

- 1 はじめに
- 2 動径基底関数
ネットワークの
概要
- 3 適者生存型学習
則の導出
- 4 競合動径基底関
数ネットワークの
提案
- 5 シミュレーション
ならびに考察
- 6 むすび

適者生存型学習則を適応した 競合動径基底ネットワーク

**Competitive Radial Basis Function Networks Applying the
"Survival of the Fittest Type" Learning Algorithm**

May 17, 2024

1 本研究の背景

2/30

背景

動径基底関数ネットワーク (Radial Basis Function Networks: 以下 RBFN) は階層型ニューラルネットワークに比較してニューロンごとの局所的な学習が可能であるなどの優れた点を持つ。しかし、RBFN では未知の非線形関数を近似するためにあらかじめ必要なニューロン数が不明であるために冗長なニューロンを必要とする。

- 動径基底関数ネットワーク … 有限個の出入力データを補完する方法として提案された 3 層（入力層、中間層、出力層）から構成されるニューラルネットワーク
- 階層型ニューラルネットワーク … 層で区分けされたユニットによって信号が順次処理され出力が得られるネットワーク。入力層、隠れ層、出力層

2 動径基底関数ネットワークの概要

3/30

RBFN

1はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

非線形関数 $\eta(X)$ を動径基底関数 $\xi^i(X)$ の足し合わせで近似するニューラルネットワークである。 d 次元の入力ベクトル $X_j \in R^d (j = 1, 2, \dots, N)$ は全ての入力ニューロンに入力される。

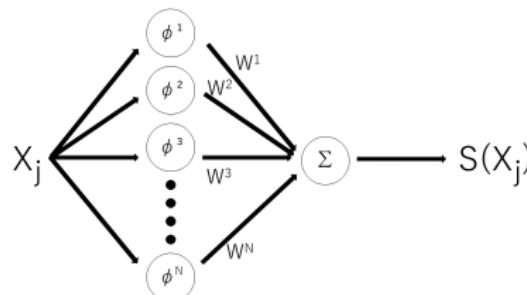


図 1

- パラメータ $\phi^i \equiv [m^i, \sum^i]$
- $m^i \equiv [m_1^i, m_2^i, \dots, m_d^i]^T$
- 正定値行列 $\sum^i \in R^{d \times d}$
- シナプス結合荷重 : w^i

2 動径基底関数ネットワークの概要

4/30

- 1 はじめに
- 2 動径基底関数ネットワークの概要
- 3 適者生存型学習則の導出
- 4 競合動径基底関数ネットワークの提案
- 5 シミュレーションならびに考察
- 6 むすび

第 i 入力ニューロンは入力ベクトル X_j に対して

$$\xi^i(X_j) = \exp\left\{-\frac{1}{2}(X_j - m_i)^T \sum_i^{-1} (X_j - m_i)\right\} \quad (1)$$

■ T ：ベクトルの転置

を出力する。出力値 ($\xi^i(X_j)$) はシナプス荷重結合 (W^i) を通して出力ニューロンへ伝達され、出力ニューロンでこれらは足し合わされ

$$S(X_j) = \sum_i^N \xi^i(X_j) \quad (2)$$

が出力される。

2 動径基底関数ネットワークの概要

5/30

- 1はじめに
- 2動径基底関数ネットワークの概要
- 3適者生存型学習則の導出
- 4競合動径基底関数ネットワークの提案
- 5シミュレーションならびに考察
- 6むすび

RBFNによる関数近似は2乗誤差評価関数を減少させることにより実現される。

$$E(W) = \frac{1}{2} \sum_j^M \{\eta(X_j) - s(X_j)\}^2 \quad (3)$$

以上の事より,RBFNが学習により獲得しなければならないのは

- 第*i*ニューロンのシナプス結合荷重 W^i
- パラメータ m^i
- パラメータ \sum^i

二乗誤差

予測値と正解ラベルの誤差を2乗したもの.

