解 説

ニューラルネットワークと進化的計算を用いた大規模最適化問題の解法について

中 野 秀 洋

東京都市大学*

Solving Large Scale Optimization Problems Using Neural Networks and Evolutionary Computation

Hidehiro Nakano

Tokyo City University*

概要

ニューラルネットワークは個々の動作が単純であり、高い並列性を有する演算が可能であるため、大規模な組合せ最適化問題を効率的に解くことができる。一方、進化的計算の研究分野では、実数値の設計変数を最適化するための優れた手法が数多く提案されている。本稿では、第一段階でニューラルネットワークを用いた組合せ最適化によって設計変数の削減を行い、第二段階で進化的計算を用いた実数値の設計変数の最適化を行うことで、大規模最適化問題を効率的に解くアプローチを紹介する。本アプローチは、様々な工学システムの最適化に対して適用できると考えられる。筆者らの最近の研究対象である無線センサネットワークにおける問題を例題として取り上げ、本アプローチの有効性と今後の発展性について議論する。

1. は じ め に

最適化問題は様々な工学システムにおいて存在する。システムが効率的に動作するためのパラメータや、利用すべきモジュールの組み合わせなど、様々な場面で最適化が必要となる。一方、近年のシステムは大規模・複雑化してきており、現在の高性能なコンピュータシステムを用いたとしても、現実的な計算時間で全ての解パターンを調査することは不可能になってきている。このため、実際の利用において許容できるレベルの解（許容解）を効率的に求められる手法が重要となる。

ニューラルネットワークを用いた組合せ最適化問題の解法として、相互結合型のホップフィールド・ネットワークが広く知られている¹⁾。ネットワークを構成する各ニューロンは重みパラメータによって相互に結合される。各ニューロンの内部状態に初期値を与えて時間発展させると、系の内部状態はある安定状態に収束する。これは、系のエネルギーが減少する方向に内部状態が変化するという原理による。この安定状態を問題の解と対応付けるように、各ニューロンの重みパラ

メータを適切に学習させることができれば、各ニューロンの単純な並列動作の繰り返しによって効率的に所望の解を得ることができる。しかし、系と対応するエネルギー関数が複雑な多峰性の構造を有している場合、与える初期値によっては質の低い局所解に容易に陥る可能性があることが問題となる。

これを回避するためには、局所解となる状態からの再加速を促し、そこから脱出するための機構が必要である。このための対策として、外部からノイズを注入する方法や^{2,3)}、各ニューロンにカオス的ダイナミクスを持たせる方法などがある。後者は、カオスニューラルネットワークと呼ばれ⁴⁾、巡回セールスマン問題、二次割り当て問題等の大規模な組合せ最適化問題に対する効率的な解法が提案されている^{5,6)}。また、このモデルの改良手法や他の諸問題への応用等、現在も盛んに研究されている。ただし、これらの解法は「発火」「非発火」という二値を出力するニューロンに基づくため、利用場面は組合せ最適化問題に限られる。出力を連続値となるように変更し、連続値の最適化問題に適用することも考えられるが、質の高い解を得るための学習方法を構築することはさほど容易ではない。

* 〒 158-8557 東京都世田谷区玉堤 1-28-1

一方、組合せ最適化問題を解くための別のアプローチとして、近年では、遺伝的アルゴリズムに代表される進化的計算に関する研究が盛んである。また、設計変数を実数値で表現される問題に対しては、実数値遺伝的アルゴリズム^{7,8)}や群知能アルゴリズムに分類される粒子群最適化アルゴリズム⁹⁾、人工蜂コロニーアルゴリズム¹⁰⁻¹²⁾等、様々な手法が提案されている。これらのアルゴリズムでは多数の探索個体を用意し、各個体に設計変数の情報を持たせて、目的関数に対する評価値が優れた解を探索する。

大規模な問題に対しては解空間が高次元になるため、多数の探索個体を用意し解空間を広く探索する必要がある。しかし、多数の探索個体を用いると、探索アルゴリズム自体が有する高い収束性のため、探索個体が質の低い局所解に早期に収束する可能性が高まる。これに対しては、解の多様性を維持するための改良手法が提案されており^{8,13)}、現在も様々な研究が盛んに行われている。

