

1L-9

巡回セールスマン問題の
ニューラルフレームワーク
高橋 祥兼
NTT情報通信処理研究所

1. まえがき

ニューラルネット(NN)を用いた巡回セールスマン問題(TSP)の近似解法として、①並列処理の利用(Hopfieldモデル⁽¹⁾)、②自己組織化の利用(Elastic Net⁽²⁾)、Kohonenアルゴリズム⁽³⁾がある。これらは、いずれも各ユニット/シナプスが適切な微分方程式(差分方程式)を満たすとき、NN全体が最小巡回路対応の最適状態に収束することを暗黙原理としている。本稿では、この原理を微分方程式と最適化関数によって表現するTSPのニューラルフレームワークを提案する。

2. 従来アプローチの位置付け(表1)

2.1 Hopfieldモデル

(1)NNモデル v_{xi} をニューロンXiからの出力 V_{xi} ($0 \leq V_{xi} \leq 1$)により、 $v_{xi} = 0$ ($0 \leq V_{xi} < 1/2$)、 1 ($1/2 \leq V_{xi} \leq 1$)と

表現し、 (v_{xi}) を行X(都市)、列i(巡回順番)の $N \times N$ 行列とする。可変シナプス荷重が[HL]の制約を満たし、同時にユニットが[HS1]と[HS2]に基づいて動作するとき、[HE]は極小値に収束する。

(2)微分方程式と最適化関数

$$\begin{aligned} \text{[HS1]} \quad & du_{xi}/dt = -(u_{xi}/\tau) \\ & -A(t)\sum_{j \neq i} v_{xj} - B(t)\sum_{y \neq x} v_{yi} \\ & -C(t)(\sum_x \sum_j v_{xj} - N) \\ & -D\sum_y dx_{xy}(v_{y, i+1} + v_{y, i-1}) \\ \text{[HS2]} \quad & v_{xi} = (1/2)[1 + \tanh(u_{xi}/u_{xi}^0)] \\ A(t) = & A \cdot \exp[-(1/\lambda)t]; \quad B(t) = B \cdot \exp[-(1/\lambda)t]; \\ C(t) = & C \cdot \exp[-(1/\lambda)t]; \\ A, B, C, D: & \text{正の定数}; \quad \tau, \lambda, u_{xi}^0: \text{定数} \\ \text{[HE]} \quad & HE(V) = (D/2)\sum_x \sum_{y \neq x} dx_{xy} \cdot v_{xi}(v_{y, i+1} + v_{y, i-1}); dx_{xy}: X-Y \text{間距離} \\ \text{[HL1]} \quad & \lambda(dT_{xi, yj}/dt) \\ = & -T_{xi, yj} + \alpha(v_{xi}, v_{yj}) \\ \alpha(v_{xi}, v_{yj}): & t, v_{xi}, v_{yj} \text{の関数} \\ \text{[HL2]} \quad & T_{xi, yj} = -A(t)\delta_{xy}(1 - \delta_{ij}) \end{aligned}$$

表1. TSPへのニューラルアプローチの位置付け

アプロ ーチ	TSP解法の NNによる 表現	ユニット動作表現		シナプス動作表現	
		微分方程式	最適化関数	微分方程式	最適化関数
Hopfield モデル	HSi, HL充足 → HE極小	出力方程式 [HS1][HS2]	エネルギー関数 [HE]	学習方程式 [HL]	-
Elastic Net	Eli充足 → EE極小	-	-	学習方程式 [EL1][EL2]	エネルギー関数 [EE]
Kohonen アルゴリズム	KL充足 → KD準最適	-	-	学習方程式 [KL]	分布関数 [KD]

$-B(t)\delta_{ij}(1-\delta_{xy})-C(t)-Dd_{xy}(\delta_{ij}, i+1+\delta_{j,i-1}); \delta$: クロネッカー δ

2. 2 Elastic Net

(1) NNモデル 都市 $x_i (1 \leq i \leq N)$ と平面上の動点 $y_j (1 \leq j \leq N)$ をニューロンとする。 $x_i - y_j$ 間の可変シナプス荷重 w_{ij} および $y_{j+1} - y_j$ 間の可変シナプス荷重 v_j が [EL1] と [EL2] に基づいて動作するとき、 [EE] は極小値に収束する。

(2) 微分方程式と最適化関数

[EL1] $d\rho_{ij}/dt = -\alpha \sum_i T_{ij} \rho_{ij} - \beta K(\sigma_{j+1} - \sigma_j)$
 $T_{ij} = \phi(|\rho_{ij}|, K) / \sum_k \phi(|\rho_{ik}|, K)$
 $\phi(|\rho_{ij}|, K) = \exp(-|\rho_{ij}|^2 / 2K^2)$
 $\rho_{ij} = x_i - y_j; \sigma_j = y_j - y_{j-1}$

