

# 乗用車による CO<sub>2</sub> 排出量の経年変化とその要因の分析

## Factors Affecting Annual CO<sub>2</sub> Emissions from Passenger Cars in Japan

橋本 陸 \*・ 兪 善 彬 \*\*・ 吉田 好 邦 \*\*\*

Riku Hashimoto

Sunbin Yoo

Yoshikuni Yoshida

CO<sub>2</sub> emissions from passenger cars account for more than 20 % of total emissions in Japan over the years. We estimated yearly CO<sub>2</sub> emissions from passenger cars from 2002 to 2016 and analyzed the factor of year-on-year change of them. Improvement of fuel efficiency continuously has contribution to constant CO<sub>2</sub> emission reduction. Number of vehicles owned increases CO<sub>2</sub> emissions, which indicates the rebound of CO<sub>2</sub> emission due to the high fuel efficiency. Driving distance has positive and negative effect to CO<sub>2</sub> emission and it varies from year to year. Lifetime of passenger cars has been extending over time. Especially, the lifetime extension of small size vehicles has positive correlation with vehicle price. In addition to the macro data analysis, driving distance per year and vehicle choice were modeled based on the behavior survey of individuals conducted by MOE. Driving distance per year has positive correlations with fuel efficiency and size and household income. Engine displacement has correlations with household income, frequency of use, driving distance per year.

**Keywords** : Passenger cars, CO<sub>2</sub> emissions, Driving distance, Fuel efficiency, Life time

### 1. はじめに

運輸部門の CO<sub>2</sub> 排出量は 1990 年代に大幅に増加した後、2000 年以降では横ばいから減少傾向にある<sup>1)</sup>。運輸部門の CO<sub>2</sub> 排出量の 9 割程度を占める自動車からの排出の影響は大きく、どのような要因で CO<sub>2</sub> 排出量に変動しているかを把握することは今後の CO<sub>2</sub> 排出削減策を検討する上で極めて重要である。自家用自動車部門では 2000 年以降に省エネ法のトップランナー規制によって低燃費化が進み、一方で低燃費化は走行距離の増加のリバウンドを誘発している<sup>2)</sup>。エコカー減税、エコカー補助金などの政策支援は、それが無い場合に比べて販売台数の増加に寄与しているだろう。また自動車車両の近年の高価格化により、車両の使用年数が長期化する傾向にあるが、これは全体として製造時のエネルギー消費の減少につながる一方で、低燃費車への更新が遅れる影響もある。本研究では、以上に挙げた燃費、走行距離、保有台数、耐用年数などの複数の要因が経年的にどのように変化してきたかを自動車関連の統計データを用いて定量化し、自家用車からの CO<sub>2</sub> 排出量の経年推移との関係を要因分解手法によって評価する。

これらの要因は、車のユーザーの選好に依存する。すな

わち燃費や走行距離は、消費者がどのような車両を購入するか、どのくらいの距離を走行するかによって決まるので、走行距離や保有車両属性がユーザーの個人属性とどのように関係するかを評価することは要因分解の次のステップとして有用な分析と位置付けられる。すなわち、本研究は前段のマクロ統計データによる自家用自動車の CO<sub>2</sub> 排出量の要因分解と、個人属性データを用いた後段のマイクロ計量分析で構成する。

### 2. 使用したデータ

自動車検査登録情報協会<sup>3)</sup>より、初度登録年別の保有車両数を 1983 年から 2019 年の期間のデータを取得した。このデータは、～ 1000cc, 1001cc～ 1500cc, 1501cc～ 2000cc, 2001cc～ 3000cc, 3001cc～ 6000cc の 5 つの排気量帯に区分されており、これにより排気量帯別の耐用年数を推定する。軽自動車については、軽自動車検査協会「軽自動車の平均使用年数」より、2005 年から 2019 年までの軽自動車の平均使用年数を使用する。

CO<sub>2</sub> 排出量の要因分解では、自動車検査登録情報協会<sup>4)</sup>より 1990 年から 2016 年における初度登録年別の保有車両数データを取得し、車両モデルごとの諸元データを紐づけることによってデータベースを作成した。加えて、国土交通省の e-Stat データ<sup>5), 6)</sup>から、年間走行距離のデータと 1 日 1 車あたりの走行距離のデータを 2001 年から 2016 年までの分使用した。

マイクロ計量分析では、環境省が調査した平成 30 年度「家

\*東京大学工学部システム創成学科 4 年生

〒113-8656 東京都文京区本郷 7-3-1 (東京大学工学部 3 号館)

\*\*九州大学大学院工学研究院 環境社会部門・都市環境システム工学 特任助教

〒819-0395 福岡市西区元岡 744

\*\*\*東京大学大学院工学系研究科技術経営戦略学専攻 教授  
科学技術振興機構低炭素社会戦略センター 特任研究員

〒113-8656 東京都文京区本郷 7-3-1

Email: y-yoshida@e.t.u-tokyo.ac.jp

庭部門の CO<sub>2</sub> 排出実態統計調査」の夏期調査票、および4月分のエネルギー使用料調査票への回答を用いた。このデータは総数 9506 の世帯について、平成 29 年度における世帯の状況や車両の使用状況などをまとめたものである。それらのデータから、自動車の利用に関して、各家庭の所有する自動車の年間走行距離を説明するモデルと、自動車排気量選択を説明するモデルを開発した。

### 3. 耐用年数分布の推定

#### 3.1 手法

保有車両数データの年度ごとの変化から、初度登録年度の保有車両数データを基準として自動車の残存率を、各年度について計算した。これらのデータから、ワイブル分布を用いて当てはめを行った。ワイブル分布は、時間に対する劣化や寿命を統計的に記述するときしばしば用いられる分布で、形状母数を  $m$ 、尺度母数を  $\alpha$  として、

$$f(x) = (m x^{m-1} / \alpha) \exp(-x^m / \alpha)$$

で表される確率分布を持つ。回帰分析を行うことで、各年度における形状母数  $m$  と尺度母数  $\alpha$  を求め、そこから平均耐用年数と分散、変動係数を計算した。

#### 3.2 推定結果

経過年数に対する残存率の推移を排気量クラス別に図 1 に示す。販売年数が 2001 年から 2018 年までの車両について 2019 年時点での残存率を示している。1000-1500 cc、1500-2000cc の排気量帯では、耐用年数が経年的に伸びていることがわかる。一方で 2000 cc 以上では耐用年数の伸長は見られないか、逆に短くなっている。表 1 に軽自動車を含めた購入後 10 年時点での残存率を示す。軽を含めて 2000 cc 未満の車両で長寿命化し、10 年残存率が 60~80% 程度に達していることがわかる。

以上から耐用年数が特に小型の車両で経年的に長くなっているが、この要因として車両の高価格化が考えられる。そこで、各年の販売価格と各年での耐用年数の関係を排気量帯別にプロットをした。図 2 に 1000-1500 cc についての結果を示すが、耐用年数と車両価格の間に正の相関がみられ、車両価格がひとつの要因である可能性が示唆される。

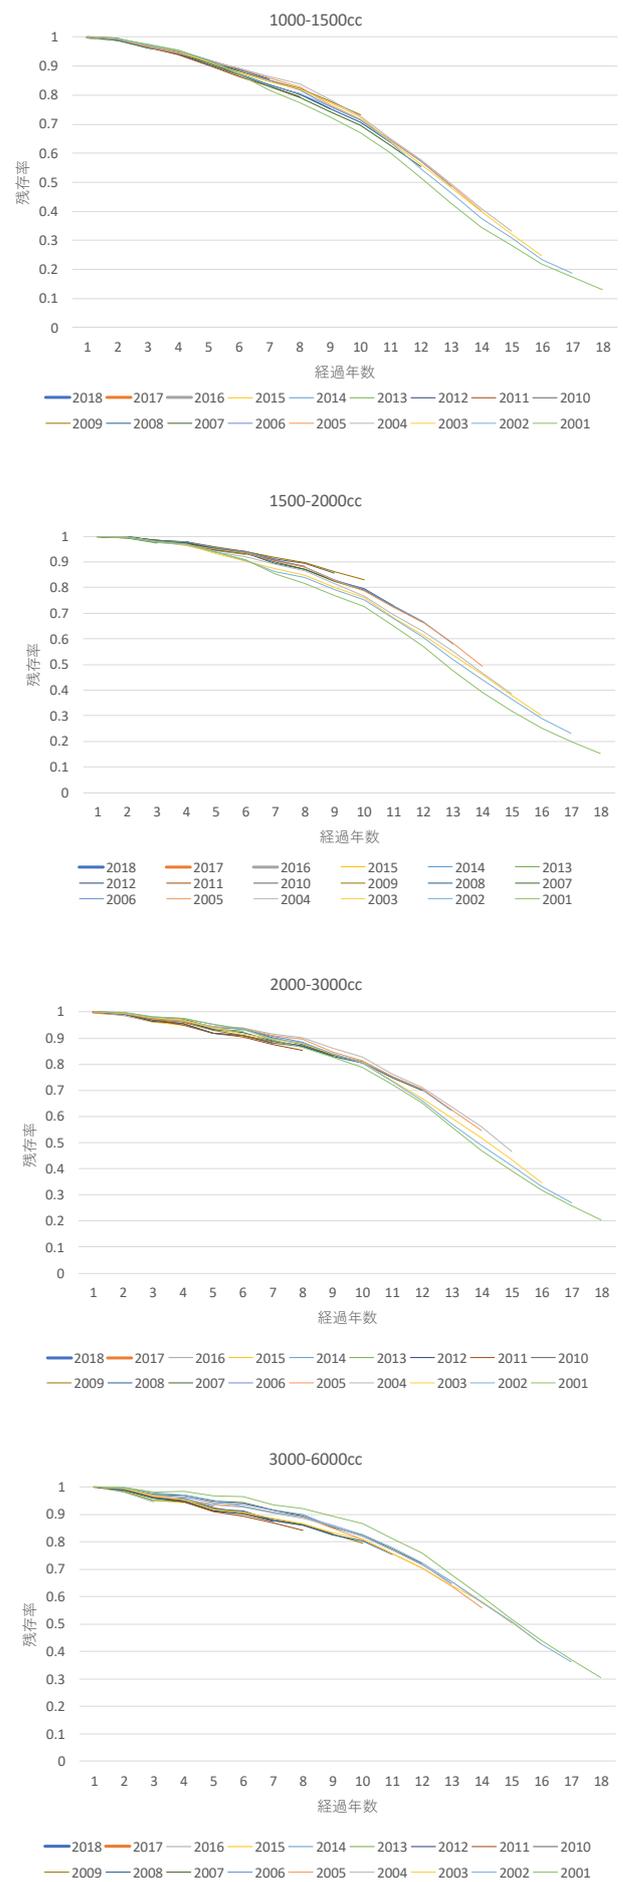


図 1 排気量帯別の乗用車の残存率の推移

表1 購入10年後の残存率

購入年	2009	2007	2005	2003	2001
軽	64%	62%	57%	56%	54%
1000-1500cc	73%	70%	72%	72%	67%
1500-2000cc	83%	79%	79%	76%	72%
2000-3000cc	81%	81%	81%	81%	79%
3000cc-	80%	83%	81%	81%	87%

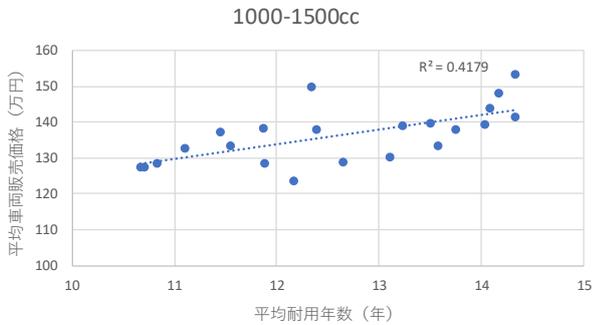


図2 1500-2000 ccの年別の車両平均価格と平均残存率

#### 4. CO<sub>2</sub> 排出量の要因分解

##### 4.1 要因分解手法

CO<sub>2</sub> 排出量は、(CO<sub>2</sub> 排出量(kg/年))=2.32(kg/L)\*(1/燃費(km/L))\*(1台あたりの年間走行距離(km/台/年))\*(自動車保有車両数(台))によって計算できる。燃費は、販売台数と推定した耐用年数を用いて加重平均をとった値を利用し、その年にある自動車の平均燃費を推定して用いる。求めたCO<sub>2</sub> 排出量について年ごとの変化量を計算し、CO<sub>2</sub> 排出の変化量について二次以上の項を残差とすると、

$$\Delta(\text{CO}_2 \text{ 変化量}) = \Delta(1/\text{燃費}) * (1 \text{ 台あたりの年間走行距離}) * (\text{自動車保有車両数}) + (1/\text{燃費}) * \Delta(1 \text{ 台あたりの年間走行距離}) * (\text{自動車保有車両数}) + (1/\text{燃費}) * (1 \text{ 台あたりの年間走行距離}) * \Delta(\text{自動車保有車両数}) + \text{残差項}$$

のように、要因分解ができる。

##### 4.2 要因分解の結果

2002年から2016年までのCO<sub>2</sub> 排出量の年次変化について、燃費、走行距離、保有台数のそれぞれの年次変化の寄与に分解した結果を図3に示す。またこれらの3つの要因の単独の変化以外の寄与は「残差」として図中に示した。

図よりCO<sub>2</sub> 排出量は概ね減少傾向にあることが分かる。特に2000年代での減少が継続的に大きい。要因としては、燃費の改善が全期間を通して年あたり50~100万トンの排出削減に寄与している。逆に保有台数の伸びは、排出増加の要因になっている。CO<sub>2</sub> 排出増加量は燃費の改善の影響よりも絶対値として小さいものの、燃費の改善に対するリバウンド効果とみなすことができる。走行距離は2000年代にかけて減少し、CO<sub>2</sub> 排出の減少に寄与していたが、2009年

以降に増加する年もみられる。

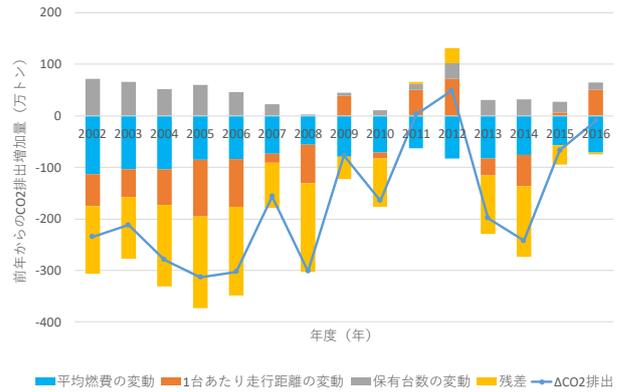


図3 自家用自動車からのCO<sub>2</sub> 排出量の要因分解

#### 5. 個人属性データを用いたマイクロ計量モデル

##### 5.1 年間走行距離モデル

まず、各家庭の所有する自動車の年間走行距離を説明するモデルについて、各家庭がメインで使用する1台目の走行距離を用いて推定した。観測数は6034で、各説明変数の係数をまとめると表2のようになった。つまり、

$$D_{ij} = \varepsilon_{ij} + a_1 N_i + a_2 I_i + a_3 E_j + a_4 F_j + a_5 FE_j + a_6 G_j + a_7 T_i + a_8 H_i$$

と表せる。ただし、 $\varepsilon_{ij}$ :切片、 $a_1$ :居住人数の係数、 $a_2$ :世帯収入の係数、 $a_3$ :自動車排気量の係数、 $a_4$ :自動車使用頻度の係数、 $a_5$ :自動車実燃費の係数、 $a_6$ :ガソリン車ダミーの係数、 $a_7$ :東京大阪ダミーの係数、 $a_8$ :北海道ダミーの係数、 $N_i$ :居住人数(人)、 $I_i$ :世帯収入(千万円)、 $E_j$ :自動車排気量(cc)、 $F_j$ :自動車使用頻度(日/週)、 $FE_j$ :自動車実燃費(km/L)、 $G_j$ :ガソリン車なら1、それ以外なら0、 $T_i$ :東京または大阪なら1、それ以外なら0、 $H_i$ :北海道なら1、それ以外なら0である。

表2 年間走行距離(万km)の回帰分析

	モデル1	モデル2	モデル3
切片	6735.0*	-46.44	-1070.5
居住人数[人]	532.5*		295.2*
世帯収入[千万円]	1.491*		1.246*
排気量[cc]		1.240*	1.030*
使用頻度[日/週]		1073.3*	1038.0*
実燃費[km/L]		262.1*	258.96*
ガソリン車ダミー[-]		-1766.2*	-1779.3*
東京大阪ダミー[-]	-259.5	-67.71	-91.29
北海道ダミー[-]	916.563*	520.1	685.6*

\*:5%水準(両側検定)で有意

3つのモデルを比較すると、東京大阪ダミー以外は、有意であった。東京大阪ダミーが有意でなかったのは、都会で車を使わない地域と、都会から少し離れた車をよく使う

地域が区別できなかったことが原因だと考える。それぞれの相関について、居住人数、世帯収入、排気量、使用頻度、実燃費とも正の相関があることがわかった。また、北海道ダミーも正の相関が出た。これは、北海道の自動車は走行距離の長さとの相関があることがわかる。そして、ガソリン車ダミーは、負の相関が見られた。ガソリン車以外の選択は、ほとんどがディーゼル車なため、ディーゼル車の方がガソリン車より走行距離が長い傾向にあることがここからわかる。そして、東京大阪ダミーも負の相関が見られた。有意ではないが、公共交通機関が発達していることが要因として考えられる。

## 5.2 車両選択モデル

自動車排気量を説明するモデルについて、こちらは各家庭の持つ全自動車について分析した。回答者  $i$  が所有する車両（排気量帯  $j$ ）を選択する確率  $P_{ij}$  を効用  $V_{ij}$  の関数として

$$P_{ij} = f(V_{ij})$$

と表し、関数  $f$  はロジットモデルで表した。効用関数は

$$V_{ij} = b_1 N_i + b_2 I_i + b_3 F_j + b_4 D1_j + b_5 D2_j + b_6 D_i$$

と表した。ただし、 $b_1$ : 居住人数の係数、 $b_2$ : 世帯収入の係数、 $b_3$ : 自動車使用頻度の係数、 $b_4$ : 1 台目ダミーの係数、 $b_5$ : 2 台目ダミーの係数、 $b_6$ : 年間走行距離の係数、 $D1_j$ : 1 台目なら 1、それ以外なら 0、 $D2_j$ : 2 台目なら 1、それ以外なら 0、 $D_i$ : 年間走行距離（万 km）で、その他は式(1)の変数と共通である。観測数は 9315 で、各説明変数の係数をまとめると表 3 のようになった。

表 3 自動車排気量を説明する効用の推定結果

	モデル1	モデル2	モデル3
居住人数 <sup>1</sup>	1.099		0.399
居住人数 <sup>2</sup>	0.483		0.172
居住人数 <sup>3</sup>	0.875		0.2943
居住人数 <sup>4</sup>	0.859		0.418
居住人数 <sup>5</sup>	0.641		0.330
世帯収入 <sup>1</sup>	-0.595		-1.467
世帯収入 <sup>2</sup>	-1.096		-1.099
世帯収入 <sup>3</sup>	-0.0652		-0.720
世帯収入 <sup>4</sup>	-0.098		-0.538
世帯収入 <sup>5</sup>	0.0411		-0.237
使用頻度 <sup>1</sup>		0.456	0.406
使用頻度 <sup>2</sup>		0.245	0.264
使用頻度 <sup>3</sup>		0.307	0.251
使用頻度 <sup>4</sup>		0.229	0.140
使用頻度 <sup>5</sup>		0.155	0.0747
1台目ダミー <sup>1</sup>		1.055	1.032
1台目ダミー <sup>2</sup>		-0.148	-0.148
1台目ダミー <sup>3</sup>		1.533	1.456
1台目ダミー <sup>4</sup>		1.603	1.259
1台目ダミー <sup>5</sup>		1.161	0.834
2台目ダミー <sup>1</sup>		1.503	1.395
2台目ダミー <sup>2</sup>		0.0766	0.129
2台目ダミー <sup>3</sup>		1.197	1.010

2台目ダミー <sup>4</sup>		1.166	0.599
2台目ダミー <sup>5</sup>		0.974	0.442
走行距離 <sup>1</sup>		-0.505	-0.469
走行距離 <sup>2</sup>		-0.514	-0.414
走行距離 <sup>3</sup>		-0.292	-0.284
走行距離 <sup>4</sup>		-0.0930	-0.112
走行距離 <sup>5</sup>		0.00204	-0.0237

<sup>1</sup>:自動車排気量 0~660cc、<sup>2</sup>:同 660~1000cc、<sup>3</sup>:同 1000~1500cc、<sup>4</sup>:同 1500~2000cc、<sup>5</sup>:同 2000~3000cc

単位は、居住人数[人]、世帯収入[千円]、排気量[cc]、使用頻度[日/週]、走行距離(万 km)

自動車排気量を説明するモデルでは、それぞれの排気量帯についての係数を推定した。3000cc 以上を基準としていて、その係数はすべて 0 で表せる。モデル3について、まず居住人数はあまり相関が見られなかった。次に世帯収入は、大きいほど排気量の小さい、軽自動車などを選びにくいという相関関係があることがわかった。ただ、モデル1を見たとき、相関があまり見られなかった。これは変数が少ないためかと考えられる。続いて、使用頻度について、モデル3では相関が見られ、よく利用する家庭ほど排気量の小さい自動車を選びやすい相関関係があるとわかった。これは、モデル2でも大方、相関が見られた。また、1台目ダミーは、モデル3で排気量の小さい自動車は少し選ばれやすいが、あまり相関が見られなかった。2台目ダミーについても、あまり相関は見られなかったが、1台目よりもさらに排気量の小さい軽自動車等が選ばれやすいことがわかった。そして、年間走行距離については、モデル3で長距離走る車は排気量の小さい車は選ばれにくいという相関関係が見られた。以上から、自動車排気量は、世帯収入、使用頻度、年間走行距離との相関関係が見られた。

## 6. おわりに

乗用車の初度登録保有台数と車両のスペックデータ、ならびに年間走行距離データに基づいて、車両の耐用年数分布を推定し、また乗用車からの CO<sub>2</sub> 排出量の推移をストックベースで評価するとともに、要因分解を行った。耐用年数の分析では、2000 cc 未満の小型車、軽を中心に耐用年数の長期化の傾向が観察され、この一因として車両の高価格化が示唆された。CO<sub>2</sub> 排出量の変化の要因としては、燃費の改善が排出削減に、保有台数の伸びが排出増加に寄与し。走行距離は年による増減があり、傾向は捉えがたい。

車両の長寿命化は低燃費車への買い替えを阻害して平均燃費の伸びを抑えて CO<sub>2</sub> 排出削減を抑制する一方で、要因分解では考慮していなかった車両製造時の CO<sub>2</sub> 排出量を抑制する効果もある。

また環境省の家庭部門の CO<sub>2</sub> 排出調査により、個人属性と走行距離の相関関係を定量化し、低燃費による走行距離

増加のリバウンド効果を評価した。

低燃費車両の優遇等の政策によるストックベースでのCO<sub>2</sub>排出削減量を評価などへの応用が可能である。

#### 参考文献

- 1) 国土交通省ウェブサイト  
<https://www.mlit.go.jp/sogoseisaku/environment/index.html>  
(アクセス日 2020.11.20)
- 2) Yoo S., Koh K.W., Yoshida Y., Wakamori N., “Revisiting Jevons's paradox of energy rebound: Policy implications and empirical evidence in consumer-oriented financial incentives from the Japanese automobile market, 2006–2016”, *Energy Policy*, Vol.133, 1-15(2019)
- 3) 自動車検査登録情報協会「自検協統計 自動車保有車両数」
- 4) 自動車検査登録情報協会「自検協統計 初度登録年別自動車保有車両数」
- 5) 国土交通省「自動車燃料消費量調査」
- 6) 国土交通省「自動車輸送統計調査」

# 家庭部門のエネルギー消費量の地域特性に関する統計分析

## Statistical Analysis on Regional Characteristics Annual Home Energy Consumption

長谷川 兼一\*・外岡 豊\*\*  
Kenichi Hasegawa Yutaka Tonooka

Home energy saving is essential to prevent global warming. And the development of local scenarios for energy saving should be useful to implement the new scheme of low carbon society. This paper describes the regional characteristic of indoor environmental performance and annual CO<sub>2</sub> emissions from home and automobiles using the data of “Statistical Survey of CO<sub>2</sub> Emissions in Private Households Sector”. A multi-regression analysis method was applied in order to clarify the association between CO<sub>2</sub> emissions and its influencing factors such as floor area, family numbers, space heating and cooling, building thermal envelope, family income and so on. The factors which influence the dispersion of annual CO<sub>2</sub> emissions are location, floor area family numbers, space heating equipment and use of automobiles.

**Keywords** : Home energy consumption, CO<sub>2</sub> emission, Statistical analysis, National questionnaire survey

### 1. はじめに

「家庭部門のCO<sub>2</sub>排出実態統計調査(家庭CO<sub>2</sub>統計)」は我が国の地球温暖化対策の企画・立案に資する基礎資料を得ることを目的として、環境省により実施されている。筆者らは、調査により得られたデータを用いて、地域における家庭部門のエネルギー消費量やCO<sub>2</sub>排出量を推計するマクロモデル<sup>1)</sup>の精度向上と推計エリアの拡充に活用するために、エネルギー消費量の地域特性を明らかにしつつある。

本報では、特に年間CO<sub>2</sub>排出量に着目して、居住環境要因の地域性を把握するとともに、CO<sub>2</sub>排出量のばらつきに関連している要因を統計分析(数量化理論I類)により明らかにする。なお、ここで扱うCO<sub>2</sub>排出量には、自家用車と二輪車の使用に伴う分も含めている。

### 2. 分析に用いる調査データの概要

本調査は、住民基本台帳から抽出された6,500世帯を対象とした調査員調査と、6,500世帯を対象としたインターネット調査から成り立っている。有効回答数は9,505世帯(回答率は73.1%)であった。

調査項目を大別すると、世帯属性(家族構成、年収など)、住宅属性(住宅形式、建設時期、延べ床面積、窓の構成など)、暖冷房(保有機器、使用状況など)、給湯・調理(保有機器、入浴状況、省エネ行動など)、家電機器(機器の使用状況、省エネ行動など)、車両(自動車・二輪車の使用状況、燃料種類、

走行距離など)、太陽光発電(発電量、売電量、総容量)、月別のエネルギー使用量(電気、ガス、灯油、ガソリン、軽油)である。CO<sub>2</sub>排出量は、エネルギー使用量に基づいて熱源毎の排出係数を乗じて算出されている。調査の詳細は文献2)を参照されたい。

### 3. 各地域の居住環境要因の状況

#### 3.1 家族属性・住宅属性・暖冷房機器

表1に各地域の主な居住環境要因の集計結果を示す。ここでは、地域を10区分にて分類している。

住宅形式では、東北や中国で「戸建住宅」の割合が高く、70%を超えている。一方で、関東甲信越では55.2%、近畿では57.2%と相対的に「集合住宅」の割合が高くなっている。建設時期では、「1981-1990年」の割合が高い地域が多く、築30-40年に該当する。「2016年以降」の新しい住宅は2.0%前後となっている。延べ床面積は、東北や北陸で大きく、「140-180m<sup>2</sup>未満」「180m<sup>2</sup>以上」の割合が高くなっており、ストックに規模が大きな戸建住宅が多いことが推察される。沖縄では、「60m<sup>2</sup>未満」が44.4%と最も割合が高くなっており、他地域と傾向が異なっている。北海道、関東甲信越、近畿、九州では、「60-100m<sup>2</sup>未満」に割合のピークがあり、大都市圏域の特徴と考えられる。

二重窓・複層ガラスの有無では、北海道において「全ての窓」が79.2%と最も割合が高く、「なし」は8.1%である。

「全ての窓」の割合は地域性が明確に表れており、寒冷な地域ほど高い。東北、北陸ではそれぞれ42.2%、29.2%であり、関東甲信越や近畿、九州では20.9%、15.9%、18.3%で