進化的計算では、各個体の目的関数に対する評価値を計算する手順が必須である。多数の探索個体を用いることは、評価値計算に要する計算コストの増大を招く。一方、ニューラルネットワークの利点は、個々のニューロンが単純な規則によって動作し、ニューロン間の結合も単純な重み付け加算によって実現され、高い並列性を有する演算が可能なことである。本稿では、大規模な実数値最適化問題の効率的な解法について議論するため、筆者らが最近行っている無線センサネットワークにおける最適化問題を例題として取り上げる^{14,15)}。

本稿の構成は、以下のとおりである。2章では、無線センサネットワークにおけるフォワーディングノード選択問題¹⁶⁾を紹介する。この問題は、グラフにおける最小頂点被覆を求める問題の一種とみなすことができる。また、この問題に対するカオスニューラルネットワークを用いた解法を説明する。3章では、無線センサネットワークにおける送信電力調整問題¹⁷⁾を紹介する。この問題は、設計変数値に応じてグラフの形状が変動するという条件下での頂点被覆問題を解くことに相当する。大規模な実数値最適化問題に対する効率的な解法として、段階的な最適化を行う手法¹⁸⁾を紹介する。4章では、本稿のまとめと本アプローチの発展性について議論する。

2. フォワーディングノード選択問題とその解法

2.1 対象とする問題

無線センサネットワーク (Wireless Sensor Network; WSN) では、数百あるいは数千の無線センサノードを

観測エリア内に散布し、各ノードがそれぞれの周囲の状態を自身がもつセンサによって測定する。測定した情報は無線マルチホップ通信によって中継ノードを介し、情報を集めるシンクノード (Sink Node; SN) に転送される。これによって、WSN は大規模な観測エリアの状態を遠隔地から測定することが可能となる^{14,15)}。

WSN では、SN から全ノードに対して広告メッセージや制御メッセージなどを普及させる際にフラッディングが用いられる。フラッディングは、自身の送信可能範囲内に存在するノードにブロードキャストすることで行われる。このメッセージを受信したノードはさらにフラッディングを行い、これを繰り返すことで全ノードにメッセージを普及させることができる。しかし、同一のメッセージを普及させる場合、全てのノードがフラッディングを行う必要はない。全てのノードの中から必要最小限の数のノードをフォワーディングノード (Forwarding Node; FN) として適切に選択し、これらがフラッディングを行うことで、全てのノードにメッセージを普及させることができる。これによって、フラッディングを行わずにメッセージを受信するのみのノードに対する消費電力を削減できる。この問題を FN 選択問題と呼ぶ¹⁶⁾。FN 選択問題の概念図を図 1 に示す。

ここで、各ノードは同一の送信可能範囲を持つとする。各ノードを頂点の集合 V とし、互いに送信可能範囲内に存在する各ノード間を辺の集合 E とする。このとき、各ノードの送受信に対する接続関係は、 V と E のグラフ G で表すことができる。FN 選択問題は G における最小頂点被覆を求める問題の一種とみなすことができる。すなわち、グラフ G における頂点の部分集合を $V' \subseteq V$ とし、 G における任意の辺 $e \in E$ が少なくとも一つの頂点 $v' \in V'$ と接続し、かつ、頂点数 $|V'|$ が最小となる V' を求める問題である。この問題

図1 フォワーディングノード選択問題の概念図

は古典的な NP 困難な問題として知られている。なお、FN 選択問題では、 V' に含まれる一つの頂点がシンクノード SN であり、全ての $v' \in V'$ が SN を根とする木構造となるように互いに接続されていることも必要となる。

特定のノードが FN として使用される場合、そのノードのみがフラッピングを行い続けることで、大きな電力を消費することになる。そこで、複数の種類の FN 群を解として得ておき、これらを定期的に切り替えることができれば、各ノードの負荷を分散させることができる。このため、FN 選択問題では、複数の良好な解が得られる解法を利用することが望ましい。

2.2 カオスニューラルネットワークのモデル

ホップフィールド・ネットワークや遺伝的アルゴリズムは、組合せ最適化問題を効率的に解けることが知られており、適切なコーディングを施すことで FN 選択問題に適用することができる。しかし、これらの手法は基本的に単一の解しか求めることができない。また、前述のように WSN では、数百あるいは数千のノードを使用することが想定される。一般に、大規模で高次元な最適化問題では、解空間に質の低い局所解が多く存在する。上記の手法はこのような局所解に容易に陥る可能性がある。そこで、筆者らは局所解の回避と複数の解の探索が可能であるカオスニューラルネットワーク (Chaotic Neural Network; CNN) を用いた解法に注目している¹⁶⁾。

