

令和 4 年 6 月 2 日現在

機関番号：34416

研究種目：基盤研究(C)（一般）

研究期間：2018～2021

課題番号：18K11484

研究課題名（和文）ディープラーニングを用いた組合せ最適化問題の新たな評価値の提案

研究課題名（英文）Proposal of new evaluation value for combinatorial optimization problem using deep learning

研究代表者

榎原 博之（EBARA, Hiroyuki）

関西大学・システム理工学部・教授

研究者番号：50194014

交付決定額（研究期間全体）：（直接経費） 3,500,000円

研究成果の概要（和文）：本研究では、組合せ最適化問題の1つである巡回セールスマン問題に対してディープラーニング（深層学習）並びに深層強化学習を適用した近似解法を提案する。ランダムに生成した大量の問題例に対して、最適解もしくは最良解を画像としてディープラーニングに学習させ、出力として得られた画像データから評価値を算出する。学習により得られた評価値を従来の距離による評価値の代りにヒューリスティック解法に適用して解を求める。計算機実験により、学習により得られた評価値が有効であることが分かった。

研究成果の学術的意義や社会的意義

組合せ最適化問題、特に、巡回セールスマン問題は応用範囲がたいへん広く、宅配便の配送計画や、ロボットの動作計画、プリント基板のドリル穴空け問題などに应用できるため、社会的意義は大きいと考える。

さらに、巡回セールスマン問題は、最も研究されている組合せ最適化問題の1つであり、この問題にディープラーニング手法の有効性を示すことは、他の組合せ最適化問題へも応用を示唆するとともに、ディープラーニングの新たな応用分野を示すことにもなっており、学術的意義は大きいと考える。

研究成果の概要（英文）：In this research, I propose approximate solution methods that apply deep learning and deep reinforcement learning to the traveling salesman problem, which is one of the combinatorial optimization problems. The deep learning is trained to learn the optimum solution or the near-optimal solution as an image for a large number of randomly generated problem instances, and an evaluation value is calculated from the image data obtained as an output. The evaluation value obtained by learning is adopted to the heuristic solution method instead of the conventional evaluation value based on distance, in order to obtain a solution. Computational experiments have shown that the evaluation values obtained by learning are valid.

研究分野：離散最適化

キーワード：深層学習 強化学習 機械学習 組合せ最適化問題 巡回セールスマン問題

科研費による研究は、研究者の自覚と責任において実施するものです。そのため、研究の実施や研究成果の公表等については、国の要請等に基づくものではなく、その研究成果に関する見解や責任は、研究者個人に帰属します。

1. 研究開始当初の背景

組合せ最適化問題は応用範囲が広く、配送計画や情報通信など様々な分野に応用されている。組合せ最適化問題の多くは NP 困難に属し、厳密解を求めるには指数関数的な時間を要するため、近似解法、特にメタヒューリスティックスの研究が盛んに行われている。しかし、メタヒューリスティックスの研究では、局所解に陥ることが多く、いかに大域的な解を見つけるかが課題である。

組合せ最適化問題の中には、配送計画問題や施設配置問題のように 2 次元平面上で頂点間の距離を重みとするユークリッド型の組合せ最適化問題が数多く存在する。これらの問題の目的関数は一般に距離の概念で定義されるため、解法の評価値に距離を採るのが一般的である。距離は最も直接的な評価値であることには相違ないが、距離以外の評価値の有効性が示せば、新たな解法の開発にもつながり、意義は大きいと考える。

近年、ディープラーニング[1]が注目されてきている。特に、画像の分野では畳み込みニューラルネットワーク (CNN) の仕組みにより汎用性に富む特徴抽出が可能であり、物体の認識率が実用レベルに達している。本研究でも経路などの解を画像として捉え、最適解の特徴抽出を試みる。

2. 研究の目的

本研究では、平面 TSP (巡回セールスマン問題) における新たな近似解法を提案する。平面 TSP とは、2 次元平面上に n 個の都市が与えられたとき、すべての都市を通る最短の経路 (巡回路) を求める問題である。

まず、教師あり学習による CNN を用いてエッジの評価値を計算する手法と、距離の代わりにエッジの評価値を用いる近似解法を提案し、それらの提案手法の性能を検証するために計算機実験を行う。この手法では、TSP 問題例とその解を画像として扱い、CNN により最短経路の画像を近似した優良エッジ分布と、ここから得られる各エッジの評価値 (優良エッジ値) を計算する。そして、距離の代わりに優良エッジ値をコストとした貪欲法により巡回路を構築し、優良エッジ値を使用した 2opt 法において経路上の優良エッジ値の総和が大きくなるようにエッジをつなぎかえることによって近傍探索を行う。

