

第 2 章

意味の数学モデル

2.1 概要

ここでは、意味の数学モデルの概要を示す。厳密な定式化については、次節において述べる。

1. **前提:** いくつかの単語を特徴づけたデータの集合が、 m 行 n 列の行列 (以下, “データ行列” と呼ぶ) の形で与えられているものとする。この行列において, m 個のそれぞれの単語 (word) は, n 個の特徴 (features) によって特徴づけられている。
2. **イメージ空間 \mathcal{I} の設定:** データ行列から, 特徴づけに関する相関行列をつくる。そして, 相関行列を固有値分解し, 固有ベクトルを正規化する。相関行列の対称性から, この全ての固有値は実数であり, その固有ベクトルは互いに直交している。このとき, 非ゼロ固有値に対応する固有ベクトル (以下, “意味素” と呼ぶ) の張る正規直交空間をイメージ空間 \mathcal{I} と定義する。この空間の次元 ν は, データ行列のランクに一致する。また, この空間は, ν 次元ユークリッド空間となる。
3. **意味射影の集合 Π_ν の設定:** イメージ空間 \mathcal{I} から固有 (不変) 部分空間 (以下, “意味空間” と呼ぶ) への射影 (以下, “意味射影” と呼ぶ) の集合 Π_ν を考える。 i 次元の意味空間は, $\frac{\nu(\nu-1)\cdots(\nu-i+1)}{i!}$, ($i = 1, 2, \dots, \nu$) 個存在するので, 射影の総数は, 2^ν となる。つまり, このモデルは, 2^ν 通りの意味の様相の表現能力をもつ。
4. **意味解釈オペレータ S_p の構成:** 文脈を決定する l 個の単語列 (以下, “文脈語群” と呼ぶ) s_l としきい値 ε_s が与えられたとする。このとき, その文脈に応じた意味射影 $P_{\varepsilon_s}(s_l)$ を決めるオペレータ (以下, “意味解釈オペレータ” と呼ぶ) S_p を次

のように構成する。

- (a) 文脈語群 s_ℓ を構成する ℓ 個の単語を各タイムイメージ空間 I へ写像する。この写像では、 ℓ 個の単語を各タイムイメージ空間 I 内でフーリエ展開し、フーリエ係数を求める。これは、各単語と各意味素の相関を求めることに相当する。
- (b) 各意味素ごとに、フーリエ係数の総和を求める。これは、文脈語群 s_ℓ と各意味素との相関を求めることに相当する。また、このベクトルは、 ν 個の意味素があるため、 ν 次元ベクトルとなる。このベクトルを、無限大ノルムによって正規化したベクトルを、以下、文脈語群 s_ℓ の意味重心と呼ぶ。
- (c) このとき、文脈語群 s_ℓ の意味重心を構成する各要素において、しきい値 ε_s を超える要素に対応する意味素を、単語を射影する意味空間の構成に用いる。これにより、意味射影 $P_{\varepsilon_s}(s_\ell)$ を決定する。

このオペレータは、文脈語群と相関の高い意味空間の自動的な選択を実現する。

5. **意味空間における距離計算:** 文脈語群 s_ℓ により、各意味素ごとに重みを定める。そして、意味空間において、その重みを考慮した単語間の距離計算を行う。これにより、文脈に忠実な単語間の関係の解釈が可能となる。

このモデルにより、文脈に応じた単語間の関係の解釈(意味空間の選択、およびその空間内における最良近似)が可能となる。


2.2 定式化

本節では、意味の数学モデルの定式化について述べる。

2.2.1 イメージ空間 I の設定

ここでは、 m 個の単語について各々 n 個の特徴 (f_1, f_2, \dots, f_n) を列挙した各単語に対する特徴付ベクトル $w_i (i = 1, \dots, m)$ が与えられているものとし、そのベクトルを並べた m 行 n 列のデータ行列を A とする。

1. データ行列 A の相関行列 $A^T A$ を作る。



2. $A^T A$ を固有値分解する.

$$A^T A = Q \begin{pmatrix} \lambda_1 & & & \\ & \ddots & & \\ & & \lambda_\nu & \\ & & & 0 \cdots 0 \end{pmatrix} Q^T,$$

$0 \leq \nu \leq n.$

ここで行列 Q は,

$$Q = (q_1, q_2, \dots, q_n)^T$$

である. この q_i は, 相関行列の固有ベクトル, つまり意味素である.