\*秋田県立大学システム科学技術学部建築環境システム学科教授  
〒015-0076 秋田県由利本荘市土谷字海老ノ口 84-4

E-mail: haseken@akita-pu.ac.jp

\*\*埼玉大学名誉教授

表1 各地域の主な居住環境要因の集計結果

要因	北海道	東北	関東甲信越	北陸	東海	近畿	中国	四国	九州	沖縄	
住宅形式	戸建住宅	521 (62.2)	661 (73.4)	889 (55.2)	667 (78.2)	651 (67.2)	641 (57.2)	556 (65.7)	561 (71.1)	568 (60.0)	286 (45.3)
	集合住宅	317 (37.8)	240 (26.6)	721 (44.8)	186 (21.8)	318 (32.8)	480 (42.8)	290 (34.3)	228 (28.9)	378 (40.0)	346 (54.7)
建設時期	1970以前	50 (6.0)	67 (7.4)	93 (5.8)	100 (11.7)	55 (5.7)	121 (108.)	110 (13.0)	80 (10.1)	87 (9.2)	46 (7.3)
	1971-1980年	114 (13.6)	104 (11.5)	183 (11.4)	105 (12.3)	97 (10.0)	156 (13.9)	124 (14.7)	101 (12.8)	129 (13.6)	65 (10.3)
	1981-1990年	149 (17.8)	159 (17.6)	290 (18.0)	134 (15.7)	194 (20.0)	180 (16.1)	110 (13.0)	125 (15.8)	176 (18.6)	92 (14.6)
	1991-1995年	113 (13.5)	84 (9.3)	157 (9.8)	95 (11.1)	121 (12.5)	115 (10.3)	60 (7.1)	64 (8.1)	86 (9.1)	56 (8.9)
	1996-2000年	110 (13.1)	108 (12.0)	230 (14.3)	126 (14.8)	110 (11.4)	154 (13.7)	105 (12.4)	116 (14.6)	101 (10.7)	56 (8.9)
	2001-2005年	79 (9.4)	111 (12.3)	219 (13.6)	81 (9.5)	94 (9.7)	110 (9.8)	99 (11.7)	70 (9.6)	85 (9.0)	50 (7.9)
	2006-2010年	73 (8.7)	114 (12.7)	178 (11.1)	68 (8.0)	102 (10.5)	87 (7.8)	78 (9.2)	79 (9.9)	91 (9.6)	67 (10.6)
	2011-2015年	67 (8.0)	64 (7.1)	135 (8.4)	81 (9.5)	123 (12.7)	99 (8.8)	69 (8.2)	13 (10.0)	84 (8.9)	71 (11.2)
2016年以降	12 (1.4)	10 (1.1)	25 (1.6)	16 (1.9)	19 (2.0)	16 (1.4)	16 (1.9)	66 (1.6)	13 (1.4)	19 (3.0)	
床面積	60㎡未満	178 (22.0)	176 (20.3)	397 (25.3)	135 (16.2)	164 (17.4)	297 (27.3)	201 (24.7)	157 (20.6)	226 (24.7)	267 (44.4)
	60-100㎡未満	259 (32.0)	145 (16.7)	631 (40.2)	127 (15.3)	266 (28.2)	419 (38.5)	222 (27.3)	206 (27.0)	287 (31.4)	199 (33.1)
	100-140㎡未満	238 (29.4)	254 (29.0)	326 (20.8)	194 (23.3)	294 (31.2)	208 (19.1)	222 (27.3)	216 (28.3)	231 (25.2)	72 (12.0)
	140-180㎡未満	79 (9.8)	159 (18.3)	136 (8.7)	166 (20.0)	117 (12.4)	105 (9.7)	99 (12.2)	92 (12.1)	119 (13.0)	37 (6.2)
	180㎡以上	55 (6.8)	136 (15.7)	79 (5.0)	209 (25.2)	101 (10.7)	59 (5.4)	70 (8.6)	92 (12.1)	52 (5.7)	26 (4.3)
二重窓・複層ガラス	全ての窓	664 (79.2)	380 (42.2)	337 (20.9)	249 (29.2)	214 (22.1)	178 (15.9)	161 (19.0)	138 (17.5)	173 (18.3)	56 (8.9)
	一部の窓	88 (10.5)	208 (23.1)	229 (14.2)	263 (30.8)	149 (15.4)	147 (13.1)	161 (19.0)	98 (12.4)	107 (11.3)	37 (5.9)
	なし	68 (8.1)	294 (32.6)	993 (61.7)	327 (38.3)	570 (58.8)	739 (65.9)	497 (58.7)	522 (66.2)	631 (66.7)	501 (79.3)
よく使う暖房機器	エアコン	10 (1.2)	126 (14.0)	603 (37.5)	228 (26.7)	344 (35.5)	364 (32.5)	337 (39.8)	313 (39.7)	385 (40.7)	230 (36.4)
	電気暖房	80 (9.6)	182 (20.2)	428 (26.6)	167 (19.6)	215 (22.2)	349 (31.2)	227 (26.9)	240 (30.4)	253 (26.7)	259 (41.0)
	ガスストーブ	57 (6.8)	15 (1.7)	133 (8.3)	27 (3.2)	91 (9.4)	136 (12.1)	21 (2.5)	8 (1.0)	17 (1.8)	1 (0.2)
	灯油ストーブ	468 (55.8)	502 (55.7)	296 (18.4)	369 (43.3)	264 (27.2)	200 (17.8)	241 (28.5)	204 (25.9)	252 (26.6)	13 (2.1)
	床暖房	33 (3.9)	29 (3.2)	123 (7.6)	38 (4.5)	38 (3.9)	61 (5.4)	7 (0.8)	11 (1.4)	21 (2.3)	0 (0.0)
	中央式暖房	171 (20.4)	24 (2.7)	5 (0.3)	7 (0.8)	1 (0.1)	0 (0.0)	2 (0.2)	0 (0.0)	1 (0.1)	0 (0.0)
	その他	11 (1.3)	17 (1.9)	9 (0.6)	9 (1.0)	4 (0.4)	1 (0.1)	5 (0.6)	4 (0.5)	7 (0.7)	1 (0.2)
	暖房なし	2 (0.2)	3 (0.3)	10 (0.6)	1 (0.1)	7 (0.7)	10 (0.9)	3 (0.4)	7 (0.9)	9 (1.0)	125 (19.8)
暖房の仕方	24時間暖房	302 (36.0)	78 (8.7)	47 (2.9)	66 (7.7)	27 (2.8)	33 (2.9)	29 (3.4)	29 (3.7)	40 (4.2)	6 (0.9)
	在室時に暖房	382 (45.6)	571 (63.4)	585 (36.3)	570 (66.8)	392 (40.5)	500 (44.6)	411 (48.6)	317 (40.2)	395 (41.8)	31 (4.9)
	寒い時のみ暖房	147 (17.5)	245 (27.2)	939 (58.3)	213 (25.0)	529 (54.6)	554 (49.4)	394 (46.6)	420 (53.2)	478 (50.5)	360 (57.0)
	暖房しない	6 (0.7)	6 (0.7)	38 (2.4)	4 (0.5)	21 (2.2)	33 (2.9)	12 (1.4)	23 (2.9)	33 (3.5)	235 (37.2)
冷暖房エアコンの使用台数	なし	603 (72.3)	173 (19.2)	58 (3.6)	36 (4.2)	33 (3.4)	29 (2.6)	25 (3.0)	30 (3.8)	33 (3.5)	80 (7.9)
	1台	184 (22.1)	325 (36.1)	424 (26.4)	216 (25.4)	231 (23.8)	270 (24.1)	223 (26.4)	192 (24.3)	313 (33.1)	259 (41.0)
	2台	33 (4.0)	200 (22.2)	444 (27.6)	222 (26.1)	260 (26.8)	299 (26.7)	230 (27.2)	190 (24.1)	237 (25.1)	157 (24.9)
	3台以上	14 (1.7)	202 (22.4)	681 (42.5)	378 (44.4)	445 (45.9)	523 (46.7)	368 (43.4)	377 (47.7)	363 (38.3)	165 (26.1)
	省エネ実施率(平均、SD) [%]	63.5 (19.0)	62.2 (18.5)	62.8 (18.4)	60.0 (18.2)	59.8 (18.9)	62.4 (18.8)	60.3 (18.8)	59.1 (19.2)	62.4 (18.8)	58.0 (15.7)
車等の有無	なし	151 (18.0)	131 (14.5)	555 (34.5)	92 (10.8)	128 (13.2)	371 (33.1)	143 (16.9)	111 (14.1)	168 (17.8)	99 (15.7)
	あり	687 (82.0)	770 (85.5)	1,055 (65.5)	761 (89.2)	841 (86.8)	750 (66.9)	703 (83.1)	678 (85.9)	778 (82.2)	533 (84.3)
年間収入	250万円未満	180 (21.5)	173 (19.2)	233 (14.5)	136 (15.9)	141 (14.6)	225 (20.1)	149 (17.6)	179 (22.7)	234 (24.7)	191 (30.2)
	250-500万円未満	312 (37.2)	327 (36.3)	495 (30.7)	292 (34.2)	314 (32.4)	401 (35.8)	339 (40.1)	289 (36.6)	350 (37.0)	251 (39.7)
	500-750万円未満	181 (21.6)	208 (23.1)	395 (24.5)	203 (23.8)	230 (23.7)	219 (19.5)	177 (20.9)	189 (24.0)	200 (21.1)	95 (15.0)
	750-1000万円未満	103 (12.3)	112 (12.4)	259 (16.1)	141 (16.5)	166 (17.1)	147 (13.1)	110 (13.0)	82 (10.4)	95 (10.0)	45 (7.1)
	1000-1500万円未満	39 (4.7)	68 (7.5)	167 (10.4)	54 (6.3)	87 (9.0)	91 (8.1)	54 (6.4)	34 (4.3)	45 (4.8)	14 (2.2)
	1500万円以上	23 (2.8)	13 (1.4)	61 (4.0)	27 (3.2)	31 (3.1)	38 (3.3)	17 (1.9)	16 (2.1)	22 (2.3)	36 (5.7)

ある。一方、沖縄では8.9%に留まっている。暖房機器を複数所有する世帯が多いが、主に使用している暖房機器として、北海道、東北では、「灯油ストーブ」の割合が高くそれぞれ55.8%、55.7%と半数を占めている。また、「中央式」は北海道で最も高く20.4%である。北海道、東北以外の地域では「エアコン」「電気暖房」の割合が高く、「エアコン」は関東甲信越以南の地域で30~40%となっている。暖房の仕方では、「24時間暖房」の割合は北海道で高く36.0%、南下するに従い暖房時間が短くなる傾向が示唆される。東北や北陸では「在室時に暖房」が、その他の地域では「寒い時のみ暖房」の割合が高い。また、沖縄では「暖房なし」の割合が高く37.2%を占め、地域性が反映されている。

冷暖房エアコンの使用台数にも地域性が確認でき、北海道では「なし」の割合が最も高く72.3%であり、次いで、

東北にて19.2%である。そのほかに地域では90%以上の世帯でエアコンを使用している。「3台以上」使用する世帯は関東甲信越では42.5%であり、40%以上とする地域が多い。一方、九州では38.3%、沖縄では26.1%と割合が低いが、エアコンの使用台数は住宅規模との関連性が推察される。

省エネ実施率は、暖冷房、給湯、家電機器に対する省エネルギー行動メニューの実施割合について、各地域の世帯の平均値と標準偏差(SD)を示している。いずれの地域においても実施率は60%前後となっているが、北海道が63.5%、沖縄が58.0%である。標準偏差の差も顕著ではない。自家用車・二輪車の所有では、「なし」は関東甲信越、近畿で割合が高く、それぞれ34.5%、33.1%である。その他の地域では、80%以上の世帯で所有している。年間収入では、いずれの地域においても「250-500万円未満」の割合が高く、

40%前後となっている。関東甲信越、北陸、東海では、「250万円未満」の割合が相対的に低く、収入が多い世帯の割合が高い傾向が見られる。

### 3.2 年間 CO<sub>2</sub> 排出量

図 1 に、各地域における年間 CO<sub>2</sub> 排出量の分布を示す。CO<sub>2</sub> 排出量には、自家用車と二輪車による分も含まれている。図には、中央値、25%・75%タイル値、最大・最小値の統計値を表している。世帯間のばらつきは、北海道、東北、北陸のような寒冷地で相対的に大きい傾向が見られる。最大値では、東北、北陸、沖縄で大きい。中央値に着目すると、ばらつきの大きい寒冷地で大きくなっているが、表 1 で確認した暖房状況や自家用車の使用状況による影響が窺える。関東甲信越や近畿などのように大都市が含まれる地域の中央値やばらつきは小さい。

図 2 に、各地域における用途別の年間 CO<sub>2</sub> 排出量の平均値を示す。全国では、家庭部門の年間 CO<sub>2</sub> 排出量が 3.8 t-CO<sub>2</sub>/year、自家用車・二輪車を含めると 5.5 t-CO<sub>2</sub>/year になり、自家用車等が全体の 30%を占めることになる。家庭部門のみに着目すると、照明・家電が 45.6%を占め、暖房、給湯ともに 23.6%の割合となる。CO<sub>2</sub> 排出量が最も多い地域は北陸であり、暖房の他に自家用車等が影響していることが確認できる。暖房は北海道が最も多く、次いで、東北、北陸となっている。沖縄を除いて冷房の割合は低く、数%に留まっているが、沖縄では、13.7%を占めている。照明・家電にも地域により差が見られ、関東甲信越や近畿で相対的に小さいが、住宅規模が影響している可能性がある。

### 4. 年間 CO<sub>2</sub> 排出量のばらつきに寄与する要因の分析

年間 CO<sub>2</sub> 排出量に及ぼす要因を明らかにするために、数量化理論 I 類<sup>2)</sup>による分析を行った。目的変数は自家用車・二輪車を含む家庭部門の年間 CO<sub>2</sub> 排出量であり、説明変数はそれに関連が深いと考えられる 13 因子を選んだ。サンプル数はデータに欠落のない 7,983 世帯を使用し、CO<sub>2</sub> 排出量の平均値は 3.83 t-CO<sub>2</sub>/year となり、図 2 に示した全国平均と同等である。

計算結果を図 3 に示す。重相関係数は 0.78、決定係数は 0.61 である。年間 CO<sub>2</sub> 排出量に対する影響度は各因子の偏相関係数の大きさにより確認することができる。図 3 の結果では、全ての偏相関係数が統計的に有意であり、年間 CO<sub>2</sub> 排出量のばらつきに影響していると考えられる。特に、地方区分や居住人数の偏相関係数は大きく、これらの寄与は強い。地方区分では、カテゴリー・ウェイトでは、「北海道」「東北」「北陸」「中国」「沖縄」の値が正值で大きくなっており、これらの地域の年間 CO<sub>2</sub> 排出量は多く地域性が明確である。また、居住人数が多くなるほど、カテゴリー・ウェイトが大きくなり、年間 CO<sub>2</sub> 排出量には居住人数の多さ

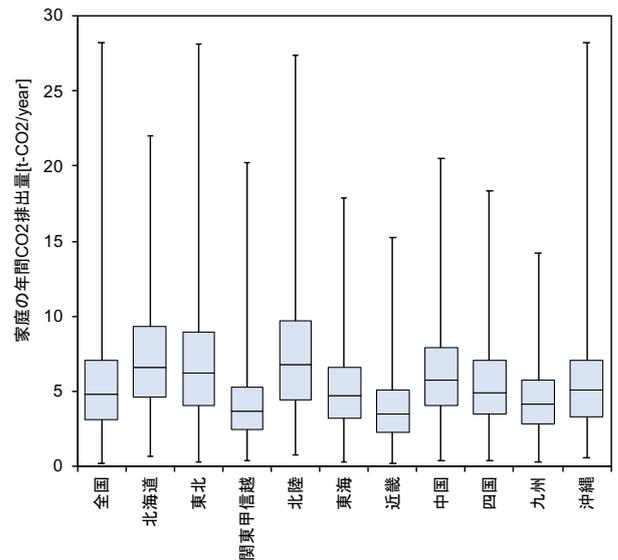


図 1 各地域における年間 CO<sub>2</sub> 排出量の統計値

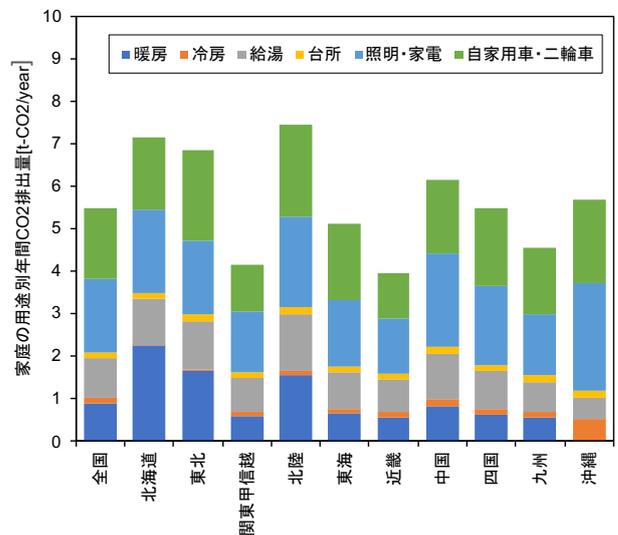


図 2 各地域における用途別の年間 CO<sub>2</sub> 排出量

が影響している。

自動車、二輪車等の有無や主暖房機器、延べ床面積の偏相関係数はそれぞれ、0.20、0.21、0.19 となっており、これらも年間 CO<sub>2</sub> 排出量のばらつきに関連している。自動車等が「あり」、主暖房機器が「電気蓄熱暖房機」「灯油床暖房」「セントラル暖房」、延べ床面積が大きいほど、年間 CO<sub>2</sub> 排出量は多くなる傾向が確認できる。

住宅形式や暖房に仕方、年間収入、省エネ実施率の偏相関係数は大きくはないが、各カテゴリーの傾向は明確である。「戸建住宅」「24 時間暖房」、収入が多い世帯ほど年間 CO<sub>2</sub> 排出量が多い。また、省エネ実施率が高いほど年間 CO<sub>2</sub> 排出量が少なくなり、省エネ行動の効果が窺える。

今回の分析では、住宅の断熱性能に関わる因子である二重サッシ、複層ガラスの有無の影響は小さく、偏相関係数は 0.03 であった。「なし」の方がカテゴリー・ウェイトは大きくなる傾向は若干見られるものの、他の要因と比較す

るとその影響は極めて小さい。住宅における断熱性能の向上は、省エネルギー・省 CO<sub>2</sub> 性能や室内環境の質を高める上では不可欠であるが、住宅規模や家族人数の影響が大きく現れている。年間 CO<sub>2</sub> 排出量には、地域性や住宅規模に代表される因子による階層性が含まれる推察される。従って、各階層に対する影響要因を分析することが必要と考えられるため、今後はマルチレベルモデルを用いて年間 CO<sub>2</sub> 排出量のばらつきの要因を説明する予定である。

## 5. おわりに

本報では、「家庭部門の CO<sub>2</sub> 排出実態統計調査(家庭 CO<sub>2</sub> 統計)」のデータを用いて、居住環境要因の地域性を把握するとともに、年間 CO<sub>2</sub> 排出量のばらつきに関連する要因を数量化理論 I 類により分析した。その結果、以下のことがわかった。

- ① 延べ床面積、窓構成、使用している暖房機器、暖房の仕方などに地域性が確認できる。
- ② 家庭部門の年間 CO<sub>2</sub> 排出量は 3.8 t-CO<sub>2</sub>/year、自家用車・二輪車を含めると 5.5 t-CO<sub>2</sub>/year になる。家庭内では、自家用車等が全体の 30%を占める。また、暖房、自家用車等、照明・家電の用途で地域差がある。
- ③ 年間 CO<sub>2</sub> 排出量に対する影響度は、暖房機器、住宅規模、居住人数、自動車等の使用にて大きい。CO<sub>2</sub> 排出量には地域と世帯間で階層性を有する可能性が高いため、分析にはマルチレベルモデルの適用が妥当である。

## 謝辞

本論文にて使用したデータは、調査票情報の提供に係る申請を経て提供されたものである。一連の申請手続きに際しては、関係各位に多大なる協力をいただいている。ここに記して謝意を表する次第である。

## 参考文献

- 1) 長谷川兼一、松本真一、細淵勇人：秋田県を対象とした住宅内エネルギー消費量の将来推計、日本建築学会技術報告集、第 25 巻、第 59 号、pp.267-270、2019.2.
- 2) 環境省：家庭部門の CO<sub>2</sub> 排出実態調査統計 調査の概要(確報値).  
<http://www.env.go.jp/earth/ondanka/ghg/kateico2tokci/H29.html> (2020.11.30 閲覧)

(注)

- i) 量的データである目的変数を、いくつかのカテゴリーデータから成る説明変数で予測するための手法。
- ii) マルチレベルモデルでは、地方区分と世帯間の効果を区別した分析が可能である。回帰分析を階層データに対応させた階層線型モデルを用いる場合が多い。

目的変数：家庭の年間CO<sub>2</sub>排出量(平均：3.83 t-CO<sub>2</sub>/year, 標準偏差：2.31 t-CO<sub>2</sub>/year)  
 サンプル数：7,983世帯, 重相関係数：0.78, 決定係数：0.61

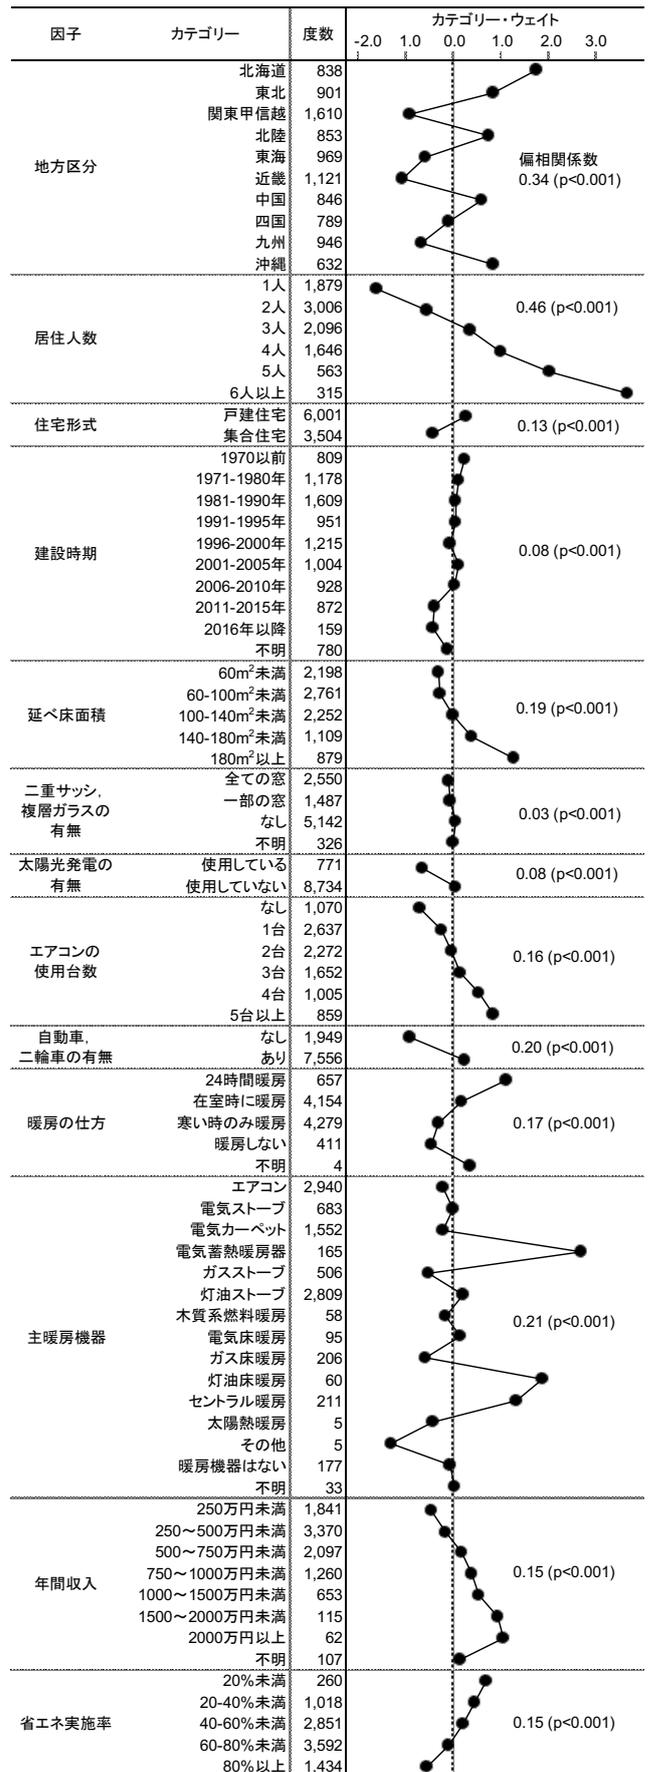


図 3 用途別の年間 CO<sub>2</sub> 排出量におよぼす居住環境要因に関する数量化理論 I による分析

# 機械学習を用いた家庭部門のエネルギー消費実態に関する分析

## Analysis of Energy Consumption in the Residential Sector Using Machine Learning

中村 仁明 \*・下田 吉之 \*\*  
Masaaki Nakamura Shimoda Yoshiyuki

This paper presents a neural network model to estimate annual energy consumption by fuel type in the residential sector. Japan's target under the Paris agreement is to reduce GHG emissions by 26% between FY 2013 and FY 2030. The residential sector is responsible for 15% of total emissions has set a high target to reduce 40% emissions over the same period. In order to reliably achieve those targets, an accurate estimate of energy consumption is important. The purpose of this paper is to estimate the energy consumption per household by fuel type in the residential building using the neural network (NNW) model, which has been attracting attention in recent years, and to verify its accuracy. Although the model demonstrated the coefficients of determination between 0.39 and 0.69, it was able to model major residential buildings accurately. There is still room for improvement of this model by increasing the number of samples or reducing the attribute.

**Keywords** : Global warming, Energy, Residential sector, Neural network model

### 1. はじめに

第 21 回国連気候変動枠組条約締約国会議(COP21)で採択されたパリ協定に基づき、日本は「国が決定する貢献(NDC)」において、国内温室効果ガス排出量を 2030 年度までに 2013 年度比で 26.0%削減、温室効果ガス排出量の約 15%を占める家庭部門においては 2013 年度比で約 40%削減するという野心的な目標を掲げている<sup>1)</sup>。目標の確実な達成のためには、エネルギー消費量の実態を正確に把握し、効果的な対策を実施、検証することが重要である。

家庭部門のエネルギー消費量を推計するため古くから様々な数値モデルに関する研究が行われてきたが、近年では人工知能研究の発展を背景に機械学習を用いたエネルギー消費量推計モデルが新たに注目されている。中でもニューラルネットワーク(以下、NNW)を用いたモデルは、建物に関する多くのパラメータとエネルギー消費量との間に存在する非線形性を分析する重要な手法として注目されており、Melvin et al. (2016)<sup>2)</sup> や Abdo et al. (2019)<sup>3)</sup> 等においては非常に予測精度の高いモデルが構築されている。国内においても Tanaka et al. (2006)<sup>4)</sup> 等にあるよう古くから NNW による住宅エネルギー消費構造モデルの研究は存在していたものの、機械学習において重要となる高品質で大量のデータを持続的に収集することが困難であったため、近年にお

いて家庭部門全体のエネルギー消費量を持続的に推計する NNW モデルに関する研究は少ない。そこで本研究では、環境省が一般統計調査として実施している「家庭部門の CO<sub>2</sub> 排出実態調査(以下、家庭 CO<sub>2</sub> 統計)」の個票データを用いた燃料種別エネルギー消費量を推計する NNW モデルを構築し、その精度を検証する。家庭 CO<sub>2</sub> 統計は平成 29 年度から毎年度、全国 13,000 世帯を対象にエネルギー消費実態等に関する詳細な基礎データを整備しており、定期的に高品質なデータを提供していることから機械学習の構築に有用であると考えられる<sup>5)</sup>。なお、本研究では選択する特徴量の違いがモデル精度へ及ぼす影響についても分析するため、使用する特徴量を 2 種類用意し、各条件でのモデル精度を比較する。

### 2. データ及び分析手法

#### 2.1 使用データ

環境省では、家庭部門の CO<sub>2</sub> 排出実態やエネルギー消費実態の詳細な基礎データの整備を目的に全国の世帯を対象とした家庭 CO<sub>2</sub> 統計調査を実施している。平成 29 年度調査では全国 13,000 世帯を対象に電気、都市ガス、LPG、灯油等の使用量や世帯属性、住宅属性、機器使用状況、省エネルギー行動実施状況等、多岐にわたる項目を調査している。本研究では平成 29 年度調査のうち有効サンプルとなった 9,505 世帯の個票データを用い、燃料種別エネルギー消費量を推計する NNW モデルを構築する。

\*三菱 UFJ リサーチ&コンサルティング株式会社  
〒105-8501 東京都港区虎ノ門 5-11-2 オランダヒルズ森タワー  
E-mail : masaaki.nakamura@murc.jp

\*\*大阪大学大学院工学研究科環境エネルギー工学専攻  
〒565-0871 吹田市山田丘 2-1, M3 棟 3 階

## 2.2 分析手法

ニューラルネットワークとは、ニューロンと呼ばれる素子を層状につなぎ合わせたアーキテクチャである。入力層、中間層及び出力層から構成される。各層における入出力の関係は以下のとおりである。

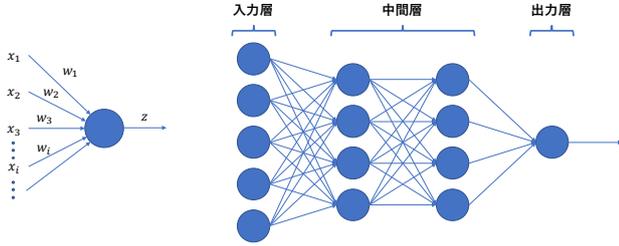


図 1 順伝播型 NNW モデルの例

入力層は、モデルへの入力ベクトル  $\mathbf{x}$  を変換せず、そのまま次層へ出力する。中間層は入力層と異なり、入力された値を変換し次層へ出力する。中間層に属する第  $l$  層中の  $j$  番目のニューロンへの入力  $u_j^{(l)}$  は式(2)で与えられる。ここで、 $w_{ji}^{(l)}$  は第  $l-1$  層のニューロン  $i$  と第  $l$  層のニューロン  $j$  との結合の強度、 $z_i^{(l-1)}$  は第  $l-1$  層のニューロン  $i$  からの入力を示す。

$$u_j^{(l)} = \sum_i w_{ji}^{(l)} z_i^{(l-1)} \quad (1)$$

第  $l$  層中の  $j$  番目のニューロンへ入力された  $u_j^{(l)}$  は、式(2)によりニューロン固有のバイアスを加えた上で活性化関数  $f(l)$  により変換され、第  $l+1$  層に属する各ニューロンへ伝播される。なお、本分析では活性化関数として式(3)で定義される ReLU 関数を用いた。

$$z_j^{(l)} = f(u_j^{(l)} + b_j^{(l)}) \quad (2)$$

$$f(l) = \max\{0, u + b\} \quad (3)$$

第  $L$  層の出力層では、前層である第  $L-1$  層の出力ベクトル  $\mathbf{z}^{(L-1)}$  に重みベクトル  $\mathbf{W}^{(L)}$  を作用させた入力ベクトル  $\mathbf{u}^{(L)}$  を、活性化関数により変換することで予測値  $\hat{\mathbf{y}}$  を出力する。なお、中間層同様、活性化関数に ReLU 関数を用いた。

$$\hat{\mathbf{y}} = \mathbf{z}^{(L)} = f(\mathbf{u}^{(L)} + \mathbf{b}^{(L)}) \quad (4)$$

## 2.3 モデル構築手法

今回構築した NNW モデルの層数は 3 層であり、中間層のニューロン数はいずれも 100 とした。教師データからの学習は誤差逆伝播法による。以下に NNW モデルの構築手順を示す。

### (1) 特徴量の設定

本研究で特徴量として設定した項目は表 1 のとおり。また、本研究では、特徴量の選択によりモデルの精度にどのような影響を及ぼすか検証を行うため、省エネ行動に関する特徴量を含まないモデル(以下、条件 1)と含むモデル(以下、条件 2)の 2 種類を設定した。なお、省エネ行動等の定性データはダミー変数化している。

表 1 条件 1 及び条件 2 で選択した特徴量

特徴量		条件 1	条件 2
地域情報	都道府県, 都市階級	✓	✓
居住者情報	年齢別世帯人数, 平日昼間の在宅状況, 世帯年収	✓	✓
住宅情報	建て方別建築時期, 居室数, 延床面積, 二重サッシ有無	✓	✓
機器保有	製造時期別保有台数 (質問項目に製造時期がない場合は保有台数)	✓	✓
平均的な機器使用	機器使用頻度, 調理食数等	✓	✓
省エネ行動	省エネ行動実施数 (全 17 種類)	-	✓

### (2) 個票データの抽出

家庭 CO<sub>2</sub> 統計の有効サンプル 9,505 世帯のうち、表 1 の項目いずれかで未回答が存在した世帯は本研究の推計対象から除外した。また、当該燃料の消費量が 1 年を通じてゼロであった個票についても対象から除外している。

### (3) ネガティブサンプルの追加

学習精度の向上を目的とし、全ての特徴量がゼロであった場合、燃料消費量もゼロとなるネガティブサンプルを追加した。

### (4) L2 正則化による過学習防止

NNW モデルでは、他の機械学習モデルと比較し格段に多い重みパラメータを含むため、不必要に自由度を大きくした場合、学習データのもつノイズまでも学習し過学習に陥る場合がある。本研究では過学習を避けるため、式(5)に示す L2 正則化による学習を実施した。

$$\arg \min \text{Loss}(\hat{\mathbf{y}}, \mathbf{y}) + \frac{\lambda}{2} \sum_i w_i^2 \quad (5)$$

## 3. 推計結果

### 3.1 条件 1 による推計精度

条件 1 では、表 1 に示した特徴量のうち「省エネ行動」

を除く「世帯属性」, 「住宅属性」, 「機器保有状況」を特徴量とする燃料種別エネルギー消費量推計モデルを構築した。各モデルにおける予測値と実績値の関係を図 2 に示す。決定係数が最も大きい燃料種は電力の 0.6869 であり, 次の灯油(0.6559), 都市ガス(0.5789), LPG(0.5180)が続く。

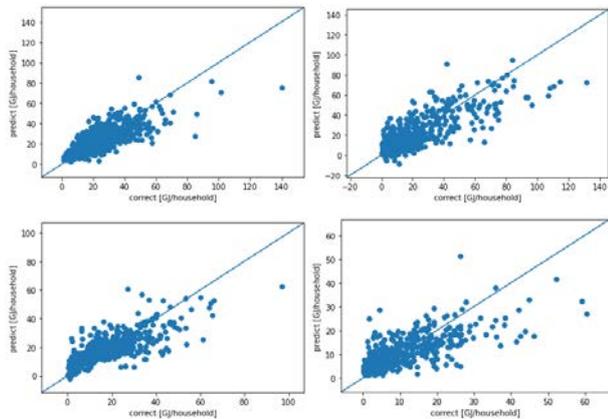


図 2 条件 1 による, 電力 (左上), 灯油 (右上), 都市ガス (左下), LPG (右下) の予測精度

家庭 CO<sub>2</sub> 統計では集計した個票から全国平均燃料消費量を推計する際, 国勢調査における地方 10 区分×都市階級 3 区分の世帯分布と一致するよう, 層化抽出法に基づく調整係数を用いた拡大推計を実施している。この調整係数を用い図 2 に示した各世帯の燃料消費量から全国平均消費量を推計し, 家庭 CO<sub>2</sub> 統計の個票データを用いて算出した全国平均消費量との間に差異が生じるか検証を行った。なお, 汎化性能の検証を実施するため対象はテストデータで利用した個票のみとする。比較結果を図 3 に示す。予測値の誤差は電力が+0.1%, 灯油が-3.7%, 都市ガスが-7.6%, LPG が+2.0%となった。都市ガスは他燃料種と比較し精度が落ちたものの電力, 灯油, LPG は予測値と実測値が概ね一致しており, 構築した NNW モデルにより世帯当たり電力, 灯油, LPG 消費量の全国平均値をある程度予測可能であることが示唆された。

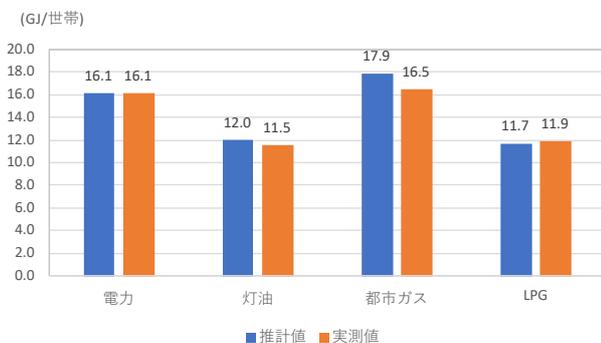


図 3 条件 1 による燃料種別世帯当たりエネルギー消費量の予測値と実測値の比較

### 3.2 条件 2 による推計精度

条件 2 では, 条件 1 で選択した特徴量である「世帯属性」, 「住宅属性」, 「機器保有状況」に「省エネルギー行動実施状況」を加え, 燃料種別エネルギー消費量推計モデルを構築した。各燃料種におけるモデルの予測値と実績値の関係は図 4 のとおりである。各燃料種の決定係数は電力が 0.6647, 灯油が 0.5633, 都市ガスが 0.5297, LPG が 0.3903 となった。図 2 と比較し, 特に灯油及び LPG において汎化性能が低下している。