$$E = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (4)$$

2 動径基底関数ネットワークの概要

Delta ルールを適用することにより、

$$\begin{aligned} \frac{dw^i}{dt} &= -\Delta \frac{\partial E(W)}{\partial W^i} \\ &= \Delta \sum_j^M \{\eta(X_j) - S(X_j)\} \xi^i(X_j) \end{aligned} \quad (5)$$

$$\begin{aligned} \frac{dm_1^i}{dt} &= -\Delta \frac{\partial E(W)}{\partial m_1^i} \\ &= \Delta \sum_j^M \{\eta(X_j) - S(X_j)\} W^i \xi^i(X_j) \times \frac{X_j - m_1^i}{\sigma^{i2}} \end{aligned} \quad (6)$$

$$\begin{aligned} \frac{d\sigma^i}{dt} &= -\Delta \frac{\partial E(W)}{\partial \sigma^i} \\ &= \Delta \sum_j^M \{\eta(X_j) - S(X_j)\} W^i \xi^i(X_j) \times \frac{X_j - m_1^i}{\sigma^{i3}} \end{aligned} \quad (7)$$

が得られる。簡単のため $d = 1, \sum^i = \sigma^i$ とした。

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

2 動径基底関数ネットワークの概要

7/30

Delta ルール

出力の誤差を最小化するようにニューラルネットワークの重みを調整することである。ニューラルネットワークが output する値と正解データとの間の誤差をもとに重みを更新する。

$$\Delta w_{ij} = \eta(t_j - y_j)x_i \quad (8)$$

- Δw_{ij} : 重み w_{ij} の更新量
- η : 学習率, 重みの更新ステップの大きさを決定する
- t_j : 教師信号 (目標出力)
- y_j : ニューラルネットワークによる現在の出力
- x_i : 入力ノード i の入力値

このルールにより、ニューラルネットワークは期待される出力と実際の出力の誤差を小さくする方向に重みを調整する。

1 はじめに
2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

3 ニューロンの仕組み

- 1 はじめに
- 2 動径基底関数ネットワークの概要
- 3 適者生存型学習則の導出
- 4 競合動径基底関数ネットワークの提案
- 5 シミュレーションならびに考察
- 6 むすび