さらに、教師データ (最適解) を必要としない強化学習を使って優良エッジ分布を求める機械学習手法を提案し、最適解を求めることが時間的に困難な大きな問題例も学習することにより、教師あり学習と同等、あるいはそれを凌駕する解が得られることを示す。

本研究の目的は、ディープラーニングや強化学習により得られた新たな評価値を提案し、その評価値の有効性を計算機実験により証明することである。

3. 研究の方法

平面 TSP では、点および線の描画によってその問題例と解を画像として表現できる。ここで、ある平面 TSP の問題例についてすべての都市を描画した頂点画像とその最短経路を描画した経路画像を最大画素値 1 で点および線で描画する。頂点画像を入力したときその問題の最短経路画像を出力するような CNN モデルを考える。

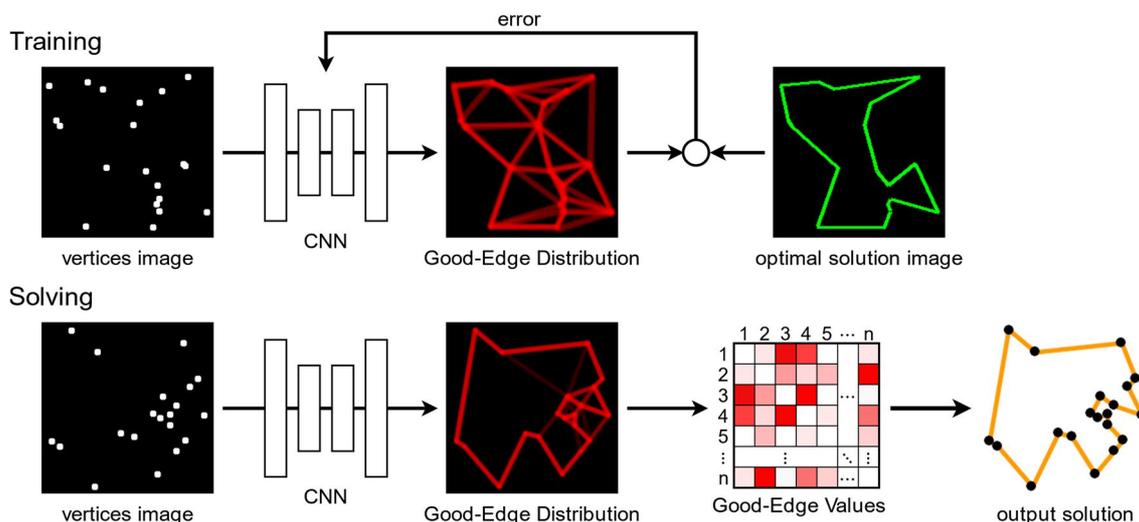


図 1 優良エッジ分布の学習方法

優良エッジ分布はその出力を教師信号 (最短経路) に近づけることを目的として誤差逆伝播法を用いて学習を行う。学習により優良エッジ分布が得られたとき、各エッジ上における優良エッ

ジ分布の平均を求めることで、そのエッジが最適経路に含まれる尤度を計算する。これを優良エッジ値と呼ぶ。優良エッジ値は出力画素値の濃度からエッジの交差ペナルティを引いて求められる。優良エッジ分布の学習方法を図1に示す。

うまく学習できれば、優良エッジ値が高いエッジを優先的に選択することで最短経路に近い解が得られることが期待できる。実際の距離の代わりに優良エッジ値を用いた解法として、優良エッジ値が高い辺を優先的に選択して巡回路を構築する EV-greedy、EV-greedy で巡回路を求めた後、優良エッジ値の総和を最大化する、評価値が優良エッジ値である 2opt 近傍探索法を行う EV-2opt、さらに、距離の総和を最小とした、評価値が距離である 2opt 近傍探索法を行う EV-2opt + 2opt を提案している。

学習に用いる平面 TSP の問題例は、都市数 20 ~ 100 のランダムな問題例を 20 万個用意する。学習時間は 300 時間である。

4. 研究成果

テスト用問題例には、16 個のランダム問題と、TSPLIB[2]に含まれる 42 個の問題例を使用する。TSPLIB の問題例に関しては、S2V-DQN (Structure2Vec Deep Q-Learning) による実験結果 [3]も同様に比較する。図2に100都市の問題例に対する優良エッジ分布と解の出力例を示す。表1にランダムな問題例に対する平均誤差率(%)、表2にTSPLIBの問題例に対する平均誤差率(%)を示す。いずれも試行回数の20回の平均である。

