

深層強化学習による発泡スチロール系漂着ゴミの資源循環方策の導出

メタデータ	言語: ja 出版者: 公開日: 2023-04-18 キーワード (Ja): キーワード (En): 作成者: 石田, 武志 メールアドレス: 所属: 水産研究・教育機構
URL	https://fra.repo.nii.ac.jp/records/199



深層強化学習による発泡スチロール系漂着ゴミの 資源循環方策の導出*

石田 武志**

Developing Strategy for Coastal Marine Debris Disposal Network Using Deep Reinforcement Learning

by Takeshi Ishida

The process of collecting and disposing of coastal marine debris isn't usually economically feasible without government subsidies. However, Ishida et al. reported this process can be made profitable by linking Styrofoam waste oil liquefaction equipment with decentralized energy systems. Examples of these energy systems include cogeneration systems (CGS) and photovoltaic power generation. In this study, a model was developed to examine which part of a coastal debris disposal operation system should be assisted with profits generated from a coastal marine debris disposal network linked to CGS. This is expected to dispose of as much coastal marine debris as possible in a short period of time. Specifically, it was modeled using deep Q-learning (DQN), which is one of deep reinforcement learning methods. On the premise that a certain amount of marine debris reached the coast, the model incorporated the combination of three elements, namely greater profits gained by increasing the capacity of CGS, stocking profits for a certain period of time and marine debris collection. The model developed herein made it possible to handle the amount of coastal marine debris that wouldn't have been treated if profits were spent on the coastal marine debris disposal network on a yearly basis. This DQN-based model resulted in the development of a strategy, which reflects the view that "the larger the initial amount of litter becomes, the longer the stock period of profits from CGS should become."

1. はじめに

1.1 沿岸漂着ゴミの現状と対策

九州東シナ海沿岸や北海道東部沿岸は、周辺国からの漂着ゴミが多く、長崎県対馬などの離島では海岸が大量のゴミで埋まる状況も見られる。日本全国に漂着するゴミの総量は、環境省報告書の推計によれば、約22万t~42万t(2015年時)であり、実際に回収されたゴミは3.3万tほどである¹⁾。このうち発泡スチロールは人工漂着物のうち容積比で16%を占めている¹⁾。これら沿岸部に漂着した発泡スチロールは波力などで破碎され、そのプラスチック片が沿岸部岩場の間に堆積し、貝類やゴカイ類の生育環境を脅かしているとの報告もある²⁾。またこのプラスチック片の破碎が進むと、5mm以下のマイクロプラスチックとなると考えられている。近年、マイクロプラスチックによる生態系への影響が懸念されるようになり、その実態調査や海洋へのプラスチックの流出を防ぐ対策も近年始められている³⁾。

このような中で、2009年7月に「美しく豊かな自然を保護するための海岸における良好な景観及び環境の保全に係る海岸漂着物等の処理等の推進に関する法律」(海岸漂着物処理推進法)が施行され、漂着ゴミの発生抑制や回収処理が進められている³⁾。しかしゴミの回収は行政からの補助金を利用したボランティア活動により支えられており、予算不足から回収が進まない自治体も多い。

さらに、回収された漂着ゴミの処理についても課題が残されている。特に離島においては島内処分施設の不整備のため島外処理を行う必要があり、島外への運搬費が非常に高くなる。対馬市の事例では、1.05m³の袋1袋当たり、島外への運搬費が約1万円と報告されている⁴⁾。このように、漂着ゴミの回収・処理においては補助金に頼る部分が多く、回収量や事業の継続性は、補助金の規模により決まる形となる。補助金が不足した場合、回収が進まなくなると共に、回収されたゴミについても、最も費用がかからない山間地への埋立て処分方式になることが危惧されている。漂着ゴミは塩分や化学物質を吸着している場合が多く、そのまま山間地に埋め立て処分を行うと、土壌汚染などの2次汚染につながる可能性も考えられる。

*原稿受付 令和2年12月1日。
**正会員 水産研究・教育機構 水産大学校(下関市永田本町2-7-1)。

このため今後は、浮遊状態も含めた漂着ゴミの効率的な捕捉・回収技術と、事業採算性を踏まえた処理・再資源化システムを検討していくことが必要である。漂着ゴミの再資源化については、発泡スチロールの油化装置の導入などが長崎県対馬市や沖縄県鳩間島などで試みられている⁹⁾。油化されたスチレン油は、油化装置の加熱用燃料に用いられるとともに、重油などと混焼して燃料として利用できる。また輸送費がかさむ発泡スチロールは、植物油を用いた脱塩・減容化技術の開発が川原、山口ら^{6,7)}により行われ、容積を1/50程度にできると報告されている。