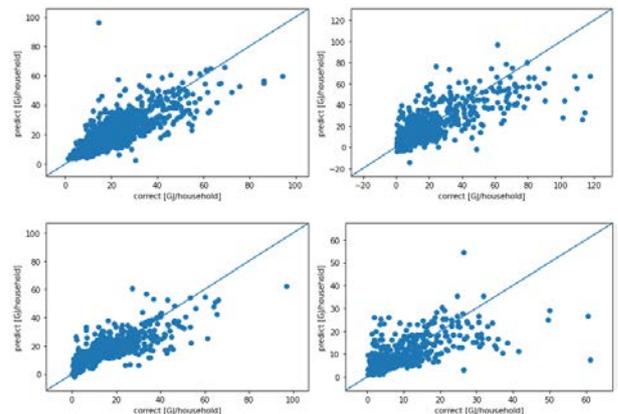


図 4 条件 2 による電力 (左上), 灯油 (右上), 都市ガス (左下), LPG (右下) の予測精度

条件 1 と同様に, 燃料種別全国平均消費量を比較した結果を図 5 に示す。予測値の誤差は電力が+0.7%, 灯油が-5.2%, 都市ガスが-6.5%, LPG が+1.0%となった。図 4 では, 灯油及び LPG の汎化性能が低下したものの, 条件 1 と同様, 世帯数分布を基に加重平均した世帯当たり電力, 灯油, LPG 燃料消費量の全国平均値については精度高く予測可能であることが示唆された。

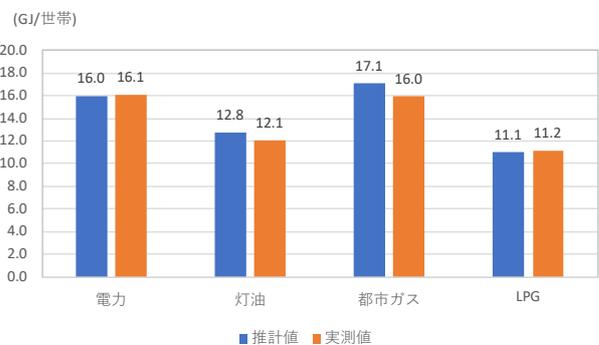


図 5 条件 2 による燃料種別世帯当たりエネルギー消費量の予測値と実測値との比較

## 4. 考察

### 4.1 学習曲線による学習状況の確認

機械学習では、訓練誤差を最小化し最適な重みを探索することでモデルを構築するが、本来最小化すべきものは汎化誤差である。訓練誤差のみを最小化した場合、汎化誤差が増大し未知のデータに対する予測性能が低下する過学習に陥る場合がある。本節では前章で構築した NNW モデルが過学習により汎化性能が低下していないか、学習曲線を用いた検証を行った。

学習曲線とは、各エポックで学習データとテストデータの精度をプロットしたものであり、構築したモデルが学習不足や過学習に陥っているか判断する指標として用いられる。データの豊かさに対してモデルの自由度が大きい場合、学習データのもつノイズまでもモデルに取り込み、訓練誤差は小さくなるものの未知のデータに対する汎化性能が低下し過学習に陥る場合がある。過学習に陥ると、学習曲線は学習データに対する正答率のみ高く、テストデータに対する正答率が低くなるよう推移する。一般的に、テストデータを用いた予測精度がサンプル数の増加とともに改善が見られる場合は学習データをさらに増やし、予測精度が既に収束している場合は特徴量を減じることでモデルの改善をはかることが多い。

条件1で構築したモデルの学習曲線を図6に示す。全てのモデルにおいて学習データの精度とテストデータの精度に大きな差が生じており過学習に陥っていることが示唆される。灯油に関してはテストデータの正答率が0.6付近で収束しているため、特徴量を減らし自由度を減らすことで精度が改善すると考えられる。一方、電力、都市ガス、LPGでは、テストデータの精度がサンプル数の増加とともに向上し続けているため、サンプル数を増やすことで推計精度をさらに改善させられる可能性がある。

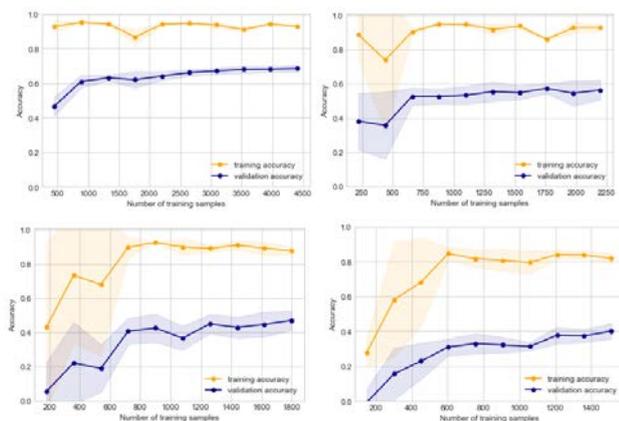


図6 条件1による電力(左上)、灯油(右上)、都市ガス(左下)、LPG(右下)モデルの学習曲線の推移

次に、条件2で構築したモデルの学習曲線を図7に示す。全ての燃料種で図6と同様の推移を示しており、上記に示した同様の方法でモデルの精度が改善される可能性がある。

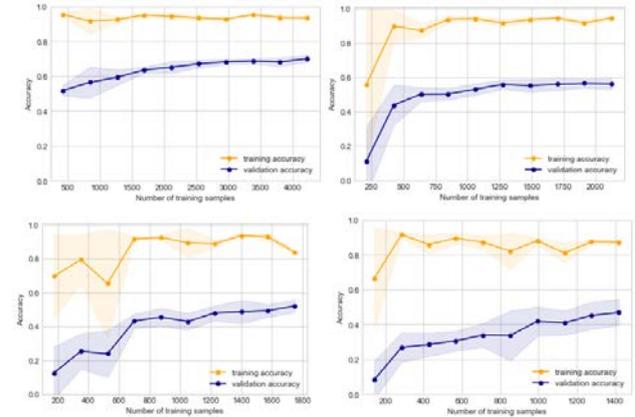


図7 条件2による電力(左上)、灯油(右上)、都市ガス(左下)、LPG(右下)モデルの学習曲線の推移

### 4.2 今後の応用

モデルの汎化性能がより改善された場合、特徴量を増やす、特徴量の値を変化させる等により以下の分析を実施することが可能である。

- 気象条件がエネルギー消費量へ与える影響の推計
- 高効率機器への切替や省エネ行動実施有無によるエネルギー削減ポテンシャルの推計
- 地球温暖化対策計画<sup>9)</sup>施されている各種対策の進捗評価

## 5. まとめ

### 5.1 NNWモデルの推計精度

本研究では家庭CO<sub>2</sub>統計を用いて燃料種別エネルギー消費量をNNWモデルにより推計する手法を検討した。本研究で得られた知見を以下に整理する。

- 家庭CO<sub>2</sub>統計を用い電力、灯油、都市ガス、LPGのエネルギー消費量を推計するため、NNWモデルを構築しその精度を検討した。各モデルの決定係数は概ね0.5から0.7の間に留まったものの、世帯数分布を基に加重平均した世帯当たり電力、灯油、LPG燃料消費量については高い予測精度を示した。
- 選択する特徴量の違いがモデル精度へ及ぼす影響について分析するため、使用する特徴量に省エネルギー行動実施状況を含めないモデル(条件1)と含めるモデル(条件2)を用意し、各条件でのモデル精度を比較した。条件1と条件2の予測精度を比較した結果、電力、都市ガスについては大きな差異が見られなか

ったが、灯油、LPG については条件 2 において予測精度が低下した。学習曲線による検証の結果、条件 1、条件 2 とともに全ての燃料種で過学習に陥っている可能性が示唆されており、灯油では特徴量を減じ、その他の燃料ではサンプル数を増やすことで精度を改善できる可能性がある。

- NNW モデルの汎化性能が改善された場合、気象条件によるエネルギー需要の変動や削減ポテンシャルの大きい特徴量の把握、地球温暖化対策計画で実施されている各種対策の進捗評価を行うことが可能である。

## 謝辞

本研究はエネルギー・資源学会主催の「家庭部門の CO<sub>2</sub> 排出実態統計調査利用研究会」における取組の一環として実施したものである。また、分析に使用した「家庭部門の CO<sub>2</sub> 排出実態統計調査」の統計データも、同研究会を通じて提供頂いたものである。ここに記し、感謝の意を表す。

## 参考文献

- 1) 地球温暖化対策推進本部; 「日本の NDC(国が決定する貢献)」(2020 年 3 月 30 日)
- 2) Biswas, MA Rafe, Melvin D. Robinson, and Nelson Fumo; "Prediction of residential building energy consumption: A neural network approach." Energy 117 (2016): 84-92.
- 3) Aowabin Rahman, Vivek Srikumar, and Amanda D. Smith; "Predicting electricity consumption for commercial and residential buildings using deep recurrent neural networks." Applied energy 212 (2018): 372-385
- 4) 田中昭雄, 小峯裕己, 関庸一, 三宅義彦. ニューラルネットワークによる住宅エネルギー消費構造モデルの研究, 空気調和・衛生工学会 論文集 31(111), 9-17, 2006
- 5) 環境省; 「平成 29 年度 家庭部門の CO<sub>2</sub> 排出実態統計調査 調査の概要」
- 6) 地球温暖化対策推進本部; 「地球温暖化対策計画」(2016 年 5 月 13 日)
- 7) 瀧雅人; これならわかる深層学習 入門(2017)

# 自家用車の保有状況と走行距離に関する個票データを用いた 家庭部門の輸送需要の長期予測

## Long-Term Projections of Transportation Demand in the Household Sector Using Survey Data on Private Car Ownership and Miles Traveled

星野優子\*・森田圭\*\*

Yuko Hoshino

Kei Morita

In this study, we focus on the transportation demand of passenger cars in Japanese households. We estimate a Heckman's two step model of the annual average mileage by passenger cars for each household based on the Survey data of Household CO<sub>2</sub> Emission which was published by the Ministry of the Environment. Furthermore, using this model, we make a prediction of the transportation demand of passenger cars in Japanese households by 2040 based on the future population and number of households as estimated by the Institute of Population and Social Security Research. Our results show that the total car mileage in Japan will decrease slower than the rate of population decline. This could be due to an increase in total vehicle miles driven due to a decrease in population density in rural areas and an increase in the number of households in large cities.

### 1. はじめに

地球温暖化防止の観点から、運輸部門においても省エネやCO<sub>2</sub>排出量削減の取り組みが求められている。燃費向上、次世代車利用や物流効率化といった省エネ、省CO<sub>2</sub>対策及びその効果を検討するベースとなるのが、将来の輸送需要の見通しである。このうち家庭における輸送需要は、世帯員各人の移動の必要量に相当し、通勤・通学だけでなく、レジャー、通院など様々な移動からなる。文献<sup>[1]</sup>では、今後予想される社会やライフスタイルの変化の要因はひとまず捨象したシンプルなモデルにより、人口および世帯の規模とそれらの地域差に着目し、その将来動向から、日本の家庭における輸送需要の将来予測の方法を検討した。しかし、人口と世帯規模だけのシンプルなモデルでは地域別の違いを十分に捉えることができず、予測精度に課題を抱えている。

以下では、文献<sup>[1]</sup>と同様に日本の家庭における乗用車による輸送需要に焦点を当て、環境省の「家庭部門のCO<sub>2</sub>排出実態調査（以下、「家庭のCO<sub>2</sub>実態調査」と呼ぶ）」<sup>[2]</sup>の個票データをもとに、世帯ごとの乗用車による年間平均走行距離のモデルを推定する。ただし、本研究では、説明変数として、人口と世帯規模だけでなく世帯属性も含め、さらに自動車の保有の有無と走行距離の2段階に分けたモデルとした。このモデルを用いて、社会保障人口問題研究所による市区町村別の将来人口および都道府県別の世帯数推計を

基に、2040年までの日本の家庭における乗用車による輸送需要の予測を試みる。

自動車輸送に関するパネルデータとしては、交通センサスOD調査、パーソントリップ調査などがある。市区町村別の輸送部門のCO<sub>2</sub>排出量に関する分析手法を比較した先行研究<sup>[2]</sup>によれば、交通センサスOD調査、パーソントリップ調査、燃料消費統計では、それぞれ登録地・目的地、現住所、通過地・給油地と調査地点が異なるため、市区町村の特性によっては推計結果が異なる可能性を指摘している。

大規模なパネルデータを用いた、自動車の保有や輸送需要に関する先行研究<sup>[3]</sup>では、交通センサスのデータを用いて、自動車保有台数と1台当たりの走行距離が分けてモデル化されており、後者の走行距離について、走行ゼロのデータを含めた後述するTobitモデルを用いて分析している。説明変数には、人口密度以外にも就業者数、免許保有者数、収入、燃費、女性免許保有率といった多くの要因が考慮されているが、保有台数のモデルに比べて走行距離のモデルでは必ずしも説明力の高いモデルが得られていないことから、「国全体での自動車保有・利用のマクロ的動向とは必ずしも整合的なものとはなっていない」と考察されている。

また、自動車の保有や走行距離に関しては、パネルデータを用いた精緻な分析がされる一方で、その分析結果を将来予測に適用することは十分には行われてこなかった。そこで本研究では、個票データから推定されたモデルをもとに、日本全体の家庭部門のマクロの走行距離の予測を試みる。

\*ENEOS株式会社 中央技術研究所 技術戦略室  
〒100-0003 東京都千代田区大手町 1-1-2  
E-mail: [hoshino.yuko@eneos.com](mailto:hoshino.yuko@eneos.com),

\*\*同上, E-mail: [morita.kei@eneos.com](mailto:morita.kei@eneos.com)

表 1 自動車保有状況別にみた世帯数と世帯属性

全国計	世帯数			世帯当たり年平均走行距離			平均世帯年収			世帯人員数			世帯員平均年齢		
	1台目	2台目	3台目	1台目	2台目	3台目	1台目	2台目	3台目	1台目	2台目	3台目	1台目	2台目	3台目
ガソリン車 (含ハイブリッド)	7,309	3,221	818	8,504	5,634	4,056	561	637	733	2.9	3.5	4.2	48	45	48
ディーゼル車 (含ハイブリッド)	155	56	16	10,873	5,982	6,144	675	660	704	3.2	3.2	3.6	48	50	49
電気自動車	30	10	3	11,420	6,780	5,000	552	801	1,000	2.6	3.2	4.3	50	50	44
プラグインハイブリッド車	33	3	2	11,364	9,000	4,350	762	917	940	2.8	3.0	5.5	49	50	35
その他 (LPG車、燃料電池車等)	12	8	5	2,033	2,838	3,820	459	970	901	2.4	4.4	4.2	42	33	32
その他 (不明)	17	18	10	6,712	1,328	1,500	495	433	614	3.1	3.4	3.7	47	45	49
車所有なし	1,949	-	-	-	-	-	407	-	-	2.0	-	-	55	52	50
<b>全車種計</b>															
北海道	687	242	33	8,741	5,215	4,539	511	592	766	2.6	3.1	3.6	50	45	47
自動車保有無し	151	-	-	-	-	-	347	-	-	1.8	-	-	58	-	-
東京	273	30	5	6,100	4,193	4,620	775	892	1,152	3.0	3.4	3.4	48	44	46
自動車保有なし	265	-	-	-	-	-	567	-	-	2.2	-	-	52	-	-
愛知	459	212	52	8,035	5,315	3,792	636	753	864	2.9	3.5	4.3	48	45	46
自動車保有なし	82	-	-	-	-	-	449	-	-	1.8	-	-	55	-	-
大阪	276	46	10	6,501	4,343	3,310	590	620	653	2.9	3.5	3.6	49	44	42
自動車保有なし	216	-	-	-	-	-	386	-	-	2.1	-	-	54	-	-
その他地域	5,652	2,759	751	6,501	4,343	3,310	549	630	722	2.9	3.5	4.2	48	45	48
自動車保有なし	1,100	-	-	-	-	-	369	-	-	1.9	-	-	55	-	-

注：世帯員平均年齢は、10歳刻みの選択肢の平均から推計。神奈川県では該当世帯数が少数のものがあり表には含めない。  
出所：環境省「家庭のCO<sub>2</sub>実態調査」個票データを用いた分析結果より著者ら作成

## 2. 分析の枠組み

### 2.1 分析に用いたデータ

表 1 は、「家庭のCO<sub>2</sub>実態調査」の 9505 世帯のサンプルについて、自動車保有台数別の世帯数、平均世帯年収、世帯平均年齢、世帯当たり平均走行距離をみたものである。文献<sup>[1]</sup>において、特に、北海道、東京都、愛知県、大阪府などでモデルの予測精度に課題があったことから、同表でも、全国及び、北海道、三大都市圏の 3 都府県およびそれ以外の道府県別に整理している。

全国では、調査世帯の 79%の世帯が少なくとも 1 台以上の自動車を保有しているのに対し、東京都、大阪府についてみると、乗用車を所有している世帯は、それぞれ 51%、56%と概ね半分にとどまる。一方、北海道では 82%、愛知では 85%が自動車を保有している。

また、乗用車を 2 台以上所有している世帯は、全国では 35%、愛知県では 39%であるのに対し、東京都では 6%、大阪府では 9%にとどまる。1 台目の世帯当たり年間走行距離については、北海道は 8504km、愛知県は 8305km であるのに対し、東京、大阪はそれぞれ 6100km、6501km と 7~8 割にとどまる。三大都市圏のうち、中部圏の愛知県では、自動車保有の比率、世帯当たり年平均走行距離ともに大きくなっていることがわかる。

### 2.2 分析に用いたモデル

自家用車の走行距離については、自動車を保有している世帯だけでなく、保有していない世帯の情報も含めて分析する必要がある。文献<sup>[1]</sup>では、Tobin<sup>[4]</sup>の考え方を基にした、従属変数がゼロか正の値をとる標準 Tobit モデルを用いた。しかし、人口と世帯規模だけで説明するモデルでは、

表 2 モデルの説明変数間の相関係数

	人口密度	世帯収入	世帯人員数	世帯員平均年齢
人口密度	1	0.09	-0.03	0.00
世帯収入	0.09	1	0.36	-0.28
世帯人員数	-0.03	0.36	1	-0.51
世帯員平均年齢	0.00	-0.28	-0.51	1

出所：環境省「家庭のCO<sub>2</sub>実態調査」個票データより著者ら作成

特に東京や大阪など大都市部について十分な説明力を持っていないことが課題であった。そこで本研究では、説明変数に収入や年齢といった世帯属性を含め、さらに以下で示すように、自動車を保有するかどうかという意味決定と、自動車の走行距離について、2 段階に分けた Heckman2 段階推定的手法<sup>[5]</sup>を用いる。

第 1 段階目においては、自動車保有の有無について、被説明変数が、1 か 0 をとる Probit モデルを推定する。なお式(1)、(2)から得られる逆 Mills 比については文献<sup>[6]</sup>に詳しいが、自動車保有の有無によってサンプルを分割することによって生じる分布のゆがみを補正する値に相当する。第 2 段階目においては、自動車保有世帯のみを対象として、世帯当たり総走行距離を説明する回帰モデルを推定する。なお(3)式は、第 1 段階で推定した逆 Mills 比を説明変数として加えている。

表 2 は、分析モデルに用いる説明変数間の相関係数を見たものである。本研究で着目している居住市町村の人口密度を含めて、説明変数間の相関は低いことが確認できる。以下は、これらの説明変数を用いた、第 1 段階、第 2 段階それぞれの分析モデルである。

第1段階：自動車の保有の有無 $d_i$

保有有り：1，保有無し：0

$$d_i = \begin{cases} 1 & z_i > 0 \\ 0 & z_i \leq 0 \end{cases} \quad (1)$$

$$z_i = \beta_0 + \beta_P P_i + \beta_I I_i + \beta_A A_i + v_i \quad (2)$$

$P_i$ ：居住市区町村の人口密度，

$I_i$ ：世帯収入， $A_i$ ：世帯員平均年齢

$v_i \sim N(0, \sigma_v^2)$ ， $i = 1, 2, \dots, n$

第2段階：保有世帯における年間走行距離 $y_i$

$$y_i = \begin{cases} \gamma_0 + \gamma_P P_i + \gamma_I I_i + \gamma_J J_i + \alpha M_i + v_i & d_i = 1 \\ 0 & d_i = 0 \end{cases} \quad (3)$$

$P_i$ ：居住市区町村の人口密度，

$I_i$ ：世帯収入， $J_i$ ：世帯人員数

$M_i$ ：第1段階で推定した逆 Mills 比

$u_i \sim N(0, \sigma_u^2)$ ， $i = 1, 2, \dots, n$

3. モデルの推定結果

3.1 自動車保有の有無に関する推定結果

表3は、第1段階に相当する自動車保有の有無に関するモデル(式(1),(2))の推定結果である。同表では、全国に加え、北海道、東京都、東京都・神奈川県、愛知県、大阪府およびそれ以外の府県の7地域について、それぞれ最も説明力の高い定式化によるモデルの推定結果を示している。

居住市区町村の人口密度の係数は、いずれもマイナスで有意な説明力を持つ。人口密度が高い市区町村では公共交通機関への依存度も高く走行距離は相対的に短くなるのに対し、そうでない地方では、移動にあたってはより自動車

表3 自動車保有の有無に関するモデルの推定結果

	全国	北海道	東京	東京・神奈川	愛知県	大阪	その他
定数項	1.191	1.443	0.563	0.556	2.048	0.278	1.260
人口密度	-0.00010	-0.00028	-0.00008	-0.00008	-0.00018	-0.00008	-0.00011
世帯収入	0.00087	0.00096	0.00086	0.00090	0.00061	0.00117	0.00084
平均年齢	-0.077	-0.114		-0.029	-0.088		-0.084
サンプル数	9505	838	538	882	541	492	6752
決定係数	0.147	0.083	0.143	0.142	0.127	0.128	0.083
対数尤度	-4193	-361	-332	-542	-197	-304	-2759

出所：環境省「家庭のCO<sub>2</sub>実態調査」個票データを用いた分析結果より著者ら作成

注：説明変数はいずれも片側5%で有意な説明力を持つ。

に依存することなどを反映していると考えられる。世帯収入の係数はすべてプラスで有意な説明力を持っており、世帯収入が高い世帯で、より自動車保有率が高くなることを示している。世帯平均年齢については、東京、大阪では説明力を持たない。それ以外の地域では、マイナスで有意な説明力を持つ。高齢者が運転をやめることなどから年齢が高くなるほど自動車保有率が低くなるためと考えられる。

3.2 世帯当たり年間走行距離に関する推定結果

表4は、第2段階に相当する世帯当たり年間走行距離に関するモデル(式(3))の推定結果である。比較のため、最小二乗法を用いて全世帯を対象にした場合と自動車保有世帯のみを対象にした場合についても推定している。まず、居住市区町村の人口密度は、東京都、大阪府のモデルでは、年間走行距離を説明する変数にはなっていない。東京、大阪を含む全国モデルにおける、人口密度の係数が-0.287であるのに対し、特に北海道、愛知、その他地域の係数は、より(絶対値は)大きな係数が推定されている。これは、特に東京、大阪では、人口密度が高く公共交通機関も発達しており自動車への依存度が相対的に低くなるためと考えられる。

次に、世帯人員数は、全国、北海道、愛知、その他地域では有意にプラスの説明力を持つのに対し、東京、東京・神奈川では年間走行距離を説明する変数にはなっていない。

表4 世帯当たり年間走行距離に関するモデルの推定結果

	全国			北海道			東京			東京・神奈川			愛知県			大阪			その他地域						
	モデル(1)	モデル(2)	モデル(3)	モデル(1)	モデル(2)	モデル(3)	モデル(1)	モデル(2)	モデル(3)	モデル(1)	モデル(2)	モデル(3)	モデル(1)	モデル(2)	モデル(3)	モデル(1)	モデル(2)	モデル(3)	モデル(1)	モデル(2)	モデル(3)				
	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯	全世帯	自動車保有世帯			
	最小二乗法		Heckmanの二段階推定		最小二乗法		Heckmanの二段階推定		最小二乗法		Heckmanの二段階推定		最小二乗法		Heckmanの二段階推定		最小二乗法		Heckmanの二段階推定		最小二乗法		Heckmanの二段階推定		
定数項	4759	7425	10673	5072	7874	12523					3368	5161	-3972	5822	6988	6114	787	5262	8537	3726	6281	7874			
人口密度	-0.678	-0.692	-0.287	-3.159	-3.151	-1.889					-0.189	-0.039	-0.709	-1.050	-0.922	-1.188							-1.137	-1.151	-0.989
世帯人員数	2332	1947	1527	2614	2089	1361								1747	1436	1510	1320	727	539	2022	1687	1608			
世帯収入							3.047	6.852	4.627	3.390	2.205	9.909	4.619	4.921	5.814						5.207	4.860	3.859		
逆MILLS比			-9509			-12843			4046			15507			4463					-4352					-3842
サンプル数	9505	7556	7556	838	687	687	538	273	273	882	482	482	541	459	459	492	276	276	276	6752	5652	5652			
決定係数	0.167	0.108	0.121	0.139	0.104	0.128	0.041	0.017	0.008	0.070	0.014	0.024	0.236	0.173	0.172	0.060	0.010	0.033	0.174	0.131	0.131				
対数尤度	-100440	-80111	-80057	-8826	-7250	-7239	-5480	-2850	-2839	-8901	-4945	-4942	-5638	-4794	-4794	-4993	-2834	-2830	-71604	-60034	-60032				

出所：環境省「家庭のCO<sub>2</sub>実態調査」個票データを用いた分析結果より著者ら作成

注：東京・神奈川モデルの定数項，愛知モデルの逆 Mills 比，大阪の世帯人員数の係数以外は、片側5%で有意

通勤や買い物に自動車を利用することの多い地方では、世帯人員数が増えると自動車利用が増加しやすいが、公共交通機関が発達している東京、神奈川では、この傾向はあまり見られないためと考えられる。

文献<sup>[1]</sup>では、東京、大阪など大都市でモデルの説明力に課題があったことから、本研究では、世帯収入を説明変数に加えた。世帯収入は、東京、東京・神奈川、愛知、その他地域のモデルで有意な説明力を持っている。第一段階の推定結果から、世帯収入は自動車保有の有無に影響を与えることが確認できるが、さらに表1でみるように、世帯収入が高くなるほど2台目、3台目の保有が増加していることも影響していると考えられる。

逆 Mills 比は、自動車保有の有無によってサンプルを分割することによって生じる分布のゆがみを補正する目的でモデルの説明変数に加えている。表4の各モデルのうち、愛知県のモデルでは、逆 Mills 比は有意ではないことから、以下の予測にあたっては、愛知県については、逆 Mills 比を含まないモデル(2)を用いる。愛知以外の地域(北海道、東京、東京・神奈川、大阪、その他地域)については、逆 Mills 比が有意なことから、これを含むモデル(3)を用いる。

## 4. 2040年までの総輸送需要の推計

### 4.1 総輸送需要の推計方法

社会保障人口問題研究所による、2040年までの日本の将来人口・世帯数予測値から、上記のモデルを用いて、2040年までの家庭部門における自動車による輸送需要の推計を行う。同将来推計では、人口予測については市町村別の将来推計があるものの、平均世帯人員を推計するために必要な世帯数の将来予測は、都道府県別にしか行われていない。そこで本研究では、各市町村別の将来人口推計の伸びに合わせて世帯数を推計したうえで、その都道府県別合計値を、社会保障人口問題研究所の都道府県別世帯数予測値に置き換えて、合計調整することで、市町村別の世帯数、世帯人員数の予測値とする。

各市(区)町村における予測対象 $t$ 年の世帯あたり年間走行距離 $\bar{y}_t$ は、(3)式で推定したパラメータを用いて、以下(4)式で予測する。ただし東京都のみ、区ごとに推計し、その他政令指定都市については、市ごとの推計とする。ここで $\bar{P}_t$ は、予測期間における居住市(区)町村の人口密度の予測値、 $\bar{I}_t$ は、予測期間における世帯収入の予測値、 $\bar{J}_t$ は、予測期間における世帯人員数の予測値、 $\sum_i M_i/n$ は、対象地域の各サンプル世帯についての第1段階で推定された逆 Mills 比の平均値である。今回の分析では、主に人口動態の変化による輸送需要への影響を主眼にしていることから、世帯収入については、予測期間を通して実績値で一定とした。

$$\bar{y}_t = \gamma_0 + \gamma_P \bar{P}_t + \gamma_I \bar{I}_t + \gamma_J \bar{J}_t + \alpha \sum_i M_i/n \quad (4)$$

$$i = 1, \dots, n,$$

ただし $n$ は、対象地域のサンプル世帯数

さらに都道府県ごとの年間総走行距離の予測値 $\bar{W}_t$ は、以下(5)式で、各市(区)町村別に世帯当たり年間走行距離の予測値 $\bar{y}_{zt}$ に当該市(区)町村の世帯数 $\bar{H}_{zt}$ を乗じて、これを都道府県単位で合意し、都道府県別の自動車保有率の予測値 $\bar{R}_z$ を乗じて求める。

$$\bar{W}_t = \sum_{z=1}^k (\bar{y}_{zt} \times \bar{H}_{zt}) \times \bar{R}_z \quad (5)$$

ただし $\bar{R}_z$ は、家庭部門CO<sub>2</sub>排出実態統計調査の個票データから推計した、47都道府県の自動車保有率と都道府県別の人口密度のデータから推定した、以下の(6)式を用いて求める。被説明変数自動車保有率は0%から100%の値をとることから、(6)式の定式化ではロジスティック曲線を想定している。

$$\ln(R_z/(1-R_z)) = 4.1465 - 0.4140 \times \ln P_z \quad (6)$$

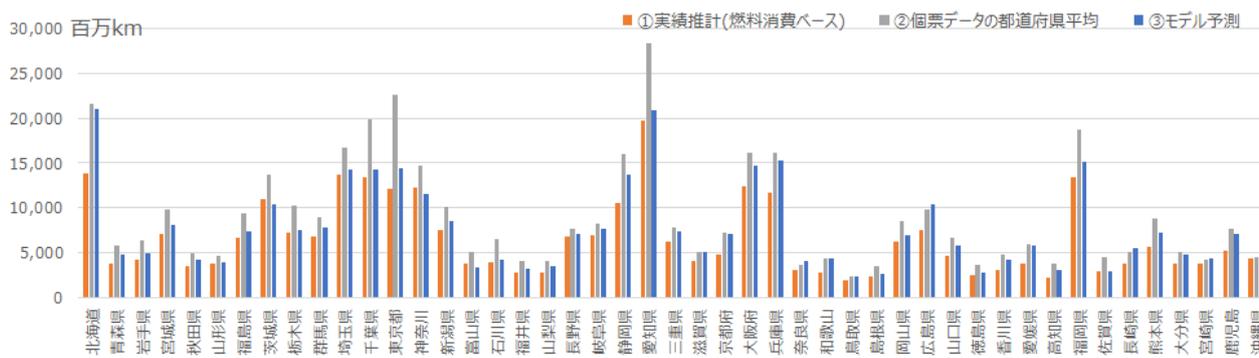
(9.28)    (-5.43)

サンプル数:47, ( )内はt値, 修正済み決定係数:0.38

### 4.2 実績値の再現力からみたモデルの説明力の検証

図1は、年間走行距離に関するモデルの説明力を確認するために、モデル予測値と実績推計値を比較したものである。国土交通省の燃料消費統計の都道府県別の2015年度実績値「①実績推計(燃料消費ベース)」、個票データから都道府県別に平均した「②個票データの都道府県平均」と、式(4)~(6)を基にした各地域別モデルを用いて実績推計した2015年度の市町村別の年間平均走行距離の都道府県別集計値「③モデル予測値」を比較している。個票データは2017年の値であるが、予測に用いる市区町村別の人口、世帯数予測値は、2015年度から5年刻みであることから、「①実績推計(燃料消費ベース)」、「③モデル予測値」は2015年度の値である。

これによると、「②個票データの都道府県平均」は、「①実績推計(燃料消費ベース)」、「③モデル予測値」と比較して、多くの都道府県について過大推計になっている。対象年度が異なることが影響している可能性があるものの、個票データは、必ずしも各都道府県の全市町村のサンプルを網羅できているわけではないので、個票データが得られた市区町村だけの走行距離の平均値は、都道府県平均として参照するのに十分な代表性を持たない可能性がある。