3. このとき, イメージ空間 \mathcal{I} を以下のように定義する.

$$\mathcal{I} := \text{span}(q_1, q_2, \dots, q_\nu).$$

(q_1, \dots, q_ν) は \mathcal{I} の正規直交基底である.

2.2.2 意味射影集合 Π_ν の設定

P_{λ_i} を次の様に定義する.

$P_{\lambda_i} \stackrel{d}{\iff} \lambda_i$ に対応する固有空間への射影,

i.e. $P_{\lambda_i} : \mathcal{I} \rightarrow \text{span}(q_i).$

意味射影の集合 Π_ν を次のように定義する.

$$\begin{aligned} \Pi_\nu := \{ & 0, P_{\lambda_1}, P_{\lambda_2}, \dots, P_{\lambda_\nu}, \\ & P_{\lambda_1} + P_{\lambda_2}, P_{\lambda_1} + P_{\lambda_3}, \dots, P_{\lambda_{\nu-1}} + P_{\lambda_\nu}, \\ & \vdots \\ & P_{\lambda_1} + P_{\lambda_2} + \dots + P_{\lambda_\nu} \}. \end{aligned}$$

Π_ν の要素の個数は 2^ν 個であり, これは 2^ν 通りの意味の様相表現ができることを示している.

2.2.3 意味解釈オペレータ S_p の構成

文脈語群

$$s_\ell = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_\ell)$$

と, 正数 $\varepsilon_s (\varepsilon_s > 0)$ が与えられたとき, 意味解釈オペレータ S_p は, その文脈語群 s_ℓ に応じて, 意味射影 $P_{\varepsilon_s}(s_\ell)$ を決定する. すなわち, $s_\ell \in T_\ell, \Pi_\nu \ni P_{\varepsilon_s}(s_\ell)$ とすると, 意味解釈オペレータ S_p は, T_ℓ から Π_ν への作用素として定義される. また, $\{\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_\ell\}$ は, 特徴付ベクトルであり, データ行列 A の特徴と同一の特徴を用いている.

オペレータ S_p は次のように定義される.

1. $\mathbf{u}_i (i = 1, 2, \dots, \ell)$ をフーリエ展開する.

\mathbf{u}_i と \mathbf{q}_j の内積を u_{ij} とする.

$$u_{ij} := (\mathbf{u}_i, \mathbf{q}_j), \quad j = 1, 2, \dots, \nu.$$

ベクトル $\hat{\mathbf{u}}_i \in \mathcal{I}$ を次のように定める.

$$\hat{\mathbf{u}}_i := (u_{i1}, u_{i2}, \dots, u_{i\nu}).$$

これは, 単語 \mathbf{u}_i をイメージ空間 \mathcal{I} に写像したものである.

2. 文脈語群 s_ℓ の意味重心 $\mathbf{G}^+(s_\ell)$ を求める.

$$\mathbf{G}^+(s_\ell) := \frac{\left(\sum_{i=1}^{\ell} u_{i1}, \sum_{i=1}^{\ell} u_{i2}, \dots, \sum_{i=1}^{\ell} u_{i\nu} \right)}{\left\| \left(\sum_{i=1}^{\ell} u_{i1}, \sum_{i=1}^{\ell} u_{i2}, \dots, \sum_{i=1}^{\ell} u_{i\nu} \right) \right\|_\infty}$$

この $\|\cdot\|_\infty$ は, 無限大ノルムを示す.

3. 意味射影 $P_{\varepsilon_s}(s_\ell)$ の決定

$$P_{\varepsilon_s}(s_\ell) := \sum_{i \in \Lambda_{\varepsilon_s}} P_{\lambda_i} \in \Pi_\nu.$$

但し $\Lambda_{\varepsilon_s} := \{ i \mid (\mathbf{G}^+(s_\ell))_i > \varepsilon_s \}$ とする.