一般的な CNN のモデルは次式で記述される⁴⁾。

$$x_i(t+1) = f(y_i(t+1)) \quad (1)$$

$$y_i(t+1) = \xi_i(t+1) + \eta_i(t+1) + \zeta_i(t+1) \quad (2)$$

$$\xi_i(t+1) = \sum_{j=1}^M Q_{ij} \sum_{r=0}^t k_{\xi}^r A_j(t-r) \quad (3)$$

$$\eta_i(t+1) = \sum_{j=1}^N W_{ij} \sum_{r=0}^t k_{\eta}^r x_j(t-r) \quad (4)$$

$$\zeta_i(t+1) = -\alpha \sum_{r=0}^t k_{\zeta}^r x_i(t-r) - \theta_i \quad (5)$$

$$f(z) = \frac{1}{1 + \exp(-\frac{z}{\varepsilon})}$$

ここで、 i はニューロンの番号、 N は結合するニューロンの総数、 M はニューロンへの外部入力数の総数を表す。 x_i はニューロン i の出力であり、 y_i はニューロン i の内部状態である。 ξ_i は外部入力項であり、 Q_{ij} は各入力に対する重み、 k_{ξ} は外部入力項に対する減衰係数である。 η_i は相互結合項であり、他のニューロンの

出力が重み付けして結合される。 W_{ij} は他のニューロンの出力に対する重みであり、 k_{η} は相互結合項に対する減衰係数である。 ζ_i は不応性項であり、自身の出力がその後の自身の発火を抑制させる効果を持つ。 α と θ_i は不応性の強さに影響を与える係数であり、 k_{ζ} は不応性項に対する減衰係数である。また、 f はシグモイド関数であり、 ε はシグモイド関数の鋭さに影響を与える係数である。

式 (3) から式 (5) では、それぞれ過去の全ての時刻における状態が含まれている。これらの式は、それぞれ以下のように逐次計算に適した式に変形することができる。

$$\xi_i(t+1) = k_{\xi} \xi_i(t) + \sum_{j=1}^M Q_{ij} A_j(t) \quad (6)$$

$$\eta_i(t+1) = k_{\eta} \eta_i(t) + \sum_{j=1}^N W_{ij} x_j(t) \quad (7)$$

$$\zeta_i(t+1) = k_{\zeta} \zeta_i(t) - \alpha x_i(t) + a_i \quad (8)$$

ただし、 $a_i = -(1 - k_{\zeta})\theta_i$ である。

2.3 カオスニューラルネットワークによる解法

WSN における FN 選択問題に対して CNN を適用するにあたり、以下のような方針で CNN を設計する。ニューロンへのコーディング

- 一つのニューロンを一つのノードに対応付ける。
- 出力 x_i が高いニューロンを FN として決定する。

外部入力項

- あるノード i の送信可能範囲に多数のノードが存在する場合、ノード i が FN となることで多くのノードをカバーできる。このため、ノード i に対応するニューロン i の発火を促進する。
- 特に、ノード i に対して近い位置に他のノードが多く存在する場合、ノード i が FN となる重要度は高いとみなし、対応するニューロン i の発火を強く促す。

相互結合項

- 互いに送信可能範囲に存在するノードと対応するニューロンを相互結合させる。
- ノード i に対して、隣接するノードと対応するニューロンの出力が高い場合、ノード i が FN となる重要度は低いとみなし、発火を抑制する。

前述のように、FN 選択問題では、全ての $v' \in V'$ が互いに隣接していることも制約条件として必要である。上記の方針はこの条件と矛盾する可能性がある。しかし、解として得られる FN 群は木構造をなしており、個々の FN の隣接ノード数はそれぞれ同一ではない。このため、適切な隣接ノード数を一意に決めることは

できない．そこで，個数が最小の FN 群を求めるという目的を重視し，相互結合項は上記のように設計する．

不応性項

- 1 回の CNN の実行において多様な解を探索するために，ある時刻において発火した（出力が高い）ニューロンは，以降，一定期間の発火を抑制する．
- 複数の解 (FN 群) を得るために，CNN を複数回実行する．過去の実行において FN として選択されたノードは，繰り返し FN として選択されることを避けるため，以降，対応するニューロンの発火を抑制する．