出所：実績値は図1に同じ。モデル推計値は、表2の「基本モデル」を用いて著者作成

図1 都道府県別の年間総走行距離(2015年)の比較によるモデルの説明力  
「実績値(燃料消費統計)」、「モデル予測」、「個票データの都道府県平均」

特に都道府県別の世帯の自動車保有率については、当該都道府県内での世帯数の比率に整合的な市町村別のサンプルが得られていない場合には、世帯数が多く走行距離は短い大都市圏を含む都道府県において、実態と乖離が生じる可能性がある。これに対して、モデル予測値は、すべての市区町村を対象にした推計値をもとに都道府県合計値を求めていることから、個票データのサンプルの偏りを補正できる可能性があることを示す結果になっている。

ここでは主に「①実績推計(燃料消費ベース)」と「③モデル予測値」を比較して、「③モデル予測値」がどの程度「①実績推計(燃料消費ベース)」を再現できているのかを確認する。その結果、特に北海道で誤差が大きく、52%の過大推計となっているほか、多くの都道府県で大きめに推計されており、全国合計では、18%の過大推計になっている。ここで燃料消費統計の実績推計値は、旅客用の家用車の総走行距離のうち家計寄与分を、総合エネルギー統計における家計と企業の旅客用燃料消費カロリーの比率値を参考に推計したものである。モデル予測値が全般に高めに推計されている要因としては、燃料消費統計から走行距離のうち家庭寄与分の実績推計に用いた家計寄与の割合の想定が影響している可能性もある。

一方、地域による差については、全体としては概ね傾向を捉えている。また、文献<sup>[1]</sup>で当てはまりが悪く、大きく過少推計になっていた東京都、神奈川県、大阪府について当てはまりが改善していることを確認できる。

### 4.3 2040年までの年間総走行距離の予測

2040年までの年間総走行距離は、式(4)~(6)のモデルに説明変数の2040年までの予測値を当てはめて市区町村別に予測する。説明変数のうち、人口、世帯関連の予測値は、社会保障人口問題研究所による、2040年までの日本の将来人口・世帯数予測値の中位推計を参照している。ただし、

同将来推計では、人口予測については市町村別の将来推計があるものの、平均世帯人員を推計するために必要な世帯数の将来予測は、都道府県別にしか行われていない。そこで本研究では、各市町村別の将来人口推計の伸びに合わせて世帯数を推計したうえで、その都道府県別合計値を、社会保障人口問題研究所の都道府県別世帯数予測値に置き換えて、合計調整することで、市町村別の世帯数、世帯人員数の予測値とした。なお世帯収入の予測値については、2015年実績値で固定としている。

図2は、こうして予測した2040年の家庭部門における自動車の総走行距離の都道府県別集計値、比較のための2015年値と2015年~2040年間の増減率を示したものである。東京都、神奈川県、愛知県、滋賀県、沖縄県を除く多くの都道府県で、2015年と比べて減少し、全国計では2015年比で8%減少する結果になった。厚生省の将来人口推計(中位推計)によれば、同期間に日本の総人口は13%減少すると予測されており、総走行距離は人口減少のスピードよりも緩やかにしか減少しない結果となった。地方での人口密度の減少による総走行距離の増加や、大都市部での世帯数の増加などが要因として考えられる。

一方、文献<sup>[1]</sup>では、今回の分析結果とは異なり、家庭の総走行距離が減少するスピードは人口減少よりも速く、2040年の家庭部門の総走行距離は2015年比16%減少するという結果を得ていた。同文献では、大都市部でのモデルの説明力が低いことなどが課題として挙げられており、これら人口が集中し世帯数の増加が予想されている地域で、過少推計となっていたことが影響していた可能性がある。本研究では、文献<sup>[1]</sup>に比べて、モデルの精度は改善したとはいえ、まだ十分とは言えないことから、図2の予測結果については、こうした留保付きの試算結果であることに注意が必要である。より多時点での個票データを用いるなど、モデルの精度向上は引き続き今後の課題である。

## 5. おわりに

輸送部門のエネルギー消費や CO<sub>2</sub> 排出量を予測には、燃費向上や EV 普及などのパワートレインの変化、さらにシェアリングといった様々な要因を検討する必要がある。しかしいずれの場合においても、家庭において自動車が担ってきた輸送需要の規模感を推計する作業がこれらの基礎になる。

本研究では、環境省の「家庭の CO<sub>2</sub> 実態調査」の個票データを用いて、市町村別の人口や世帯属性の変化が、家庭における自動車による輸送需要に与える影響を踏まえて、2040 年までの総走行距離の見通しを試みた。文献<sup>[1]</sup>で課題であった東京や大阪などの大都市部でのモデル説明力、予測精度の改善のため、自動車の保有の有無と走行距離を分けて分析する Heckman の 2 段階推定を用いた。個票データは、必ずしも各都道府県の全市町村のサンプルを網羅できているわけではないのに対し、モデル予測値は、すべての市区町村を対象にした推計値をもとに都道府県合計値を求めていることから、個票データのサンプルの偏りを補正できる可能性がある。本研究では、個票データの情報を元にマクロの輸送需要の将来推計を行う手法を検討したが、サンプルの偏りを補正できる点も、本研究で検討した予測手法のメリットである。

予測の結果、家庭部門の総走行距離は全国計では 2040 年に 2015 年比で 8% 減少する結果となった。同期間に総人口は 13% 減少すると予測されていることから、総走行距離は人口減少のスピードよりもゆっくりとしか減少しないこと

を意味している。地方での人口密度の減少による総走行距離の増加や、大都市部での世帯数の増加などが要因として考えられる。モデルの予測精度の向上は、今後の課題としたい。

## 謝辞

本研究は、環境省が実施する一般統計調査である「家庭部門の CO<sub>2</sub> 排出実態統計調査」及び「家庭からの二酸化炭素排出量の推計に係る実態調査 全国試験調査」の調査票情報を用いて実施しました。関係者の皆様に感謝申し上げます。

## 参考文献

- 1) 星野優子, 森田圭; 人口減少に着目した家庭の自家用車による輸送需要の将来推計, 第 39 回エネルギー・資源学会研究発表会講演論文集, (2020)
- 2) 環境省; 『家庭部門の CO<sub>2</sub> 排出量実態調査 2017 年版』, (2019)
- 3) 松橋啓介, 工藤祐揮, 上岡直見, 森口祐一; 市区町村の運輸部門 CO<sub>2</sub> 排出量の推計手法に関する比較研究, 環境システム研究論文集 Vol. 32, (2004)
- 4) Tobin, J.; Estimation of Relationship for limited Dependent Variables, *Econometrica*, 26, pp24-36, (1958)
- 5) Heckman, J.J.; Sample selection bias as a specification error, *Econometrica*, Vol.47 No.1, pp.153-161, (1979).

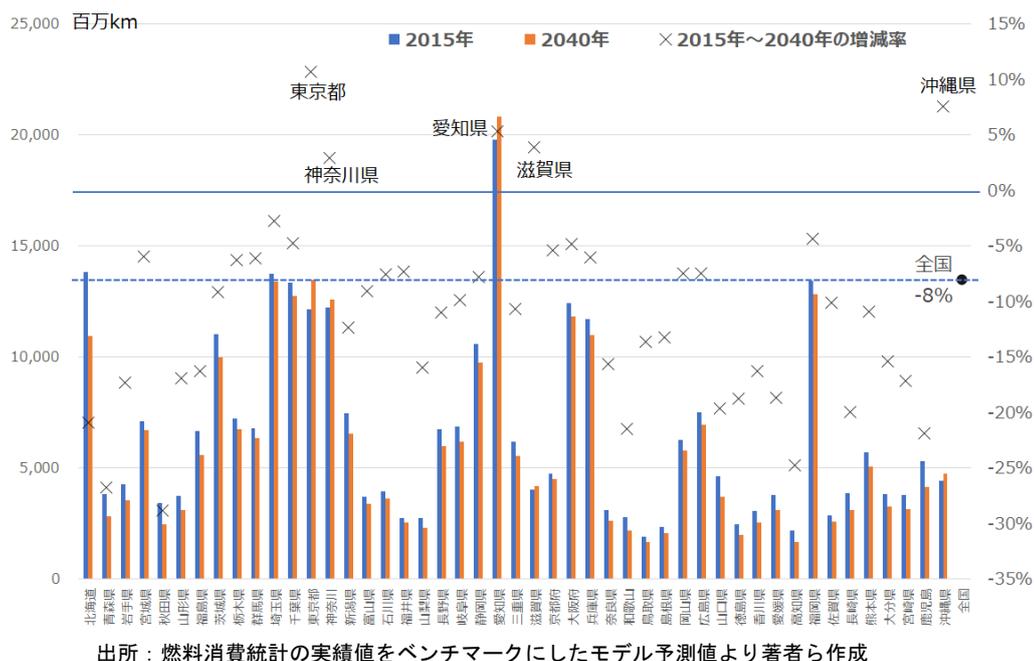


図 2 都道府県別の年間総走行距離の予測 (2015 年, 2040 年, 2015~2040 年増減率)

# Cluster analysis of Japan households' energy consumption per resource

Delage Rémi\*, Nakata Toshihiko\*

## ***Abstract***

The analysis of energy systems has so far been limited to aggregated statistics or analytical modeling with underlying assumptions and approximations. The results of such approaches do not reflect real world complexity including uncertainties or heterogeneity in energy systems agents' preferences and behaviors. Recently, the opening access to individual data allows the use of advanced tools such as machine learning to perform complex, deeper analysis of the systems and fill our lack of knowledge to design more accurate solutions toward energy sustainability. The present study focuses on the analysis of clusters in Japan households' energy consumption per resources. Statistically significant patterns are identified in the households' data for each cluster.

**Keywords** : Consumption analysis, Residential sector, clustering.

## **1. Introduction**

The interest in energy systems started in the mid-1970s when modeling was employed for energy planning as a response to the oil crisis [1]. Today, researchers are working on improving our energy systems by solving the sustainability trilemma between affordability, security and sustainability toward a carbon-neutral society in order to mitigate climate change. Although the objective has shifted, the methodology has fundamentally remained the same with the use of aggregated statistics and optimization based analytical models to analyze current systems performance, suggest optimum designs, and forecast possible evolution scenarios with the integration of new technologies and policies. New idea has yet emerged to integrate concepts such as sector coupling or cross-border sharing, as well as dynamical considerations of energy demand and power generation from intermittent resources.

One of the major obstacles faced by researchers of this field remains the complexity of energy systems because of their many actors or agents distributed in social, economic, technological and environmental groups [2, 3]. Such systems are self-organized in local subsystems with intra and inter feedback loops making them highly nonlinear. They are optimized from the bottom-up through a process of evolution rather than being the result of a centralized mechanism with global information.

The analysis and design of energy systems requires either the use of complex techniques such as agent models, dynamical networks and machine learning, or their simplification at the expense of accuracy. The later has so far been the standard strategy with the

E-mail: delage@tohoku.ac.jp

\*Department of Management Science and Technology,  
Graduate School of Engineering, Tohoku University,  
6-6-11-816, Aramaki-Aza-Aoba, Aoba-ku, Sendai, 980-8579, Japan.

grouping of agents from supply side to demand side in sectors often defined by societal criteria such as industrial, commercial and residential demand sectors. However, agents from different demand sectors might have similar supply needs, and agents from the same sector might have different needs. Furthermore, agents from a demand sector might produce energy for others, especially in a system with sector-coupling, cross-border and peer-to-peer energy sharing.

With the increasing amount of data from individual agents available, it is now becoming possible to shift from these arguably strong assumptions toward more objective and accurate system simplifications based on actual agents' behaviors regarding energy. Several studies have introduced clustering as one of these alternatives [4]. While these techniques do allow for an accurate grouping, the complex mechanisms at the roots of identified clusters are still unclear.

The present study focuses on the analysis of clusters in Japan households' energy consumption per resources by looking for statistically significant characteristics in their geographical location, building data, residents' data, and equipment.

## **2. Data and preliminary analysis**

We use the 2017 statistics survey of residential sector provided by the Japanese Ministry of the Environment [5]. The data set contains 9505 households distributed all over Japan with various data including their energy consumption. We search for clusters in the 5-dimensional space constituted by their total consumption per year of electricity, city gas, LP gas, kerosene, and vehicle fuel resources.

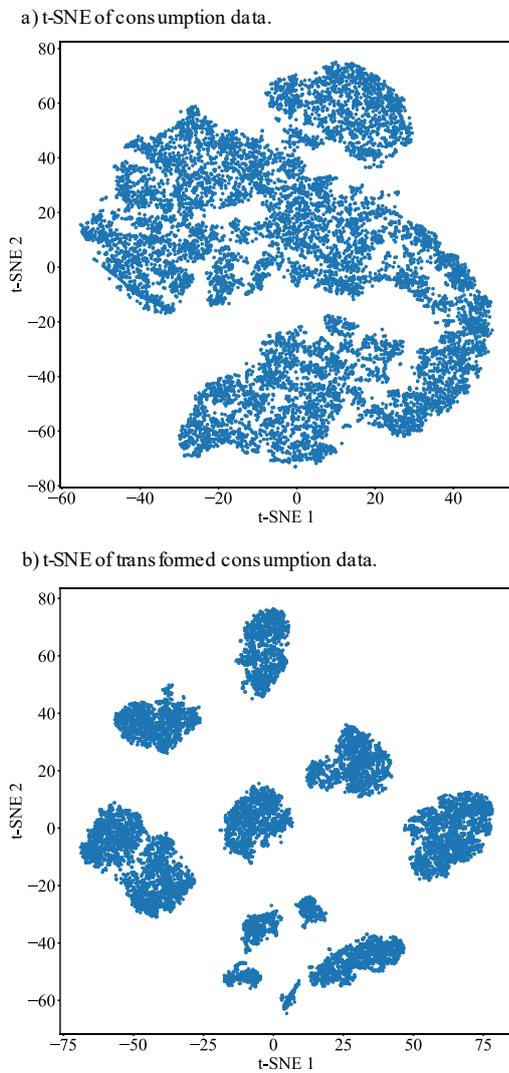
In order to verify the existence of clusters, we first visualize the

data by mapping each household to a 2-dimensional space using t-Stochastic Neighbor Embedding (t-SNE) [6]. It is a machine learning technique that consists in constructing a low-dimensional map such that the data pairwise probability distribution is similar to that in the original high-dimensional space by minimizing the Kullback-Leibler divergence. Data points pairs are attributed a higher probability the more similar they are using any similarity metrics (here we use the Euclidean distance). This technique is particularly adapted to the visualization of clusters in high-dimensional data. Figure 1 a) shows the result of t-SNE on the 9505 households' consumption data using a perplexity parameter of 100 which is almost equal to 1% of the sample size [7]. No clusters are clearly distinct here. In order to reveal the clusters, we apply a nonlinear transformation on the data using the inverse

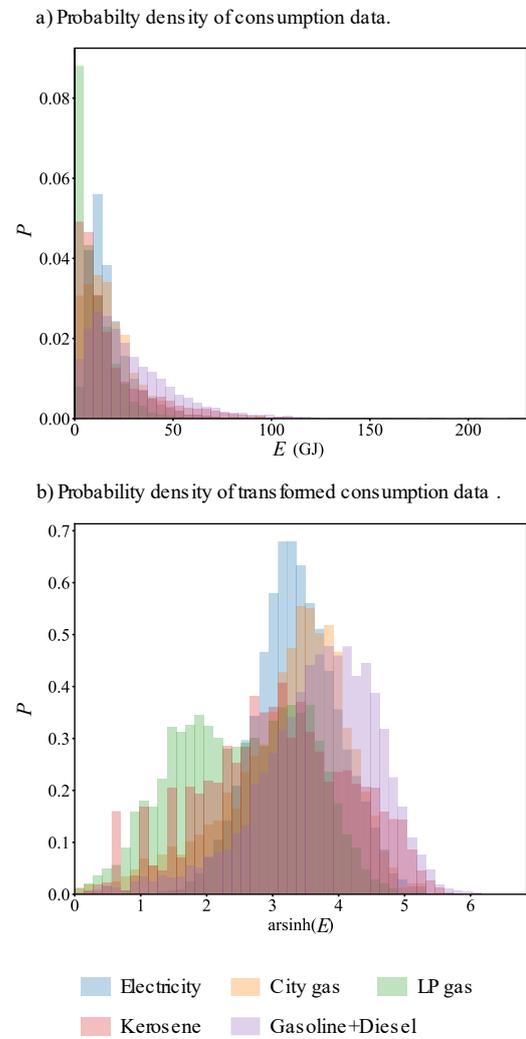
hyperbolic sine function [7] defined by:

$$\operatorname{arsinh}(x) = \log(x + \sqrt{x^2 + 1}). \quad (1)$$

The effects of this transformation are shown in Fig. 2. In the original distributions of households' energy consumption for each resource Fig. 2 (a) show that the majority of households have a low, even not distinguishable from zero energy consumption, while few have very high consumption not comparable with the whole set. As one can see from the distributions of transformed data Fig. 2 (b), households with low energy consumption are clearly separated from zero values (not including here), while the increasingly rare households with high consumption are now comparable with others. Another benefit of this transformation is that it keeps zero values as zero. One could also use  $\log(x + 1)$



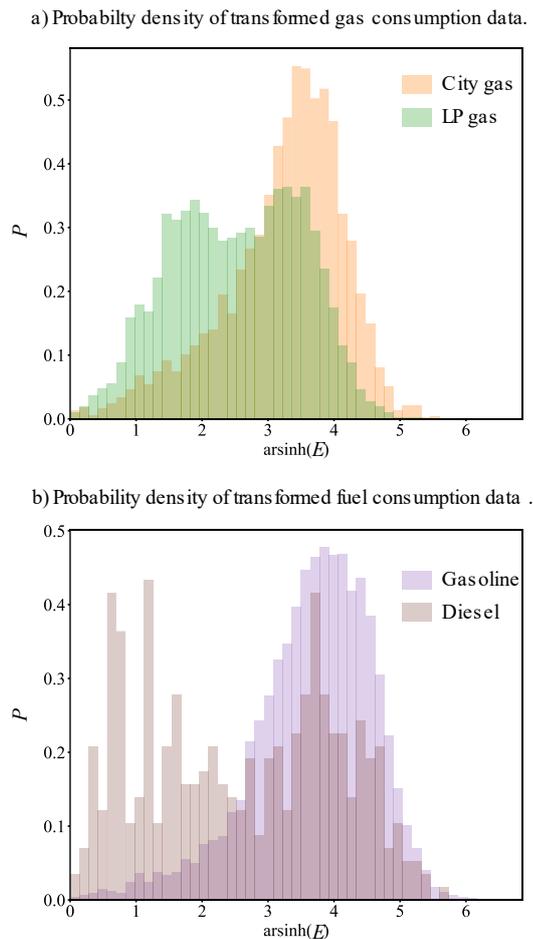
**Fig. 1.** t-SNE maps of a) the original energy consumption data, and b) the data after transformation using arsinh function.



**Fig. 2.** Effect of arsinh transformation on the probability distributions of households' energy consumption per resource. Zero values are omitted for better readability.

for this purpose but we found that clusters were qualitatively more distinct with arsinh transformation. Notice how the distributions of resemble that of normal distributions after transformation. This hints at log-normal type distributions resulting from the multiplicative product of random independent variables and commonly observed in complex systems [8].

To justify our choice of these five energy resources for our analysis, we compare the distributions of gas resources and vehicle fuel resources in Fig. 3. (a) and (b) respectively. City gas and LP gas consumptions show very distinct patterns. Especially, LP gas distribution seems to be composed of several random processes. For this reason, we consider these resources separately. The diesel fuel consumption seems to be on average lower than that of gasoline, which might be due to the former being 20% more efficient. However, the number of households using this resource constitutes only 8% of the whole set so it is difficult to identify a clear pattern in the distribution. Clustering applied on the 6-dimensional space with separated vehicle fuel resources resulted in the identification of most of these households as

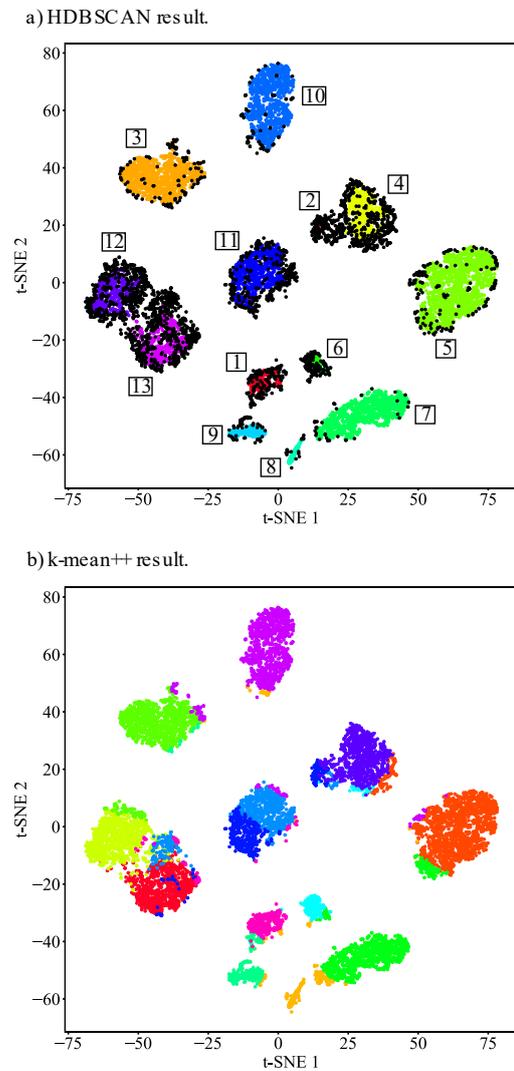


**Fig. 3.** Comparison of probability distributions for gas and vehicle fuel resources.

outliers. Since these resources have the same consumption purpose, we chose to consider them together. The remaining resources, electricity and kerosene, are interesting on their own, one having broad usage purposes and the other mostly found in cold areas or in older buildings.

### 3. Consumption clustering

We use HDBSCAN clustering algorithm [9] offering several advantages over other widely used algorithms like k-mean. As a density-based algorithm, it uses a minimum cluster size to identify the actual clusters and outliers rather than searching for the optimal arrangement of all points into a pre-decided number of clusters. Results of HDBSCAN and k-mean++ clustering on the original 5-dimensional space are shown in Fig. 4 (a) and (b). The input parameters are respectively a minimum cluster size of 20



**Fig. 4.** Clustering results from a) HDBSCAN and b) k-mean++ algorithms.

**Table 1.** Clusters size and average energy consumption in GJ.

Cluster	1	2	3	4	5	6	7	8	9	10	11	12	13	Outliers
Nb points	203	31	934	437	1312	75	926	135	222	931	688	396	427	2788
% points	2.1	0.3	9.8	4.6	13.8	0.8	9.7	1.4	2.3	9.8	7.2	4.2	4.5	29.3
Per household	Electricity	12.3	12.2	12.9	13.7	14.5	11.9	11.8	25.8	10.3	33.0	28.2	12.5	15.6
	City gas	0	2.7	0	19.2	21.2	16.4	15.5	0	0	0	0	0	0
	LP gas	4.5	0	12.3	0	0	0	0	0	9.1	0	0	16.0	2.9
	Kerosene	16.5	44.4	0	10.4	0	9.6	0	0	0	0	16.4	9.5	38.5
	Gasol.+Dies.	0	24.2	28.5	25.7	20.3	0	0	0	0	31.3	33.6	32.6	35.0
	Total	33.3	83.4	53.8	69.0	56.0	37.9	27.3	25.8	19.4	64.3	78.3	70.6	92.0
Per resident	Total	18.4	34.5	20.4	24	19.4	15.7	12.9	11.4	10.6	20	25.5	25.3	31.1

points and a number of clusters of 13, the same number as identified by HDBSCAN and visible on the t-SNE map. HDBSCAN provides results qualitatively in concordance with the t-SNE mapping. While outlier households seem to clearly belong to clusters, t-SNE algorithm has a tendency to over-represent the existence of clusters.

The size and average energy consumption for each cluster is summarized in Table 1. Absent resources combinations are: no electricity; city gas with LP gas; electricity with kerosene only. Clusters 2, 4 and 12, 13 use the same combination of resources in different quantities.

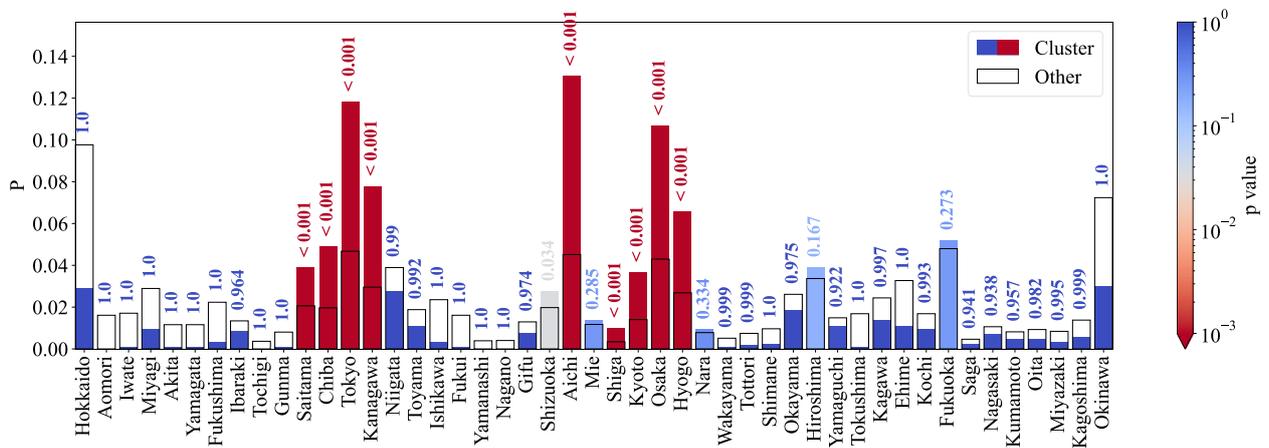
**4. Households characteristics**

After identifying households with common energy consumption profiles, we search for significant differences between these clusters in their geographical location, residents’ data and equipment using either the conditional probability (probability given data  $\in$  cluster) or average value depending on the nature of the data. We estimate the corresponding p-values based on the null-hypothesis that clusters’ households’ data are not different from the other households’ data using a bootstrapping method as follows: for each cluster, 100.000 test sample sets with the same size as the considered cluster are

generated by randomly drawing households from the whole set with replacement excluding households from the cluster. The conditional probabilities or average values probability distributions are computed using the test sets. Based on the actual cluster data, the p-value is then estimated from these probability distributions using a right-tailed test for conditional probabilities and two-tailed test for average values. Figure 5 shows the conditional probability distribution of cluster 5 households in Japan prefectures with the corresponding p-values as an example of such calculation. Although the conditional probability for Fukuoka prefecture is higher than for Shiga prefecture, its p-value is relatively high so the null-hypothesis cannot be invalidated. Meanwhile, the p-value for Shiga prefecture is low meaning that the percentage of households from this prefecture is abnormally high compared with that of the set of other households.

**5. Results and interpretations**

Table 2 shows significant (i.e., with low p-value) conditional probabilities and average values from the identified clusters. For practical reasons, only p-values lower than 0.01 are represented. Heating equipment and vehicles fuel data are omitted here because of their triviality (households using kerosene have kerosene-based heating equipment etc.).



**Fig. 5.** Example of prefectures conditional probability distribution for cluster 5 with corresponding p-values.

**Table 2.** Statistically significant households' data for each cluster. Only p-values less than 1% are represented.

Cluster	1		2		3		4		5		6		7																							
Prefecture	Hokkaido 20.7%	Aomori 6.4%	Iwate 4.9%	Hokkaido 54.8%	Aomori 9.7%	Ehime 5.5%	Kagoshima 3.4%	Ibaraki 2.2%	Shimane 1.7%	Gunma 1.4%	Niigata 13.3%	Osaka 9.4%	Aichi 9.2%	Miyagi 6.4%	Hiroshima 5.9%	Chiba 4.3%	Gifu 3.0%	Nara 2.3%	Aichi 13.0%	Tokyo 11.8%	Osaka 10.7%	Kanagawa 7.8%	Hyogo 6.6%	Chiba 4.9%	Saitama 3.9%	Kyoto 3.7%	Shiga 1.0%	Tokyo 14.7%	Kanagawa 13.3%	Kyoto 8.0%	Tokyo 26.1%	Osaka 19.0%	Kanagawa 10.8%	Hyogo 6.7%	Saitama 4.2%	Kyoto 3.1%
Av. Residents Nb. (diff. other)	1.8 (- 0.9)									2.9 (+ 0.2)		2.9 (+ 0.2)																				2.1 (- 0.6)				
Income (10k yens)	< 250 58.6%		250-500 67.7%		250-500 39.3%		250-500 43.7%		> 500 59.1%		< 250 32.0%		< 250 27.2%																							
Av. Floor Area m <sup>2</sup> (diff. other)	90.1 (- 12.3)						69.7 (- 36.1)						93.4 (- 10.2)									68.1 (- 37.8)														
Constr. Year	< 1981 38.9%				2001-2010 26.9%		1981-1990 25.9%		1996-2000 17.3%		2011-2015 13.7%		< 1970 17.3%																							
Av. Cars Nb. (diff. other)	0.4 (- 0.9)						1.4 (+ 0.1)					1.2 (- 0.1)		0.3 (- 1.0)		0.2 (- 1.2)																				

Cluster	8		9		10		11		12		13																		
Prefecture			Okinawa 23.4%	Fukuoka 11.7%	Ehime 6.9%	Kagawa 5.2%	Okayama 4.2%	Ishikawa 3.8%	Tokushima 3.2%	Fukui 2.6%	Ishikawa 3.8%	Yamaguchi 3.3%	Akita 3.2%	Toyama 3.1%	Shimane 2.3%	Wakayama 1.2%	Miyagi 5.1%	Okayama 4.5%	Iwate 4.0%	Fukushima 4.0%	Kochi 3.3%	Nagano 2.3%	Hokkaido 29.7%	Iwate 4.4%	Toyama 4.2%	Aomori 3.5%	Akita 3.5%	Yamagata 3.0%	Yamanashi 1.6%
Av. Residents Nb. (diff. other)	2.3 (- 0.4)		1.8 (- 0.9)		3.2 (+ 0.6)		3.1 (+ 0.4)				3.0 (+ 0.3)																		
Income (10k yens)	< 250 36.3%		< 250 49.5%		500-2000 61.9%		500-1000 44.2%		250-500 46.2%		250-500 41.2%																		
Av. Floor Area m <sup>2</sup> (diff. other)	90.0 (- 12.4)		54.3 (- 49.0)		126.2 (+ 26.6)		135.3 (+ 35.7)		88.5 (- 14.3)		138.4 (+ 37.9)																		
Constr. Year	2006-2015 37.0%				> 2001 69.3%		2001-2010 31.3%		1991-1995 15.4%		1971-1990 46.8%																		
Av. Cars Nb. (diff. other)	0.6 (- 0.7)		0.3 (- 1.0)		1.7 (+ 0.4)		1.9 (+ 0.6)		1.6 (+ 0.3)		1.9 (+ 0.7)																		

Following are possible interpretations of these results:

- Clusters 1, 2 and 13 tends to be located in northern Japan or cold mountainous regions. Households from these clusters have a higher heating demand due to cold climate and poor isolation resulting in higher gas and kerosene resources consumption which are cheaper than electrical alternatives. The difference between these clusters is typically in there number of residents with impact on the houses size, total income, and number of vehicles.
- Clusters 3 and 9 tends to be located in southern Japan. They consist of small houses with low energy consumption. As this region consists mainly of islands, they do not use city gas. Kerosene is unnecessary because electricity and LP gas are sufficient for heating. Cluster 9 represent individual households and cluster 3 average households with vehicles.
- Clusters 4, 5, 6 and 7 are located in high population density regions. All uses city gas. Clusters 6 and 7 have no vehicles because they live in large cities with high public transportation capacity. They have lower than average

income. Clusters 4 and 5 have higher number of residents and income resulting in higher energy consumption. Clusters 4 and 6 use kerosene.

- Households from clusters 8 and 10 live in recent buildings with all electricity. Cluster 8 has no particular location, few residents, low income and no vehicle. Cluster 10 have several residents, high income, vehicles, and have a statistically significantly higher number of households from Shikoku island and Ishikawa region which could be an indication of recently populated or developed area.
- Cluster 11 tends to be located in regions with very low population density, which might explain the absence of gas consumption due to a lack of supply capacity.
- The interpretation of cluster 12 is still unclear.

As mentioned above, clusters 2, 4 and 12, 13 use the same combination of resources in different quantities. All four clusters use kerosene for room heating and gas for cooking but clusters 4 and 12 use gas for water heating while clusters 2 and 13 use kerosene.