2.2.4 意味空間における距離計算

単語 x と単語 y 間の距離 $\rho(x, y; s_\ell)$, $x, y \in \mathcal{I}$ を次のように定める.

$$\rho(x, y; s_\ell) = \sqrt{\sum_{j \in \Lambda_{e_s}} \{c_j(s_\ell) (x_j - y_j)\}^2},$$

ここで, $c_j(s_\ell)$ は, 文脈語群 s_ℓ に依存して決まる重みであり, 次のように定義する.

$$c_j(s_\ell) := \frac{\sum_{i=1}^{\ell} u_{ij}}{\left\| \left(\sum_{i=1}^{\ell} u_{i1}, \dots, \sum_{i=1}^{\ell} u_{i\nu} \right) \right\|_{\infty}},$$

$$j \in \Lambda_{e_s}.$$

2.3 意味の数学モデルによる連想検索の実現

意味空間における距離が定まると, 文脈語を与え, 検索キーワードを与えることで, 検索対象単語群の中から, 検索キーワードに最も近い単語を選び出すことが可能となる. この動作が, 意味の数学モデルによる連想検索である.

意味の数学モデルによる連想検索システムの実現にあたり, “The General Basic English Dictionary” [24] と “Longman Dictionary of Contemporary English” [22] の 2 つの英英辞典を用いた. これらの辞書は基本単語が決められており, 基本単語のみで全ての単語を説明している.

まず, 最初に “Longman Dictionary of Contemporary English” における約 2,000 の基本英単語について, “The General Basic English Dictionary” の説明語を参照した. ただし, 基本語の活用形なども説明語に使用されているので, それらの単語を行列作成にする場合において, 次のフィルター群を用いて, 全ての単語の原型を使用した.

1. 熟語や慣用表現を同義語 1 単語に変換
2. 辞書中で「基本語以外の単語」とされている語を削除
3. 基本語に接頭語, 接尾語, 他の基本語が接続している語を基本語 (の列) に変換
4. 基本語の活用形や複数形を原型や単数形に変換
5. 未定義の基本語以外の単語 (固有名詞など) を削除
6. 句読記号, 文法記号など, 不要な記号を削除
7. 特徴語とするのに不適当な基本語を削除

8. 合成する必要のある基本語を合成した形に変換

上記の様に単語の原型のみの状態にした後、説明語の中に基本語が出ていれば 1, 出ていなければ 1, 反対の意味に用いられていれば -1 を与え, $2,000 \times 800$ の行列を作成した。次に行列のトランスポーズと行列そのものを掛け, 固有値分解を行い, 得られた固有ベクトルのみ構成される意味空間を作成した。検索で用いられる単語群も, フィルター群を用いて 0, 1, -1 の状態にし, ベクトル群を構成した。

その後, 文脈や状況を与えるベクトルによって部分空間を切り出し (閾値 ϵ_s を超えた軸のみで部分空間を構成する), 検索対象語や, キーワードとなる点を, その空間に乗せ, キーワードに最も近い検索対象語を, 文脈や状況に応じた検索対象語として取り出す。この一連の操作が意味の数学モデルによる連想検索である [32]。

本モデルを利用すると, 記号ではなく, 意味による情報伝達が可能になる。パターンマッチでは不可能なことが可能になるのである。実際, 本システムを利用して, マルチデータベースシステムへの応用研究 [12, 14, 16, 29, 34], 基本システムの高速度化研究 [33, 48], 画像データベースへの適用研究 [49, 30, 44], 学習システムの研究 [34], メディア情報検索システムの実現 [50] の研究がなされている。特に同一メディア間ではなく, 異種メディアによる検索が可能であることを強調したい。画像データベースシステムへの適用研究では, 画像を言葉で検索している。言葉で表せるものであれば, 全て本モデルで扱うことが可能なのである。