以上の方針に基づき，FN 選択問題を解くために設計した CNN の各項を次に示す．

$$\xi_i(t+1) = C_\xi \sum_{j \in D_i} \frac{\|S_i - S_j\|}{R_c} \quad (9)$$

$$\eta_i(t+1) = k_\eta \eta_i(t) + C_\eta \sum_{j \in D_i} x_j(t) \quad (10)$$

$$\zeta_i(t+1) = k_\zeta \zeta_i(t) - \alpha x_i(t) + C_\zeta T_i(n) \quad (11)$$

ここで， $\|\cdot\|$ はノード S_i と S_j のユークリッド距離であり， R_c は各ノードの送信可能範囲である． D_i はノード i の送信可能範囲内に存在する隣接ノードの集合であり， $T_i(n)$ は，ノード i が $n-1$ 回目以前の実行において FN として選択された回数である．また， C_ξ ， C_η ， C_ζ はそれぞれ，固定値の係数である．ノードの配置が固定的である場合，外部入力項 ξ_i は時間的な変化を伴わない．そこで，式 (6) における k_ξ は 0 とし，時間に対して一定の外部入力を与える．なお，ノードの離脱や追加，残余電力などを考慮したモデルの拡張を行う際には，この項を変更することで対応できる．また，相互結合項 η_i は，前述の方針に基づき，隣接するニューロンに対して一定の重みによって抑制の効果を与える．不応性項 ζ_i は，それ自身が同一の解を繰り返し探索することを抑制する効果がある．しかし，過去の実行によって得られた解を明示的に与えて抑制することで，複数の異なる解をより確実に得ることができる．このため，不応性項 ζ_i には $T_i(n)$ を与えている．

式 (1)，(2)，(9)，(10)，(11) を動作させることで，CNN の各ニューロンの状態は解空間を継続的に探索するように変化する．ただし，このモデルでは問題の前提条件を満たす解（実行可能解）が確実に得られる保証は無い．そこで，実行可能解を得ることを確実にものとするために，発火判定法を導入する．各ノードの送信可能範囲を R_c とし，送信範囲の下限値を $R_{th} (< R_c)$ とする．発火判定法の手順を以下に示す．

1. $FNlist$ と $RNlist$ を空とする．
2. シンクノード SN を $FNlist$ に追加する．
3. $FNlist$ と $RNlist$ のいずれにも含まれていないノードのうち， $FNlist$ に含まれる各ノードとの距離の最小値が R_c 以下のものを $RNlist$ に追加する．
4. $RNlist$ に含まれるノードのうち， $FNlist$ に含まれる各ノードとの距離の最小値が R_{th} 以上のものを FN 候補群として選ぶ．
5. 選ばれるノードが一つも存在しない場合は $R_{th} = R_{th} - \Delta R_{th}$ として，4 に戻る．
6. R_{th} を初期化する．
7. 選ばれたノードのうち，対応するニューロンの出力 x_i が最大のものを $FNlist$ に追加する．
8. 全てのノードが $FNlist$ か $RNlist$ に含まれるまで 3～7 を繰り返す．

発火判定法を各時刻において行い $FNlist$ を参照することで，実行可能解を確実に得ることができる．なお， $FNlist$ に含まれるノードとの距離が近いノードを新たな FN として $FNlist$ に追加すると，最終的な解となる FN の個数が著しく増加する可能性がある．これを避けるため，FN 候補群を選ぶ際に下限値 R_{th} を設けている．

2.4 数値実験による評価

上述の解法の有効性は様々な数値実験によって確認されている¹⁶⁾．ここでは，結果の一例を紹介する．図 2 に実験で用いた WSN のモデルを示す．WSN におけるパラメータは，エリアサイズが 100 [m]×100 [m]，ノー

図2 無線センサネットワークのモデル

図3 各ノードがFNとして選択される回数

表1 5回のCNNの実行で得られた最小FN数(100回試行の平均値)

実行	1	2	3	4	5	total
FN数	7.02	7.56	8.79	9.27	10.02	42.66

ドの総数が100, 通信可能範囲が $R_c = 30$ [m], SNの位置座標が $(x, y) = (50, 0)$ である. 全ノードにメッセージを普及させることができる最小のFNの数は7である. CNNのモデルのパラメータは, $k_\eta = k_\zeta = 0.7$, $\alpha = 1.0$, $\varepsilon = 0.02$, $C_\xi = 0.08$, $C_\eta = 0.01$, $C_\zeta = 50$, $R_{th} = 20$ である. 1回のCNNの実行は $t = 1000$ まで行い, これを5回実行することで, 5種類の異なるFN群を解として得る. 以上を100回試行した平均値を実験値とする.