1.2 沿岸漂着ゴミの処理システムの経済性研究

通常は補助金などが無ければ経済的には成立しない漂着ゴミの回収・処理プロセスが、分散エネルギーシステムと連携させることにより、経済的に成立できる可能性を石田ら⁸⁾は報告している。この研究は、漂着ゴミの再資源化が事業として成立するための技術的、制度的および経済的条件を総合的に検討して、漂着ゴミの回収・利用が経済的に成立する可能性を最適化モデルにより示している。この研究で評価対象としたシステムは図1に示すものであり、沿岸に流れ着く発泡スチロール系の漂着ゴミに対して、発泡スチロール油化装置とコージェネレーションシステム (CGS)、太陽光発電 (PV) を組み合わせたものである。発泡スチロール系の漂着ゴミを沿岸部で回収・減容化し、その発泡スチロールを一か所に収集し、油化装置によりスチレン油を生成する。さらに、近隣に所在する事業所に設置されたA重油を燃料とするCGSと、PVが導入された住宅群の組み合わせを想定している。油化装置で生成されたスチレン油は、油化過程でその一部が自己消費されるとともに、余剰分はCGSの燃料として使用され、さらにCGSによる発電のうち事業所で消費しなかった余剰電力分は、住宅に供給される。逆に住宅のPVによる余剰電力も事業所へ融通するシステムを考えている。

このような事業所のCGSと住宅用PV間でのエネルギーの相互融通を考慮した最適化モデルによる評価で、より大きな省エネルギーが確保できることは石田らの研究⁸⁾などでも報告されている。またこのシステムの場合、漂着ゴミなどから得られたスチレン油をCGSの燃料として用いることで、CGSの経済性をより向上させることが可能となり、さらに住宅用PVとの電力融通により、お互いに市場価格より安い電力を確保でき、より経済的な利益が大きくなる。そしてそこで生み出された利益を漂着ゴミ回収へと投じることができ、補助金などに頼らない資源循環が成立できる可能性があることをシミュレーションで示している⁸⁾。

この石田らの報告に基づけば、発泡スチロール油化装置とCGS、PVを組み合わせた「漂着ゴミも処理できる地域発電所」を経済的に設置できる可能性を示していると考えられる。しかし一定の条件下での経済的成立条件は示すことができたものの、ゴミ回収量や電力単価などの外的環境が変動する中で、得られた利益をどのようにシステムの設備や運転に投じていけば漂着ゴミの回収処理量の最大化が図れるかなど、システムの運用方策を導出していく点は明らかではなく、今後検討していく必要がある。

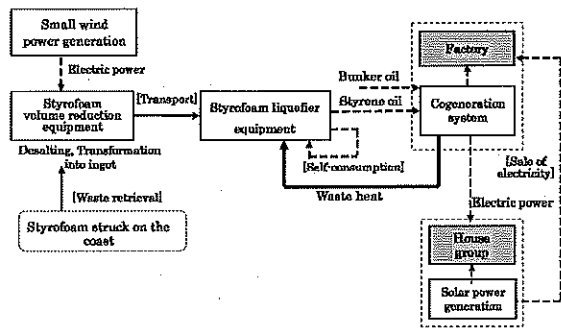


Fig. 1 Outline of assumed waste collection and energy system⁸⁾

1.3 研究目的

本研究では、様々な変動要因下においても漂着ゴミ回収が継続されるシステムの導入・稼働方策を導出できる基礎モデルを構築するために、深層強化学習の一つである深層Q学習 (DQN) の手法により、図1に示す「漂着ゴミも処理できる地域発電所」の導入・稼働方策を検討したものである。具体的には、一定規模の漂着ゴミを削減していくために、CGSから生み出される利益を、システムの運用上での部分 (CGS容量の拡張、漂着ゴミの回収の推進、利益のストックなど) に投入すれば、短期間でより多くの漂着ゴミの処理が可能なのかについて、DQNの手法をプログラミング言語pythonにより実装することにより導出した。

DQNは、強化学習のひとつであるQ学習と深層学習を組み合わせたもので、強化学習に基づいて解を探索しつつ、その解探索の経験データを学習用データとして深層学習モデルを導出するもので、2015年にDeepMind社により開発され発表された¹⁰⁾。その後DQNの応用は多岐にわたり非常に多くの研究が発表されている。しかし、沿岸漂着ゴミの処理システムに関して、深層強化学習を応用した研究は国内外ともにみられない状況である。一方で地域の再生可能エネルギーシステムの運用における深層学習の利用の研究例としては、^{11), 12), 13)}など多くの事例が報告されている。また、投資戦略の導出などに深層強化学習を利用した