## 6. Summary

We analyzed the status of residential sector demand in Japan by identifying real energy consumption clusters as well as statistically significant characteristics for each in corresponding households' data. We expect these results to support the elaboration of more accurate scenarios analysis based on the prospective persistence, evolution, or disappearance of these clusters considering the complexity of energy systems.

The data set used in this study still represents a negligible part of the residential sector and one cannot exclude the risk of biases in the sampling. An increase in data amount and diversity would be beneficial, particularly for some prefectures represented by very few households.

## References

- [1] T. Nakata; Energy-economic models and the environment, *Progress in Energy and Combustion Science*, 30(2004) 417.
- [2] R. Delage and T. Nakata, Machine learning for modeling energy systems complexity, *Proceedings of ECOS2020*, (2020), 2405.
- [3] C. S. E. Bale, L. Varga, and T. J. Foxon, Energy and complexity: New ways forward, *Applied Energy*, 138(2015), 150.
- [4] E. Calikus, S. Nowaczyk, A. Sant'Anna, H. Gadd, and S. Werner, A data-driven approach for discovering heat load patterns in district heating, *Applied Energy*, 252(2019), 113409.
- [5] 環境省. 家庭部門の CO<sub>2</sub> 排出実態統計調査平成 29 年度  
<http://www.env.go.jp/earth/ondanka/ghg/kateiCO2tokei.html> (Accessed on June 12, 2020).
- [6] L. V. D. Maaten, and G. Hinton; Visualizing Data using t-SNE, *Journal of Machine Learning Research*, 9(2008) 2579.
- [7] D. Kobak, and P. Berens; The art of using t-SNE for single-cell transcriptomics, *Nature Communications*, 10(2019) 5416.
- [8] H. Kuninaka and M. Matsushita, Statistical properties of complex systems -lognormal and related distributions-, *AIP Conference Proceedings*, 1468(2012), 241.
- [9] R. J. G. B. Campello, D. Moulavi, A. Zimek, and J. Sander; Hierarchical Density Estimates for Data Clustering, Visualization, and Outlier Detection, *ACM Transactions on Knowledge Discovery from Data*, 10(2015).

# 家庭 CO2 統計を活用した ZEH と一般住宅の評価

## Evaluation of ZEH and General Housing Using Survey on Carbon Dioxide Emissions from Residential Sector

田中昭雄\*  
Akio Tanaka

Using the individual table data of household CO2 statistics and the ZEH data of 100 households, we considered the difference in energy demand and CO2 emissions between ordinary houses and ZEH using a statistical model. And This study created a statistical model of the self-consumption of solar cell power generation in two types of houses.

**Keywords:** Empirical Bayes, Low Birthrate and Longevity, Small Area Estimation

### 1. はじめに

ネット・ゼロ・エネルギー・ハウス (ZEH) は、徹底的な省エネルギー技術の導入で、住宅内のエネルギー消費量を低く抑えるとともに、エネルギーを自力で創出することで、その収支を相殺する住宅である。政府は地球温暖化ガスの排出量削減が世界的な課題とされるいま、2020年までに標準的な新築住宅で、2030年新築住宅平均で ZEH 実現をめざしている。

本研究は ZEH の運用データ<sup>1)</sup> を分析して、ZEH の脱炭素化効果 (CO2 削減効果) の有無を確認するとともに、「家庭 CO2 統計調査」<sup>2)</sup> と比較することで一般住宅との相違を見る。ZEH は創エネルギーを自家消費する他に、蓄電池導入率の高いこともその特徴の 1 つである。住宅では卒 FIT も課題となっており、自家消費量を高めることは、卒 FIT 対策として有効である。そこで現在の ZEH の再生可能エネルギーの自家消費状況との一般住宅との比較を行うとともに、蓄電池導入が自家消費率にどのように影響しているかについても検討を行う。

なおここで住宅のエネルギー消費量 (原単位) と、太陽電池の自家消費分電力量を含んだ値である。

### 2. 研究手法

#### 2.1 分析対象 ZEH 住宅

ZEH データは (一社) 環境共生イニシアチブが 2018 年 4 月～2019 年 3 月に実施した全国の一戸建て 100 戸の ZEH 運用データおよび、設計データ<sup>1)</sup> である。

#### 2.2 一般住宅

比較対象とする一般住宅としては、環境省「家庭部門の CO2 排出実態統計調査」<sup>2)</sup> データから建物と家族属性が類似する建物を抽出して行う。この抽出はエネルギー消費の階層性<sup>4)</sup> を考慮して世帯人数、住宅面積、都市サイズ (CO2 調査の 3 区分)、省エネ法 8 地域区分、電力会社 (10 地域) を用いて、各 ZEH と「家庭 CO2 統計」の全住宅と比較して、その類似度  $r$  を (1) 式で求め、最も類似する 5 戸を抽出したものである。

$$r = \frac{\mathbf{a} \cdot \mathbf{b}}{|\mathbf{a}| |\mathbf{b}|} \quad (1)$$

$\mathbf{a}$ : ZEH の属性ベクトル

$\mathbf{b}$ : 家庭 CO2 調査の属性ベクトル

#### 2.3 再生可能エネルギー自家消費割合と蓄電池効果

太陽電池発電量の自家消費量については、その状況を統計モデル化し、一般住宅の同統計モデルと比較することで、ZEH を評価する。一般住宅の統計モデルは、2000～2003 年の住宅用太陽電池の運用実績データから求めたモデル<sup>3)</sup> である。

\* 熊本県立大学環境共生学部居住環境学専攻教授  
〒862-8502 熊本県熊本市東区月出 3-1-100  
e-mail: [a-tanaka@pu-kumamoto.ac.jp](mailto:a-tanaka@pu-kumamoto.ac.jp)

### 3. ZEH 住宅の性能

#### 3.1 エネルギー消費原単位（設計値・実績）

表 1 に、検討した ZEH データの概要を示す。住宅の 90 %が省エネルギー法の地域区分 5~7 の温暖地域である。居住者数の平均は 3.6 人で、延床面積は 120.9 m<sup>2</sup>，89%は全電化住宅である。

ZEH には全ての住宅で太陽電池が設置されており、その容量の平均は 6.2 kW で、蓄電池設置率は 15% である。外皮平均熱貫流率 UA 値は 0.49 [W/m<sup>2</sup>・℃] である。2009 年の住宅平均 UA 値は平均 1.58<sup>5)</sup> であるので、ZEH の平均熱貫流量は 2009 年一般住宅の約 30 %と小さく、高断熱であるといえる。

#### 3.2 一般住宅とのエネルギー消費原単位比較

図 1 は、ZEH のエネルギー原単位の基準値と設計値、実績と一般住宅（CO<sub>2</sub> 統計）実績である。ZEH のエネルギー原単位の運用実績値は 6,052 kWh/年（自家消費分含む）で、一般住宅の 11,097 kWh/年よりも 45%小さい。ZEH の原単位設計値は 4,183 kWh なので、実績は設計値より 40%大きいことになる。これは設計時の居住者の生活パターンと実生活パターンが異なることも原因の 1 つと考えられる。しかし売電平均は 6,085 kWh なのでトータルでは ZEH を実現している。

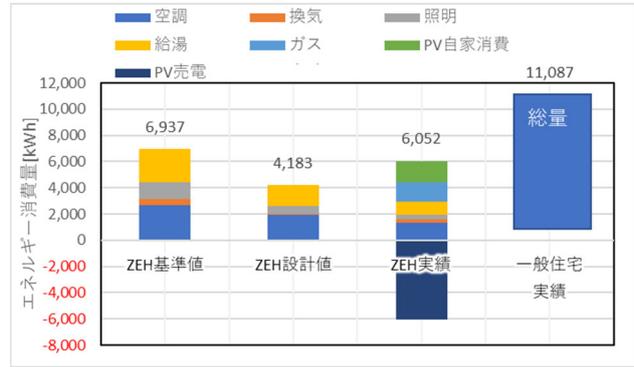


図 1. ZEH と一般住宅のエネルギー原単位

図 2 に、ZEH 個別に対応する一般住宅のエネルギー需要と ZEH の売電量を示す。図のゼロラインと、その上の破斜線に囲まれた三角形の範囲内の■マークが、NearlyZEH ゾーンの ZEH、ゼロラインの下の■マークが Net ゼロを実現した ZEH で 93%の住宅が Net ゼロを実現している。

### 3.3 太陽電池発電量の自家消費量と蓄電池の影響

#### 3.3.1 一般住宅の自家消費量モデル

式 (2) に、一般住宅の太陽電池発電分の自家消費量予測式<sup>3)</sup>を示す。この値は 2000 年~2003 年の首都圏、広島県、九州の住宅の太陽電池の運用実績データから求めた統計モデルでありモデル作成に用いたデータについては R<sup>2</sup>=0.95 と高い再現性があった。このモデルでは太陽電池の容量により別々の係数を用いる事で、モデル精度の向上につなげている。

表 1. ZEH データ概要

地域区分 (省エネ法)	n数	平均世帯 人数 [人]	平均延床 面積 [m <sup>2</sup> ]	太陽電池 [kW]	蓄電池		外皮平均熱貫流率 UA*[W/m <sup>2</sup> ・℃]	
					設置率	平均容量 [kWh]	*1	*2
3	1	4.0	121.8	5.25	0%	0	0.34	1.00
4	8	2.9	114.8	5.89	25%	4.9	0.43	1.40
5	20	3.3	122.6	6.34	15%	6.8	0.48	1.60
6	54	3.7	123.0	6.53	19%	5.7	0.51	1.60
7	17	3.9	115.2	5.29	0%	0	0.48	1.60
平均/計	100	3.6	120.9	6.2	15%	—	0.49	1.58

\*1 今回分析ZEH設計値平均

\*2 2009年時点住宅のUA値換算：(榎田,2017)<sup>5)</sup>

$$PV_{SG} = k_E E_p + k_G PV_{all} \quad (2)$$

$PV_{SG}$  : 一般住宅自家消費電力量  
[kWh/年]

$E_p$  : 住宅総電力需要[kWh/年]

$PV_{all}$  : 太陽電池発電量 [kWh/年]

$k_E$  : 係数 1 (表 2)

$k_G$  : 係数 2 (表 2)

表 2. 一般住宅 発電自家消費量予測式係数<sup>3)</sup>

係数	太陽電池容量 [kWp]		
	0.5~2	2~5	5~12
$k_E$	0.041	0.132	0.205
$k_G$	0.467	0.166	0.055
$R^2$	0.947	0.949	0.951

### 3.3.2 ZEHの自家消費量モデルと蓄電池の効果

図 3 の ZEH のエネルギー消費原単位と自家消費量の関係を示す。この自家消費量については実績データから式 (3) の統計モデルを作成した。

$$PV_s = 0.282E_p + 0.027PV_{all} + 74.0 \quad (3)$$

$(R^2=0.61)$

$PV_s$  : ZEH 自家消費電力量 [kWh/年]

$E_p$  : 住宅総電力需要[kWh/年]

$PV_{all}$  : 太陽電池発電量 [kWh/年]

回帰分析では、蓄電池の容量と自家消費量には有意な相関性は確認できなかった。

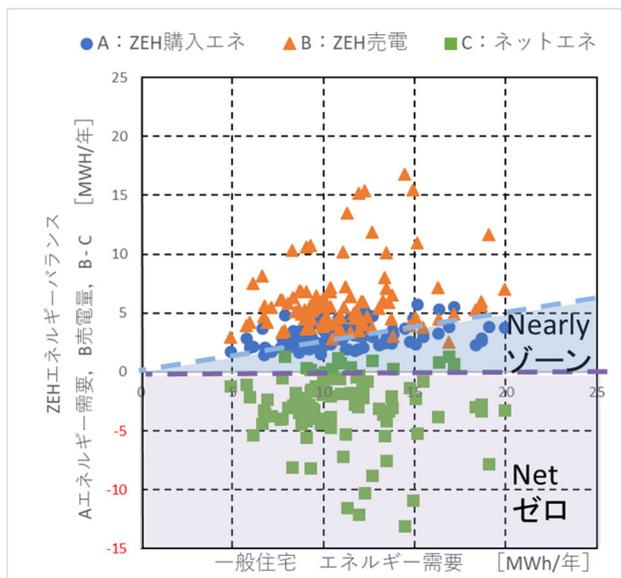


図 2. 一般住宅から見た ZEH の NET ゼロエネルギー実現状況

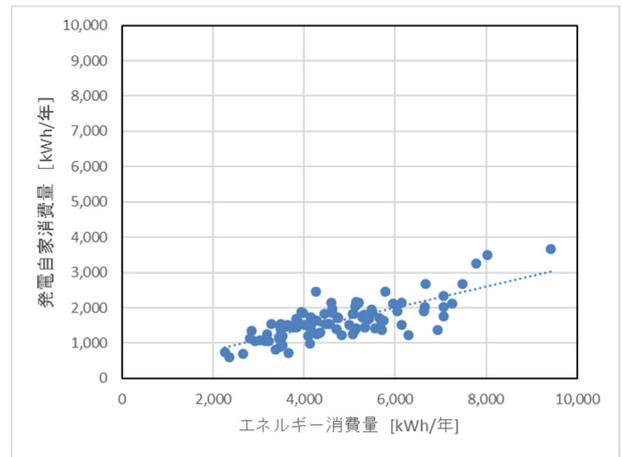


図 3. ZEH の年間エネルギー消費原単位と自家消費電力量

### 3.3.3 2モデルの比較

図 4 に ZEH の自家消費量実績 (●) と, (3) 式による予測値 (▲), (2) 式による予測値 (◆) を示し ZEH と一般住宅での自家消費構造の相違を検討する。一般住宅の予測式 (2) 式では, ZEH 住宅の自家消費量を 10~30% 程度小さめに予測する事があるが, 全体としては (3) 式が (2) 式に比べて飛躍的に精度が高いわけではなく, ZEH の自家消費率が高いというわけではない。

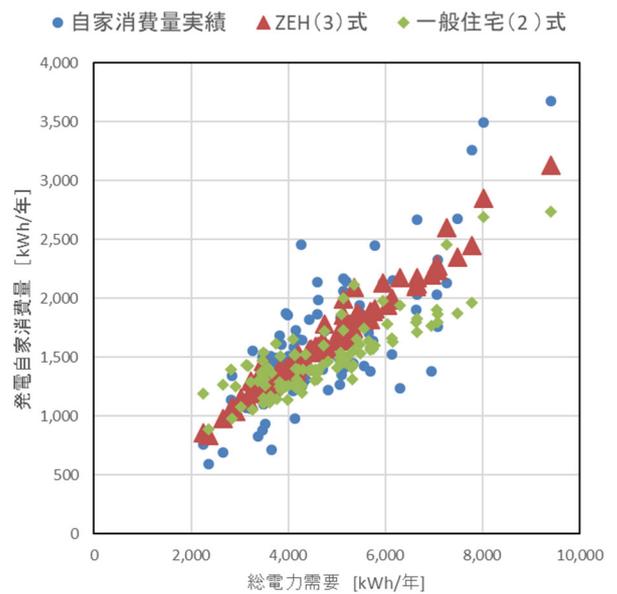


図 4. 自家消費量予測モデル比較

#### 4. まとめ

ZEH の運用データ<sup>1)</sup> を分析して、ZEH の脱炭素化効果 (CO<sub>2</sub> 削減効果) の有無を確認するとともに、「家庭 CO<sub>2</sub> 統計調査」<sup>2)</sup> と比較することで、ZEH が一般住宅に比較して、低いエネルギー消費量であることを確認した。

また ZEH の蓄電池導入率は 15% であるが、太陽電池発電電力の自家消費率の向上に寄与していないことが確認された。

#### 謝辞

本研究実施に当たり、貴重な情報を提供いただいた環境省地球環境局総務課低炭素社会推進室様、家庭部門の CO<sub>2</sub> 排出実態統計調査利用研究会事務局の運営にご尽力いただいた一般社団法人 エネルギー・資源学会様に、謝意を申し上げます。

#### 参考文献

- 1) (一社) 環境共創イニシアチブ; 経済産業省および環境省による戸建 ZEH 補助事業 <https://sii.or.jp/zeh02/> (アクセス日 2020. 11. 16)
- 2) 環境省 CO<sub>2</sub> 統計
- 3) 田中昭雄, 石原修; 住宅用太陽エネルギー利用設備の省エネルギー効果に関する研究, 太陽エネルギー, 41-6 (2015), 41-48.
- 4) 田中昭雄; 単身・高齢者世帯地域別 CO<sub>2</sub> 排出原単位の経験ベイズ推定, 第 39 回エネルギー資源学会研究発表会講演論文集, pp. 354-359, 2020. 7
- 5) 榎田拓人; 住宅のエネルギー需要の地域性とゼロエネルギー住宅実現手法の研究, 熊本県立大学卒業論文, 2017. 3

# 家庭部門の CO<sub>2</sub> 排出実態統計調査の個票データに基づく 地域別，エネルギー構成別，所得階層別の エネルギー源別価格と支出の分析

Analysis of Energy Prices and Expenditures by Region, Energy Composition, and  
Income Level Based on the Individual Data from the Household CO<sub>2</sub> Emission Survey

星野 優子 \*・小川 順子 \*\*  
Yuko Hoshino Junko Ogawa

This study focuses on household energy expenditure and prices, and clarifies the characteristics of household CO<sub>2</sub> emissions by region, energy composition pattern, and income class, based on the statistics of the Ministry of the Environment's survey of household CO<sub>2</sub> emissions.

It was confirmed that lower income households in northern Japan have a greater burden on energy expenditure. In addition, the impact of energy price changes on demand is more limited for households in lower income and in northern Japan, indicating that the burden of energy expenditure due to higher energy prices is likely to increase. We analyzed the likelihood of an energy shift in the household sector, which is expected to reduce CO<sub>2</sub> emissions. The results show that substitution between electricity and non-electricity energy is more likely to occur in northern Japan and less likely to occur in western Japan. However, in northern Japan, the share of energy expenditure in the household budget is larger than in other regions, so encouraging electricity shifts through price effects could be a significant burden, especially for low-income households.

**Keywords** : Household Energy Demand, Price Elasticity, Survey Data

## 1. はじめに

地球温暖化防止の観点から，家庭部門においても省エネや CO<sub>2</sub> 排出量の削減の取り組みが求められている．その手段として，カーボンプライシングなどの価格上昇による省エネや燃料転換の効果を狙う方法が検討されている．一方，エネルギーの持つ必需性から，その価格上昇による影響については，省エネ効果だけでなく，家庭のエネルギー支出という負担面についても考慮していく必要がある．

家庭のエネルギー需要に対する価格変化の影響については既に多くの先行研究があるが，居住地の気候（必要なエネルギー量），エネルギーの使い方（使用するエネルギー源／機器），家計収入といった家庭の属性別の分析から得られる示唆は大きい．エネルギー支出が家計に与える影響を考えるためにも，家庭の属性による違いに着目することが重要になる．

文献<sup>[1][2]</sup>においても，家庭のエネルギー需要の価格弾力性に関して，家計の属性の違いを考慮する必要性を指摘している．地域特性に着目した分析として，例えば米国の家



データ出所：環境省「家庭の CO<sub>2</sub> 実態調査」<sup>[7]</sup>  
図出所：文献<sup>[8]</sup>より引用

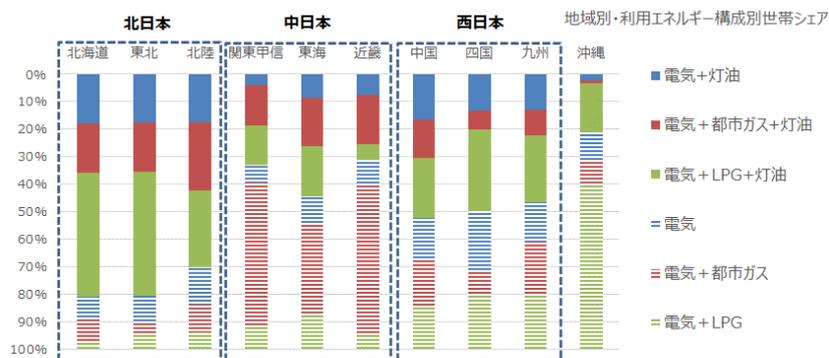
図 1 調査世帯の都道府県別世帯数(単位:世帯)

庭部門エネルギーを分析対象とした文献<sup>[3]</sup>では，エアコンを多用する南部の地域では，より価格変化に対する需要が弾力的であるという結果を得ている．日本に関しては，家計調査のデータから電力需要の価格弾力性を 9 地域別に推定し，東日本大震災の影響を分析した文献<sup>[4]</sup>がある．また，文献<sup>[5]</sup>では，家計調査の時系列データから，所得階層別の価格弾力性を推定し，所得が低いほど価格弾力性が低く，エネルギー価格上昇の影響を受けやすい可能性があることを指摘している．個票データを用いた分析として，文献<sup>[6]</sup>では，全国消費実態調査の 2 回分のプーリングデータを用いて，エネルギーを含む家計の費目別消費についての線形支出体系のモデルを推定している．その結果，家計の効用

\*ENEOS 株式会社中央技術研究所技術戦略室  
〒100-0003 東京都千代田区大手町 1-1-2

E-mail: hoshino.yuko@eneos.com

\*\*一般財団法人日本エネルギー経済研究所地球環境ユニット  
〒104-0054 東京都中央区勝どき 1-13-1 イヌイビル・カトドキ



出所：「家庭のCO<sub>2</sub>排出実態調査」より著者ら作図

図2 地域別にみた利用エネルギー構成別の世帯数シェア

水準に対しては、寒冷地の戸建て世帯では電気の省エネ、寒冷地の戸建て以外の住宅では電気以外の省エネの影響が大きいことを確認している。この結果については、戸建住宅、集合住宅の違いだけでなく、利用しているエネルギー種別や世帯収入といった違いが影響する可能性も考えられる。

家庭の属性別の分析においては、属性と紐づいたエネルギー消費に関する個票データは貴重な情報源となるものの、日本では、家庭のエネルギー消費に関する包括的、継続的な統計調査は十分には行われてこなかった。こうした状況のなかで2017年度から環境省の家庭部門のCO<sub>2</sub>排出実態統計調査<sup>[7]</sup>（以下では「家庭のCO<sub>2</sub>排出実態調査」）が開始された。図1は、同調査の2017年版の個票データの都道府県別世帯数である。本研究では、2017年度の「家庭のCO<sub>2</sub>排出実態調査」の個票データから、自動車用燃料を除く家庭内のエネルギー消費を対象に、世帯属性別に家庭のエネルギー源別需要と支出の特徴を分析する。

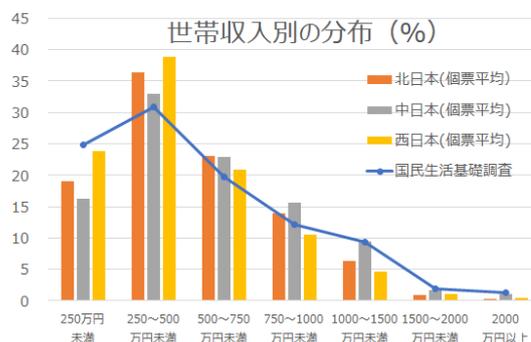
以下では、2節において個票データを地域別、エネルギー構成別、所得階層に整理し、それぞれの特徴点を明らかにする。次に3節では、2節で明らかになった特徴的なセグメントに絞って、エネルギー価格が必要に与える影響を明らかにする。

## 2. 家庭用CO<sub>2</sub>調査の個票データの整理

### 2.1 地域別、エネルギー構成別の特徴

家庭のCO<sub>2</sub>排出実態調査では、家庭内でのエネルギー消費について、電気、都市ガス、LPG、灯油を対象に調査している。全9505世帯のうち、電気は全世帯で利用していることから、利用エネルギー構成については、「電気+灯油」、「電気+都市ガス+灯油」、「電気+LPG+灯油」、「電気」、「電気+都市ガス」、「電気+LPG」の6タイプに分けることができる。

図2は、地域別に利用エネルギー構成別の世帯数のシェアをみたものである。北海道、東北、北陸では、灯油を使



出所：「家庭のCO<sub>2</sub>排出実態調査」、「国民生活基礎調査2017年度」<sup>[9]</sup>より著者ら作図

図3 地域別個票データに関する世帯の所得階層別分布

表1 地域別・エネルギー構成別・所得階層別世帯数 (単位:世帯)

		電気+灯油	電気+都市ガス+灯油	電気+LPG+灯油	電気	電気+都市ガス	電気+LPG
北日本	250万円未満	67	98	243	26	32	23
	250~500万円未満	138	227	385	74	59	48
	500~750万円未満	121	105	206	77	51	32
	750~1000万円未満	90	53	111	56	32	14
	1000~1500万円未満	31	29	56	27	16	2
	1500万円以上または不明	10	12	25	8	5	3
	合計	457	524	1026	268	195	122
中日本	250万円未満	33	101	82	34	286	63
	250~500万円未満	62	223	199	82	533	111
	500~750万円未満	56	139	86	82	396	85
	750~1000万円未満	40	79	60	58	293	42
	1000~1500万円未満	30	55	33	35	176	16
	1500万円以上または不明	10	16	10	17	72	5
	合計	231	613	470	308	1756	322
西日本	250万円未満	74	70	194	58	98	259
	250~500万円未満	145	108	323	161	168	324
	500~750万円未満	84	48	140	140	95	154
	750~1000万円未満	51	25	55	81	50	70
	1000~1500万円未満	21	13	26	42	26	19
	1500万円以上または不明	6	3	24	18	16	24
	合計	381	267	762	500	453	850

出所：「家庭のCO<sub>2</sub>排出実態調査」より著者ら作図

用している世帯が7~8割を占めており、他の地域とは大きく異なる特徴がみられる。これに対して、関東甲信、東海、近畿地方では、灯油を利用している世帯は3~4割強にとどまる。また電気と都市ガス利用世帯が3~5割と大きなシェアを占めていることも特徴である。中国、四国、九州では、

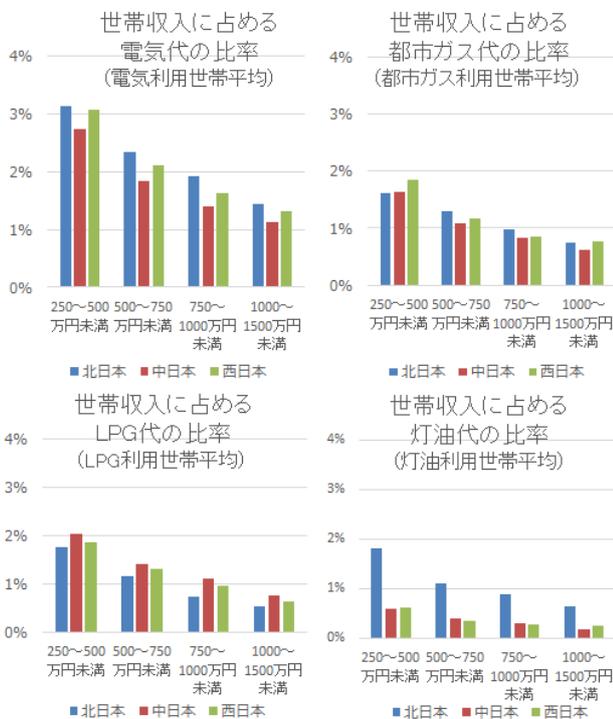
灯油を利用している世帯は約半分と「北日本」、「中日本」と比べて利用エネルギー構成の偏りは少ないことが特徴である。

本研究では、エネルギー構成の近い地域をまとめて分析するために、北海道、東北、北陸をあわせて「北日本」、関東甲信、東海、近畿を合わせて「中日本」、中国、四国、九州をあわせて「西日本」とする。沖縄については、かなり異なる特徴を持つことから、他に含めず、地域別の分析対象とはしない。

## 2.2 所得階層別の特徴

図3は、3地域別の所得階層別に、個票データの世帯分布を比較したものである。3地域とも、年収250～500万円の世帯が最も多い。また、北日本、西日本ではより低収入の世帯の割合が高く、中日本ではより高収入の世帯の割合が高いことを確認できる。世帯分布について、家庭のCO<sub>2</sub>排出実態調査と厚生省の国民生活基礎調査を比較すると、年収250万円未満の世帯の割合が低めで、代わりに年収250万円～500万円未満の世帯の割合が高めであるが、それ以外は概ね似通っていることが確認できる。

表1では、3地域別、6つの利用エネルギー構成ごとに、所得階層別の世帯数の分布を整理している。利用エネルギーの構成は、所得階層別にみても概ね図2で確認した特徴



出所：「家庭のCO<sub>2</sub>排出実態調査」より著者ら作成  
注：分母にあたる世帯収入については、それぞれの所得階層の所得の下限と上限の中央値を用いた

図4 地域別・所得階層別にみた収入に占めるエネルギー支出シェア

を保持していることが確認できる。

家計に占めるエネルギー支払の負担感をみるために、エネルギー源別に、世帯収入に対する、エネルギーの支払い額のシェアを所得階層別・地域別に比較したのが図4である。それぞれ、当該エネルギーを利用している世帯について世帯収入当たりの平均の支払いシェアを示している。家庭のCO<sub>2</sub>排出実態調査では、世帯収入について、該当する所得階層区分を質問していることから、ここでは、それぞれの所得階層の下限と上限の中央値を用いた。

エネルギー別では、電気代の支払いシェアが最も高く、世帯収入が250～500万円未満の世帯では、収入の約3%が電気代の支払いに充てられていることがわかる。一方、都市ガス、LPGは、ほぼ同程度の負担感になっている。地域別にみると暖房需要の大きな北日本で、灯油代の支払いシェアが特に高くなっており、世帯収入が250～500万円未満の世帯では、収入の約2%弱が、灯油代の支払いに充てられていることがわかる。世帯収入別にみると、いずれのエネルギーについても、収入の少ない世帯でよりエネルギー支出シェアが高く、光熱費支払いの負担感が大きいと考えられる。

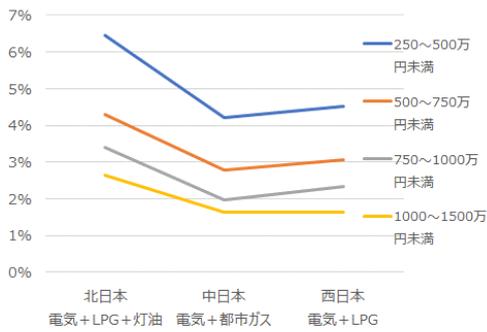
表2 地域別・利用エネルギー構成別・所得階層別の収入に占めるエネルギー支出シェア

		電気+灯油	電気+都市ガス+灯油	電気+LPG+灯油	電気	電気+都市ガス	電気+LPG
北日本	250～500万円未満	5.8%	5.8%	6.5%	5.3%	4.8%	4.7%
	500～750万円未満	4.1%	4.1%	4.3%	3.5%	3.3%	3.4%
	750～1000万円未満	2.9%	3.2%	3.4%	2.9%	2.7%	2.1%
	1000～1500万円未満	2.3%	0.0%	2.7%	2.1%	1.8%	1.7%
中日本	250～500万円未満	5.0%	4.6%	5.2%	4.3%	4.2%	4.7%
	500～750万円未満	2.7%	3.0%	4.0%	2.5%	2.8%	3.1%
	750～1000万円未満	2.2%	2.6%	2.9%	1.8%	2.0%	2.9%
	1000～1500万円未満	1.8%	1.8%	2.0%	1.6%	1.6%	1.9%
西日本	250～500万円未満	4.3%	5.2%	5.5%	4.1%	4.4%	4.5%
	500～750万円未満	2.9%	3.2%	3.9%	2.5%	2.9%	3.1%
	750～1000万円未満	2.2%	2.5%	3.1%	1.9%	2.1%	2.3%
	1000～1500万円未満	1.6%	2.2%	2.3%	1.6%	1.8%	1.6%

出所：「家庭のCO<sub>2</sub>排出実態調査」より著者ら作成  
注：分母にあたる世帯収入については、それぞれの所得階層の所得の下限と上限の中央値を用いた

表2では、同じく地域別・所得階層別の世帯収入に占めるエネルギー支払いシェアを、利用エネルギー構成別に比較している。各セグメントの平均収入については、図4と同様にそれぞれの所得階層の下限と上限の中央値を用いた。なおサンプル数の少ない年収1500万以上の世帯と、中央値で代表することができない250万円未満の世帯は集計から除いている。

図5は、表1で確認した各地域で最も該当世帯が多い典型的なエネルギー構成を持つ世帯を対象に、所得階層別に収入に占めるエネルギー支出のシェアを比較している。いずれの地域においても、収入が少ない世帯ほど世帯収入に