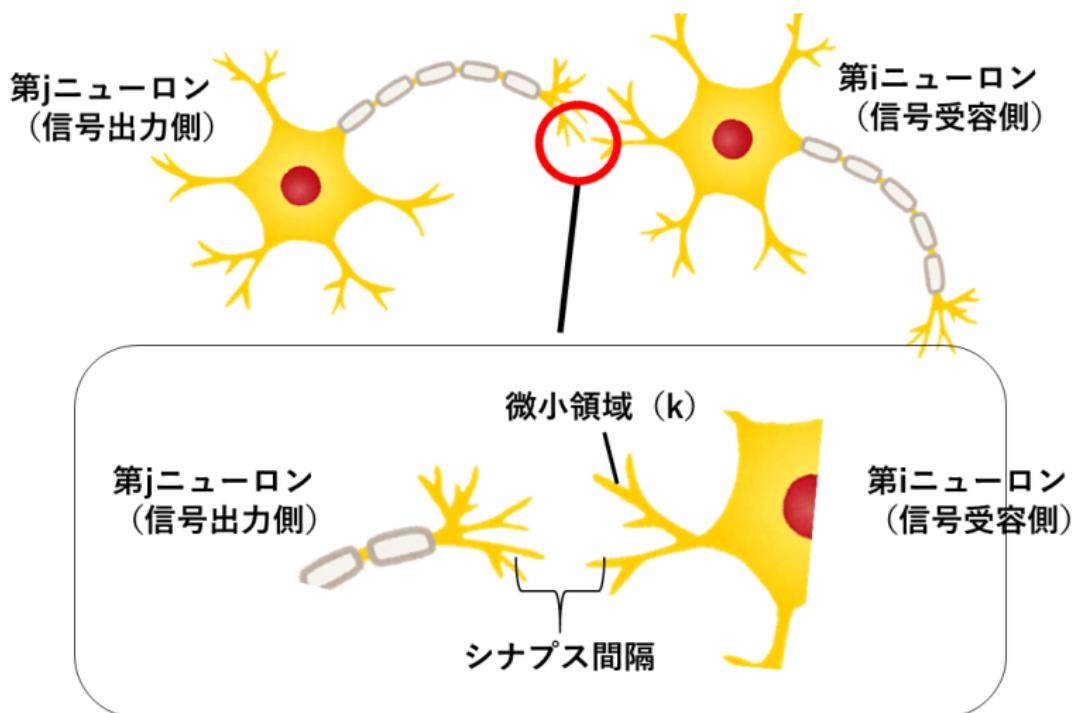


図 2

3 シナプス可塑性方程式の導出

9/30

シナプス結合荷重のシナプス可塑性方程式

$$\frac{dw_{ik}^j}{dt} = \alpha_{ik}^j w_{ik}^j + g_{ik}^j w_{ik}^j + f_{ik}^j \quad (9)$$

- w_{ik}^j : 第 i ニューロンの第 k 微小領域に付着する第 j ニューロンからのシナプス結合荷重
- α_{ik}^j : 内的自然増加率（個体生態学において、その生物が潜在的に持っている最大の繁殖増加率）
- g_{ik}^j : w_{ik}^j における神経成長因子（Nerve Growth Factor: 以下 NGF）の摂取量
- f_{ik}^j : NGF と環境因子に依存する揺らぎ

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

3 シナプス可塑性方程式の導出

10/30

内的自然増加率 (a_{ik}^j) の定義

$$a_{ik}^j = \int_{x \in B_{ik}} \eta_{ik}(x) \xi_{ik}^j(x) dx \quad (10)$$

- B_{ik} : NGF が他の因子と競合する際のシナプス感覚の微小な領域
 i はニューロンの番号, k はそのニューロン内の微小領域の番号
- ξ_{ik}^j : 微小領域 B_{ik} における第 j ニューロンのシナプス前終末発火頻度
- η_{ik} : 第 i ニューロンのニューロン膜におけるシナプス後発火頻度
- シナプス前終末 : 神経細胞の軸索の先端は、他の細胞と接触してシナプスを形成する。軸索終末のシナプス結合部はやや膨大しており、これをシナプス前終末と呼ぶ。
- 発火 : 神経細胞では、外界からの刺激などに応じて Na^+ イオンが細胞内に一過的に流入し、活動電位が発生する

1はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

3 シナプス前終末

11/30

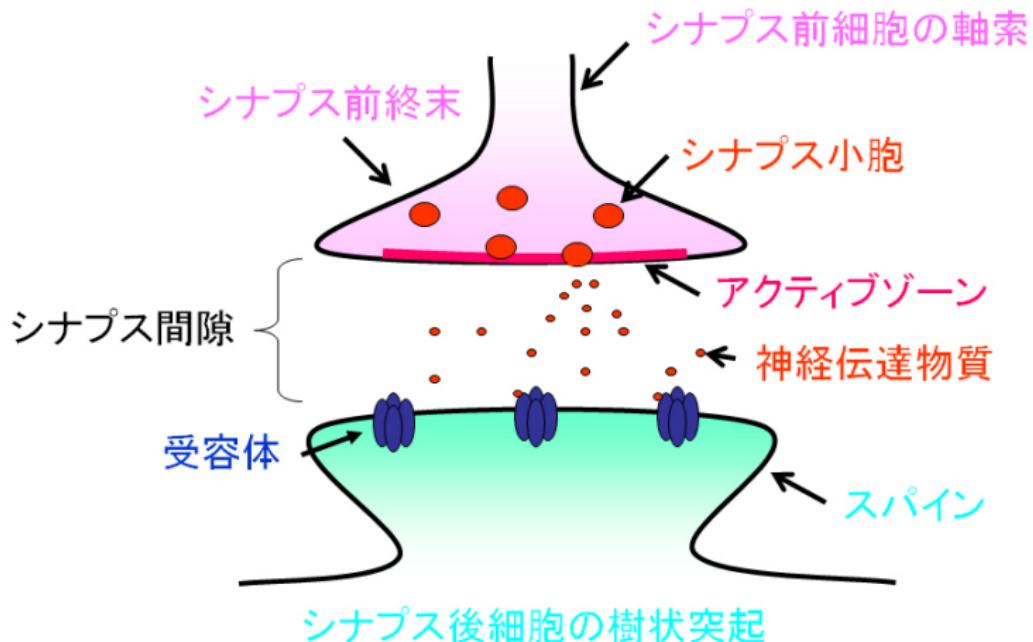


図 3

- 1 はじめに
- 2 動径基底関数
ネットワークの
概要
- 3 適者生存型学習
則の導出
- 4 競合動径基底関
数ネットワークの
提案
- 5 シミュレーション
ならびに考察
- 6 むすび

3 シナプス可塑性方程式の導出

12/30

NGF の摂取量 (g_{ik}^j) の時間変化

$$\frac{dg_{ij}^k}{dt} = \epsilon_{ik}^j (G_{ik}^k - g_{ik}^j) - \sum_{h=1}^{N_{ik}} \beta_{ik}^j h \mu^h w_{ik}^h \quad (11)$$

- G_{ik} : 細胞体から微小領域 B_{ik} への NGF の供給速度. ニューロンの特性により決定される.
- μ^j : 第 j ニューロンが興奮性であるなら 1, 抑制性であるなら -1 となる.
- N_{ik} : 微小領域 B_{ik} に付着するシナプス前終末の数である.

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

3 シナプス可塑性方程式の導出

13/30

競争係数 $\frac{\beta_{ik}^{jh}}{\epsilon_{ik}^j}$ の定義

$$\gamma_{ik}^{jh} = \frac{\beta_{ik}^{jh}}{\epsilon_{ik}^j} = \int_{x \in B_{ik}} \xi_{ik}^j(x) \xi_{ik}^h(x) dx \quad (12)$$

- 競争係数：第 j ニューロンと第 h ニューロンが同時に NGF を消費することによる競合の効果

ここで、シナプス結合荷重 w_{ik}^j の時間変化に対し NGF の摂取量 g_{ik}^j の時間変化が無視できるものとする。

$$g_{ik}^j = G_{ik} - \sum_{h=1}^{N_{ik}} \gamma_{ik}^j h \mu^h w_{ik}^h \quad (13)$$

3 シナプス可塑性方程式の導出

シナプス可塑性方程式

上記の (9)(13) の式を利用し,Dale 則を考慮したシナプス可塑性方程式

$$\frac{dw_{ik}^j}{dt} = (\alpha_{ik}^j + G_{ik} - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h) w_{ik}^j + f_{ik}^j \quad (14)$$

が導かれる. 簡単のため, 以下では B_{ik} に着目し, NGF の摂取量が一定 ($G_{ik} = 0$) で揺らぎのない ($f_{ik}^j = 0$) 場合を考える.

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

3 シナプス可塑性方程式の導出

シナプス可塑性方程式

このとき, 正定関数 $V(w_{ik})$ として

$$V(w_{ik}) = \frac{1}{2} \int_{x \in B_{ik}} \{\eta_{ik}(x) - s_{ik}(x)\}^2 dx \quad (15)$$

- 正定関数 : 原点を含むある領域で定義されたスカラ関数
- $w_{ik} \equiv [w_{ik}^1, w_{ik}^2, \dots, w_{ik}^{N_{ik}}]^T \in R^{N_{ik}}$
- $s_{ik}(x) = \sum_{j=1}^{N_{ik}} \mu^j w_{ik}^j \xi_{ik}^j(x)$
 - $\xi_{ik}^j(x) : B_{ik}$ に付着しているすべてのシナプス前終末のシナプス前発火頻度
 - $\mu^j w_{ik}^j$: Dale 則を考慮したシナプス結合荷重
 - $s_{ik}(x)$: 上記 2 つの積の総和. 神経伝達物質放出量とよぶ.