事例は、¹⁴⁾ ¹⁵⁾ などがあるが、CGS と PV の地域ネットワーク設備への投資への応用事例はみられない状況である。

2. 計算モデルの構築

2.1 評価システムの設定

本研究では、図 2 に示すような CGS と PV を核とした漂着ゴミ回収エネルギーシステムを考えた。このシステムにおいて、初期条件として回収処理すべき一定量の漂着ゴミ量が存在するとして、CGS、PV の運転から得られる利益により回収を進めていき、年単位の時系列を考え 20 年以内にゴミを回収できるかという問題を設定した。

毎年の電力売買による余剰利益により、1) 漂着ゴミの回収・処理、2) 利益のストック、3) CGS の容量増強の 3 つの行動選択が可能であるとした。ここで 1) は一度に投入する金額が大きいほど、複数の人員で分業が可能のため、ゴミ回収量が指数関数的に増加するとした(式は後述)。また、3) については CGS を増強することにより年間の利益が大きくなる(式は後述)。設定された問題の環境においては、毎年の利益を単にゴミ回収・処理に充てるだけでは期間内にゴミ回収が終わらない状況を設定しており、ストックした利益によりゴミ回収の規模を大きくするか、CGS の増量を行い毎年の利益を大きくするかの選択を適切に組み合わせることで、期間内にゴミ処理が完了する解を求める問題設定とした。

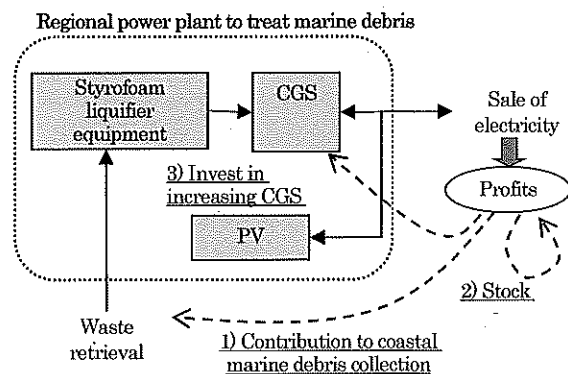


Fig. 2 Evaluation frame for styrofoam recovery system

2.2 深層強化学習モデルの概要

漂着ゴミを期間内に回収するという目的を達成するために、各年での 3 つの行動選択を算定するモデルを深層強化学習 (DQN) により構築した。Q 学習により各状態における価値 (行動価値関数) を以下の Q 学習

の標準的な式でステップ (年) ごとに更新して求めた。

$$Q(s_{t+1}, a_{t+1}) = Q(s_t, a_t) + \eta(R_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a)) \quad (1)$$

ここで $Q(s_t, a_t)$ は行動価値関数であり、タイムステップ t 、状態 s における行動 a (本モデルでは 3 つの行動) の「価値」を表している。「価値」は選択する行動における仮想的な価値であり、電力売買における金銭的利益とは別のものである。 η は学習係数、 R_{t+1} は即時報酬 (これも金銭的利益とは別のもの)、 γ は将来の価値に対する割引率、 $\max_a Q(s_{t+1}, a)$ は、次のステップで価値が最大となる行動選択時の行動価値関数である。初期状態から各年での行動を 1 ステップとして、20 年間 (20 ステップ) で 1 エピソードとした。すなわち本モデルでは、「状態」は経過年数を指し、それぞれの経過年数の状態において、漂着ゴミの残量という「環境」に対して、3 つの「行動」の中から「価値」の高い行動を選択するという構成になっている。そして漂着ゴミが 0 になった場合、即時報酬が得られるとした。

各年 (タイムステップ) における行動選択の価値関数値は、完全にランダムな初期設定から計算を開始し、修正 greedy 法によるランダムな行動選択による探索の割合を減少させながら、目的を達成できる価値関数値を導出した。各年において、導出された最終的な価値関数値が最大である行動を選択すれば、目的を達成できることになる。

さらに、目的を達成できる価値関数値を経験データとして蓄積し、ニューラルネットワーク (NN) により行動選択モデルを導出した。NN の入力層は 20 ノードで、経過年数に相当する入力端末が一つ選択され、出力層は 3 ノードで 3 つの行動選択の一つが出力される。隠れ層は 1 層 8 ノードとし、活性化関数には隠れ層では tanh 関数、出力層では LeRu 関数 (ランプ関数) を用いた (図 3)。損失関数は、交差エントロピー誤差関数を用いている。最適化の計算は Adam を用いて損失関数が最小値になる係数を計算している。また、学習データを一度に処理するバッチ学習を行いドロップアウトは導入していない。