α, β, K : 正定数
 [EL2] $\sigma_j = -\rho_{ij} + \rho_{i,j-1}; S_j = |\sigma_j|$
 [EE] $EE(|\rho_{ij}|, S_j) = -\alpha K \sum_i \log \sum_j \phi(|\rho_{ij}|, K) + \beta \sum_j S_{j+1}^2$

2. 3 Kohonenアルゴリズム

(1) NNモデル 都市 $A_j (1 \leq j \leq n)$ と平面上の動点 $X_i = X_i(t) (1 \leq i \leq N, \text{以下 } N = n \text{ と簡単化})$ をニューロンとする。 $X_i - A_j$ 間の可変シナプス荷重 $h_{ij} = h_{ij}(t) (0 \leq h_{ij} \leq 1)$ と $A_j - A_k$ 間の固定シナプス荷重 $\gamma_{jk} (0 \leq \gamma_{jk} \leq 1)$ が [KL] に基づいて動作するとき、 [KD] のシナプス分布 KD_t は準最適シナプス分布 KD^* に収束する。

(2) 微分方程式と最適化関数

[KL] $dh_{ij}/dt = \eta_i(t, h_{rs}, p) \varepsilon(t) h_{ij} [1 - h_{ij} + (h_{ij}/H_i(t, p)) - (h_{ij}/\Gamma_j(t, p))]$

① $p = p(t) = \sum_k p_k(t) k = k_0$
 $p_k(t)$: A_k の活性化確率 (0 または 1)
 ② $h_{i_0(t), k_0} = \text{Sup}_i \{h_{ik_0}\}, m \in N$ として、
 $\eta_i(t, h_{rs}, p) = 1 (i \in [i_0(t) - m, i_0(t) + m]) = 0 (i \notin [i_0(t) - m, i_0(t) + m])$

(h_{rs} : 全可変シナプス荷重の代表略記)
 ③ $\varepsilon(t) = c / (1 + \log t)$; c : 正定数
 ④ $H_i(t, p) = \sum_k p_k(t) h_{ik} = h_{ik_0}$
 ⑤ $\Gamma_j(t, p) = \sum_k p_k(t) \gamma_{jk} = \gamma_{jk_0}$

[KD] $KD_t(X_i, A_j) = h_{ij}$
 $KD^*(X_i, A_j) = h_{ij}^*$; $\forall i$ に対して、
 $h_{ij}^* = 1 (\exists j, j = j(i)), = 0 (j \neq j(i))$

($\forall i \neq i'$ に対して、 $j(i) \neq j(i')$)

3. TSP のニューラルフレームワーク

ユニット i の状態 (出力電圧等) を $V_i = V_i(t)$, 状態変化確率を $p_i = p_i(t)$ とし、シナプスの荷重を $T_{ij} = T_{ij}(t)$, 荷重変化確率を $q_{ij} = q_{ij}(t)$ とする。 NN の動作は、一般に次の微分方程式系を満たす。

[EQ1] $dV_i/dt = \phi_i(t, V_k, T_{ki}, p_k, q_{ki})$
 [EQ2] $dT_{ij}/dt = \phi_{ij}(t, V_k, T_{ki}, p_k, q_{ki})$
 (V_k, T_{ki}, p_k, q_{ki} : 全変数の代表略記;
 ϕ_i, ϕ_{ij} : 関数)

従来の TSP アプローチでは、 $\phi_i = \Phi_i(t, V_k, T_{ki})$, $\phi_{ij} = \Psi_{ij}(t, V_k, T_{ki})$ なる Lipschitz 条件を満たす連続関数 Φ_i, Ψ_{ij} が存在する。そこで、Cauchy の定理より、 [EQ1]、[EQ2] は唯一解 $\{V_i\}, \{T_{ij}\}$ をもつ。

NN 全体の状態は、一般に次の最適化関数 ξ によって評価できる。

[OF] $\xi = \xi(t, V_i, T_{ij}, p_i, q_{ij})$
 (V_i, T_{ij}, p_i, q_{ij} : 全変数の代表略記)
 ξ は $t \rightarrow \infty$ のとき最適状態 ξ^* に収束する。従来の TSP アプローチでは、 $\xi = \Xi_v(t, V_i)$ または $\Xi_T(t, T_{ij})$ なる連続関数 Ξ_v または Ξ_T が存在し、 NN が [EQ1]、[EQ2] を満たすとき、 $\xi \rightarrow \xi^*$ が成立する。

ニューラルフレームワーク [EQ1]、[EQ2]、[OF] に基づく TSP 解は、「最小巡回路対応の ξ^* に収束する [OF] を導出する [EQ1]、[EQ2]」である。

4. むすび

TSP はニューラルフレームワークの単純特殊形を利用しているにすぎない。ニューラルフレームワークを最大限に活用して、TSP レベルの古典的難問を容易に解決することが期待される。

文 献

(1) Hopfield 他: Biol. Cybern. 52 (1985)
 (2) Durbin 他: Nature 326 (1987)
 (3) Fort: Biol. Cybern. 59 (1988)