出所：「家庭のCO<sub>2</sub>排出実態調査」より著者ら作成  
**図5 各地域の代表的セグメント  
 収入に占めるエネルギー支出シェア**

占めるエネルギー支出の割合が高くなることを確認できる。これは、総務省の家計調査報告のデータから所得階層とエネルギー支出が家計支出に占める比率の関係についてみた文献<sup>[5]</sup>の結果とも整合的である。

地域別にみると、特に北日本では収入に占めるエネルギー支出シェアが大きく、北日本の世帯年収250万円～500万円の「電気+LPG+灯油」利用世帯の支出シェアは6.5%と、中日本の世帯年収1000万円～1500万円の「電気+都市ガス」利用世帯あるいは西日本の世帯年収1000万円～1500万円の「電気+LPG」利用世帯の支出シェア1.6%の4倍にもなる。このように地域や所得階層によって、収入に占めるエネルギー支出のシェアには大きな差があり、特に北日本の収入の少ない世帯においては、エネルギー支出の負担感が大きいことがわかる。

### 3. エネルギー価格が需要やエネルギー選択に与える影響

ここまでは、世帯の個票データから地域別、利用するエネルギー構成別、所得階層別の特徴点を明らかにした。「家庭のCO<sub>2</sub>排出実態調査」では、各世帯のエネルギー源別の支出額、エネルギー消費量のデータがあることから、支出額を消費量で除すことで、各エネルギーの需要端の平均単価を求めることができる。これ以降は、エネルギー価格が、エネルギー需要やエネルギー選択にどのような影響を与えるのかを分析する。

#### 3.1 集計エネルギー価格の変化によるエネルギー需要への影響

##### 3.1.1 分析モデル

世帯当たりのエネルギー需要の合計CEについて、文献<sup>[10]</sup>より、集計エネルギー価格PEと世帯収入Yに回帰するモデルを(1)式に示す。ここで*i*は、利用するエネルギー種別を示す。

$$\ln CE = \alpha + \beta \ln PE + \gamma \ln Y \quad (1)$$

$$CE = \sum CE_i$$

$$PE = \sum PE_i \cdot \frac{PE_i \cdot CE_i}{\sum PE_i \cdot CE_i}$$

(1)式を最小二乗法で推定する。価格弾力性は $\beta$ 、所得弾力性は $\gamma$ で得られる。

#### 3.1.2 分析結果

表3は、表1で確認した各地域で最も該当世帯が多い典型的なエネルギー利用の組み合わせの世帯を対象に、(1)式で示すモデルの推定結果を示したものである。価格弾力性に相当する係数 $\beta$ を見ると、西日本で-1.560と最も大きく、中日本、北日本と続く。先に見たように北日本は、3地域の中で世帯収入に占めるエネルギー支出のシェアが最も高いものの、エネルギー価格変化がエネルギー需要に与える影響を示す価格弾力性は3地域の中では相対的に小さいことが確認できる。このことから、北日本においては、エネルギー価格が上昇しても需要が減少しにくいいため、世帯収入

**表3 各地域の典型的な利用エネルギー構成世帯におけるエネルギー需要関数の推定結果**

	北日本	中日本	西日本
$\alpha$	2.364**	1.197**	1.776**
$\beta$	-1.074**	-1.497**	-1.508**
$\gamma$	0.196**	0.224**	0.156**
サンプル数	1008	1741	832
決定係数	0.376	0.284	0.578
D.W.	1.572	1.768	1.939

注：\*\*は片側5%で有意であることを示す。ここで各地域の典型的な利用エネルギー構成とは、北日本は「電気+LPG+灯油」、中日本は「電気+都市ガス」、西日本は「電気+LPG」。

**表4 各地域の典型的な利用エネルギー構成世帯における所得階層別のエネルギー消費関数の推定結果**

	$\alpha$	$\beta$	サンプル数	決定係数	D.W.	
北日本	250万円未満	3.347**	-0.919**	243	0.242	1.421
	250～500万円未満	3.524**	-1.066**	385	0.292	1.576
	500～750万円未満	3.499**	-1.374**	206	0.352	1.714
	750～1000万円未満	3.692**	-1.121**	111	0.235	1.613
	1000～1500万円未満	3.719**	-1.196**	56	0.205	1.453
中日本	250万円未満	2.450**	-1.183**	286	0.127	1.624
	250～500万円未満	2.348**	-1.821**	533	0.244	1.745
	500～750万円未満	2.683**	-1.416**	396	0.162	1.978
	750～1000万円未満	2.437**	-1.871**	293	0.264	1.575
	1000～1500万円未満	3.058**	-1.100**	176	0.085	1.893
西日本	250万円未満	2.554**	-1.366**	259	0.502	2.042
	250～500万円未満	2.685**	-1.533**	324	0.552	1.834
	500～750万円未満	2.695**	-1.830**	154	0.572	1.804
	750～1000万円未満	2.794**	-1.582**	70	0.470	1.829
	1000～1500万円未満	2.740**	-1.820**	19	0.675	2.124

注：\*\*は片側5%で有意であることを示す

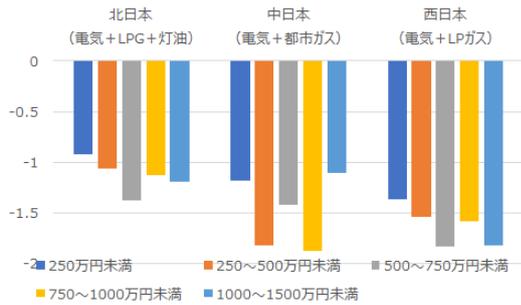


図6 各地域の典型的な利用エネルギー構成の世帯における所得階層別のエネルギー消費関数の推定結果 (表4のβ値の比較)

に占めるエネルギー支出シェアが高くなりやすく、家計の負担感がより大きくなる可能性があることを示している。

次に表4, 図6は(1)式において所得項 $\ln Y$ を落としたモデルを用いて、所得階層別に分けて推定した結果である。各地域において、価格弾力性に相当する係数 $\beta$ を所得階層別に比較すると、概ね収入が少ないほど $\beta$ が小さい傾向が読み取れる。収入が少ない世帯では、エネルギー価格が上昇しても、より省エネ型のエネルギー設備への転換・買換などが進みにくく価格上昇への対応が十分にできないことが理由として考えられる。この結果は、先行研究<sup>[5]</sup>の結果とも整合的である。このように収入の少ない世帯では、エネルギー価格が上昇しても需要が減少しにくく、世帯収入に占めるエネルギー支出シェアが高くなりやすいため、家計の負担感がより大きくなる可能性があることを示唆している。

ここまで、集計レベルのエネルギー需要全体を対象に分析してきたが、続いて個別エネルギーについて価格変化の影響をみていきたい。家庭におけるCO<sub>2</sub>排出量削減手段の一つとして、エネルギーの電力シフトの重要性が指摘されていることから、以下では、地域別に、電力と電力以外のエネルギーとの代替弾力性について分析する。

### 3.2 電力と電力以外のエネルギーとの代替弾力性

#### 3.2.1 分析モデル

家計のエネルギー投入(消費)を以下のように、エネルギー支出予算制約 $Y$ の下での家庭部門のエネルギー投入における費用最小化問題と考える。ここで、エネルギー投入を電力と電力以外に分け、電力投入を $E$ 、電力以外のエネルギー投入を $G$ 、電力価格を $P_E$ 、電力以外のエネルギーの平均価格を $P_G$ とする。

$$\min CE = P_E \cdot E + P_G \cdot G \quad \text{subject to } Y = f(E, G) \quad (2)$$

ここで費用最小化の条件から、要素間の限界代替率は要

素価格の比に等しくなることから、

$$\frac{\partial F(E, G)/\partial E}{\partial F(E, G)/\partial G} = \frac{P_E}{P_G} \quad (3)$$

ここで電力とそれ以外のエネルギーの要素需要関数はそれぞれ、要素価格の関数として以下のようにあらわすことができる。

$$E^* = E \left( \frac{P_E}{P_G} \right), \quad G^* = G \left( \frac{P_E}{P_G} \right) \quad (4)$$

このとき電力とそれ以外のエネルギー間(要素需要間)の代替弾力性 $\varepsilon$ は、(5)式で求められる。ここで $\varepsilon$ は、要素価格の比 $\frac{P_G}{P_E}$ が、1%上昇したときに要素投入の比 $\frac{E}{G}$ が何%変化するかを示す。

$$\varepsilon = \frac{\frac{d \left( \frac{G}{E^*} \right)}{\frac{G}{E^*}}}{\frac{d \left( \frac{P_G}{P_E} \right)}{\frac{P_G}{P_E}}} = - \frac{d \ln \left( \frac{G^*}{P^*} \right)}{d \ln \left( \frac{P^G}{P^E} \right)} = \frac{d \ln \left( \frac{E^*}{G^*} \right)}{d \ln \left( \frac{P^G}{P^E} \right)} \quad (5)$$

以下で、以下の(6)式を最小二乗法で推定し、 $\varepsilon$ を求める。

$$\ln \left( \frac{E}{G} \right) = \varepsilon \cdot \ln \left( \frac{P^G}{P^E} \right) \quad (6)$$

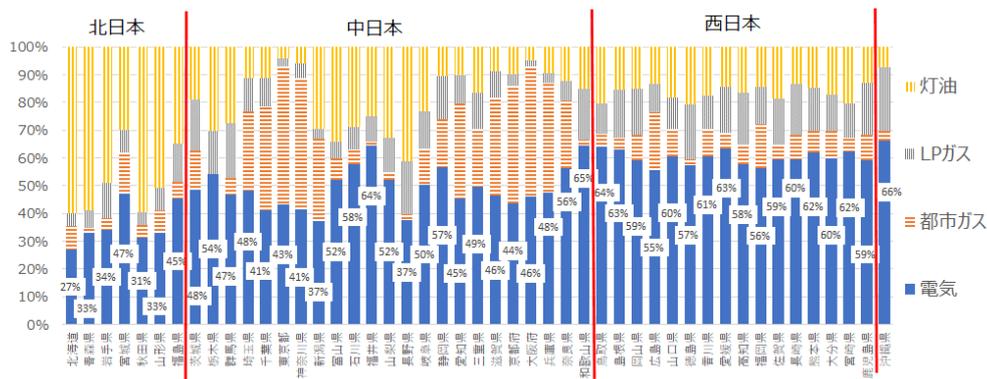
#### 3.2.2 分析結果

表5は、全国、北日本、中日本、西日本別に、(6)式の $\varepsilon$ を推定した結果である。 $\varepsilon$ は全ての地域について統計的に有意なパラメータが推定されている。ここでは、電力と電力以外のエネルギーの代替弾力性を分析することから、使用エネルギーが電力のみのオール電化世帯は、サンプルから除外している。 $\varepsilon$ は、前節でみたように、電力以外のエネルギーの平均価格に対する電力価格の比が1%上昇したときに、電力需要に対する電力以外のエネルギー需要が何%増

表5 電力と電力以外のエネルギーとの代替弾力性

	全国	北日本	中日本	西日本
$\varepsilon$	0.569**	0.974**	0.471**	0.115**
サンプル数	7862	1586	4138	2146
決定係数	0.182	0.118	0.182	0.047
D.W.	1.644	1.756	1.784	1.939

注: \*\*は片側5%で有意であることを示す。電力と電力以外の代替を分析したいことから、使用エネルギーが電力のみの世帯はサンプルには含めていない



出所：「家庭のCO<sub>2</sub>排出実態調査」より著者ら作成

図7 都道府県別にみたエネルギー源別の家庭のエネルギー需要量の構成

加するかを示した値である。なお定義から、この代替弾性は、電力から電力以外への代替弾性と、電力以外から電力への代替弾性は対称になることに注意が必要である。

表5から、全国では、 $\epsilon$ は0.569であるのに対し、北日本は0.974と大きい。北日本では、電力とそれ以外のエネルギーとの代替が、全国平均よりも起こりやすいことを示している。

図7は、都道府県別にみたエネルギー源別の家庭のエネルギー需要構成である。ここで北日本地域における電力のシェアを見ると、最も低いのは北海道の27%で、最も高い宮城県も47%といずれも50%以下である。これに対して、西日本では、電力のシェアは最も低い広島県でも55%、最も高い鳥取県は64%といずれも6割前後と高い。また中日本では、新潟県、長野県の37%から和歌山県の65%まで比較的ばらつきがあるものの、北日本よりは高く、西日本よりは低い傾向にあることが確認できる。

このことを、表5の $\epsilon$ で示される電力と電力以外のエネルギーとの代替弾性とあわせて比較すると、電力のシェアが低い北日本では、相対価格の変化による代替が起こりやすく、シェアが高い西日本では、相対価格が変化しても代替が起こりにくいことがわかる。北日本では、暖房用のエネルギーとして灯油やガスなど電力以外のエネルギーが多く使われており、また暖房用のエネルギー支出の家計負担が大きいことから、電力との相対価格変化に応じて、エネルギーの柔軟な使い分けがされていると考えられる。

これに対して西日本では、暖房用のエネルギー需要は相対的に少ないことから、エネルギー需要に占める電力の比率が高く、相対価格の変化によっても、灯油やガスなど電力以外のエネルギーとの比率は変わりにくいと考えられる。すなわち料金が上がっても他のエネルギーにスイッチしにくいことから、特に低所得世帯では、家計への負担が重くなることを意味している。

北日本では、他の地域に比べて電力とそれ以外のエネルギー

は相対価格変化の影響を比較的受けやすいものの、2節でみたように、他の地域に比べて家計に占めるエネルギー支出のシェアが大きいことから、価格効果による電力シフトを促すことは、特に収入の少ない世帯には大きな負担になることに注意が必要である。

#### 4. おわりに

本研究で使用した、「家庭のCO<sub>2</sub>排出実態調査」は、家庭の属性と紐づいたエネルギー消費に関する個票データとして貴重な情報源である。本研究では、家庭のエネルギー支出と価格に着目し、地域別、エネルギー構成別、所得階層別の特徴点を明らかにした。

その結果、所得階層では収入が少ない世帯ほど、地域別では北日本において、よりエネルギー支出の負担感が大きいことを確認した。また、エネルギー価格変化が需要に与える影響においても、所得階層では収入の少ない世帯ほど、地域別では北日本において、エネルギー価格の変化が需要に与える影響が限定的であり、このためエネルギー価格上昇によるエネルギー支出の負担感が増加しやすいことがわかった。最後に家庭部門のCO<sub>2</sub>削減策として期待されるエネルギーにおける電力シフトの起こりやすさについて、地域別に電力と電力以外との代替弾性を推定した。その結果、北日本では代替が起こりやすく、西日本では起こりにくいことが分かった。しかし北日本では、他の地域と比べて家計におけるエネルギー支出のシェアが大きいことから、価格効果による電力シフトを促すことは、特に低所得世帯には大きな負担になる可能性がある。家庭におけるCO<sub>2</sub>削減策の検討にあたっては、家計負担に与える影響やエネルギー利用の地域的特性を考慮することが重要である。

#### 謝辞

本研究は、環境省が実施する一般統計調査である「家庭部門のCO<sub>2</sub>排出実態統計調査」及び「家庭からの二酸化炭

素排出量の推計に係る実態調査「全国試験調査」の調査票情報を用いて実施しました。関係者の皆様に感謝申し上げます。

### 参考文献

- 1) Frondel, Manuel, Gerhard Kussel, Stephan Sommer, Heterogeneity in the price response of residential electricity demand: A dynamic approach for Germany, *Resource and Energy Economics*, Vol.57(2019), pp119-134,
- 2) Chindarkar, Namratam, Nihit Goyal, One price doesn't fit all: An examination of heterogeneity price elasticity of residential electricity in India, *Energy Economics*, Vol.81(2019). pp765-778
- 3) Bernstein, M.A, J.Griffin, Regional Differences in the Price-Elasticity of Demand for Energy, National Renewable Energy Laboratory, SR-620-39512(2006)
- 4) Tanishita, Masayoshi, Price Elasticity of Residential Electricity Demand by Region in Japan: Have They Changes Since the Great East Japan Earthquake?, *JSER Vol. 40, No.5, 2019*
- 5) 星野優子,小川順子; 家計消費支出からみたエネルギー価格変化の影響, 第37回エネルギー・資源学会エネルギーシステム・経済・環境コンファレンス講演論文集(2020)
- 6) 中野諭, 鷺津明由; 食とエネルギーのスマート化が必要に与える影響評価のためのデータベース作成—『全国消費実態調査』のマイクロデータに基づく分析—, 早稲田大学先端社会科学研究所ワーキングペーパー-IASS WP 2016-J002(2016)
- 7) 環境省; 家庭部門の CO<sub>2</sub> 排出実態統計調査 平成 29 年度版 (2019)
- 8) 星野優子,森田圭; 人口減少に着目した家庭の自家用車による輸送需要の将来推計, 第39回エネルギー・資源学会研究報告会講演集(2020)
- 9) 厚生省; 『国民生活基本調査』(2017)
- 10) Nordhaus, William D; *International Studies in the Demand for Energy*, editor with contribution, North-Holland Publishing Company(1977)

# 家庭 CO<sub>2</sub> 統計の個票データを用いた光熱費の実態把握

## Understanding the Actual Status of the Energy Expenditures using Micro Data of Survey on Carbon Dioxide Emissions from Residential Sector

西尾 健一郎 \*

Ken-ichiro Nishio

This study analyzed the factors causing the difference in the amount of utility bill payments by housing construction period, using micro data of about 9,000 households. The analysis consisted of (1) building a model of gradient boosting decision tree, which is one of the machine learning techniques, (2) identifying contribution of each household and each feature using SHAP value, which is a novel method to improve the interpretability of machine learning, and (3) revealing the breakdown of differences on a macro level by aggregating each contribution. The results showed that the factors that have reduced the amount of payments in recently constructed houses were partly caused by the spread of heat pump water heaters and IH cooking heaters, so-called "electrification", in addition to the improvement of housing insulation performance. It was also confirmed that the effects of higher efficiency refrigerators and lighting have been steadily increasing.

**Keywords** : Energy efficiency, Decarbonization, Water heating, Space heating, Machine learning, Electrification

### 1. はじめに

温暖化・省エネ対策を検討する上で、CO<sub>2</sub> 排出量やエネルギー消費量の削減効果が重要であることは言うまでもないが、需要家の視点に立つと光熱費も関心事項であり、その節約効果は、対策の社会的受容性にも影響する。

環境省が平成 29 年度より実施している、「家庭部門の CO<sub>2</sub> 排出実態統計調査」(家庭 CO<sub>2</sub> 統計)<sup>1)</sup> では、世帯・住宅属性、家電・機器の保有・利用状況、各種エネルギー消費量・CO<sub>2</sub> 排出量に加えて、光熱費支払額も把握されている。政府統計ポータルサイト e-Stat でも、各種属性による有用なクロス集計表が多数公開されている。さらには、エネルギー・資源学会の「家庭部門の CO<sub>2</sub> 排出実態統計調査利用研究会」では、温暖化防止へ貢献すべく、家庭 CO<sub>2</sub> 統計の調査票情報(個票データ)を直接利用し、多様な視点で分析することとしている。筆者らも既報において、建築時期による給湯機器・主暖房機器・台所用コンロのシェアの差異を分析した<sup>2)</sup>。

一方、それら機器シェアは基礎情報の 1 つに過ぎず、対策の検討を更に進めていく上では、他の要因も含めて、光熱費などにどのような影響を与えているかも明らかにしていく必要がある。例えば、近年になって建築された住宅の光熱費が抑えられている理由として、住宅断熱性能の向上や省エネ機器の普及、太陽光発電の増加など、幾つもの仮説を立てることができ、その検証をしておく意義はある。

計測データに基づき、ZEH (net zero energy house) のエネルギー消費量を約 15 年前に建てられた住宅と比較した研究では、用途によって変化が大きいたことが示されているが<sup>3)</sup>、計測サンプル数にも限りがあるため、マクロ的な実態把握も併せて必要となる。しかし、たとえサンプル数が多くても、要因影響は複雑に絡み合うため、属性によるクロス集計表を一見するだけでは、正確な因果関係を知ることとはできない。個別寄与度を同定する目的で頻りに利用される手法は、重回帰モデルによる統計的分析であり、家庭 CO<sub>2</sub> 統計の全国試験調査の個票データに基づき、CO<sub>2</sub> 排出量や用途別エネルギー消費量を推計した研究がある<sup>4,6)</sup>。重回帰モデルは、注目する要因の偏重回帰係数やその有意性といった定量結果を示せる優れた特徴を有するが、多数の要因を考慮に入れて、寄与度の非線形性や相互関係を捉えつつ、全体を俯瞰するためには、分析上の工夫を相当重ねていく必要がある。家庭 CO<sub>2</sub> 統計に類似の統計調査である、米国の Residential Energy Consumption Survey (RECS) や Commercial Buildings Energy Consumption Survey (CBECS) の個票データ分析では、機械学習は重回帰モデルと比べて良好な精度でエネルギー消費などを推定可能との指摘例が増えている<sup>7,9)</sup>。

そこで本研究では、家庭 CO<sub>2</sub> 統計の個票データに基づき、(1) 機械学習手法の 1 つである勾配 Boosting 木 (Gradient Boosting Decision Tree, GBDT) を適用することで、世帯・住宅属性や機器保有・利用行動などの多数の特徴量から光熱費を推定するモデルを構築した上で、(2) 機械学習の解釈可能性を高める手法の SHAP (SHapley Additive

\*電力中央研究所 社会経済研究所 上席研究員  
〒100-8126 東京都千代田区大手町 1-6-1  
E-mail : nishio@criepi.denken.or.jp

exPlanations) を応用することで、建築時期による光熱費差異に対する各種要因の寄与度を明らかにする。

研究意義としては、手法提案という基盤的側面と実態把握という応用的側面とがある。前者については、GBDT や SHAP という最近注目されている要素技術を組み合わせた上で、サンプル全体の要因分解まで行う一連の分析過程は、少なくともエネルギー需要関連データを扱う先行研究には見当たらない。後者については、光熱費の違いがもたらされる構造を、部分的ではなく 11 の要因で包括的に分解し、その詳細も示すものである。

## 2. 分析データ

### 2.1 対象サンプル

本研究では、平成 29 年度家庭 CO<sub>2</sub> 統計の元となる 9,505 世帯分の個票データのうち、建築時期が不明の世帯を除く 8,725 サンプルのデータを用いる。

図 1 によれば、本研究の対象世帯平均（建築時期不明を除く）の年間光熱費支払額は合計 17.5 万円である。参考までに、エネルギー別の内訳を確認しておくと、電気が 11.0 万円、都市ガスが 3.1 万円、LP ガスが 2.0 万円、灯油が 1.5 万円である。建築時期に見ると、各々のサンプル数が減ることで値が変動することに留意するとして、合計光熱費は建築時期が 1991～1995 年や 2001～2005 年の住宅で多く、2006 年以降は減少傾向にある。2016 年以降に建築された住宅は、対象世帯平均を 3.4 万円（19%）下回る。こうした変動の理由を同図から推測することは難しい。

なお、建築時期が不明のサンプルは、集合住宅に住む単身世帯が多めなことなどにより、平均光熱費は少ない。建築時期が不明の世帯を除外した理由は、建築時期による光熱費差異を生む要因を明らかにするという本研究の目的に照らして、それら世帯を含めることの必要性は低く、また、建築時期が把握できるサンプル間の平均的水準を基準値とすることで、建築時期の比較考察がしやすいからである。

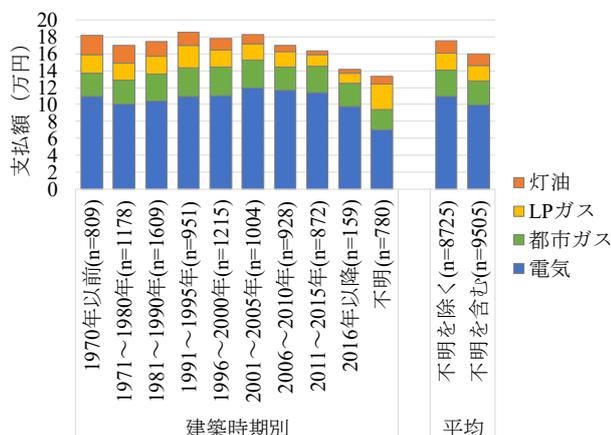


図 1 建築時期別の光熱費支払額

家庭 CO<sub>2</sub> 統計では、回答者が都市部へ偏る可能性があることを踏まえて、集計の際には都市階級別の世帯数による比例配分を行うこととしている。そのための重み付け係数は個票データに収録されているので、GBDT モデル構築時と寄与度分析時にも考慮している。

### 2.2 目的変数

GBDT モデルの目的変数は、年間合計（2017 年 4 月～2018 年 3 月）の光熱費支払額（単位：万円）である。電気・都市ガス・LP ガス・灯油の 4 種の支払額の合計であり、ガソリン・軽油は含まない。太陽光発電の保有世帯において、売電に伴う受取額は反映されないが、自家消費に伴う支払額の減少は反映されている。

### 2.3 特徴量

GBDT モデル構築時に、目的変数に影響を与えうる特徴量（説明変数）を投入することになるが、本研究では、個票データの情報を最大限活用することにした。特徴量を絞り込み過ぎると本研究が目指す寄与度分析が簡易的なものになる可能性があるし、関連が深い特徴量であっても何らかの情報を有するかもしれないからである（例：各種暖房機器の保有台数と主暖房機器）。

内容的な重複度が極めて高い設問については、情報量が多いデータを投入する（例：家電有無データは投入せず、家電保有台数を投入）。使用時間などの幅を持つ選択肢でたずねているデータについては、解釈のしやすさも考慮して中央値などで数値化（例：テレビ使用時間が「4 時間～8 時間未満」なら「6」）する。欠損値は、それ自体が特徴としてモデルに考慮されるので、事前や事後に除外・補完処理をすることはしない。機器種別などの集約はせず、むしろ、調査票ではガス種別の区別をせずに保有状況をたずねている機器については、本研究では細分化する（例：「ガスコンロ」は、利用エネルギー情報に基づき、「都市ガスコンロ」か「LP ガスコンロ」に変換）。10 地域を表す特徴量と共に、都道府県の代表地点の年間平均気温も投入する。

逆に、個票データに収録されているが投入しなかったのは、エネルギー別の購入量・支払額、合計や用途別のエネルギー消費量・CO<sub>2</sub> 排出量、太陽光発電の売電量、毎月の生活や機器変化に関するデータなどである。また、個別の省エネ行動データを投入するため、省エネ行動実施率は投入せず、電気自動車・プラグインハイブリッド車・電動スクーター等の有無データは投入するが、ガソリン車の有無や利用状況などは投入しない。

以上の方針に基づき、表 1 に示す特徴量を投入することにした。表中では各種機器や各種省エネ行動といった具合に適宜まとめて表記しているため、実際の特徴量は 231 個

である。各特徴量の具体的な選択肢や選択率はここで明示しないが、公開されている調査票や建築時期別のクロス集計表に合致するので、必要に応じて参照されたい。

表1では更に、各特徴量を11の大分類と41の小分類からなる「要因」に関連付けている。これら要因は、後段の寄与度分析のために定義したものであり、前段のGBDTモデル構築時に用いるものではない。

表1 特徴量の一覧と要因分類

要因	小分類	特徴量
世帯	世帯人数	世帯人数
	世代	世帯主の年齢、世帯構成員の最低・最高年齢
	世帯年収	世帯年収
	在宅率他	平日昼間の在宅状況、就業者人数比率
住宅	建て方	住宅の建て方
	所有関係	住宅の所有関係
	延床面積	延床面積
	窓状況	二重サッシまたは複層ガラスの窓の設置状況
冷暖房	建築時期	建築時期
	エアコン	エアコンの使用台数、1・2・3・4・5台目エアコンの種類・製造時期
	暖房機器	主暖房機器、各種暖房機器の使用台数、セントラル暖房・床暖房・太陽熱暖房の使用有無
	冷房行動	夏季平日の1台目エアコン使用時間、1台目エアコンの冷房設定温度、ベットののための冷房使用状況
給湯	暖房行動	冬季平日の主暖房機器使用時間、主暖房機器の暖房設定温度・強度、暖房居室比率、暖房の仕方、ベットののための暖房使用状況
	給湯機器	各種給湯機器の設置有無
	入浴行動	夏・冬季の湯はり・シャワー確率、入浴の各種省エネ行動
	他行動	冬季の洗面・台所お湯使用確率、入浴以外の各種省エネ行動
コンロ	コンロ機器	各種台所用コンロの設置有無
	調理行動	朝・昼・夜の調理確率、調理の各種省エネ行動
冷蔵庫	台数	冷蔵庫の使用台数
	1台目仕様	1台目冷蔵庫の種類・内容積・製造時期
	2台目仕様	2台目冷蔵庫の種類・内容積・製造時期
	利用行動	冷蔵庫の各種省エネ行動
テレビ	台数	テレビの使用台数
	1台目仕様	1台目テレビの種類・画面サイズ・製造時期
	2台目仕様	2台目テレビの種類・画面サイズ・製造時期
	3台目仕様	3台目テレビの種類・画面サイズ・製造時期
	利用行動	1台目テレビの平日使用時間、テレビの各種省エネ行動
照明	居間照明	居間における各種照明の使用有無、居間主照明の種類
	他照明	食卓・台所・個室・その他場所における各種照明の使用有無
	利用行動	居間照明の使用時間、照明の各種省エネ行動
家電他	洗濯乾燥	洗濯機・衣類乾燥機・浴室乾燥機の使用台数、乾燥機能の使用確率
	食洗乾燥	食器乾燥機・食器洗い乾燥機の使用台数
	トイレ	温水洗浄便座・暖房便座の使用台数、トイレの各種省エネ行動
	水サーバー	ウォーターサーバーの使用台数
	その他	各種家電の使用台数、家電の各種省エネ行動、ペット関連機器の使用有無、HEMSの導入有無、電気自動車・プラグインハイブリッド車・電動オートバイ等の使用有無
地域	地域	10地域区分
	都市階級	都市階級
	気温	都道府県代表地点の年間平均気温
	融雪機器	各種融雪機器の使用有無
太陽光	太陽光有無	太陽光発電の使用有無
	太陽光容量	太陽光発電の総容量

### 3. 勾配 Boosting 木 (GBDT) モデルの構築

GBDT は機械学習手法の1つであり、勾配降下法・アンサンブル学習・決定木の組み合わせにより、目的変数を予測する。重回帰モデルよりも、非線形性や相互作用を考慮しやすい。本研究と性格に近い CBECS データを用いた研究でも、重回帰モデルや複数の機械学習モデルとの精度比較において良好な結果が示されることが多く<sup>8,9)</sup>、家庭 CO<sub>2</sub> 統計を用いた機器保有状況の分類でも GBDT の精度が高めだったとされている<sup>10)</sup>。

GBDT モデル構築にあたっては、予測精度を左右するハイパーパラメータの値をチューニングする必要がある。そこで、予測精度の向上と過学習の抑制を目的として、対象サンプルの 80% をランダム抽出した上で、その中で 10 分割交差検証 (CV, cross validation) により、グリッド探索で値を決定した (eta=0.015, max\_depth=4, gamma=0.9, colsample\_bytree=0.4, min\_child\_weight=3, subsample=0.75, nrounds=3,000)。これら値を用いて、対象サンプル全体で改めて 10 分割 CV により平均的な予測誤差を確認したところ、RMSE (二乗平均平方根誤差) は 5.21, MAE (平均絶対誤差) は 3.74, R<sup>2</sup> (決定係数) は 0.674 であった。本研究では欠損データをそのまま用いることも受けて、同一条件下で重回帰モデルと精度比較することは難しく、また、予測精度比較が研究目的ではないため、複数モデル間の比較検証は行っていない。対象サンプル全体の GBDT モデルの学習誤差は、RMSE は 3.39, MAE は 2.55, R<sup>2</sup> は 0.867 であった。

### 4. 特徴量の寄与度の解釈

#### 4.1 モデル解釈手法としての SHAP

機械学習は精度が高い手法として期待される一方で、ブラックボックス問題もしばしば指摘される。これに対して、説明可能性 (解釈性) を高める手法も提案されており、その1つが、2017年に提案された SHAP である<sup>11)</sup>。協力ゲーム理論において獲得利得を各プレイヤーに公平に分配する手法として Shapley 値が知られているが、これを応用した SHAP は、各特徴量が予測値に及ぼす影響を解釈するための手法である。CBECS データを用いた分析でも、事業所のエネルギー消費多寡の理由解釈を試みる研究などが出てきている<sup>12-14)</sup>。

本研究にあてはめて具体的に述べると、特徴量テーブルは 8,725 行×231 列であるから、得られる SHAP 値テーブルも 8,725 行×231 列である。あるサンプルの 231 個の SHAP 値の合計は、目的変数である支払額の当該サンプル予測値と全体平均値の差分に一致する。