1 はじめに
2 動径基底関数
ネットワークの概要

3 適者生存型學習則の導出

4 競合動径基底関数ネットワークの提案

5 シミュレーションならびに考察

6 むすび

3 シナプス可塑性方程式の導出

シナプス後発火頻度 $\eta_{ik}(x)$ が時間に依存しないと仮定すると、その時間変化が

$$\begin{aligned}
 \frac{dV(w_{ik})}{dt} &= \sum_{j=1}^{N_{ik}} \frac{\partial V(w_{ik})}{\partial w_{ik}^j} \frac{dw_{ik}^j}{dt} \\
 &= - \sum_{j=1}^{N_{ik}} \mu^j \left[\int_{x \in B_{ik}} \eta_{ik}(x) \xi_{ik}^j(x) dx \right. \\
 &\quad \left. - \sum_{h=1}^{N_{ik}} \int_{x \in B_{ik}} \xi_{ik}^j(x) \xi_{ik}^h(x) dx \mu^h w_{ik}^h \right] \frac{dw_{ik}^j}{dt} \quad (16) \\
 &= - \sum_{j=1}^{N_{ik}} \mu^j w_{ik}^j \left(\alpha_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h \right)^2 \\
 &\leq 0
 \end{aligned}$$

となり、正定関数 $V(w_{ik})$ が Lyapunov 関数となる。

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

3 シナプス可塑性方程式の導出

17/30

Lyapunov 関数

ある平衡点の安定性を証明できる可能性のある関数

“ 定理

U を \bar{x} の近傍とする。

$V : U \rightarrow \mathbb{R}$ を次の条件を満たす C^1 級関数とする。

$$V(\bar{x}) = 0$$

$x \neq \bar{x}$ ならば、 $V(x) > 0$ (この2つの条件を、 V は正定値 positive definite であるという)

$$x \neq \bar{x} \text{ ならば、} \frac{dV}{dt}(x) \leq 0$$

このとき、 \bar{x} は (リヤプノフの意味で) 安定。

さらに、次の条件を満たすならば、 \bar{x} は漸近安定。

$$x \neq \bar{x} \text{ ならば、} \frac{dV}{dt}(x) < 0$$

図 4: 参考 : Wiggins Introduction to Applied Nonlinear Dynamical Systems and Chaos

3 特異点を利用したシナプス可塑性方程式

18/30

望ましい時刻 t^* で収束するシナプス結合荷重の時間変化を Lyapunov 関数を用いて規定する。そこで, Lyapunov 関数の時間変化を下記のように定義する。

$$\frac{dV(w_{ik})}{dt} = -\frac{\{V(w_{ik}^0)\}^R \{V(w_{ik})\}^{\frac{1}{r}}}{Rt^*} \quad (17)$$

- r : 任意の奇数
- $R : \frac{(r-1)}{r}$
- $w_{ik}^0 : w_{ik}$ の初期値

上記のような定義が可能となったのは, Dale 則を考慮したシナプス可塑性方程式に対する Lyapunov 関数が導出され, 望ましい出力が動径基底関数を定数倍して足し合わせることで実現できる特別の場合を考えているから。シナプス可塑性方程式は下記とすることができます。

$$\frac{dw_{ik}^j}{dt} = \Delta_{ik}(a_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h) w_{ik}^j \quad (18)$$

