 9 】

$$c' / (U_{mn}^0 / U_{mn})$$

【 0 0 2 3 】

【 数 1 0 】

40

$$c' / (U_{mn}^0 / U_{mn})$$

【 0 0 2 4 】

をそれぞれ用語*m*、用語対*m*、*n*の重みとして用いて文書共通度の算出を行ってもよい。このようにすることにより、話題*i*を述べた文書に対して文書共通度は大きな値をとるようになる。その結果クラスタリングの精度の向上が期待できる。

【 0 0 2 5 】

上記のクラスタリングの全体手順においては、先ずクラスターの種となる文書をひとつ取り出し、ついでその種と同じ話題を記述する文書を検出して種を成長させるという処理を繰り返し行うこととなる。従って、種の文書の数が入力文書における話題の数と過不足な

50

く一致すれば正しい数のクラスターが得られることになる。たとえステップ1において同じ話題に対して2つの種文書が検出されたにしても、ステップ6で冗長なクラスターを検出して除去するので正しい数のクラスターが得られる。また、ステップ1においてある話題に対して種文書が検出されない時にはクラスターの数不足になることになる。このような事態は、クラスタリングの精度が低く、検出されるべき話題の文書がすでに存在するクラスターとの文書類似度が高くなってしまった時に起きる。言い換えれば、このような事態は、クラスタリングの精度が低いために、ひとつのクラスターに本来有すべきでない話題を有する文書が混入することによって引き起こされる。しかしながら、本発明では上記A)、B)の手段によってクラスタリングの精度を高めているので異なる話題の文書の混入の可能性は低く、求められるクラスターの数が少なくなるという事態は起こりにくい。本発明では正しい数のクラスターが得られる公算が非常に大きい。

10

【0026】

また、クラスターの階層化は、前記Aの値を変えつつ、もしくはクラスタリング処理に用いる用語、用語対を選択しつつ、上記クラスタリング方法を再帰的に適用することにより実現する。ここで、色々な話題を含む文書集合が存在する層を第0層、第0層のクラスタリングを行って、“イラク戦争”、“SARS”などの同じ話題を含む文書集合に分けられた層を第1層、第1層に存在する親の文書集合をサブクラスタリングによって下位の話題で再分類した層を第2層と呼ぶこととする。以下も同様である。階層的なクラスターを求める処理では、先ず第0層の文書集合に対して前記Aの値に適当な値を設定して前述のクラスタリング処理を行う。この処理で得られるひとつの文書集合に属する文書は共通の話題を述べている筈である。

20

【0027】

次に、第1層に存在するひとつの文書集合に対するサブクラスタリングでは、Aの値として相対的により大きな値を設定してより話題の揃ったクラスターが得られるようにする。その結果、第1層の既にある程度の共通性を有する文書集合が細分化され、同じ下位の話題を述べた文書集合が得られるようになる。また、第2層で得られるサブクラスターの特有用語、用語対は第1層の親となる文書集合全体においては出現頻度の小さい用語、用語対の筈である。従って、親となる文書集合において出現頻度の高い用語、用語対を除去したうえで前述のクラスタリング処理を施すことにより、第2層で有効なサブクラスターが得られるようになる。第3層以下も同様である。

30

【実施例】

【0028】

図1は、本発明の概要を示すブロック図である。110は文書入力ブロック、120は文書前処理ブロック、130は文書情報処理ブロック、140は出力ブロックを示す。文書入力ブロック110には、処理したい文書集合が入力される。文書前処理ブロック120では、入力された文書の用語検出、形態素解析、文書セグメント区分け等が行われる。文書セグメントについて説明する。文書セグメントは文書を構成する要素であり、その最も基本的な単位は文である。英文の場合、文はピリオドで終わり、その後ろにスペースが続くので文の切出しは容易に行うことができる。その他の文書セグメントへの区分け法としては、ひとつの文が複文からなる場合主節と従属節に分けておく方法、用語の数がほぼ同じになるように複数の文をまとめて文書セグメントとする方法、文書の先頭から含まれる用語の数が同じになるように文とは関係なく区分けする方法などがある。文書情報処理ブロック130は以下に詳細に説明するが、情報処理を行い、種の文書の検出、全文書と着目クラスターとの文書集合共通度の算出、各クラスターの特有でない用語、用語対の検出などクラスタリングに直接関わる処理を行う。出力ブロック140は文書情報処理ブロック130で得られた結果を、ディスプレイ等の出力装置に出力する。