SHAP 値を算出することで、サンプル a の特徴量 b の寄与度は c といったミクロ的解釈から、構築モデルにおける

特徴量  $b$  の重要度 (SHAP 値の絶対値の平均) は  $d$  といったマクロ的解釈までを、一貫して行うことができる。

#### 4.2 重要度の高い特徴量の例

モデル解釈の例として、重要度が高いとされた上位 15 個の特徴量を確認しておく。

図 2 は、各特徴量の寄与度を概観するものであり、最も重要度が高かった世帯人数は、その値が大きくなるほど支払額にプラス寄与をする。その逆に、2 番目の年平均気温は、値が小さいほどプラス寄与をし、すなわち、寒冷地ほど支払額が増えることを表す。

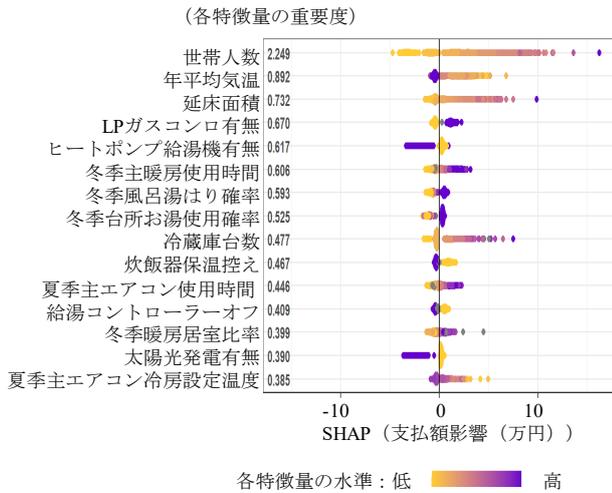


図 2 特徴量 (上位 15 個) の重要度

各特徴量が値によってどのような寄与をするかは、図 3 で確認できる。

例えば、3 番目の延床面積の寄与度は、 $100\text{m}^2$ を下回るあたりから傾きが小さくなる。戸建住宅か集合住宅かを表す住宅建て方の特徴量も別途投入しているとはいえ、外壁面積などの少ない集合住宅のほうが住宅断熱性能は高めである特徴が、投影されている可能性もある。ここでは推測の域を出ないが、事前に定義しづらい非線形性を捉えていること自体に価値を見出すことができよう。

4 番目と 5 番目に重要度が高いとされたのは、LP ガスコンロによる支払額増や、ヒートポンプ給湯機による支払額の減である。データの中身として、多くの場合はその他のコンロや給湯器の有無状況と連動するので、機器保有状況による支払額影響を算出するためには、関連する特徴量の寄与度を合算する必要がある点に注意されたい。同じことは、6 番目の冬季風呂湯はり確率についてもあてはまり、湯はり確率と連動するシャワー確率の寄与度と合算する必要がある。

特徴量の中には、炊飯器保温控えや給湯コントローラーオフのように、一般に想定される節約効果を上回るものもあり、相関する他の影響も混在する可能性が示唆される。分析にあたり、そうした特徴量を除外することも考えられるが、除外判断の統一基準を設けることが難しく、意図せず新たなバイアスを生む可能性も懸念されたので、個票データの情報を最大限活用する方針に従うことにした。集約して寄与度分析をする際の影響は軽微だが、サンプルごとに各特徴量の寄与度を抽出する際には、注意を要するとい

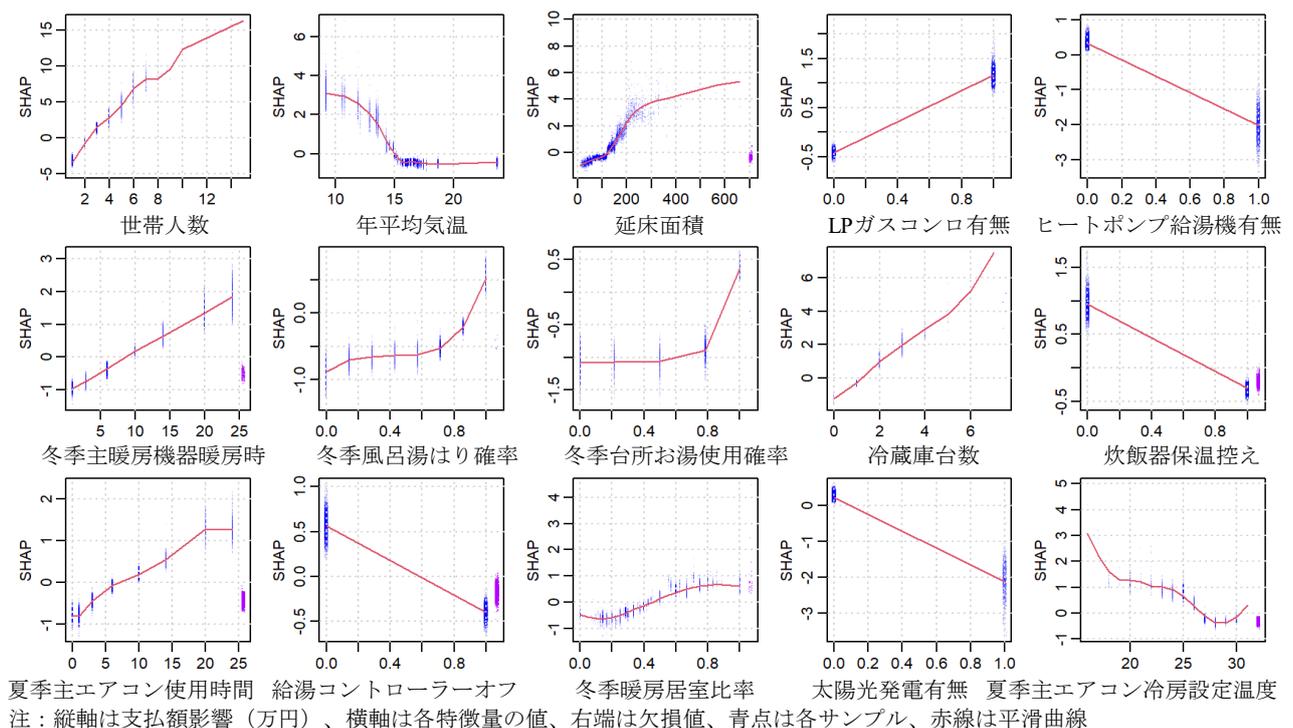


図 3 特徴量 (上位 15 個) の寄与度

える。このような課題があるとはいえ、特徴量全体で見れば、推定された寄与度の傾向は予想を大きく外れるものではないと考えられる。

### 4.3 ミクロ的解釈の例

図4は、ある世帯について、SHAP 値を 11 要因で集約したイメージ（値は概数）である。光熱費の予測値は平均値を約 2 万円下回る。主な内訳として、利用時間が長いことなどにより冷暖房要因で約 3 万円プラスになっているが、給湯要因（ヒートポンプ給湯機の利用）や太陽光要因により約 4 万円マイナスになっている。他世帯比較は省エネ情報提供として有効な手法であり、筆者らもスマートフォンアプリとスマートメータデータを活用することでその高度化を図る手法を提案しているが<sup>15)</sup>、本研究で提示した解釈手法を応用すれば、比較のみならず、差を生み出す要因についても情報提供できるようになり、省エネ余地の気づきをもたらす可能性がある。

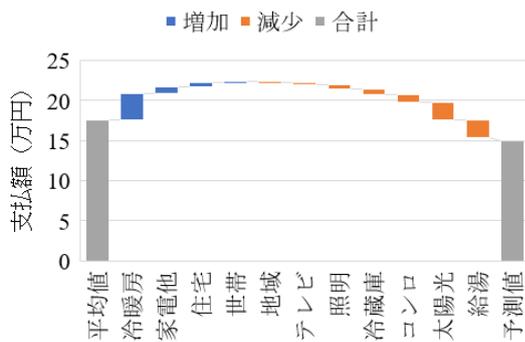


図4 平均値との差異の要因分解例

## 5. 建築時期による光熱費支払額の差異

### 5.1 全体の要因分解

対象サンプル全体の SHAP 値テーブルを用いて、本研究で焦点をあてる属性（建築時期）で行を集約すると共に、関連する特徴量（例：世帯要因や住宅要因）で列を集約することにより、マクロ的な寄与度分析を行う。なお、建築時期による差異を相対比較するものであるため、建築時期によらず一様に寄与する要因については、顕在化しない点に留意されたい。先に例を挙げれば、テレビは建築時期によらず比較的買い替えが生じやすいことも作用し、その省エネ効果が観察されにくい可能性があり、省エネ行動についても、建築時期によらず実施可能なものについては表出しない。

図5では、建築時期による支払額の差異を、11の要因で分解している。

まず、築年数が経過している住宅に着目すると、1980年以前に建てられた住宅は、世帯人数が少なめの高齢世帯が

他よりも多いことなどで世帯要因がマイナス寄与し、家電他要因もマイナスである。他方で、特に1970年より前に建てられた住宅では、低い断熱性能などが反映されたものと考えられるが住宅要因がプラス寄与し、古い機種が残存しやすいために冷蔵庫要因もプラス寄与をする。

次に、1991～2005年に建築された住宅を見ると、支払額が多めである。その背景として、世帯要因がプラス寄与しやすい点と、2006年以降にマイナス寄与を拡大させる住宅・給湯・コンロ・冷蔵庫要因などの効果が、これらの時期では顕在化していない点が挙げられる。

2006年以降に建てられた住宅における支払額の減少が、複数要因の効果によるものであることは、上述のとおりだが、2011年以降築の住宅では太陽光要因によるマイナス寄与も加わる。2016年以降築の住宅については、世帯要因は安定的な傾向といえないので除外するとして、住宅・冷蔵庫・給湯・太陽光・照明・テレビ・コンロ要因などのマイナス寄与が大きい。

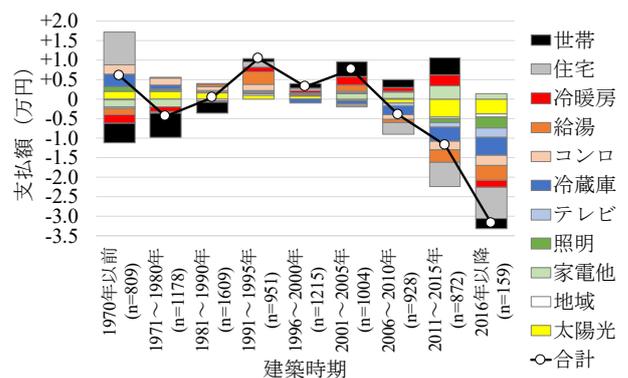


図5 光熱費支払額の差異の要因分解

### 5.2 各要因の詳細

次に、11 要因の各々について、小分類で内訳を明らかにする。特に断りのない場合、築浅住宅に注目して結果を解釈する。

世帯要因（図6）は築浅住宅ではプラス寄与していて、世帯人数が多めであることが背景にある。2016年以降に建てられた住宅において世帯人数要因の寄与は小さいが、これは2011～2015年と比べて平均人数が減っているためであり、サンプル数が少ないことにも留意する必要がある。年齢層が低めになることはマイナス寄与するが、2016年以降は別として、世帯人数の効果を打ち消すほどではない。世帯年収が多めであることも、築浅住宅ではプラス寄与している。

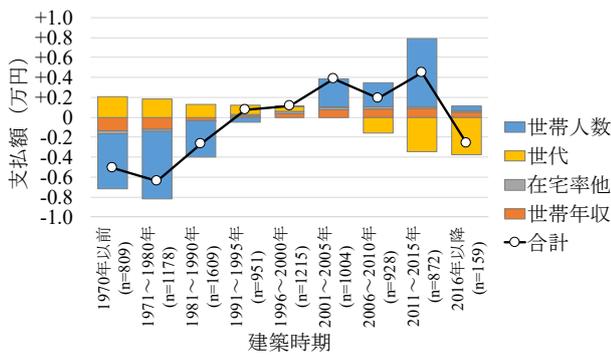


図6 世帯要因

住宅要因 (図 7) は、建築時期によるマイナス寄与が顕著であり、窓状況もマイナス寄与をしている。建築時期と窓状況の寄与度を合わせて、住宅断熱性能の向上による効果が現れているものと予想される。延床面積の減少もマイナス寄与しており、住宅断熱性能の向上効果とあわせて、冷暖房需要などを減少させる効果を持つものと考えられる。

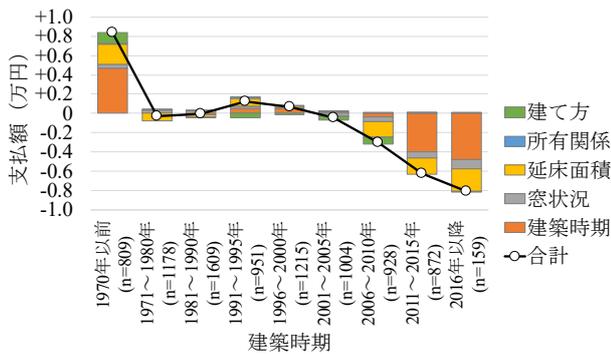


図7 住宅要因

冷暖房要因 (図 8) については、保有機器 (冷房はエアコン、暖房は各種機器) の移り変わりが、2011 年以降に建築された住宅ではマイナス寄与である。エアコンは新しい住宅ほど製造時期が新しい傾向にあり、省エネ効果も現れやすい。また、主暖房機器としてエアコンが選択される比率が高まっている点もマイナス寄与をしている。一方で、暖房行動によるプラス寄与も、建築時期による変動はありながらも、表出しやすくなっている。温熱環境が豊かになっていることを示唆するものであり、特徴量を見ても、暖房スペース比率の増加などが確認できる。これらからは、住宅断熱性能や機器性能の向上効果を一部キャンセルする「リバウンド効果」の存在が示唆される。とはいえ、採暖文化を経験してきたわが国の暖房充足水準は欧米のそれと比べて低いといわれる中で、健康改善効果などの副次的便益などを考えると、無駄と批判されるべきものではない。また、実際には、先述の住宅要因のマイナス寄与があるため、これと合わせれば冷暖房関連の支払額自体は減少する。

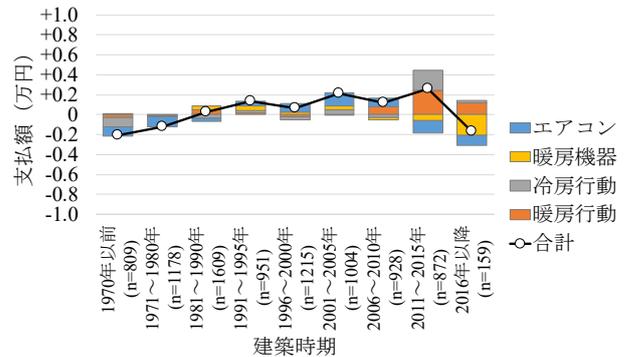


図8 冷暖房要因

給湯要因 (図 9) は、機器構成の変化によるマイナス寄与が大きい。特に、2006 年以降に建築された住宅では、ガス給湯器が減少し、ヒートポンプ給湯機がシェアを増やしていることが寄与している。2016 年以降築の住宅のヒートポンプ給湯機の保有率が、2011~15 年築より低下するため、マイナス寄与は弱まっている。入浴行動がプラスに寄与するのは湯はり頻度が増加傾向にあるためであり、暖房ほどではないが、サービス水準の向上も見られる。

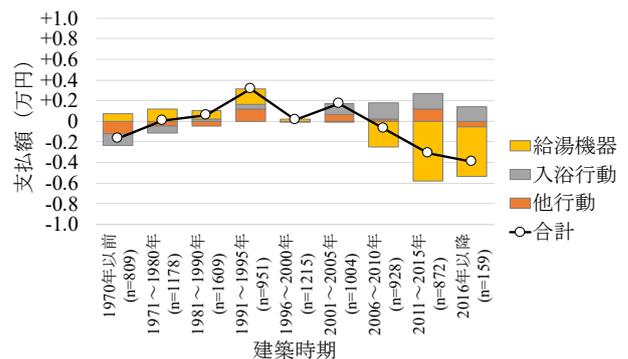


図9 給湯要因

コンロ要因 (図 10) は、機器選択の影響が大きく、データを詳しく見ると、近年の住宅ほど、LP ガスコンロが減る一方で IH キッキングヒーターが増えていることが、支払額へのマイナス寄与の主要因となっている。

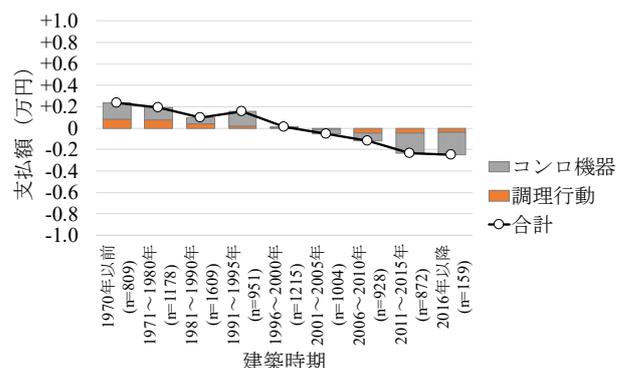


図10 コンロ要因

冷蔵庫要因（図 11）は、建築時期が最近になるほど、着実にマイナス寄与している様子をうかがい知れる。冷蔵庫は大型化傾向にあるが、その影響は軽微であり、製造時期が新しくなることによる省エネ効果が発現している。特に最近の住宅ほど、1 台目の製造時期が新しいことが多く、マイナス寄与が顕著である。また、台数影響もマイナス寄与をしており、築年数の経過した住宅でありがちな複数台保有が、少なめだからである。

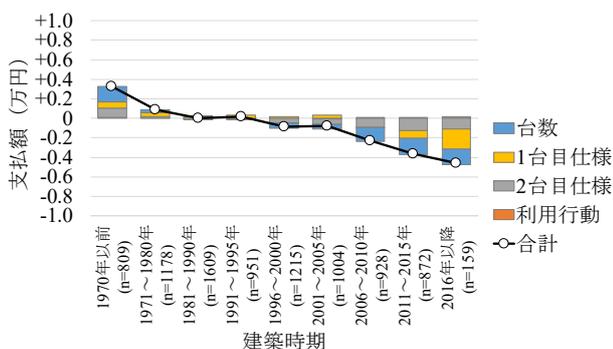


図 11 冷蔵庫要因

テレビ要因（図 12）もマイナス寄与であるが、その大きさは冷蔵庫要因ほどではない。建築時期によらず、買い替え行為が発生しやすいことも、差異の小ささにつながっているものと考えられる。実際に、建築時期による製造時期の差はエアコンや冷蔵庫のそれより小さい。詳細を見ると、画面サイズの大型化によるプラス寄与がありながらも、1 台目テレビの使用時間の減少などによるマイナス寄与のほうが大きい。2006 年以降に建築の住宅では、台数が少ないことによるマイナス寄与が拡大していく。

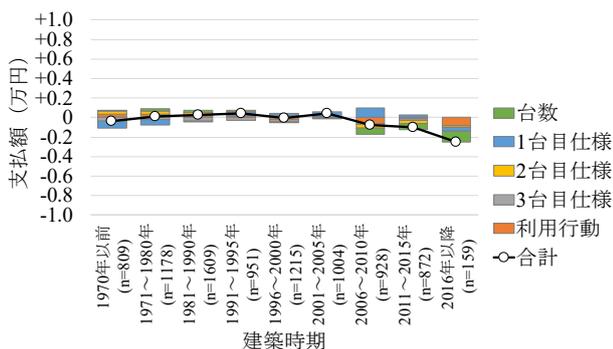


図 12 テレビ要因

照明要因（図 13）については、2011 年以降、特に 2016 年以降に建築された住宅において、居間照明（保有している照明器具及び最も使う照明器具）やその他の部屋の照明によるマイナス寄与が顕著である。すなわち、新築住宅で LED 照明が確実に広がりを見せていることが、支払額の減少をもたらしている。

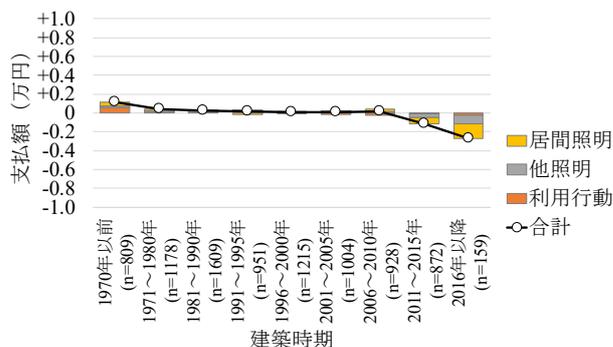


図 13 照明要因

家電他要因（図 14）は、プラス寄与である。小分類は、特徴量の中から寄与の大きかった用途を抽出したものであり、洗濯衣類乾燥関連、食器洗浄乾燥関連、トイレ関連、ウォーターサーバーなどによるプラス寄与が観察された。これらは、新築住宅の備え付け機器としての普及進展や、築浅住宅の居住者のライフスタイルが投影されている可能性がある。

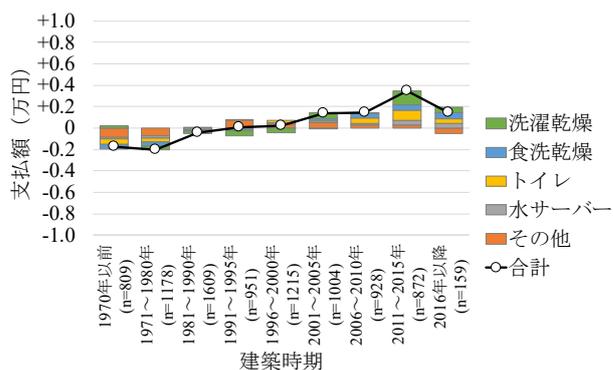


図 14 家電他要因

地域要因（図 15）は、建築時期による違いはほとんど生み出さないことは想定範囲内である。実際には、平均気温が 2 番目に重要な特徴量である点は既に述べたとおりであり、各世帯の支払額には大きく影響しているし、同図はあくまでも建築時期との関連性が低いことを確認したに過ぎない。

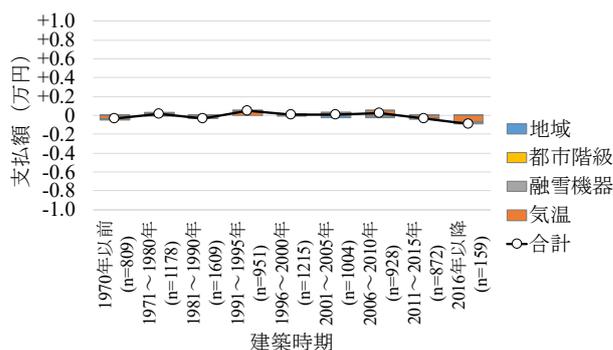


図 15 地域要因

太陽光要因（図 16）は、特に 2011 年以降に建築された住宅でマイナス寄与が見られる。その要因を更に分解すると、太陽光発電の設置が進むことに加えて、設置容量が大きくなっていることも追加的な効果を有し、支払額の減少に寄与している。なお、本研究の分析対象は支払額であるため、売電収入を考慮した実質的な支払額は、同図よりも減少することになる。

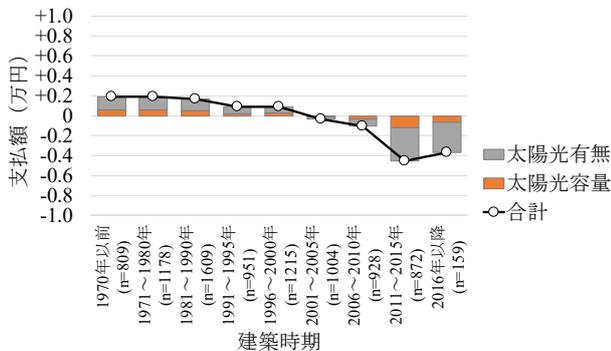


図 16 太陽光発電要因

## 6. おわりに

本研究では、家庭 CO<sub>2</sub> 統計の個票データを用いて、建築時期別の光熱費支払額の差異、特に築浅住宅における光熱費の抑制傾向に注目して、その要因を明らかにした。

分析にあたっては、8,725 世帯の年間合計支払額及び 231 個の特徴量データを用いた。分析手順としては、(1) 機械学習手法の 1 つである勾配 Boosting 木によるモデル構築、(2) 機械学習の解釈可能性を高める手法である SHAP 値を用いて各世帯・各特徴量の寄与度をミクロ的に同定した上で、(3) 寄与度を集約することでマクロ的な実態把握を行う手法を提案した。

分析結果からは、近年の住宅で光熱費支払額が抑えられている要因として、住宅断熱性能の向上に加えて、ヒートポンプ給湯機や IH キッキングヒーターの普及、いわゆる「電化」により給湯機器や台所用コンロの光熱費が抑えられていること、冷蔵庫・照明の高効率化などの効果も着実に現れていることなどが確認できた。また、暖房行動や給湯行動の変化によりサービス水準が向上していることが示唆され、省エネの進展と同時に、リバウンド効果やライフスタイルの変化などについても今後注視が必要であることが示唆された。

今後の研究課題として、分析精度の更なる向上が挙げられる。機械学習と SHAP のような解釈可能性を高める手法を併用することで、特定の省エネ対策の効果が一般に指摘される効果とどの程度異なるか、異なるとすればその理由は何かについても議論を深められる可能性があるし、その過程で分析手法や調査方法の課題を見出すことができよう。

また、本研究では精度向上のためのモデルや特徴量の選択についてはスコープ外としたが、実用上は、どのような特徴量を用いれば十分な精度を担保できるか、このような分析を行う上でどの程度のサンプル数が必要か、なども検討余地がある。

研究の発展可能性について言えば、各特徴量による目的変数への寄与度を同定できる手法は、ミクロ的な分析にもマクロ的分析にも応用しやすい。本研究では建築時期別の光熱費差異分析を行ったが、比較軸は建築時期によらないし、目的変数も光熱費に限るものではない。分析内容に応じて手法をカスタマイズすることがそれほど求められないとすれば、効率的に知見を蓄積できる可能性がある。家庭 CO<sub>2</sub> 統計のように大規模かつ内容が練られた調査が行われることで、学術的にも手法高度化をもたらす機会となり、社会的・政策的にも参考となる分析結果が得られることの一例を示せたとすれば幸いである。

## 謝辞

本研究は、エネルギー・資源学会の「家庭部門の CO<sub>2</sub> 排出実態統計調査利用研究会」のメンバーとして、実施しました。平成 29 年度家庭 CO<sub>2</sub> 統計の実施に尽力された環境省や委託事業者であるインテージ・住環境計画研究所、学会・研究会の関係者の皆様に、この場を借りて御礼申し上げます。なお、本分析の結果にかかる責任は筆者が負います。

## 参考文献

- 1) 環境省; 家庭部門の CO<sub>2</sub> 排出実態統計調査 (家庭 CO<sub>2</sub> 統計). <http://www.env.go.jp/earth/ondanka/ghg/kateiCO2tokai.html> (アクセス日 2020.11.30)
- 2) 西尾健一郎, 中野一慶; 家庭 CO<sub>2</sub> 統計の個票データを用いた給湯機器の保有実態などに関する基礎検討, 第 39 回エネルギー・資源学会研究発表会 講演論文集, (2020), pp.244-249.
- 3) 大木玲奈, 小川崇臣, 田辺新一; 全電化のネット・ゼロ・エネルギー・ハウスの電力需給に関する実態分析, 日本建築学会環境系論文集, 85(775), (2020), pp.685-694.
- 4) 石河正寛, 松橋啓介, 金森有子, 有賀敏典; 家庭 CO<sub>2</sub> 統計に基づく全国 10 地方別の排出要因分析と市町村別世帯あたり排出量の推計—全国試験調査結果を用いて—, 土木学会論文集 G (環境), 74(6), (2018), II\_193-II\_201.

- 5) 石河正寛, 松橋啓介, 金森有子, 有賀敏典; 市町村別家庭部門 CO<sub>2</sub> 排出量推計モデルの改良—欠測データ処理と非線形回帰の適用—, 土木学会論文集 G (環境), 75(5), (2019), I\_89-I-98.
- 6) 岩船由美子, 河合俊明; 「家庭からの二酸化炭素排出量の推計に係る実態調査」に基づく家庭部門のエネルギー消費構造分析, 第 34 回エネルギーシステム・経済・環境コンファレンス, (2018), pp.415-420.
- 7) Chen, K., Jiang, J., Zheng, F., and Chen, K.; A novel data-driven approach for residential electricity consumption prediction based on ensemble learning. *Energy*, 150, (2018), pp.49-60.
- 8) Deng, H., Fannon, D., and Eckelman, M. J.; Predictive modeling for US commercial building energy use: A comparison of existing statistical and machine learning algorithms using CBECS microdata, *Energy and Buildings*, 163, (2018), pp.34-43.
- 9) Robinson, C., Dilkina, B., Hubbs, J., Zhang, W., Guhathakurta, S., Brown, M. A., and Pendyala, R. M.; Machine learning approaches for estimating commercial building energy consumption, *Applied Energy*, 208(May), (2017), pp.889-904.
- 10) 向井登志広, 田中拓朗; 家庭 CO<sub>2</sub> 統計を用いた機器保有状況の分類手法に関する検証, *エネルギー・資源*, 41-6, (2020), pp.328-335.
- 11) Lundberg, S.M., and Lee, S.-I.; A unified approach to interpreting model predictions, *Advances in Neural Information Processing Systems*, (2017).
- 12) Papadopoulos, S., and Kontokosta, C. E.; Grading buildings on energy performance using city benchmarking data, *Applied Energy*, 233-234(July 2018), (2019), pp.244-253.
- 13) Arjunan, P., Poolla, K., and Miller, C.; EnergyStar++: Towards more accurate and explanatory building energy benchmarking, *Applied Energy*, 276(January), (2020), 115413.
- 14) Tian, Z., Wei, S., and Shi, X.; Developing data-driven models for energy-efficient heating design in office buildings. *Journal of Building Engineering*, 32, (2020), 101778.
- 15) 中野一慶, 西尾健一郎, 向井登志広, 大館陽子, 佐々木正信; スマートフォンを活用した家庭向け省エネサービスの実証研究: 他世帯比較のパーソナライズ手法の提案, *エネルギー・資源*, 42-1 (2020).

# 情報化技術が家庭部門／産業部門に及ぼす影響の分析 —情報トラヒックとテレワークの影響の調査データの分析—

An Empirical Study on Impacts of ICT on Household and Industry Sectors  
— An Analysis of Information and Communication Traffic and Telework Survey —

森 俊介\*  
Shunsuke Mori

The diffusion of new ICT is often expected to contribute to reducing carbon emissions by replacing physical mobility with information communications, while there are few empirical case studies to measure its effect. It is also pointed out that such wide adoption of ICT would cause explosion of information transactions and thus increase the demand for electricity. Until today, increase of information communications has been covered by the technological progress of ICT facilities, but the experts of electronics devices have cautioned the physical limits of microfabrication. On the other hand, the Japan's state of emergency over coronavirus issued on 13, March, 2020 forced Japan companies to deploy the telework. This unfortunate event revealed the effects of "telework!" and how the ICT could replace the daily transportation. This study shows an empirical analysis on the effects of telework on information transactions and mobility as well as the future trend of information traffic caused by the expansion of ICT services. This study shows (1) information traffic will increase by 22.4% per year by 2030 while 10.9% per year by 2050 unless new service is rapidly introduced, (2) telework would decrease CO2 emission by 1.23Mt-CO2 per year while 2.95Mt-CO2 would be possible when available workers adopt telework two day per week which are compatible with existing studies.