Fig. 3 Structure of deep learning part

2.3 学習モデルにおける設定

2.3.1 稼働する CGS 容量と余剰利益の関係式

稼働する CGS 容量 x (kW)と年間の利益 y (万円)の関係式は以下を用いた。

$$y = 9.82 \ln x + 0.169 \quad (2)$$

この式は対数関数であるため、CGS 容量が大きくなるにつれて、利益の伸びが抑制される関数となっている。これは、CGS と電力を融通し合う住宅数を 1000 戸に限定しているため、CGS の容量が大き過ぎると住宅との融通時に電力の余剰が出て、利益が逡減するためである。CGS と太陽電池住宅の条件設定は、文献 8)と同様とし、計算式のベースとなったデータの詳細は最後の「6. 付録」に示す。

2.3.2 コストと漂着ゴミ回収量の関係式

計算の前提となる投入資金 x (万円) と発泡スチロールの回収量 y (t)の関係式は以下の式により設定した。

$$y = 0.1 x^{1.5} \quad (3)$$

回収人件費 5000 円/人日、回収・選別量 50 kg/人日、運搬費用 25 円/kg (2t トラック=5 万円) と想定すると、これより回収 1kg 当たりの単価は 125 円/kg となる。これより 80 kg/万円が導出できる。概算として 1 万円あたり 100 kg (0.1 t) の回収と想定し、投入資金が増加するとともに、投入人員が多くなり分業などにより作業効率が向上するため、投入資金が多くなるほど指数 1.5 (この値は暫定値であり、今後回収量と費用のデータを蓄積して確認していく必要がある) として回収量が増加するとした。また再生されたスチレン油のうち、40%は油化装置で自己消費されると設定した (設定値の根拠は 6. 付録に示す)。

2.3.3 DQN 計算条件

Q 学習における設定として、割引率 $\gamma=0.8$ 、学習率 $\eta=0.5$ で計算した。ε-greedy 法は $\epsilon=1$ (完全にランダム) から計算を開始し、エピソードが成功すると

に 0.05 ずつ低減させ、ε が 0.5 以下になった場合、ε を半減させていった。経験データとして 50 エピソード分を計算して NN の学習用データとした。これら γ 、 η 、 ϵ 値の設定やエピソード数などのパラメータについては、いくつかの試行計算により目標達成をする選択肢を導出できるパラメータを設定した。これらのパラメータの相違による計算結果の体系的な相違については今後の課題と考えている。

2.3.4 計算ケース

CGS の初期容量は文献 8)における評価規模を踏襲し 10kW とした。上記式(2)によれば 10kW での年間の利益は 22.8 万円となり、これを式(3)に代入すると、回収できる量は 10.8 t/年なる。毎年得られる利益をそのままゴミ回収に充てた場合では、20 年間で 216 t の回収までが限界である。このため初期の漂着ゴミ量として、回収が可能である 200t に加え、毎年得られる利益をそのままゴミ回収に充てた場合では回収しきれない量として 250t, 300t, 350t, の 4 ケースを計算した。

3. 計算結果

Q 学習による経験データを用い NN の重み係数を最適化したモデルに基づいて、各年数における最適な行動戦略を導出した計算事例を表 1 に示す。表 1 は初期漂着ゴミ量別の各年の行動である。いずれの初期ゴミ量においても、利益のストックを一定期間行い、それをゴミ収集にまとめて投下することで、回収の増加を図っている戦略であることが読み取れる。また初期ゴミ量が多いほど、利益のストックを長期間行わないと、20 年以内での処理が難しいことがわかる。この結果は、様々な経過年数で目標達成できた Q 学習による経験データに基づいており、このデータを用いて NN モデルの係数を決定しているため、NN モデル上では 20 年分全ての経過年数における行動選択肢を出力することが可能になっている。図 4 はこの行動選択肢に基づいて経過年数ごとのゴミ残量の推移を示したものである。それぞれの初期ゴミ量の計算において Q 値の初期設定をランダムに設定しているため経験データの状況により、同じ初期ゴミ量でもゴミ量削減の推移が異なってくる。図 4 における 300 t, 350 t の推移もその一例であり、ここでの結果では 350 t のほうが減少が早かった結果になっているものと考えられる。

表 2 には初期ゴミ量が 300 t の場合の Q 学習のみで行動を最適化した解と、DQN による結果の比較を示す。いずれの結果でも、CGS 増量と利益ストック、ゴミ回収を適度に組み合わせていることがわかる。