40

【0029】

この発明の方法は、汎用コンピュータ上でこの発明を組み込んだプログラムを走らせることによって実施することができる。図2は、そのようなプログラムを走らせている状態でのコンピュータのフローチャートである。ブロック21は文書集合入力、ブロック22は文

50

書前処理、ブロック23は全体文書情報抽出処理、ブロック24はクラスターの種文書及び初期クラスターの決定、ブロック25はクラスターの成長処理、ブロック26は残存文書検出、ブロック27は終了条件チェック、ブロック28は残存文書の文書情報抽出処理、ブロック29は帰属クラスター決定、ブロック30は冗長クラスターの検出・除去、である。以下、英文文書を例に実施例を説明する。

【 0 0 3 0 】

まず、文書集合入力21において対象となる文書集合が入力される。階層的なクラスタリングで第2層以下のサブクラスターを求めるときはこの文書集合は第1層におけるひとつのクラスターに属する文書集合となる。文書前処理22においては各入力文書に対して、用語検出、形態素解析、文書セグメント区分け、文書セグメントベクトル作成などの前処理が行われる。用語検出としては、各入力文書から単語、数式、記号系列などを検出する。ここでは、単語や記号系列などを総称して全て用語と呼ぶ。英文の場合、用語同士を分けて書く正書法が確立しているので用語の検出は容易である。次に、形態素解析では、各入力文書に対して用語の品詞付けなどの形態素解析を行う。文書セグメント区分けにおいて各入力文書に対して文書セグメントへの区分けを行う。文書セグメントベクトル作成では、まず文書全体に出現する用語から作成すべきベクトルの次元数および各次元と各用語との対応を決定する。この際に出現する全ての用語の種類にベクトルの成分を対応させなければならないということではなく、品詞付け処理の結果を用い、例えば名詞と動詞と判定された用語のみを用いてベクトルを作成するようにしてもよい。次いで、各文書セグメントに出現する用語に対応する成分のみが値1、他は0となるような文書セグメントベクトルを作成する。

【 0 0 3 1 】

全体文書情報抽出処理23では、後段のクラスタリング処理に用いるデータを各文書と入力文書集合全体から求める。求めるデータは各文書の共起行列、前記共通文集合の共起行列（共通共起行列）、入力文書集合全体の文書頻度行列である。各文書の共起行列は用語の出現頻度、用語間の共起頻度を反映する行列である。文を文書セグメントとした場合について説明を続ける。ここでは、現れる用語集合が $\{w_1, \dots, w_M\}$ で与えられ、 R 個の文書から成る入力文書集合 D を考える。さらに、 r 番目の文書を D_r とすると、 D_r は Y_r 個の文からなるものとし、 y 番目の文及びその文ベクトルを D_{ry} 、 $d_{ry} = (d_{ry1}, \dots, d_{ryM})^T$ とする。ここで、 T はベクトルの転置を表す。 d_{ry} は2値ベクトルであり、 d_{rym} は m 番目の用語の有無を表す。文書の D_r の共起行列を S^r とすると、これは