3 特異点を利用したシナプス可塑性方程式

式 18 のときの、Lyapunov 関数の時間変化は下記のとおりとなる。

$$\frac{dV(w_{ik})}{dt} = -\Delta_{ik} \sum_{j=1}^{N_{ik}} \mu^j w_{ik}^j (a_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_i^h)^2 \quad (19)$$

Δ_{ik} は式 17 と式 19 より決定することができる。以上の事より、望ましい時刻 t^* で平衡解へ収束する修正されたシナプス可塑性方程式を下記のとおり定義することができる。

$$\begin{aligned} \frac{dw_{ik}^j}{dt} &= \frac{(a_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h) w_{ik}^j}{\sum_{j=1}^{N_{ik}} \mu^j w_{ik}^j (\alpha_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h)^2} \\ &\times \frac{\{V(w_{ik}^0)\}^R \{V(w_{ik})\}^{\frac{1}{r}}}{Rt^*} \end{aligned} \quad (20)$$

1 はじめに
2 動径基底関数
ネットワークの概要

3 適者生存型学習則の導出

4 競合動径基底関数ネットワークの提案

5 シミュレーションならびに考察

6 むすび

4 競合動径基底関数ネットワークの提案

20/30

- 1 はじめに
- 2 動径基底関数ネットワークの概要
- 3 適者生存型学習則の導出
- 4 競合動径基底関数ネットワークの提案
- 5 シミュレーションならびに考察
- 6 むすび

入力ベクトル $X_j \in R^d (j = 1, 2, \dots, M)$ ならびにそれに対する望ましい出力 $\eta(X_j)$ から、それらを滑らかにつなぐ非線形関数を再構成するための競合動径基底関数ネットワーク (Competitive Radial Basis Function Networks: 以下 CRBFN) の構造は RBFN と同様 (図 1) である。この場合、出力ニューロンと微小領域がそれぞれ 1 つであるため、右下の添え字を省略できる。

- シナプス結合荷重 $w_{ik}^j : w^j$
- 内的自然増加率 $\alpha_{ik}^j : \alpha^j$

CRBFN における入力ニューロンの動作規則

$$\xi^i(X_j) = \exp\left\{-\frac{1}{2}(X_j - m_i)^T \sum_i^{-1}(X_j - m_i)\right\} \quad (1)$$

出力ニューロンの出力

$$S(X_j) = \sum_i^N \xi^i(X_j) \quad (2)$$

4 競合動径基底関数ネットワークの提案

21/30

- 1 はじめに
- 2 動径基底関数ネットワークの概要
- 3 適者生存型学習則の導出
- 4 競合動径基底関数ネットワークの提案
- 5 シミュレーションならびに考察
- 6 むすび

CRBFN の学習則は 2 乗誤差評価関数を減少させるために第 i 入力ニューロンのシナプス結合荷重 w^i , パラメータ m^i の第 k 要素 m_k^i ならびにパラメータ \sum^i の第 k 行 l 列要素 σ_{kl}^i に対し,

$$\frac{dw^i}{dt} = (\alpha^i - \sum_{h=1}^N \gamma^{ih} w^h) w^i \quad (21)$$

$$\frac{dm_k^i}{dt} = -\Delta \frac{\partial E(w)}{\partial m_k^i} \quad (22)$$

$$\frac{d\sigma_{kl}^i}{dt} = -\Delta \frac{\partial E(w)}{\partial \sigma^i} \quad (23)$$

が与えられる. 簡単のため Δ は適当な正の定数とした.

4 競合動径基底関数ネットワークの提案

22/30

内的自然増加率 a^i , ならびに競争係数 γ^{ih} は下記の式で定義される.

$$\alpha^i = \sum_{j=1}^M \eta(X_j) \xi^i(X_j) \quad (24)$$

$$\gamma^{ih} = \sum_{j=1}^M \xi^i(X_j) \xi^h(X_j) \quad (25)$$

学習中に第 i 入力ニューロンのシナプス結合荷重 $w^i \approx 0$ となった第 i シナプス結合荷重は消滅したものとして, 生き残っているシナプス結合荷重, ならびにそれらにより伝達される入力が変化を受ける入力ニューロンのパラメータについてのみ学習を続ける.