*Keywords: ICT, information traffic, telework, transportation substitution, CO2 reduction*

## 1. 背景と目的

気候変動リスクに関する科学的知見が進んだ結果、より厳しい温度上昇制約が求められつつある。日本政府も2020年10月26日、2050年までの「ゼロエミッション化」<sup>1)</sup>を宣言した。これに先立つ政府の「革新的環境イノベーション戦略」<sup>2)</sup>では、温暖化ガス排出削減のためのエネルギー転換部門から農林水産業までの5分野16課題が挙げられている。ここには個別の排出削減技術だけでなく情報通信技術(ICT)を活用した分野横断的な削減方策が示されている。

ICTが社会を様々に変える可能性はこれまでも指摘されており、例えばテレワークが交通機関を置き換えることによるCO2排出削減の可能性も周知である。しかし、これまでそのようなスマート化の社会実験は限定的であり、定量的評価は不十分であった。また、ICT拡大普及がもたらす電力消費の拡大についても、これまでは「過去の延長による爆発的増大」と「技術進歩による緩和」が並行しており、結論には至っていない。

このように、ICTの温暖化ガス排出削減への寄与に期待はあるものの、その定量的な効果の評価は、まだ不確かと

言わざるを得ない。

2020年に世界を襲ったコロナウイルス感染は、我が国にも多大な影響を与えた。特に、2020年3月13日に出された緊急事態宣言の後は、都市部の企業はそれまでにない規模で在宅勤務採用を余儀なくされた。6月になって緊急事態が解除された後も、テレワークは部分的に採用が続いている。

テレワークなど企業でのICT技術の採用状況は、総務省は「通信利用動向調査」(企業編)でH21年からICT技術の利用動向や生産性の変化を調査している<sup>3)</sup>。質問項目は54項目に及び、①IoT、AIによるデータ収集と分析、②クラウドコンピューティング/SaaSによる処理、③テレワークによる働き方、について採択企業数と労働生産性の変化を示している。コロナ後の影響では、パーソル総研が2020年4月と6月に、テレワークの実施状況を全国県別・業種別・職種別に調査している<sup>4)</sup>。

この間の通信トラヒック変化について2020年4月からNTTが平日・休日別のトラヒックの変化を公開している<sup>5)</sup>。

これらのデータから、ICTによる働き方の変化と生産性への影響、通信トラヒックへの影響を分析できる。

本報告では、まず総務省「我が国のインターネットにおけるトラヒックの集計・試算」<sup>6)</sup>、「我が国の移動通信トラ

(\*) 科学技術振興機構低炭素社会戦略センター研究統括/上席研究員  
〒102-8666 東京都千代田区四番町5-3 サイエンスプラザ  
E-mail: [mori@jst-ics.jp](mailto:mori@jst-ics.jp)

ヒックの現状<sup>7)</sup> および総務省情報通信政策研究所の「メディア・ソフトの制作及び流通の実態に関する調査研究」<sup>8)</sup>に基づいて通信トラフィックの変化をコンテンツ別に予測する。ついで、上述のテレワークに関する調査をもとに、テレワークの影響を分析し、さらに通勤用自動車燃料消費削減への影響を評価する。

本研究は、科学技術振興機構 低炭素社会戦略センターの研究活動の一環であるが、本報告にありうる誤りはすべて筆者の責に帰すものである。

## 2. 情報トラフィックの分析と予測

インターネットの急速な普及により、世界でも日本でも、通信トラフィックは急速に増加してきた。上記の総務省調査は、図1のフレームに基づき、トラフィックの集計結果を公表している。一例を図2、図3に示す。図2から、2014年付近からダウンロードトラフィックが急増しており、このまま延長すると爆発的な拡大が予想される。移動体トラフィックは2010年からの公表であり、2015年以降年率32%の上昇を示す。5Gの普及によりさらなる増加が予想される。

科学技術振興機構低炭素社会戦略センターこの傾向を延長し、将来の電力消費と結び付ける推計を行った<sup>9)</sup>。結果の一部を表1に示す。このように、過去の趨勢を外挿すると爆発的なトラフィックの増大が起こり、もし電力消費原単位が変わらないならばこれも増加することになる。もちろん、これは現実的ではないものの電力需給の圧迫要因となることは予想される。トラフィックの爆発的な増加は当然予想されるものの、情報処理機器の省電力技術の進歩については不確実性が大きく、結果として電力消費増加の将来予測には幅が生じる。例えば、IEA<sup>10)</sup>はCiscoのVisual Networking Indexに従い、通信量の急速な増加を採用すると同時に、Kooameyの法則「1.57年で新型計算機のエネルギー

消費効率が2倍になる」が今後も成り立つなら、電力消費増加は抑制できる、としている。

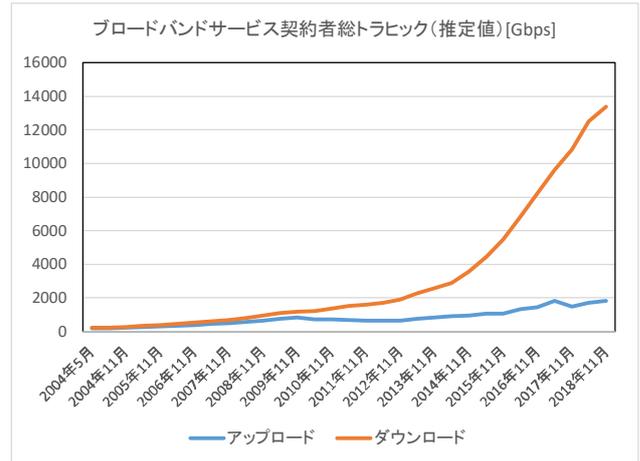


図2 ブロードバンドサービス契約者総トラフィック<sup>8)</sup>から作成

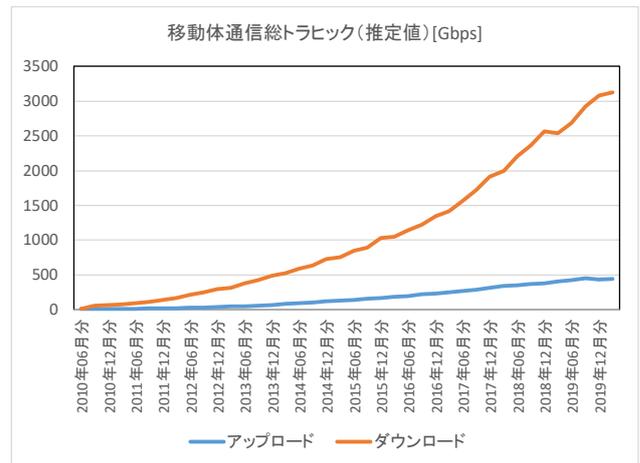


図3 移動通信トラフィックの推移<sup>7)</sup>から作成

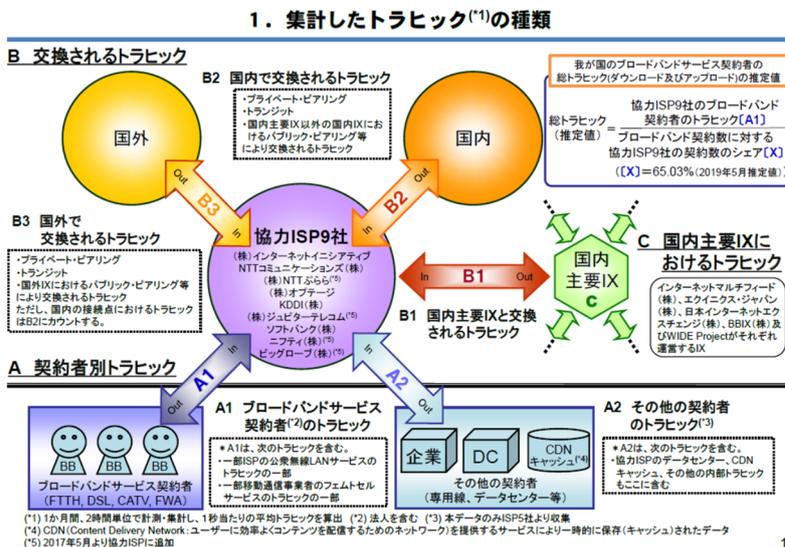


図1 我が国のインターネットにおけるトラフィックの集計・試算 2020年5月時点の集計結果の公表 (令和2年7月31日)<sup>9)</sup>  
[https://www.soumu.go.jp/menu\\_news/s-news/02kiban04\\_04000273.html](https://www.soumu.go.jp/menu_news/s-news/02kiban04_04000273.html)

トラフィックの将来需要予測のためには、まずその内訳を見る必要がある。図4である。明らかに、端末のダウンロード需要が増大の主要因である。そこで、ここでは、コンテンツ

需要から将来のトラフィック予測を行う。総務省情報通信政策研究所<sup>8)</sup>は通信を含むメディア消費の推移を示している。地上波、BSなど放送は非通信系コンテンツに分類されている。表2は図1の各フローのトラフィックのこの調査は、情報の固有単位を情報量に換算している特徴がある。結果の一例を表2に示す。

次に、この中で最もシェアの大きい映像系コンテンツと総務省のトラフィック調査を比較したものが表3である。流通量の比率から、次第に映像系コンテンツが支配的になっていることがわかる。

表2 総務省情報通信政策研究所、「メディア・ソフトの制作及び流通の実態に関する調査研究」による通信系コンテンツ消費の推移

	ソフト形態別	2008年	2009年	2010年	2011年	2012年	2013年	2014年	2015年	2016年	2017年
全市場	映像系ソフト(億時間)	1,735	1,727	1,670	1,775	1,830	1,859	1,786	1,762	1,770	1,775
	音声系ソフト(億時間)	275	294	263	248	249	270	261	253	232	240
	テキスト系ソフト(兆頁)	11.5	10.6	10.4	10.3	10.5	9.8	11.8	9.5	10.7	11.6
	映像系ソフト(EB)	1,320	1,313	1,270	1,350	1,392	1,414	1,358	1,340	1,346	1,350
	音声系ソフト(EB)	0.932	0.997	0.892	0.841	0.844	0.915	0.885	0.858	0.787	0.814
	テキスト系ソフト(EB)	2.277	2.099	2.060	2.040	2.079	1.941	2.337	1.881	2.119	2.297
	合計(EB)	1322.8	1316.6	1273.1	1352.9	1394.8	1416.7	1361.6	1342.9	1349.1	1353.1
通信市場	映像系ソフト(億時間)	126	163	182	254	294	403	461	475	517	600
	音声系ソフト(億時間)	91.67	98.00	98.63	110.22	124.50	101.25	97.88	108.43	116.00	90.00
	テキスト系ソフト(兆頁)	1.49	1.48	1.49	1.53	1.75	1.52	2.10	2.11	2.43	2.97
	映像系ソフト(EB)	96.0	123.9	138.6	192.9	223.7	306.3	350.5	361.6	393.5	456.6
	音声系ソフト(EB)	0.311	0.332	0.334	0.374	0.422	0.343	0.332	0.368	0.393	0.305
	テキスト系ソフト(EB)	0.295	0.294	0.294	0.304	0.347	0.302	0.415	0.418	0.482	0.588
	合計(EB)	96.3	124.2	138.9	193.2	224.1	306.7	350.9	362.0	393.9	456.9

表1 ICT 関連需要と電力消費予測<sup>9)</sup>

	2016	2030	2050
トラフィック(ZB/年)	4.7	170	20,200
消費電力(日本 Twh/年)	41	1,480	176,200
消費電力(世界 Twh/年)	1,170	42,300	5,030,000

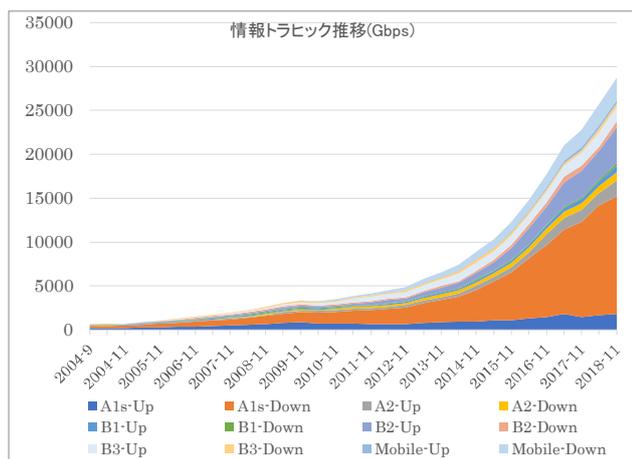


図4 情報トラフィック内訳別推移(A1s はISP5社による推定値)

さらに、一人当たりコンテンツ消費量を一人当たり実質GDPで回帰分析する。全人口一人当たりでは相関がみられないが、表4のように64歳以下人口当たりの消費量では高い相関を得ることができた。今後、さらに、欧米では研修など法人向け需要が急増しているAR/VR(通信量は約4倍になるとされる)が日本でも導入されれば、先行する消費者向け以上の需要拡大が見込まれる。同様に、音声系、テキスト系コンテンツについても分析を行ったが、消費がほとんど

表3 映像コンテンツとトラフィック

	総務省トラフィック調査(EB/年)	映像情報：通信系換算(EB/年)	流通比率
2008	29.3	96.0	30.6%
2009	37.7	123.9	30.4%
2010	45.0	138.6	32.5%
2011	55.4	192.9	28.7%
2012	69.7	223.7	31.2%
2013	97.5	306.3	31.8%
2014	136.2	350.5	38.8%
2015	205.5	361.6	56.8%
2016	304.1	393.5	77.3%
2017	404.6	456.6	88.6%
2018	501.8	—	—

ど変化して  
いないため  
有意な関係  
を得られな  
かった。  
さらに通  
信系シェア  
への移行の  
推移をロジ  
ットモデル  
に適用する  
ことで、将来

のA1-Downトラフィック予測を行う。A1とA2、B1-3との相互関係を回帰分析で求めていくことで、コンテンツが誘発するトラフィック変化を推計した。

表4 年齢クラス別一人当たり映像情報消費と実質GDPの相関

	ln(一人当映像時間)	ln(U59当映像時間)	ln(U64当映像時間)	ln(U69当映像時間)	ln(U74当映像時間)
傾き	0.44	1.04	1.16	0.91	0.80
切片	-0.99	-5.57	-6.67	-4.73	-3.91
R2	0.27	0.62	0.72	0.59	0.55

最も大きな影響を及ぼすのは動画配信の画質であり、図5のような推移を得た。成長率を表5にまとめる。このようなコンテンツベースでトラフィックを予測すると、2030年以降は飽和の可能性が高くなる。それ以降の成長は、VRのような新しいメディア形普及による。

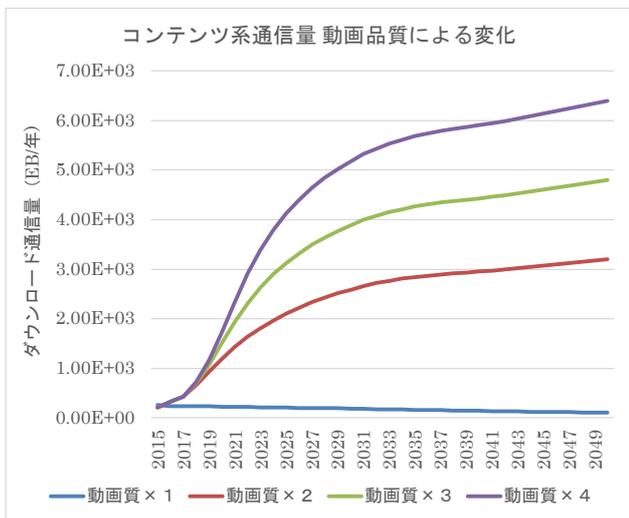


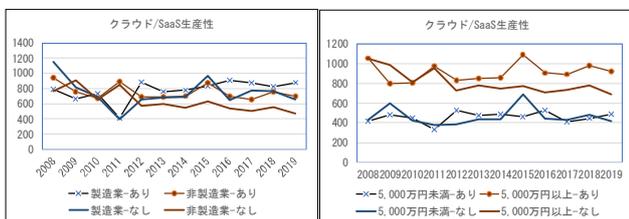
図5 コンテンツ系通信量 動画品質による変化

表5 各トラフィックの成長率

年成長率	A1+M	A2	B1+B2+B3	Total
2030/2010	22.5%	24.5%	21.0%	22.4%
2050/2010	11.4%	12.4%	8.4%	10.9%

### 3. テレワークの影響について

コロナ禍で注目された在宅勤務であるが、既述のように務省はすでに「通信利用動向調査」(企業編)でH21年からICT技術の利用動向や生産性の変化を企業に対し54項目に及ぶ質問からなるアンケート調査を行い、結果を公開している<sup>3)</sup>。特筆すべき点として、①IoT, AIによるデータ収集と分析、②クラウドコンピューティング/SaaSによる処理、③テレワークによる働き方、について採択企業と労働生産性の変化を業種/規模/地域別に示している点が挙げられる。結果の一例を図6に示すが、業種差よりも企業の規模の差が共通して差を与えている。



(a) 製造業・非製造業 (b) 資本金5000万以上・未満  
図6 クラウド/SaaS採用と生産性変化

$$(\text{生産性}) = 436 + 402 \cdot (\text{5000万以上ダミー}) + 49.5 \cdot (\text{クラウドダミー}) \quad (14.6) \quad (1.8) \quad R^2 = 0.821$$

テレワークについては、図7のように生産性の差は観測されるが、有意な回帰式は得られていない。

これに対し2020年3月13日の緊急事態宣言以降、全国の多くの企業が在宅勤務を取り入れた。この状況は、いくつかの調査機関が企業アンケートを行っているが、中で、パーソル総研<sup>4)</sup>は2020年4月10~12日に全国2.5万人規模

の調査を実施し、地域別・業種別・職種別テレワーク実施率に加え、4/3-4/10までの出勤率を県別に報告している。表6はこの集計結果である。

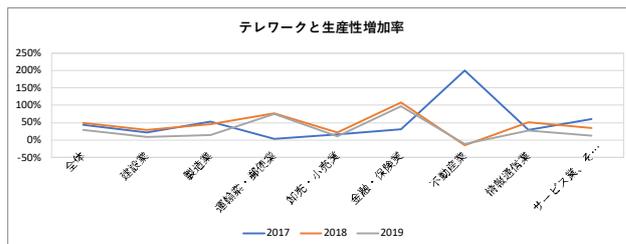
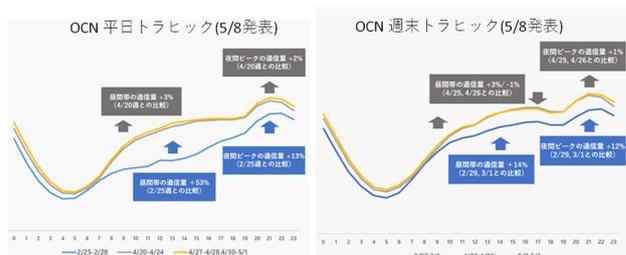


図7 テレワークの採用と生産性増加率

表6 テレワーク実施率・出勤率の地域別まとめ<sup>4)</sup>

	サンプル数	出勤率 (%)	テレワーク実施率 (%)	テレワーク出勤率 (%)
全体	(22477)	72.3	27.9	40.4%
北海道・東北	(1998)	81.2	12.5	73.5%
関東	(10003)	62.8	41.0	33.6%
東海・北陸・甲信越	(3743)	82.3	15.2	67.8%
近畿	(3886)	76.1	25.8	45.1%
中国・四国・九州	(2847)	80.9	12.4	80.6%
緊急事態宣言対象地域 (東京、神奈川、埼玉、千葉、大阪、兵庫、福岡)	(12678)	65.4	38.8	34.9%
それ以外の地域	(9799)	81.2	13.8	71.3%
東京圏 (東京、神奈川、埼玉、千葉)	(9093)	61.1	43.5	31.3%
名古屋圏 (愛知、岐阜、三重)	(2051)	82.9	17.8	60.9%
大阪圏 (大阪、兵庫、京都、奈良)	(3563)	76.1	26.6	44.6%

他方、テレワークの実施により通信トラフィックも変化したものと予想される。NTT Communications<sup>5)</sup>はインターネットトラフィック推移データを図8のように示しており、テレワークの増加によるトラフィックの増加は顕著であること、夜間、休日にもトラフィックが増えていることなど生活全般の情報化が進んだことも示唆している。NTT 東日本・西日本はさらに全国13地域について同様の変化グラフを示している。これらからトラフィックの変化を読み取り、パーソル総研のテレワーク業務率を比較を行う。まとめたものを表7に示すが、やはり地域差は大きい。



(a) 平日の変化 (b) 週末の変化

図8 緊急事態宣言前後のトラフィック変化<sup>5)</sup>

両者の間に、

$$(\text{一日平均トラフィック増加率}) = 1.05 + 0.28 \times (\text{テレワーク業務率}) \quad (4.24) \quad R^2 = 0.59, N = 13$$

の関係を得た。

北海道や、テレワーク業務率が極めて低いにも関わらず

トラヒックが上昇した四国・九州を除き比較的良い適合度を示した。

表7 NTT による地域別トラヒック変化とパーソル総研テレワーク業務率の比較

	テレワーク業務率	トラヒック増加率	
		Peak(12:00)	24時間平均
東京	33.9%	135.0%	113.1%
神奈川	27.7%	150.0%	114.6%
千葉	24.7%	142.9%	110.7%
埼玉	22.3%	150.0%	112.5%
茨城・栃木	7.7%	120.0%	105.0%
山梨・群馬・長野・新潟	3.0%	133.3%	108.3%
宮城・山形・福島・岩手・青森・秋田	2.9%	119.0%	104.8%
北海道	5.3%	103.4%	100.9%
大阪・京都	14.6%	127.8%	108.1%
兵庫・奈良・滋賀・和歌山・北陸	10.5%	130.4%	107.6%
東海	6.3%	132.3%	109.4%
中国・四国	0.4%	120.0%	105.0%
九州・沖縄	7.3%	134.4%	110.0%

パーソル総研調査による各業種のテレワーク実施率と出勤率の関係から、日本の県別の通勤用自動車利用の平日平均走行距離をどの程度減らせ、CO2 排出削減にどれほど貢献したかの推計を試みる。通勤に公共交通機関を利用する都市部では、テレワークによりどの程度通勤需要が減少したかを、電車の混雑率や移動量と比較検討を可能とすることが期待できる。しかし、このためにはパーソル総研の会社数を従業員数に一度変換する必要がある。

ここでは、県別(i)・業種別(j) 就業者数を県別テレワーク比率P(i)および業種別テレワーク比率q(j)を用い、全体として整合するよう、RAS 法で推計することを試みた。次に、県別の平均自動車通勤移動距離、通勤時間、パーソル総研調査に基づくテレワーク業務率(週 5 日のうち何%をテレワークにあてているか)を取り上げる。

まず、通勤の利用手段として自家用車を使用する人の割合は、平成 22 年国勢調査の「従業員・通学地による人口・産業等集計」<sup>11)</sup>をから県別に抽出した。平均自動車通勤距離は、東京理科大学 Web 調査<sup>12)</sup>から「平日の自動車利用主目的が通勤」であるサンプルを抽出し、そのサンプルの平均 1 日当たり移動距離を求める。ついで、国土交通省の平成 30 年住宅・土地統計調査<sup>13)</sup>にもとづき平均通勤時間を抽出する。こうして、テレワーク導入による自動車通勤からの排出 CO2 削減量と、回避された通勤時間を推計した。結果を図 9 にまとめる。テレワークによる通勤時間の節減は、明らかに首都圏で大きい。

「回避された自動車通勤」推計値に基づいて CO2 排出削減量を求めると、1.23Mt-CO2 削減となる。このとき、テレワーカーは全 6,180 万人中 1,460 万人と推定された。

産業構造が地域で異なるため、テレワーク可能な就業者の分布も地域ごとに異なる。もし、テレワーク可能な就業者が全国一律に週 2 日在宅勤務とした場合、2.95Mt-

CO2 の排出削減となる。もしパーソル総研の「会社からのテレワーク可能な就業者へのテレワーク指示率」に基づいて全国一律に週 2 日在宅勤務とした場合、4.33Mt-CO2 の排出削減となる。

これに対し、既存の国土交通省と日本テレワーク協会の 2004 年試算<sup>14)</sup>では、2010 年のテレワーカーの数を 1,295 万人と予測し、3.21-4.42 Mt-CO2 の削減を報告した。総務省(2010 年)は、テレワークにより 1990 年と 2020 年の比較で最大 1.03 Mt-CO2no の削減を試算した<sup>15)</sup>。今回の試算は、ほぼこれらの先行調査と整合している。

節減された通勤時間の時間価値については、加藤ら<sup>16)</sup>、業種や移動時刻等によっても差があるものの、通勤では 25.5 円/分/人を推計しており、用い節減された通勤の時間価値を求めると 10,680 億円(パーソル総研テレワーク実績)~37,682 億円(同会社からの指示ベース+週 2 日在宅勤務)となる。

#### 4. 結論と今後の展望

情報技術による生活の変化が大きいことは疑いない。これによりどのようにエネルギー消費が変化するかの推計を、コロナ禍によって集められたデータに基づき試みた。情報技術の影響は、①情報サービス市場委の増大による of ICT の電力消費と、②移動の代替によるエネルギー消費の削減(by ICT)の②側面があることは指摘されていたが、定量的な評価はこれまで困難であった。本研究では、既存の調査に基づき、これらの間を結ぶ評価試算を行い、テレワークの効果を推計した。

他方、of ICT の電力評価については、なお技術動向調査が必要であるが、ここでは、過去の動画配信を延長する限り、飽和に向かう傾向が示唆された。

本研究は、エネルギー・資源学会による「環境省 家庭部門の CO2 排出実態統計調査及び家庭からの二酸化炭素排出量の推計に係る実態調査 全国試験調査の調査票情報を用いて行う研究」<sup>17)</sup>の一環として家庭部門 CO2 排出実態と比較することで、ICT による働き方や住まい方の変化の将来予測が可能となる。これを次の課題とする。

#### 参考文献

- 1) 令和 2 年 10 月 26 日 第二百三回国会における菅内閣総理大臣所信表明演説)
- 2) 「革新的環境イノベーション戦略」令和 2 年 1 月 21 日 統合イノベーション戦略推進会議、内閣府 <https://www8.cao.go.jp/cstp/siryu/haihui048/siryu06-2.pdf>
- 3) 総務省、「通信利用動向調査」(企業編)、<https://www.soumu.go.jp/johotsusintokei/statistics/statistics05a.html>
- 4) パーソル総研、「新型コロナウイルス対策によるテレワークへの影響に関する緊急調査 調査結果」,

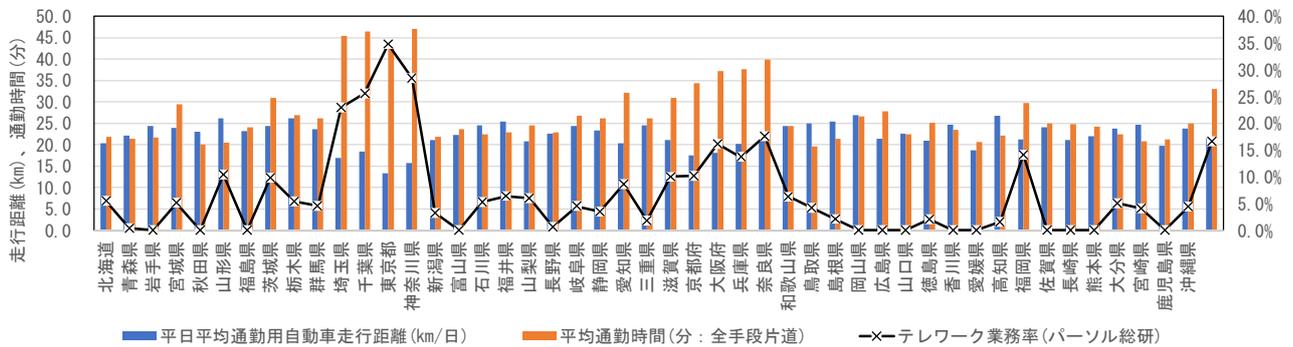
<https://rc.persol-group.co.jp/news/files/news-data.pdf> (2020/6/19 取得)

- 5) NTT コミュニケーションズ, インターネットトラフィック (通信量) 推移データ, <https://www.ntt.com/about-us/covid-19/traffic.html>, (2020/6/19 取得)
- 6) 総務省「我が国のインターネットにおけるトラフィックの集計・試算」[https://www.soumu.go.jp/joho\\_tsusin/eidsystem/market01\\_05\\_03.html](https://www.soumu.go.jp/joho_tsusin/eidsystem/market01_05_03.html)
- 7) 総務省, 「我が国の移動通信トラフィックの現状」<https://www.soumu.go.jp/johotsusintokei/field/tsuushin06.html>
- 8) 総務省情報通信政策研究所の「メディア・ソフトの制作及び流通の実態に関する調査研究」, [https://www.soumu.go.jp/main\\_content/000630317.pdf](https://www.soumu.go.jp/main_content/000630317.pdf)
- 9) 科学技術振興機構 低炭素社会戦略センター, 情報化社会の進展がエネルギー消費に与える影響 (Vol. 1) - IT 機器の消費電力の現状と将来予測 -, LCS-FY2018-PP-15, 2019
- 10) IEA, “Digitalization & Energy”, 2017, [https://www.iea.org/reports/digitalisation-and-](https://www.iea.org/reports/digitalisation-and-energy)

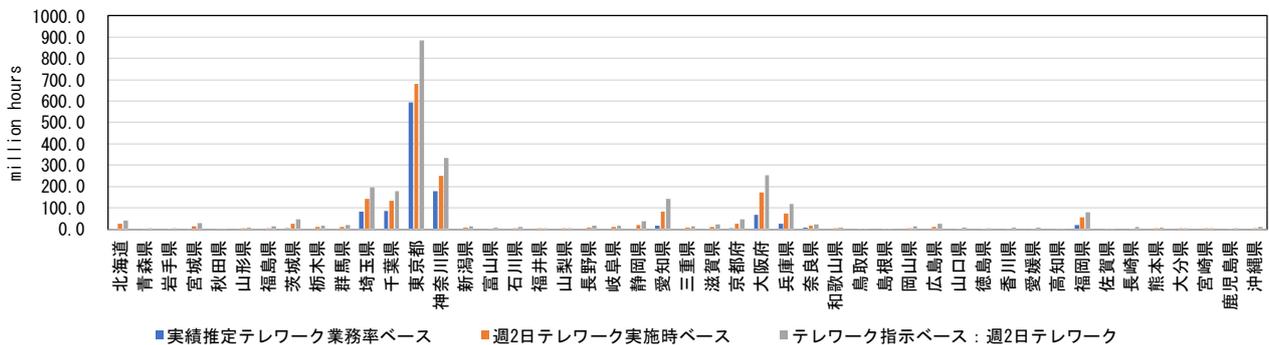
[energy](#)

- 11) 総務省, 平成 22 年国勢調査 (利用交通手段), [https://www.e-stat.go.jp/stat-search/files?page=1&layout=dataset&stat\\_infid=00013173584](https://www.e-stat.go.jp/stat-search/files?page=1&layout=dataset&stat_infid=00013173584)
- 12) Web アンケート調査, 東京理科大学 Green&Safety 研究センター (S1001018, 2011-2015 および科研費基礎研究 (C) (22560407, 2011-2013) による
- 13) 政府統計, 平成 30 年住宅・土地統計調査
- 14) 国土交通省, テレワーク導入ガイドブック, [https://www.mlit.go.jp/crd/daisei/telework/guidebook2009/05\\_3.pdf](https://www.mlit.go.jp/crd/daisei/telework/guidebook2009/05_3.pdf) (2020/7/20 取得)
- 15) テレワーク学会, 「テレワークが未来を創る」, インプレス R&D, 2015
- 16) 「道路交通の時間価値に関する研究」道路政策の質の向上に資する技術研究開発成果報告レポート, No. 21-1, H24, <https://www.mlit.go.jp/road/tech/jigo/h21/pdf/report21-1.pdf> (2020/7/20 取得)
- 17) 環境省, 家庭部門の CO2 排出実態統計調査, <http://www.env.go.jp/earth/ondanka/ghg/kateiCO2tokei.html>

県別通勤特性データ



テレワークによる節減通勤時間長 百万時間/年



テレワークによる自動車ガソリン節減量 百万L/年

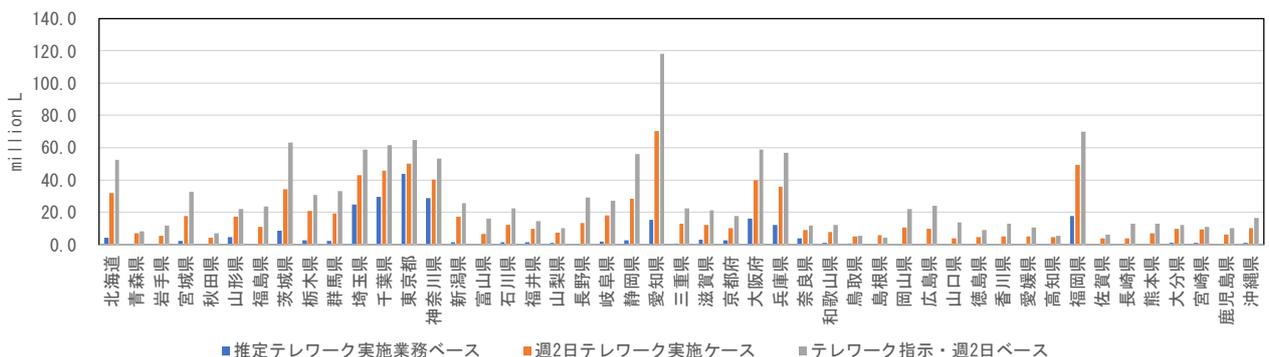


図9 輸送特性およびテレワークによる県別自動車ガソリン節減量とCO2排出節減量