

自己組織化神経回路モデル (3)

論文紹介

P. Foldiak

Forming sparse representations by local anti-Hebbian learning,
Biological Cybernetics, vol. 64, pp. 165-170, 1990.

1. 情報表現の仕方 (発火率 p の違いに着目)

1.1. 局所表現 ($p = 1/n$)

n ... ニューロン数, p ... 活動度 $0 \leq p \leq 1$ (興奮しているニューロンの割合)
別名「おばあさん細胞」表現. SOM による表現形成. ヘブ学習と競合学習で実現

1.2. 分散表現 (完全分散 $p = 1/2$)

1.3. スパース表現 (例: $p = \log n$)

それぞれの利点: 容量, 耐ノイズ性, ...

2. 数理モデル

2.1. ネットワークの構造 (二層の回路)

入力 $x_1, x_2, \dots, x_m \in \{0, 1\}$

出力 $y_1, y_2, \dots, y_n \in \{0, 1\}$

2.2. ニューロン活動のダイナミクス

$$\frac{dy_i}{dt} = f \left(\sum_{j=1}^m q_{ij} x_j + \sum_{j=1}^n w_{ij} y_j^* - t_i \right) - y_i^*$$

$$f(u) = \frac{1}{1 + \exp(-\lambda u)}$$

2.3. 学習アルゴリズム

入力層の素子 x_j と出力層の素子 y_i の間: Hebb 学習 $\Delta q_{ij} = \beta y_i (x_j - q_{ij})$

出力層内: anti-Hebb 学習 $\Delta w_{ij} = \alpha (y_i y_j - p^2)$ 学習の平衡状態で $E[y_i y_j] = p^2$

出力素子の閾値: $\Delta t_i = \gamma (y_i - p)$ 平均活動度を p にする

3. コンピュータシミュレーション その1: 縦線, 横線の学習

3.1. 図1: ネットワークの構造 (入力層 64 個, 出力層 16 個)

3.2. 図2: 入力信号の例 ($8 \times 8 = 64$ ピクセル)

入力は縦線, 横線の組合わせ. 各縦線, 横線が確率 $1/8$ で独立に on/off

表現可能なパターンの総数 2^{64} 個

そのうち入力として出現する可能性のあるパターンの総数 2^{16} ($\ll 2^{64}$) 通り

3.3. 図3: 自己組織化が進む様子 ($t = 0, 400, 800, 1200$) . $q_{ij}, i = 1, \dots, 16$ を表示 .

4. コンピュータシミュレーション その2：文字の学習

- 4.1. 図1：ネットワークの構造（入力層 120 個，出力層 16 個）
- 4.2. 図4：自己組織化の様子（ $t = 0, 4000, 8000, 16000$ ）. $q_{ij}, i = 1, \dots, 16$ を表示 .
- 4.3. 入力パターン：Sun-3 ワークステーションのフォント .
各文字が出現する頻度を，ある英文で使われている頻度に設定 .
入力層で表現可能なパターンの総数は 2^{120} 個 . そのうち出現するのは 82 個 .
出力層には 16 素子あるので $2^{16} = 256$ 通りのパターンを 1 対 1 で表現できる .
（実際には 256 パターンのうち，48 パターンが使われるようになった） .
- 4.4. 表1：学習後，各文字を入力すると，どういう出力パターン（16 ビット）が出力されるようになったかを示した一覧表 . 多対 1 の写像になっていることに注意 .
例：k, B, R, F を入力すると，どの場合も出力は 0000010000010000 になる .
- 4.5. 表2：各表現（入力パターン出力パターン）の性質

4.5.1. 入力

$A_j \dots j$ 番目の文字の出現頻度 . $j = 1, \dots, 82$.

$$E(A) = - \sum_{j=1}^{82} A_j \log_2 A_j = 4.34 \text{ bit}$$

j 番目の文字の入力パターン $(a_{1j}, a_{2j}, \dots, a_{120j})$

$$q_i = \sum_{j=1}^{82} a_{ij} A_j \dots \text{入力パターンの } i \text{ 番目の要素の平均値 (1 になる確率)}$$

$$e(A, a) = - \sum_{i=1}^{120} [q_i \log q_i + (1 - q_i) \log(1 - q_i)] = 24.14 \text{ bit}$$

4.5.2. 出力

82 通りの入力に対して得られる出力 $b_k = (b_{1k}, b_{2k}, \dots, b_{16k})$, $k = 48$

$B_k \dots b_k$ を観測する確率

$$E(B) = - \sum_k B_k \log_2 B_k = 4.22 \text{ bit}$$

各文字パターンを 16 ビットの列に変換したところ，出力パターンの総数は 82 個より小さく，48 個になっていた ($k = 48$) . そのため，もとのエントロピーより小さくなっている .

$$p_i = \sum_{k=1}^{48} b_{ik} B_k \dots \text{出力層の素子の } i \text{ 番目の要素が 1 になる確率}$$

$$e(B, b) = - \sum_{i=1}^{16} [p_i \log p_i + (1 - p_i) \log(1 - p_i)] = 5.86 \text{ bit}$$

スパース性：16 ビットのうち，1 の個数は 0 ~ 4 になっている .

出現頻度が高い文字ほど 1 の数が少ないパターンに符合化されている .

4.5.3. 各ビットのエントロピーの和は何を意味するか .

$H(X), H(Y) \leq H(X, Y) \leq H(X) + H(Y)$ の関係を思い出す .

$$H(p_i) \leq H(p_1, p_2, \dots, p_{16}) \leq H(p_1) + H(p_2) + \dots + H(p_{16})$$

16 個のビットが互いに独立な場合に = が成立する .

$$H(p_1, p_2, \dots, p_{16}) = 4.22 \text{ [bits]}$$

$$H(p_1) + H(p_2) + \dots + H(p_{16}) = \sum_{i=1}^{16} H(p_i) = 5.86 \text{ [bits]}$$

$$\text{冗長性} : [e(B, b) - E(B)]/E[B] = (5.86 - 4.22)/4.22 = 0.388$$

この意味：すべてのビットが独立だと仮定すると 5.86 ビットの情報を得られる．実際には 4.22 ビットしか得られなかった．これをどうして著者らは冗長性と定義したか． 4.22 ビットの情報を表現するのに 5.86 ビット使用，と考える．入力パターンについても同様に考える：

$$\text{冗長性} : [e(A, a) - E(A)]/E[A] = (24.14 - 4.34)/4.34 = 4.562$$

5. その他

5.1. パラメータ $\alpha, \beta, \gamma, \lambda$ などは，どう決定したか．

5.2. 速修 確率論と情報理論

- 情報の量をいかに定めるか
- エントロピーとは
- 確率変数の依存性，確率変数が互いに独立であるとは