【 0 0 3 2 】

【 数 1 1 】

$$S^r = \sum_{y=1}^{Y_r} d_{ry} d_{ry}^T \quad (1)$$

【 0 0 3 3 】

で与えられる。式(1)から分かるように、 S^r の mn 成分は

【 0 0 3 4 】

【 数 1 2 】

$$S^r_{mn} = \sum_{y=1}^{Y_r} d_{rym} d_{ryn}$$

【 0 0 3 5 】

より与えられる。従って、 S^r_{mm} は文書 D_r において用語 m が生起する文の数、 S^r_{mn} は用語 m と n とが共起する文の数を表すことになる。もし同じ用語が同じ文に2回以上出現しないのであれば、 S^r_{mm} は文書 D_r における用語 m の出現頻度となる。次に、各文書の共起行列を用いて行列 T を算出する。行列 T の mn 成分 T_{mn} は次式で与えられる。

【 0 0 3 6 】

10

20

30

40

【数 1 3】

$$T_{mn} = \prod_{r=1}^R S_{mn}^r$$

$$S_{mn}^r > 0$$

【0 0 3 7】

さらに、入力文書集合における各用語、用語共起の文書頻度を格納した行列 U^0 を求める。 U_{mm}^0 、 U_{mn}^0 はそれぞれ用語 m の出現する文書数、用語 m 、 n の共起する文書数となる。このような行列 T 、 U^0 を用いて共通共起行列 T^A を求める。共通共起行列 T^A の mn 成分は以下のよう

$$T_{mn}^A = T_{mn} \quad U_{mn}^0 > A \text{ のとき}$$

$$T_{mn}^A = 0 \quad \text{それ以外}$$

A はパラメータであり、実験的に決められる。

【0 0 3 8】

また、 mn 成分が以下のように与えられる行列 Q^A を

$$Q_{mn}^A = \log(T_{mn}^A) \quad T_{mn}^A > 1 \text{ のとき}$$

$$Q_{mn}^A = 0 \quad \text{それ以外}$$

により定義し、共通共起行列として用いてもよい。

【0 0 3 9】

なお、階層的なクラスタリングで第2層以下のサブクラスターを求めるときは、 U_{mm}^0 、 U_{mn}^0 の値が実験的に決められる閾値以上の場合には0となるようにしてもよい。

【0 0 4 0】

クラスターの種文書及び初期クラスターの決定24では、前記ステップ1及び2に対応する処理を行う。ここで、その時点で存在するどのクラスターに対しても文書共通度が一定値以下の文書の集合を残存文書集合として求める。残存文書集合はその時点で存在するどのクラスターにも属さない公算の大きい文書の集合である。共通共起行列 T^A 、 Q^A 、文書頻度行列 U は最初の繰り返しにおいては入力文書集合に基づいて計算され、2回目以降の繰り返しにおいては、残存文書集合に基づいて計算される。一方、クラスターの種となる文書はどの話題の文書が選ばれようと、その話題の中では中心的な文書であることが望ましい。本発明では、残存文書集合の中で最も優勢な話題の文書群において中心的な文書は、残存文書集合との共通度も高いであろうとの仮定のもとに、残存文書集合中の文書と残存文書集合との文書共通度を求め、文書共通度の高い文書をクラスターの種の候補として選択する。任意の文書を P 、その共起行列を S^P とすると、文書 P と残存文書集合との文書共通度としては例えば以下を用いることができる。

【0 0 4 1】

【数 1 4】

$$com_q(D^i, P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M Q_{mn}^A S_{mn}^P}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M (Q_{mn}^A)^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M (S_{mn}^P)^2}} \quad (2)$$

【0 0 4 2】

式(2)において行列 Q^A の代わりに行列 T^A を用いることもできる。また、式(2)において、複数の話題に共通する用語の影響を軽減するために、共起行列、共通共起行列の対角成分は用いないようにしてもよい。

【0 0 4 3】

クラスターの種文書の候補は、残存文書集合中の全ての文書に対して式(2)により文書共通度を求め、文書共通度の高い一定個の文書を選択することにより求められる。次にクラスターの種文書の決定について説明する。先ず各候補文書について残存文書集合又は入力文書集合中の全ての文書との類似度を求める。類似度の尺度としては余弦類似度を用いることが出来る。次いで各候補文書について各候補文書との類似度が一定値より大きい文書を各候補文書の近隣文書として求める。近隣文書数が最も大きい文書を候補文書の中