表1にCNNの5回の実行において得られた最小FN数を示す. 1回目の実行では, FN数が7となる最適解を高い頻度で得ていることがわかる. 2回目以降の実行では, 過去に選ばれたFNが繰り返し選ばれることを避けるように不応性項が作用するため, FN数は徐々に増加する傾向がある. しかし, いずれの実行においても良好な結果が得られていることがわかる.

図3に各ノードが5回の一連の実行を通じてFNとして選ばれた回数を示す. なお, 比較の対象として, 不応性項を以下のように変更したモデルを用いた.

$$\zeta_i(t+1) = k_\zeta \zeta_i(t) - \alpha x_i(t) + a \quad (12)$$

ここで, a は定数のパラメータであり, 実験では $a = 0.02$ とした. すなわち, 過去の実行で得られた解に対して積極的な抑制を行わないモデルである. 縦軸は選ばれた回数(100回試行の平均値)であり, 横軸は縦軸の値によってソートされたノード番号である. 過去の解の抑制を行わない不応性項(12)によるモデルでは, 一部

のノードが重複してFNとして選択されていることがわかる. 一方, 不応性項(12)によるモデルでは, FNとして選ばれる回数が高々1回であることがわかる. すなわち, 5回の一連の実行において, FNとして複数回選択されたノードは無く, 不応性項(12)のモデルの方が各ノードの負荷分散に対して有効であることがわかる. なお, 結果は割愛するが, 本手法はよりノード数が多い大規模で高次元な問題に対しても, 良好な解が得られることを確認している. また, 他の進化的計算手法との比較を行い, 本手法が特に高次元な問題に対して優れた性能を示すことも確認している.

進化的計算手法では, 多くの探索個体を用意し, 与えられた目的関数に対する評価値をそれぞれについて求める手順が必要である. このため, 問題の大規模化に伴い, 評価値の計算コストが著しく増大することが問題となる. CNNによる解法は, 問題に対するコーディングとパラメータの調整が事前に必要であるものの, 個々のニューロンの動作は比較的単純であり, 問題が大規模になった場合の評価値の計算コストも, 進化的計算手法と比べるとさほど大きくはない. この点が, ニューラルネットワークによる最適化手法を用いる利点の一つであると考えられる. 特に, CNNを用いた解法は, 質の低い局所解からの脱出が可能であり, 良好な解を得ることができ, 複数の解を得る問題に対しても有効である.

3. 送信電力調整問題とその解法

3.1 対象とする問題

前章で紹介したFN選択問題では, 各FNが常に一定の送信出力でフラッディングを行うことを前提としている. しかし, 各FNが同一の送信出力でフラッディングを行わなくても, 全ノードにメッセージを普及させることは可能である. 送信に要する電力は送信出力のべき乗に比例することが知られている¹⁵⁾. そこで, 送信出力を必要最小限となるように調整することができれば, WSNにおける各ノードの負荷をさらに抑制することができる. この問題を送信電力調整問題と呼ぶ. 図4に送信電力調整問題の概念図を示す. 図4(a)は調整を行わない場合であり, FN選択問題と等価である. 図4(b)は調整を行う場合である. この問題の目的は, FNの個数が最小となるFN群を得ることではなく, 各ノードの送信出力を設計変数として, WSN全体の総消費電力を最小化することである. また, FNの個数が最小となるFN群がこの問題における最適解になるとは限らない.

送信電力調整問題は前述の頂点被覆の問題の一種と

図4 送信電力調整問題の概念図

みなすことができる。ただし、各ノードの送信出力に応じて、ノード間の接続関係は変化する。送信電力調整問題は、この条件下において頂点被覆となる頂点集合を求める問題であるとみなせる。設計変数値が送信出力という実数値であるため、「発火」か「非発火」の二値の出力によって表現される前章で述べたような解法は利用できない。各ニューロンの出力を実数値とみなして、解を求めるアプローチも考えられるが、質の高い解を得るための学習法を構築することはさほど容易ではないと思われる。