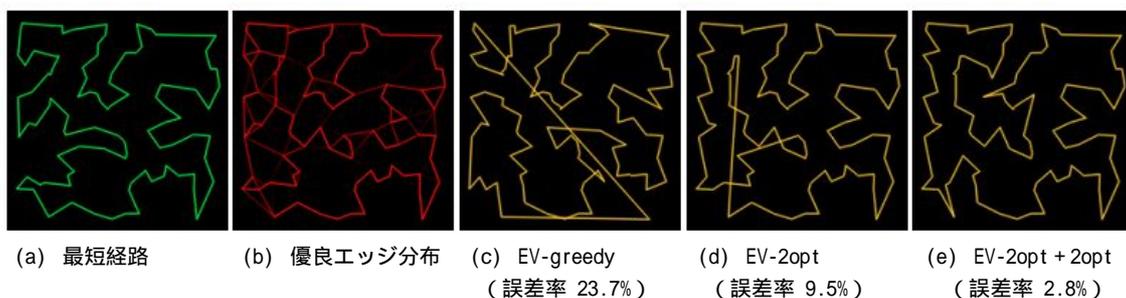


図2 優良エッジ分布と解の出力例 (rand100-A)

表1 ランダムな問題例に対する平均誤差率 (%)

問題例	2opt	EV-2opt	EV-2opt+2opt
rand20-A	1.389	0.000	0.000
rand20-B	0.000	0.000	0.000
rand50-A	5.207	0.220	0.170
rand50-B	2.449	0.405	0.405
rand75-A	2.196	14.779	2.369
rand75-B	7.034	4.115	0.685
rand90-A	2.925	1.090	0.419
rand90-B	7.680	6.633	0.993
rand100-A	5.485	7.584	2.727
rand100-B	7.149	0.022	0.022
rand100-C	5.118	4.732	1.965
rand150-A	5.708	3.861	0.604
rand200-A	5.015	9.216	2.620
rand300-A	4.630	15.269	4.449
rand400-A	4.857	13.631	4.635
rand500-A	5.277	15.470	5.261
総平均	4.508	6.064	1.708

学習データが100都市以下であったため、200都市以下の問題例ではかなり良い結果が得られた。特に、最後に距離を評価値として解の改良を実施した EV-2opt + 2opt は、他の近似解法に

遜色ない解が得られている。このことから、機械学習により最適解の特徴抽出に成功したと考えている。今後、200都市以上の問題例に対しても良い結果が得られるように改良する必要がある。

200都市以上の問題例に対しても良い結果が得られるように強化学習により手法を提案している。強化学習による手法のデータは現在整理中であるが、表1と表2の結果と同等な結果が得られており、特に都市数の多い問題例では、表1と表2の結果を上回っていると思われる。

表2 TSPLIBの問題例に対する平均誤差率(%)

問題例	2opt	S2V-DQN	EV-2opt	EV-2opt+2opt
eil51	3.462	3.052	11.162	2.958
berlin52	9.382	0.000	0.350	0.000
st70	3.993	3.111	1.489	0.452
eil76	4.089	4.833	0.372	0.037
pr76	4.293	0.265	6.648	2.188
rat99	4.013	5.698	5.925	1.936
kroA100	2.407	2.890	1.415	0.477
kroB100	2.238	2.489	3.426	0.660
kroC100	3.162	1.566	4.170	0.104
kroD100	5.071	3.794	4.013	0.986
kroE100	2.696	3.829	8.449	2.708
rd100	4.149	3.148	2.996	1.320
eil101	6.065	4.769	5.469	1.932
lin105	3.418	4.479	5.709	0.807
pr107	1.943	1.828	8.474	1.750
pr124	2.698	4.393	7.042	2.506
bier127	6.416	2.785	8.553	2.681
ch130	4.865	2.619	9.814	3.205
pr136	9.426	2.792	10.905	2.221
pr144	1.507	1.536	20.047	1.198
ch150	7.027	7.001	7.354	2.500
kroA150	3.579	5.143	10.163	2.672
kroB150	5.987	4.129	5.678	2.577
pr152	3.036	2.173	8.800	1.254
u159	5.617	7.968	0.291	0.107
rat195	5.390	11.106	15.189	5.568
d198	5.445	4.265	17.931	2.817
kroA200	4.893	5.438	7.388	2.747
kroB200	5.682	7.660	14.944	3.326
ts225	2.099	7.627	6.448	2.742
tsp225	3.807	6.078	10.409	3.390
pr226	4.753	1.871	9.276	4.601
gil262	5.200	6.686	7.881	2.096
pr264	7.277	6.572	28.820	1.551
a280	5.737	11.167	13.722	5.572
pr299	6.877	7.686	24.754	4.663
lin318	5.565	7.961	16.362	4.186
rd400	3.866	—	12.274	3.923
fl417	5.370	—	13.318	3.526
pr439	6.431	—	28.604	7.120
pcb442	5.639	—	11.380	4.241
d493	4.514	—	20.373	4.917
総平均 (lin318 まで)	4.683	4.606	8.969	2.230
総平均 (全問題例)	4.740	—	9.947	2.529