10

20

30

40

50

から一文書選択することにより、クラスターの種文書が決定される。また、初期クラスターはその種文書の近隣文書で与えられる。

【 0 0 4 4 】

クラスターの成長処理25では、クラスターの初期クラスターと共通度の高い文書を吸収することによりクラスターを成長させる。図3はそのようなクラスターを成長させる処理のブロック図である。31は文書頻度行列作成、32は共通共起行列作成、33は用語・用語対の特有度算出、34は文書共通度算出、35はクラスターメンバー決定、36は終了条件チェックである。

【 0 0 4 5 】

文書頻度行列作成31、共通共起行列作成32では、その時点で一時的に着目クラスターのメンバーとなっている文書集合に対して、図2のブロック23における文書頻度行列作成処理、共通共起行列作成と同等の処理を行う。31で求められた文書頻度行列をUにより表す。32で求められた共通共起行列を T^A もしくは Q^A により表す。用語・用語対の特有度算出33では、各用語・用語対の特有度を決定し、重みを決定する。各用語・用語対の特有度の算出は U_{mm}^0 、 U_{mn}^0 の値が0でない用語・用語対に対して実行する。 U_{mm}^0 、 U_{mn}^0 の値が0の用語・用語対の特有度は0とする。先ず、前述のように、 U_{mm}^0/U_{mm} を用語mの文書頻度比として求め、Uから求められる最も頻度の高い一定個の用語のうち、文書頻度比の値の小さな一定個を着目クラスターの特有用語として選択する。次いで、これらの用語の文書頻度比の平均を平均文書頻度比 c' として求め、用語mの特有度 v_{mm} 、用語対m、nの特有度 v_{mn} を以下により決定する。

【 0 0 4 6 】

【 数 1 5 】

$$v_{mm} = c' / (U_{mm}^0 / U_{mm})$$

【 0 0 4 7 】

【 数 1 6 】

$$v_{mn} = c' / (U_{mn}^0 / U_{mn})$$

【 0 0 4 8 】

あるいは、特有用語に限定することなく、特有用語対と特有用語の両方を用いて平均文書頻度比を求めるようにしてもよい。この場合には U_{mn}^0/U_{mn} をmとnが等しくないときは用語対m、nの文書頻度比として、mとnが等しいときは用語mの文書頻度比として求め、Uから求められる最も頻度の高い一定個の用語、用語対のうち、文書頻度比の値の小さな一定個を着目クラスターの特有用語または用語対として選択する。次いで、これらの用語、用語対の文書頻度比の平均を平均文書頻度比 c' として求めるようにする。

【 0 0 4 9 】

用語m、用語対m、nの重みをそれぞれ z_{mm} 、 z_{mn} とする。これらは、重み決定関数 $f(x)$ を用いて、以下のように決定する。

【 0 0 5 0 】

【 数 1 7 】

$$z_{mm} = f(v_{mm})$$

【 0 0 5 1 】

【 数 1 8 】

$$z_{mn} = f(v_{mn})$$

【 0 0 5 2 】

$f(x)$ の決め方は任意であるが、 $f(x)=x$ 、 $f(x)=x^2$ のようにするのがひとつの方法である。あるいは、 x が一定値よりも大きいときは $f(x)=1$ 、そうでないときは $f(x)=0$ としてもよい。

【 0 0 5 3 】

文書共通度算出34では、全入力文書に対して着目クラスターとの文書共通度を算出する。

任意の文書をP、その共起行列を S^P とすると、文書Pの文書共通度は、

【 0 0 5 4 】

【 数 1 9 】

$$com_l(D, P; Q^A) = \frac{\sum_{m=1}^M z_{mm} Q_{mm}^A S_{mm}^P}{\sqrt{\sum_{m=1}^M z_{mm} (Q_{mm}^A)^2} \sqrt{\sum_{m=1}^M z_{mm} (S_{mm}^P)^2}}$$