3.2 大規模実数値最適化問題における問題点

設計変数が実数値の最適化問題に対しては、近年、進化的計算の分野において、様々な手法が提案されている。例えば、実数値遺伝的アルゴリズム^{7,8)}や群知能アルゴリズムに分類される粒子群最適化アルゴリズム⁹⁾、人工蜂コロニーアルゴリズム^{10~12)}等が挙げられる。これらのアルゴリズムでは多数の探索個体を用意し、各個体に設計変数の情報を持たせて、目的関数の評価値が優れた解を探索する。様々な改良手法や新しいアルゴリズムが数多く提案されており、実装が容易であることから様々な工学システムにおける最適化問題への応用も試みられている。

一般に、これらのアルゴリズムは、最適化すべき設計変数の数が増え、問題が高次元になると解の探索性能は低下する。その理由の一つとして、解空間の広さに対して、探索個体数が不足することが挙げられる。しかし、探索個体数を多くしすぎると、以下のような

問題が生じる。各探索個体は設計変数を持ち、それに対する目的関数の評価値を計算する。探索個体数の増加は、評価値の計算コストの増大を招く。目的関数が高次元で複雑になるにつれて、この計算コストの増大は深刻になる。また、探索アルゴリズム自身が有する高い収束性のため、探索個体数を多くしすぎると、かえって質の低い局所解に早期に陥る可能性が高くなる。このため、解の多様性を維持するための様々な改良手法が提案されている^{8,13)}。しかし、解の多様性維持のために要する計算コストも、問題が大規模化するにつれて、また、探索個体数が多くなるにつれて極めて大きくなる。

一方、ニューラルネットワークによる解法の利点は個々のニューロンの動作が単純であり、相互結合も単純な重み付け加算によって実現され、高い並列性を有する演算が可能である。事前の学習やパラメータの調整が必要ではあるものの、実行後の計算コストは、問題が大規模になったとしても進化的計算手法と比べればさほど大きくはならない。

3.3 二段階最適化法による解法

筆者らはニューラルネットワークと進化的計算のそれぞれの特徴を活かした、送信電力調整問題に対する解法の提案を行っている¹⁸⁾。まず第一段階として、CNNを用いてFNの選択を行う。次に第二段階として、選択されたFNのみを対象として、進化的計算によって最適な送信電力を求める。この手法は主に次の利点がある。全てのノードの送信電力を設計変数とする場合、解空間の次元数はノード数に比例する。一般的なWSNでは、数百あるいは数千の無線センサノードを利用することが想定されるため、進化的計算のみを用いると、前述したように計算コストが増大する問題、質の低い局所解に容易に陥る問題などが生じる。第一段階でCNNを用いて明らかにFNとなるべきではないノードを選択の候補から除外することにより、第二段階で進化的計算を適用する際の解空間の次元数を大幅に削減することができる。これによって、進化的計算に対する計算コストを減らし、良好な解を効率的に得ることができる。

この手法によって得られる解は、真の最適解とは異なる構造になる可能性がある。なぜなら、第一段階で選択の候補から除外されるノードの中には、真の最適解の構成要素となるものが含まれる可能性があるためである。従って、この手法によって真の最適解が得られる保証は無い。しかし、数値実験を行った結果、この手法はWSNにおける各ノードの負荷分散に対して有効であることを確認している¹⁸⁾。

具体的な手法を次に説明する．まず，前章で紹介した CNN による解法を用いて，FN の選択を行う．このときの FN の個数を N_f とする．これを第一段階とする．次に，以下の設計変数を定義する．

$$x = (E(R_1), E(R_2), \dots, E(R_{N_t}))^T \quad (13)$$

$$E(R_i) = k(E_{elec} + \varepsilon_{amp} R_i^2) \quad (14)$$

ここで， N_t は全ノードの個数である．また， $E(\cdot)$ は各 FN の送信電力の関数である¹⁵⁾．この関数において， k は情報ビット数， E_{elec} は送受信機の動作のための電力， ε_{amp} は送信機の信号増幅のための電力である．この設計変数に対して，以下の目的関数を定義する．

$$f(x) = \frac{S^{-(N_t - N_r)}}{\sum_{i=1}^{N_t} E(R_i)} \quad (15)$$

ここで， N_r は FN を介してメッセージを受信できるノードの個数である．また， S は指数関数のパラメータである．式 (15) の分母は，全 FN の総消費電力が最小となるとき最小値となる．式 (15) の分子では，FN を介して SN からのメッセージを受信できるノードの総数が最大となるとき最大値となる．指数関数を用いて分子の評価値を優先することで，SN からのメッセージの普及をより確実なものとする．ただし，最適化の対象とする設計変数は第一段階で FN として選択された N_f 個のみとし，それ以外の設計変数値は全て 0 とする．これに対する解を進化的計算手法によって求める．以上を第二段階とする．