またこれらは1つの解であり、乱数により設定している価値関数の初期条件などが変化することにより解も変わってくる。表3にそれぞれの初期ゴミ量において、10回ずつ計算を行ったうえで、利益ストックの連続継続年数の平均(a)と、20年間の中での利益ストックの連続が発生した平均回数(b)をまとめたものを示す。初期ゴミ量が大きくなるにつれて、連続継続年数の平均が大きくなっていくことがわかり、連続が発生した平均回数は2回前後であることがわかる。(a)×(b)より20年間のうちでの利益のストックの継続年数の平均をみると、これも初期ゴミ量が大きくなるにつれて、平均(a)×(b)が大きくなっていくことがわかる。この標準偏差はいずれも3程度であり、初期値によらず一定範囲の方策を導出できていることがわかる。

Table 1 Results of action choice of each year with DQN

Years	200 t Action choice	250 t Action choice	300 t Action choice	350 t Action choice
1	1 Stock profits	2 Marine debris collection	3 Invest in CGS	1 Stock profits
2	3 Stock profits	1 Stock profits	1 Stock profits	1 Stock profits
3	2 Marine debris collection	2 Marine debris collection	1 Stock profits	2 Marine debris collection
4	1 Stock profits	2 Marine debris collection	1 Stock profits	1 Stock profits
5	2 Marine debris collection	2 Marine debris collection	1 Stock profits	1 Stock profits
6	2 Marine debris collection	1 Stock profits	3 Invest in CGS	2 Marine debris collection
7	2 Marine debris collection	2 Marine debris collection	2 Marine debris collection	3 Stock profits
8	1 Stock profits	2 Marine debris collection	1 Stock profits	1 Stock profits
9	1 Stock profits	1 Stock profits	2 Marine debris collection	3 Stock profits
10	1 Stock profits	1 Stock profits	1 Stock profits	2 Marine debris collection
11	2 Marine debris collection	1 Stock profits	3 Invest in CGS	1 Stock profits
12	2 Marine debris collection	1 Stock profits	2 Marine debris collection	1 Stock profits
13	2 Marine debris collection	2 Marine debris collection	1 Stock profits	1 Stock profits
14	1 Stock profits	3 Invest in CGS	1 Stock profits	1 Stock profits
15	2 Marine debris collection	2 Marine debris collection	1 Stock profits	1 Stock profits
16	3 Invest in CGS	1 Stock profits	1 Stock profits	1 Stock profits
17	1 Stock profits	1 Stock profits	1 Stock profits	1 Stock profits
18	2 Marine debris collection	1 Stock profits	1 Stock profits	1 Stock profits
19	2 Marine debris collection	2 Marine debris collection	2 Marine debris collection	2 Marine debris collection
20	2 Marine debris collection	1 Stock profits	1 Stock profits	1 Stock profits




Fig. 4 Changes in the amount of remaining coastal marine debris over the years

Table 2 Results of action choice of each year with Q learning and DQN

Years	300 t (Q learning)		300 t (DQN)	
	Action choice		Action choice	
1	3 Invest in CGS	1 Stock profits	1 Stock profits	
2	1 Stock profits	1 Stock profits	1 Stock profits	
3	1 Stock profits	1 Stock profits	1 Stock profits	
4	1 Stock profits	2 Marine debris collection	2 Marine debris collection	
5	1 Stock profits	1 Stock profits	1 Stock profits	
6	3 Invest in CGS	1 Stock profits	1 Stock profits	
7	2 Marine debris collection	2 Marine debris collection	2 Marine debris collection	
8	1 Stock profits	3 Invest in CGS	3 Invest in CGS	
9	2 Marine debris collection	1 Stock profits	1 Stock profits	
10	1 Stock profits	3 Invest in CGS	3 Invest in CGS	
11	3 Invest in CGS	3 Invest in CGS	3 Invest in CGS	
12	2 Marine debris collection	1 Stock profits	1 Stock profits	
13	1 Stock profits	1 Stock profits	1 Stock profits	
14	1 Stock profits	1 Stock profits	1 Stock profits	
15	1 Stock profits	1 Stock profits	1 Stock profits	
16	1 Stock profits	1 Stock profits	1 Stock profits	
17	1 Stock profits	1 Stock profits	1 Stock profits	
18	1 Stock profits	1 Stock profits	1 Stock profits	
19	2 Marine debris collection	2 Marine debris collection	2 Marine debris collection	
20	1 Stock profits	1 Stock profits	1 Stock profits	

Table 3 Average number of years and number of continuations of profit stock

	200 t	250 t	300 t	350 t
Average duration of profit stock (a)	3.1	4.3	5.6	8.4
Average number of profit stock continuations (b)	2.2	2.6	2.4	1.8
(a)×(b)	6.7	11.1	13.4	15.2
Standard deviation of (a) × (b)	3.7	3.5	3.0	3.5