【 0 0 5 5 】

もしくは、

【 0 0 5 6 】

【 数 2 0 】

$$com_q(D, P; Q^A) = \frac{\sum_{m=1}^M \sum_{n=1}^M z_{mn} Q_{mn}^A S_{mn}^P}{\sqrt{\sum_{m=1}^M \sum_{n=1}^M z_{mn} (Q_{mn}^A)^2} \sqrt{\sum_{m=1}^M \sum_{n=1}^M z_{mn} (S_{mn}^P)^2}}$$

【 0 0 5 7 】

により求めることができる。上式において行列 Q^A の代わりに行列 T^A を用いることもできる。

【 0 0 5 8 】

クラスターメンバー決定35では、ブロック34で求められた各文書の着目クラスターに対する文書共通度を用いて、一定値以上の文書共通度を有する文書を求め、着目クラスターの一時的なメンバーとする。

【 0 0 5 9 】

終了条件チェック36では、着目クラスターの成長処理を終了するか否かをチェックする。まず、初回の繰り返し、即ち初めて36に到達したときには無条件に31に戻って処理を繰り返す。2回目以降の繰り返しの時には、上記35で求められた着目クラスターのメンバーの文書数をカウントし、それが前回の繰り返しのメンバー数と等しくない場合には31に戻って処理を繰り返す。等しければ、全入力文書と着目クラスターとの文書共通度を保持し、着目クラスターの成長処理を終了する。

【 0 0 6 0 】

図2に戻って説明を続ける。残存文書検出26では、その時点で存在する全てのクラスターに対する各文書の文書共通度をもとに、どのクラスターに対しても文書共通度が一定値以下の文書を残存文書として抽出する。

【 0 0 6 1 】

終了条件チェック27では、残存文書数をもとにクラスターの種の検出から成長に到る一連の処理を終了するか否かのチェックを行う。例えば、残存文書数が0、もしくは残存文書数が一定値以下でかつ前回の繰り返し時の残存文書数と等しい場合にはブロック29に移行するようにする。もし、このような条件が満たされなければ、ブロック28に移行し、残存文書集合に対してブロック23と同等な処理を行う。

【 0 0 6 2 】

帰属クラスター決定29では、各文書が最終的に求められたクラスターのどれに帰属するかを決定する。これは、図3において各文書について求められた各クラスターに対する文書共通度の情報を用い、各文書は文書共通度が一定値以上のクラスターに帰属させることで実行できる。

【 0 0 6 3 】

冗長クラスターの検出・除去30では、冗長なクラスターが存在するか否かをチェックし、存在する場合には除去する。冗長なクラスターは、ひとつの話題に対して2つ以上のクラスターが求められたときに発生する。そのような時、その話題を記述した文書は2つ以上のクラスターに対して大きな文書共通度を有するようになり、2つ以上のクラスターが重複する格好になる。冗長なクラスター検出のためには、まず、求められた全てのクラスターと全ての文書との文書共通度を求め、次いで文書共通度が着目クラスターに対しては一定値よりも大きく、他のどのクラスターに対しても一定値よりも小さくなる文書数を求め

10

20

30

40

50

る。

【 0 0 6 4 】

そのような文書数は着目クラスターが他のクラスターと重複しない場合には、その着目クラスターと一定値以上の文書共通度を有する文書数と等しくなる。一方、着目クラスターが他のクラスターと重複する場合には、他のクラスターと重複していない文書数すなわち当該着目クラスターにのみ属する文書数となる。このような文書数を各クラスターの重要度と定義する。重要度は、図 4 (a) の場合「クラスター 1」及び「クラスター 2」に属する文書数である。重要度は、着目クラスターが他のクラスターと一部重複して存在する場合には、他のクラスターと重複していない文書数となる。すなわち、「クラスター 1」に対しては、図 4 (b) の「 c 」で示される部分に含まれる文書数を意味する。「クラスター 2」に対しては、図 4 (b) の「 d 」で示される部分に含まれる文書数を意味する。ひとつのクラスターの重要度が一定値よりも小さい場合は、そのクラスターに属する文書の数がいくら多くとも冗長なクラスターとみなし除去する。そのようなクラスターが複数存在すれば、クラスター重要度が最も小さいクラスターを先ず除去する。その後残されたクラスターについてクラスター重要度の算出を行い、クラスター重要度が最も小さいクラスターを除去する。このような処理を冗長なクラスターが存在しなくなるまで繰り返す。クラスターの削除を行った場合は、除去されたクラスターに属していた文書の帰属クラスターの決定を改めて行う。このときには、各文書は文書共通度が最も高くなるクラスターに帰属させるようにしてもよい。