このような段階的な最適化を行うことで，第二段階における解空間の次元数を削減し，計算コストの増大を大幅に抑制することができる．また，第二段階の最適化によって，第一段階で得た解に対するさらなる改善が可能である．

3.4 数値実験による評価

次に本手法を適用した結果の一例を紹介する．WSN のパラメータは，エリアサイズが 500 [m]×500 [m]，ノード数が 400，通信可能範囲（送信出力の最大値）が $R_c = 150$ [m]，シンクノード SN の位置座標が $(x, y) = (250, 0)$ である．各ノードの送信電力の関数のパラメータはそれぞれ， $E_{elec} = 50$ [nJ/bit]， $k = 24$ [byte]， $\varepsilon_{amp} = 100$ [pJ/m²/bit] である．

第一段階で用いる CNN のパラメータは， $R_{th} = 100$ [m] とし，それ以外のパラメータは前章で示した値を用いた．第二段階で用いる進化的計算手法は人工蜂コロニー（Artificial Bee Colony；ABC）アルゴリズム^{10~12)}とした．ABC アルゴリズムは，他の手法と比較して，高次元な問題において高い性能を示すことが知

図5 各ノードの消費電力

表2 全ノードの総消費電力

解法	総消費電力 [mJ]
二段階最適化法	143.3
CNN による解法	167.2
TABC による解法	137.1

られている．ABC アルゴリズムの詳細は文献^{10~12)}，本実験で用いたパラメータ設定等については文献¹⁸⁾を参照されたい．比較の対象は，第一段階の CNN のみを用いた手法，および，ABC を複数の解が得られるように改良した Tabu ABC (TABC)¹⁷⁾とした．TABC による手法では，全てのノードに対して式 (13) に示した設計変数を割り当て，式 (15) に示した目的関数を用いて各探索個体の評価を行うものとした．TABC のアルゴリズムの詳細や本実験でのパラメータ設定等は文献¹⁷⁾を参照されたい．各手法ともに，20 種類の FN 群を得る試行を 10 回行い，その平均値を実験値とした．

図5に数値実験の結果を示す．縦軸は各ノードの消費電力，横軸は縦軸の値でソートしたノード番号である．また，表2に全ノードの総消費電力を示す．これらの結果から次のようなことが確認できる．

CNN による解法では，FN の個数が最小となるような FN 群を求めるため，FN として選択されるノードは限定的となる．また，最大送信出力（送信可能範囲）で送信を行うため，FN として選択されるノードの消費電力は固定的となる．結果として，総消費電力は3つの手法の中で最も高いことがわかる．

TABC による解法では，全ノードの総消費電力を目的関数としているため，この値は3つの手法の中で最も小さいことがわかる．しかし，FN としてフラッディングを行うノードの総数は CNN と比べて多くなり，また，一部のノードの負荷が高くなっていることがわかる．

一方、二段階の最適化による解法は、CNN による解法で得られた解に基づきさらに送信出力の最適化を行うため、CNN よりも各ノードの消費電力は全体的に低くなる。また、負荷が高くなるノードも生じていない。全ノードの総消費電力は TABC による解法で得られた結果よりも若干劣るが、CNN による解法で得られた結果よりも大きく改善されていることがわかる。本手法は、全ノードの総消費電力を削減できるとともに、各ノードの負荷を分散することもできる。これによって、WSN の運用可能期間を延ばすことが可能である。

4. ま と め

本稿では、第一段階でニューラルネットワークによる組合せ最適化を行い、第二段階で進化的計算による実数値最適化を行うアプローチを紹介した。本アプローチの適用例として、筆者らの最近の研究対象である無線センサネットワークにおける問題を取り上げた。ニューラルネットワークは個々のニューロンの動作が単純であり、高い並列性を有する演算が可能であるため、比較的低い計算コストで大規模な組合せ最適化問題を効率的に解くことができる。進化的計算の分野では様々な優れた手法が開発されており、連続値の設計変数の最適化に対して極めて有効である。本アプローチは、これらの利点を段階的な最適化という方法で活用することで、大規模な実数値最適化問題を効率的に解くことができる。このアプローチは無線センサネットワークにおける問題に限らず、様々な場面での利用が期待できる。各段階で用いる手法をどのように選択するか、第一段階でどの程度の解候補の抽出を行うか、第二段階でその結果をどのように利用するか、といった点については、さらなる検討の余地があると思われる。本アプローチはさらなる発展が期待できると考えている。