4. 考察

CGSの稼働により各年に得られる利益をそのまま回収に充てては、20年間で回収が難しい環境において、利益をストックして投資規模を増やして、回収することにより、回収を加速させる戦略をDQNにより導出できた。特に初期ゴミ量が増加した場合においても、長期間利益をストックして、一度にゴミ回収に投下するという方策を安定的に導出することができた。

またDQNによる計算では、CGS容量の増加よりも利益をストックしておいてゴミ回収に投下することがいずれの初期ゴミ量でも戦略としては主となることが導出された。この点に関しては、CGS増量による利益の増加率と、ゴミ回収の投資効率とのバランスにより決まると考えられ、今後様々な条件で検討していくことを考えている。

また本研究での条件のような単純な評価フレームであれば、Q学習のみでも最適な行動戦略を導出することが表2より判断できる。しかし今後、季節変動や社会環境条件（電力売買価格、ゴミ漂着量など）などのよ

り複雑な環境条件に応じた中で、運用戦略を構築して
くうえでは、DQN モデルを用いていくことが必須に
なると考えられ、本モデルはその基盤となるものであ
る。

5. まとめ

本研究は、DQN の手法を用いて、漂着ゴミの処理
システムの導入・稼働方策を導出できる基礎的なモデ
ルを構築したものである。一定の設定・条件下ではあ
るが、DQN が導出した戦略により、一定規模のゴミ
処理が可能な解を導出することが可能であることがわ
かった。

次の研究テーマとしては、電力売買価格、ゴミ漂着
量などの環境値や、利益のストック状況などの入力に
対して最適な行動方策を導出できる DQN モデルを構
築していくことを考えている。

さらに本研究での検討を進めていくことで、CGS や
PV などの分散エネルギーで得られた利益を、他地域
のゴミ回収や CGS 設置・増量に投下できれば、漂着
ゴミ回収のための自律システムを複数の箇所に導入し
て拡大していくことができると考えられ、最終的には広
範囲の沿岸部の漂着ゴミをゼロにすることを旨とする
可能性がある。

6. 付録

CGS の稼働による利益の推計は以下の条件で行っ
た。

(1) 事業所のエネルギー需給・コスト推計

CGS を導入する事業所の 1 日 24 時間の電力需要の
設定(季節変動がないと想定)により、CGS の発電量、
余剰発電の売電量、不足電力の購入量を推計した。ま
たこれらの数値から、CGS の燃料消費量、購入電力料
金、売電収入などを計算し、全ての電力を電力事業者
から購入した場合と比較したエネルギーコストの低減
額を利益とした。現状の電力供給制度では、時間帯別
に異なる電力事業者から電力を購入することはできな
いが、本推計では余剰電力が生じた時間帯のみ、住宅
への電力の独自供給を検討できる設定とした。このと
きの電力の託送料金は考慮していない。

さらに CGS 燃料については、油化装置からのスチ
レン油を無償で受け入れるとしている。CGS の熱は事
業所内の生産設備や油化装置などで全て使い切れると
想定した。小型のディーゼル発電 CGS を想定し、発
電効率は低位発熱量基準で 40%、排熱回収効率は 32%
とした。事業所の電力需要は、昼間のみ稼働する中小
規模の事業を想定し、以下のように設定し、事業所の

需給の季節別変動はないとした。

事業所の電力需要(季節変動無し, 365 日稼働と想定)

昼間(8~18 時) : 毎時 200kWh
夜間(18~翌 8 時) : 毎時 10 kWh

(2) PV 住宅のエネルギー需給・コスト推計

住宅の 1 日 24 時間の電力需要値を基礎として、季
節別(夏期, 冬期, 中間期)、天候別(晴れ, 曇り, 雨)
に、PV 発電量、余剰発電の売電量、不足電力の購入
量を推計した。住宅戸数は 1000 戸に固定した。

本推計での住宅は PV が設置されているものとし、
都市ガス等を用いないオール電化住宅を想定した。住
宅のエネルギー負荷は、住宅の床面積を 100m² として、
空気調和・衛生工学会の原単位データ¹⁶⁾を用いて、
季節別 24 時間値を空調用、給湯用、その他電力用と
して求めた。この負荷をベースに、空調用エネルギー
負荷から COP が 3.0 の想定で割り戻し空調用消費電
力量を求め、給湯用負荷から COP が 3.0 の想定で給
湯用消費電力量を求めた。そしてこれらを、その他電
力負荷と合わせ住宅全体の電力需要量とした。図 5 に
本推計で用いた住宅のエネルギー需要量を示す。