10

【 0 0 6 5 】

ここで本発明の効果を説明する為に図 2、3 の実施例に沿った実験結果を示す。用いたコーパスはTDT2である。TDT2は1998年の1月から6月の間の100個のイベントに関するニュースストーリーの集合であり、6個のニュースソースから採取されている。本報告では同じくTDT2を用いて行われたLiuらの非階層型のクラスタリング（非特許文献1）の結果と比較するため、Liuらが行ったようにABC、CNN、VOAから採取された15イベントに関するニュースストーリーの集合を実験対象とした。表1にそれらの詳細を示す。

20

【 0 0 6 6 】

【表 1】

イベント ID	イベントの内容	文書数			
		ABC	CNN	VOA	Total
01	Asian Economic Crisis	27	90	289	406
02	Monica Lewinsky Case	102	497	96	695
13	1998 Winter Olympic	21	81	108	210
15	Current Conflict with Iraq	77	438	345	860
18	Bombing AL Clinic	9	73	5	87
23	Violence in Algeria	1	1	60	62
32	Sgt. Gene McKinney	6	91	3	100
39	India Parliamentary Election	1	1	29	31
44	National Tobacco Settlement	26	163	17	206
48	Jonesboro shooting	13	73	15	101
70	India, A Nuclear Power?	24	98	129	251
71	Israeli-Palestinian Talks	5	62	48	115
76	Anti-Suharto Violence	13	55	114	182
77	Unabomer	9	66	6	81
86	GM Strike	14	83	24	121

【 0 0 6 7 】

表2に実験に用いられた14種類のデータセットとそれに対する提案手法とLiuらの手法のクラスタリングの精度を示す。Liuらの手法の結果はLiuらの論文より再掲したものである。本発明では、ある文書が属するイベントとその文書が帰属するクラスターの種となった文書のイベントが一致するときクラスタリングの結果は正しいとされる。また、全てのクラスターに対して文書共通度が0の文書は誤りとする。精度は正しくクラスタリングされた文書数の全文書数に対する比により求める。Liuらの方法は、混合ガウス分布モデル (Gaussian Mixture Model) に基づき非階層形のクラスタリングを行った後、各クラスターの特有用語を求め、特有用語の投票によって結果を修正している。表2において、テストデータのABC-01-02-15とあるのは、ABCより採取されたイベントIDが01、02、15に属する文書であることを意味している。表2から、精度の高いデータセットの数は、Liuらの方法よりも本発明の方が多く、本発明が優ることが分かる。

【 0 0 6 8 】

【表 2】

番号	データセット	Liuらの方法	本発明
1	ABC-01-02-15	1.0000	0.9806
2	ABC-02-15-44	0.9902	0.9805
3	ABC-01-13-44-70	1.0000	1.0000
4	ABC-01-44-48-70	1.0000	1.0000
5	CNN-01-02-15	0.9756	0.9932
6	CNN-02-15-44	0.9964	0.9964
7	VOA-01-02-15	0.9896	0.9986
8	VOA-01-13-76	0.9583	0.8943
9	VOA-01-23-70-76	0.9453	0.9206
10	VOA-12-39-48-71	0.9898	1.0000
11	VOA-44-48-70-71-76-77-86	0.8527	1.0000
12	ABC+CNN-01-13-18-32-48-70-71-77-86	0.9704	0.9917
13	CNN+VOA-01-13-48-70-71-76-77-86	0.9262	0.9500
14	ABC+CNN+VOA-44-48-70-71-76-77-86	0.9938	1.0000