参考文献

- [1] Yann LeCun, Yoshua Bengio, Geoffrey Hinton: Deep learning, Nature 521, 436-444, DOI:10.1038/nature14539 (2015).
- [2] G.Reinelt: TSPLIB–A Traveling Salesman Problem Library, ORSA Journal on Computing, Vol. 3, No. 4, pp. 376-384 (online), DOI: 10.1287/ijoc.3.4.376 (1991).
- [3] H.Dai, E.B.Khalil, Y.Zhang, B.Dilkina and L.Song: Learning Combinatorial Optimization Algorithms over Graphs, arXiv preprint arXiv:1704.01665 (2017).

5. 主な発表論文等

〔雑誌論文〕 計1件（うち査読付論文 1件 / うち国際共著 0件 / うちオープンアクセス 0件）

1. 著者名 三木彰馬, 榎原博之	4. 巻 60
2. 論文標題 深層学習を用いた巡回セールスマン問題の解法	5. 発行年 2019年
3. 雑誌名 情報処理学会論文誌	6. 最初と最後の頁 651-659
掲載論文のDOI（デジタルオブジェクト識別子） なし	査読の有無 有
オープンアクセス オープンアクセスではない、又はオープンアクセスが困難	国際共著 -

〔学会発表〕 計6件（うち招待講演 0件 / うち国際学会 2件）

1. 発表者名 Shoma MIKI, Hiroyuki EBARA
2. 発表標題 Solving Traveling Salesman Problem with Image-based Classification
3. 学会等名 IEEE 31st International Conference on Tools with Artificial Intelligence (ICTAI), Portland, OR, USA (国際学会)
4. 発表年 2019年

1. 発表者名 濱洲陵, 山本大輔, 三木彰馬, 榎原博之
2. 発表標題 巡回セールスマン問題に対するファインチューニング
3. 学会等名 2019年電子情報通信学会 基礎・境界ソサイエティ大会 (N-1-16), 大阪大学
4. 発表年 2019年

1. 発表者名 山本大輔, 三木彰馬, 榎原博之
2. 発表標題 強化学習を用いた巡回セールスマン問題の解法
3. 学会等名 情報処理学会 第81回全国大会
4. 発表年 2019年

1. 発表者名 Shoma MIKI, Daisuke YAMAMOTO, Hiroyuki EBARA
2. 発表標題 Applying Deep Learning and Reinforcement Learning to Traveling Salesman Problem
3. 学会等名 IEEE International Conference on Computing, Electronics & Communications Engineering 2018 (国際学会)
4. 発表年 2018年

1. 発表者名 三木彰馬, 山本大輔, 榎原博之
2. 発表標題 深層学習を用いた組合せ最適化問題の解法と強化学習の適用
3. 学会等名 情報処理学会 数理モデル化と問題解決研究会,
4. 発表年 2018年

1. 発表者名 三木彰馬, 榎原博之
2. 発表標題 強化学習を用いた畳み込みニューラルネットワークによる巡回セールスマン問題の解法
3. 学会等名 情報処理学会 第84回全国大会
4. 発表年 2022年

〔図書〕 計0件

〔産業財産権〕

〔その他〕

-

6. 研究組織

氏名 (ローマ字氏名) (研究者番号)	所属研究機関・部局・職 (機関番号)	備考
---------------------------	-----------------------	----

7. 科研費を使用して開催した国際研究集会

〔国際研究集会〕 計0件

8 . 本研究に関連して実施した国際共同研究の実施状況

共同研究相手国	相手方研究機関
---------	---------