1 はじめに
2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出
4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察
6 むすび

4 競合動径基底関数ネットワークの提案

23/30

- 1 はじめに
- 2 動径基底関数
ネットワークの
概要
- 3 適者生存型学習
則の導出
- 4 競合動径基底関
数ネットワークの
提案
- 5 シミュレーション
ならびに考察
- 6 むすび

ある関数密度関数に従い発生している M 個の標本点から元の確率密度関数を推定する問題を考える。サンプルされた標本点は CRBFN の入力ベクトル X_j として用いられるが、入力ベクトルに対する望ましい出力 $\eta(X_j)$ が不明である。各標本点に観測誤差を考慮して平均ベクトル X_j 、共分散行列 $\tilde{\Sigma}$ をもつ正規確率密度関数以下のように考える。

$$N(X_j, \tilde{\Sigma}) \equiv \frac{1}{\sqrt{(2\pi)^d |\tilde{\Sigma}|}} \times \exp\left(-\frac{1}{2}(x - x_j)^T \tilde{\Sigma}^{-1}(x - x_j)\right) \quad (26)$$

$|\tilde{\Sigma}|$ は共分散行列 $\tilde{\Sigma}$ の行列式を表す。望ましい出力 $\eta(X)$ として考えることとする。

$$\eta(X) = \frac{1}{M} \sum_{j=1}^M N(X_j, \tilde{\Sigma}) \quad (27)$$

4 競合動径基底関数ネットワークの提案

24/30

以上の事より、内的自然増加率 α^i ならびに競争係数 γ^{ih} の定義式にあるサンプルされた標本点 X_j についての足し合わせは

$$\sum_{j=1}^M f(X_j) \rightarrow \int f(x)dx \quad (28)$$

のように書き換えることができ、積分で与えることが可能となる。

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

5 関数近似問題への適用

- 1はじめに
- 2動径基底関数
ネットワークの概要
- 3適者生存型学習則の導出
- 4競合動径基底関数ネットワークの提案
- 5シミュレーションならびに考察
- 6むすび

簡単な1次元非線形関数 $f(x)$ の近似に適用することにより、提案されたCRBFNがRBFNに比較し高速に関数近似ができる事を示す。ここで、1次元非線形関数 $\eta(x)$ として下記の式を考える

$$\eta(x) = 3N(-1.5, 1) + 2N(1, 0.5) \quad (29)$$

サンプルは $x \in [-5, 5]$ の間から 0.1 ずつ 101 個取り教師信号として $(x_j, \eta(x_j)) j = 1, 2, \dots, 101$ を与える。

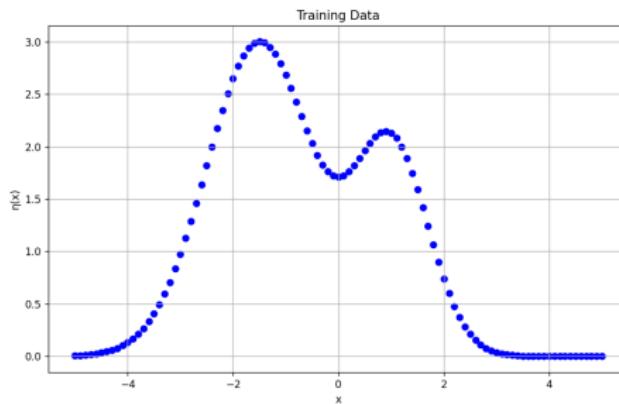


図 5

5 関数近似問題への適用

学習前のシナプス結合荷重と学習が収束した時のシナプス結合荷重を図 4 に示す。学習収束判定は $E(x) \leq 0.0001$ とした。

	w^1	w^2	w^3	w^4	w^5	w^6
初期値	0.431	0.898	0.324	0.927	0.389	0.161
RBFN	0.290	1.880	2.065	1.054	0.109	0.109
CRBFN	0.000	0.000	2.990	1.986	0.000	0.000

