

### 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.
- キーワード
  - 局所表現, 分散表現, スパース表現
  - 情報分離, 情報圧縮, 独立成分, 教師なし学習
- いろいろな情報表現 (発火率の違いに着目)
  - ニューロン数  $n$ , 活動度  $p, 0 \leq p \leq 1$  (興奮しているニューロンの割合)
  - 局所表現 ( $p = 1/n$ )
    - \* 「おばあさん細胞」表現とも呼ばれる
    - \* ヘブ学習と競合学習で実現
    - \* 表現形成の最も単純なモデルが SOM
  - 完全分散表現 ( $p = 1/2$ )
  - スパース表現 (例:  $p = \log n$ )
  - それぞれの利点, 容量, 耐ノイズ性, ...
- ネットワークの構造
  - 入力  $x_1, x_2, \dots, x_m \in \{0, 1\}$
  - 出力  $y_1, y_2, \dots, y_n \in \{0, 1\}$
- 学習アルゴリズム
  - 入力素子と出力素子間:  
ヘブ学習  $\Delta w_{ij} = \alpha(y_i y_j - p^2)$  学習の平衡状態で  $E[y_i y_j] = p^2$
  - 出力層内: 反ヘブ学習  $\Delta q_{ij} = \beta y_i (x_j - q_{ij})$
  - 出力素子の閾値:  $\Delta t_i = \gamma(y_i - p)$  平均活動度を  $p$  にする]
- 例 1: 縦線, 横線の学習
  - 図 1: ネットワークの構造 (入力層 64 個, 出力層 16 個)
  - 図 2: 入力信号の例 ( $8 \times 8 = 64$  ピクセル)  
入力は縦線, 横線の組み合わせ. 各縦線, 横線が確率  $1/8$  で独立に on/off  
入力層には 64 素子 表現可能なパターンの総数  $2^{64}$  個  
そのうち縦線と横線の組み合わせのパターンの総数  $2^{16}$  通り
  - 図 3: 自己組織化の様子 ( $t = 0, 400, 800, 1200$ )
- 例 2: 文字の学習

- 図1: ネットワークの構造 (入力層 120 個, 出力層 16 個)
- 図4: 自己組織化の様子 ( $t = 0, 4000, 8000, 16000$ )  
 入力には Sun-3 ワークステーションのフォント. 各文字を入力する頻度は, ある英文で使われている頻度に設定. 入力層には 120 素子あるの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  $2^{16} = 256$  までは 1 対 1 で表現できる構造にはなっている (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).
- 表1: 学習後, 各文字がどういう出力 (16 ビット) に変換されるようになったか示した一覧表. 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.
- 表2: 符合の性質

\* 入力

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

$$E(A) = - \sum_j A_j \log_2 A_j = 4.34$$

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

$q_i = \sum_j A_j a_{ij} \cdots i$  番目のビットの平均値 (ビットが 1 になる確率)

$$e(A, a) = - \sum_i [q_i \log q_i + (1 - q_i) \log(1 - q_i)] = 24.14$$

\* 出力

$A_j$  を入力したときに得られる出力  $b_k = (b_{1k}, b_{2k}, \dots, b_{16k})$

$B_k \cdots b_k$  を観測する確率

$$E(B) = - \sum_k B_k \log_2 B_k = 4.22$$

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.

$p_i = \sum_k B_k b_{ik} \cdots i$  番目のビットが 1 になる確率

$$e(B, b) = - \sum_i [p_i \log p_i + (1 - p_i) \log(1 - p_i)] = 5.86$$

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.

\* 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：

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

- パラメータ  $\alpha, \beta, \gamma, \lambda$  などは，どう決定したか．
- 速修 確率と情報理論
  - 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