10

20

【 0 0 6 9 】

また、求められるクラスターの個数も表 2 のデータに対して全て正しく求められている

。

30

また、Liuらの論文で挙げられている12種類のデータに対してもクラスター数は正しく求められている。一方、Liuらの方法では12種類のうち3種類のデータに対して正しく求められていない。表 3 にLiuらの方法及び本発明の結果を示す。

【 0 0 7 0 】

【表 3】

テストデータ	正しい クラスタ数	Liu等の テスト結果	本願発明の テスト結果
ABC-01-03	2	2	2
ABC-01-02-15	3	3	3
ABC-02-48-70	3	2	3
ABC-44-70-01-13	4	4	4
ABC-44-48-70-76	4	4	4
CNN-01-02-15	3	4	3
CNN-01-02-13-15-18	5	5	5
CNN-44-48-70-71-76-77	6	5	6
VOA-01-02-15	3	3	3
VOA-01-13-76	3	3	3
VOA-01-23-70-76	4	4	4
VOA-12-39-48-71	4	4	4

【 0 0 7 1 】

このように本発明によれば、入力文書集合から正しい数のクラスターを抽出すること、及び各文書が帰属すべきクラスターを精度よく決定することができ、ユーザの情報獲得の効率性が高められる。

なお、上記実施例は文書を例にとって説明したが、実施例で示した文書と同じ様に表現でき、かつ、同様の性質を有するパターンについても適用できる。すなわち、実施例で示した、文書をパターン、文書の用語をパターンの構成要素、文書セグメントをパターンセグメント、文書頻度行列をパターン頻度行列、文書共起行列をパターン共起行列、文書共通度をパターン共通度等のように置き換えることによって、本願発明がパターン集合に同様に適用できる。

【図面の簡単な説明】

【 0 0 7 2 】

【図 1】本発明の概略を示すブロック図である。

【図 2】文書集合が入力された段階からクラスターと各文書が帰属するクラスターが決定されるまでの手順を示す図である。

【図 3】一つのクラスターについて初期クラスターの段階からの成長の手順を示す図である。

【図 4】冗長なクラスターを削除する為のクラスターの重要度を説明する図である。

【符号の説明】

【 0 0 7 3 】


1 1 0 : 文書入力ブロック

1 2 0 : 文書前処理ブロック


1 3 0 : 文書情報処理ブロック

140：出力ブロック

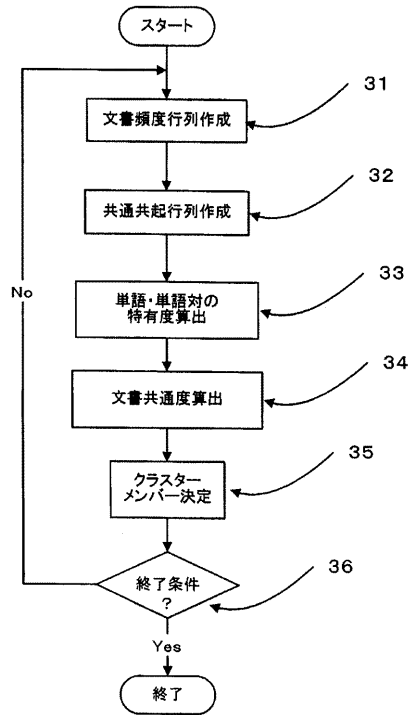
【図1】




【図2】



【図 3】



【図 4】



フロントページの続き

(56)参考文献 特開2002-108894(JP,A)

川谷隆彦, 多文書間の共通性の分析, 情報処理学会研究報告, 日本, 社団法人情報処理学会, 2002年11月12日, 第2002巻, 第104号, 第85-92頁(2002-NL-152-13)

(58)調査した分野(Int.Cl., DB名)

G06F 17/30