図 6

- 入力ニューロン数：6 個
- パラメータ $[m_1^1, m_2^2, m_3^3, m_4^4, m_5^5, m_6^6]^T : [-5, -3, -1, 1, 3, 5]^T$
- $\sigma^i : 1.5 (i = 1, 2, \dots, 6)$
- シナプス結合荷重の初期値：一様乱数

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

5 関数近似問題への適用

学習が収束するまでの学習回数を下記の図 5 に示す.

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび

	全体ループ [°]	局所ループ [°]
RBFN	219	10723224
CRBFN	11	232710

図 7

- RBFN : 式 (5) $\frac{dw^i}{dt} \Delta \sum_j^M \{\eta(x_j) - s(x_j)\} \xi^i(x_j)$
- CRBFN : 式 (21) $\frac{dw^i}{dt} = (a^i - \sum_{h=1}^N \gamma^{ih} w^h) w^i$

5 関数近似問題への適用

- 1 はじめに
- 2 動径基底関数
ネットワークの概要
- 3 適者生存型学習
則の導出
- 4 競合動径基底関
数ネットワークの
提案
- 5 シミュレーションならびに考察
- 6 むすび

	全体ループ [°]	局所ループ [°]
RBFN	219	10723224
CRBFN	11	232710

図 8

- 局所ループ：シナプス結合荷重 w^i , パラメータ m_1^i, σ^i を 1 つ更新するたびの回数を数えている。
- 全体ループ：シナプス結合荷重ならびにパラメータを一通り更新するたびに回数を数えており、途中で学習が収束した時はその回数は数えないものとする。

5 関数近似問題への適用

ターミナルアトラクタの概念を用いて望ましい学習回数 t^* で学習を収束させることができる特別な場合を考える。

- 1 はじめに
- 2 動径基底関数
ネットワークの概要
- 3 適者生存型学習
則の導出
- 4 競合動径基底関
数ネットワークの
提案
- 5 シミュレーションならびに考察
- 6 むすび

	全体ループ [°]	局所ループ [°]
RBFN	0	912
CRBFN	0	16344

図 9

- RBFN : 式 (5) $\frac{dw^i}{dt} \Delta \sum_j^M \{\eta(x_j) - s(x_j)\} \xi^i(x_j)$
- CRBFN : 式 (20)

$$\begin{aligned} \frac{dw_{ik}^j}{dt} &= \frac{(a_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h) w_{ik}^j}{\sum_{j=1}^{N_{ik}} \mu^j w_{ik}^j (\alpha_{ik}^j - \sum_{h=1}^{N_{ik}} \gamma_{ik}^{jh} \mu^h w_{ik}^h)^2} \\ &\times \frac{\{V(w_{ik}^0)\}^R \{V(w_{ik})\}^{\frac{1}{r}}}{Rt^*} \end{aligned}$$

6 おわりに

ニューロンの微小領域において生じている NGF の競合を考慮したシナプス可塑性方程式を導出した。また、このシナプス可塑性方程式を適者生存型学習則として RBFN に適用した CRBFN を提案した。

- シナプス結合荷重の調節のみで学習できる特別な関数近似の場合を除いて CRBFN は RBFN に比較し学習回数が大幅に少なくて済むことが示された。
- シナプス結合荷重の調節のみで学習できる特別な場合には、望ましい学習回数で学習が終了させることが出来ることが示された。

1 はじめに

2 動径基底関数
ネットワークの
概要

3 適者生存型学習
則の導出

4 競合動径基底関
数ネットワークの
提案

5 シミュレーション
ならびに考察

6 むすび