(3) PV 発電量の推計

日本建築学会 拡張アメダスデータにおける標準気
象データ(365 日別 24 時間値, 福岡)における日射
量データを用いて、PV 発電量を時刻別に推計した。
このとき PV パネルは正南に向けて、水平から 30° の
角度で設置するとし、発電効率を 14% として計算した。
住宅用電力需給は季節別に計算を行うため、365 日デ
ータの時刻別値から季節別・天候別の代表的な発電量
を選定した。天候の出現率は、福岡管区気象台の天気
出現率(1980~2010 年の月別平均)より、季節別の
晴れ・曇り・雨の出現日数を求めた。

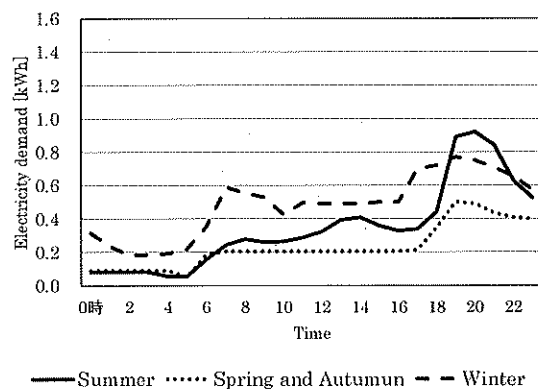


Fig. 5 Assumed electricity demand of House

(4) CGS 経済性の推計

CGS の設備諸元と稼働状況より、購入電力+従来型ボイラーによるシステムと比べた場合の利益を推計した。計算条件は以下のとおりである。

- ・機器効率
CGS 発電効率 : 0.40
CGS 熱回収効率 : 0.32
年間稼働時間 : 8760h
従来型ボイラー効率 : 0.80
- ・経済単価
CGS 初期コスト = 280,000 円/kW
CGS 運転コスト = 1.5 円/kWh
燃料費 (A 重油) = 52 円/l
- ・事業用電力単価は、九州電力の離島供給約款の料金メニュー (低圧電力) を用いて、想定した事業所の電力需要より平均単価を推計し 15.6 円/kWh を用いた。
- ・CGS により発電した電力の電気事業者への売電単価は 5 円/kWh とした。また、CGS から住宅に独自に電力を供給する電力単価は 16 円/kWh とした。

(5) PV 発電経済性の推計

PV の計算条件は以下のとおりである。

- ・PV 発電容量 : 3kW/住宅
- ・PV 初期コスト : 400,000 円/kW
- ・電力事業者から従来住宅が購入する電力単価は、九州電力の離島供給約款の料金メニュー (電灯電力 B) に基づき、住宅の電力需要より平均単価を推計し 24 円/kWh を用いた。
- ・電力事業者から PV 住宅が購入する電力単価は、オール電化住宅用のメニューである、九州電力の離島供給約款の料金メニュー (季節別電灯) に基づき、昼間 (10-17 時) 30 円/kWh、朝・夜 (8~10 時、17~22 時) 23 円/kWh、深夜 (23~7 時) 10 円/kWh を用いた。

(6) CGS へのスチレン供給量の設定

計算の前提となる発泡スチロールの回収量は、漂着ゴミ量×発泡スチロール比率×回収率により算定される。本報告では、石田らの論文⁹⁾の想定に基づき漂着ゴミ量 365 t/年、回収率 20%、発泡スチロール比率 40%と想定し、減容化する量を 1日 80kg と仮定した。また再生されたスチレン油のうち、40%は油化装置で自己消費されると設定したため、CGS へのスチレン油投入量は 32kg/日となる。

DQN モデルにおいては、ゴミ回収する年としない年に分かれており、ゴミ回収しない年にはスチレン油が得られないこととなるが、この部分については油化

装置の能力や貯蔵設備の規模などのモデル化をより詳細に設定することが必要となるが、石田らの論文でも、情報の少なさもあり、詳細モデルが得られていない状況である。本来であればゴミ処理装置の設定により、各年によって CGS に投入するスチレン油も変動するはずであるが、現在のモデルでは、「年によって得られるスチレン油は変動するはずであるが、CGS には継続的に一定量供給できている」という想定となっている。この部分については今後、油化装置のモデル化の詳細化、CGS 経済性モデルと深層強化学習モデルの一体化などを考えていく必要がある。