参 考 文 献

- 1) J.J. Hopfield: "Neurons with graded response have collective computational properties like those of two-state neurons," *Proc. Natl. Acad. Sci. USA*, vol.81, pp.3088–3092, 1984.
- 2) Y. Hayakawa and Y. Sawada, "Effects of the chaotic noise on the performance of a neural network model for optimization problems," *Phys. Rev. E, Stat. Phys. Plasmas Fluids Relat. Interdiscip. Top.*, vol.51, no.4, pp.2693–2696, 1995.
- 3) M. Hasegawa, T. Ikeguchi, T. Matozaki and K. Aihara, "An analysis on additive effects of nonlinear dynamics for combinatorial optimization," *IEICE Trans. Fundamentals*, vol.E80-A, no.1, pp.206–213, 1997.
- 4) K. Aihara, T. Takabe, M. Toyoda, "Chaotic neural networks," *Phys. Lett. A.*, vol.144, pp.333–340, 1990.
- 5) M. Hasegawa, T. Ikeguchi, K. Aihara, "Solving Large Scale Traveling Salesman Problems by Chaotic Neurodynamics," *Neural Networks*, vol.15, no.2, pp.111–123, 2002.
- 6) M. Hasegawa, T. Ikeguchi, K. Aihara, K. Itoh, "A Novel Chaotic Search for Quadratic Assignment Problems," *European Journal of Operational Research*, vol.139, no.3, pp.543–556, 2002.
- 7) 小野 功, 山村雅幸, 喜多 一, "実数値 GA とその応用," *人工知能学会誌*, vol.15, no.2, pp.259–266, 2000.
- 8) 佐藤 浩, 小野 功, 小林重信, "遺伝的アルゴリズムにおける世代交代モデルの提案と評価," *人工知能学会誌*, vol.12, no.5, pp.734–744, 1997.
- 9) J. Kennedy and R. Eberhart, "Particle swarm optimization," *Proc. Int. Conf. on Neural Netw.*, pp.1942–1948, 1995.
- 10) D. Karaboga, "An idea based on bee swarm for numerical optimization," *Tech. Rep. TR-06*, Erciyes University, Engineering Faculty, Computer Engineering Department, 2005.
- 11) D. Karaboga and B. Basturk, "A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm," *J. Global Optim.*, vol.39, pp.459–471, 2007.
- 12) D. Karaboga and B. Basturk, "On the performance of artificial bee colony (ABC) algorithm," *Appl. Soft Comput.*, vol.8, pp.687–697, 2008.
- 13) K. Deb, A. Pratap, S. Agarwal, and T. Meyarivan, "A Fast and Elitist Multiobjective Genetic Algorithm: NSGA-II," *IEEE Trans. Evolutionary Computation*, vol.6, no.2, pp.182–197, 2002.
- 14) I. Akyildiz, W. Su, Y. Sankarasubramaniam, and E. Cayirci, "Wireless sensor networks: A survey," *Computer Networks Journal (Elsevier)*, vol.38, no.4, pp.393–422, 2002.
- 15) W.R. Heinzelman, A. Chandrakasan, and H. Balakrishnan, "Energy-efficient communication protocol for wireless microsensor networks," *Proc. of the Hawaii International Conference on System Sciences (HICSS)*, pp.3005–3014, 2000.
- 16) T. Sasaki, H. Nakano, A. Utani, A. Miyauchi and H. Yamamoto, "An Adaptive Selection Scheme of Forwarding Nodes in Wireless Sensor Networks Using a Chaotic Neural Net-

- work,” ICIC Express Letters, vol.4, no.5(A), pp.1649–1655, 2010.
- 17) H. Lee, H. Nakano, and A. Miyauchi, “A Tabu Artificial Bee Colony Algorithm for Effective Forwarding Power Adjustment in Wireless Sensor Networks,” Proc. NOLTA, pp.227–230, 2012.
- 18) R. Sato, H. Nakano, and A. Miyauchi, “A Power Optimization Method in Large-Scale Wireless Sensor Networks Using a Two-Stage Meta-Heuristic Algorithm,” Proc. NOLTA, pp.302–305, 2013.