(7) 発泡スチロール油化装置の自己消費率の設定

発泡スチロール油化装置の自己消費率については、具体的な数値が明記されている出典が見当たらない状況のため、以下のように対馬市の事例から設定した。

『平成 22 年度漁場漂流・漂着物対策促進事業のうち漂流・漂着物発生源対策等普及委託事業報告書』(平成 23 年 3 月、社団法人マリノフォーラム 21、社団法人海と渚環境美化推進機構、株式会社東京久栄) <http://www.umitonagisa.or.jp/pdf/mb21/report/hasseigen22.pdf> の 38 頁によると、対馬市に設置された発泡スチロール油化装置の性能について「スチレン油 40 リットル/発泡スチロール 80kg/1 日」との記述があり、これよりスチレン油の比重 0.9 として、

$$40 \text{ リットル} \times \text{比重 } 0.91 / 80 \text{ kg} = 0.45$$

よりおよそ 40%として設定した。この設定値については、ひとつの事例から設定しているため、今後さらに情報を集めていく必要がある。

(8) CGS 容量による年間利益

上記(1)から(7)の設定により CGS 容量と年間利益の計算を行うと表 4 のようになる。このデータから対数関数の近似式を求めると図 6 となり、本編式(2)が求められる。

Table 4 Calculation results of CGS capacity and annual profit

CGS capacity (kW)	Annual profit (10,000Yen)
5	20
10	22
15	25
20	27
25	29
30	31
35	33
40	35
45	37
50	39
60	43
70	44
80	44

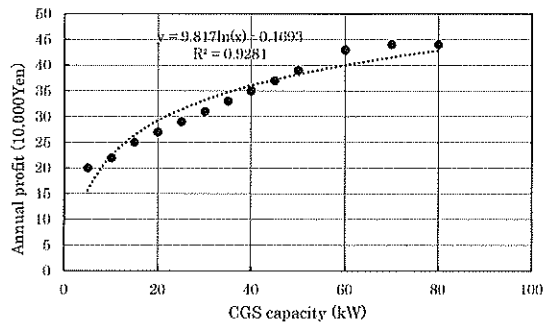


Fig. 6 Approximate curve of CGS capacity and annual profit

References

1) 内外地図株式会社, 環境省委託業務 平成 28 年度漂着ごみ対策総合検討業務報告書, (2017), 内外地図株式会社, https://www.env.go.jp/water/marine_litter/pamph/h_youtyakugaiyou.pdf (accessed on 1 December 2020).

2) Yoshinori Mihara, Microplastics and Mili-plastics, Journal of the JIME, 52, 5, (2017), 566-568

3) Masateru Ishida, Yu Mihara, Yoshinori Mihara, Trend of regulation about marine litter, Journal of the JIME, 52, 5, (2017), 560-565

4) Hiroki Wakimoto, Yoshinori Mihara, Yasunari Mihara, Current status of ocean/coastal pollution at Tsushima in Nagasakiprefecture: Tasks and prospects, Journal of the JIME, 49, 2, (2014), 170-172

5) 宇野秀敏, 発泡スチロールから燃料 ~宝の島を夢みて~, 食品と容器, 52, 8, (2011), 496-501

6) Hideo Kawahara, Shinya Yamaguchi, Yoshinori Mihara, Attempts to Desalt and Shrink Foaming Polystyrene Waste by Using Oil Bath, Journal of

the JIME, 52, 5, (2017), 569-573

7) Shinya Yamaguchi, et al., On Volume Reduction of Foam Polystyrene for Local Supply and Local Consumption, Journal of the JIME, 49, 2, (2014), 185-187

8) Takeshi Ishida, Masateru Ishida, Minoru Tsuda, Nobuyasu Ikoma, Economy-evaluation model for a resource circulation system of polystyrene foam from marine debris, Journal of National Fisheries University, 67, (2018), 79-90

9) Takeshi Ishida, Shunsuke Mori, Development of Evaluate Model of the Distributed Energy Supply Network System of Urban District, Journal of Japan Society of Energy and Resources, 29, 1, (2008), 8-14

10) Volodymyr Mnih, et.al., Human-level control through deep reinforcement learning, Nature, vol.518, (2015), pp.529-533

11) A. T. D. Perera, et al., Introducing reinforcement learning to the energy system design process, Applied Energy, 262: 114580, (2020)

12) C. Correa-Jullian, et al., Operation scheduling in a solar thermal system: A reinforcement learning-based framework, Applied Energy, 268: 114943, (2020)

13) S. Zhou, et al., Combined heat and power system intelligent economic dispatch: A deep reinforcement learning approach, International Journal of Electrical Power & Energy Systems, 120: 106016, (2020)

14) J. J. Kelly and P. G. Leahy, Optimal investment timing and sizing for battery energy storage systems, Journal of Energy Storage, 28: 101272, (2020)

15) 福井貴也, 高橋明彦, 深層学習を用いた投資手法, 経済学論集 82(1), (2017), 2-40,

16) (社) 空気調和・衛生工学会, 都市ガスによるコージェネレーションシステム計画・設計と評価, (1994), (社) 空気調和・衛生工学会