



RIETI Discussion Paper Series 18-J-005

自動運転の導入による走行距離への影響： 家計への調査を用いた実証分析

岩田 和之
松山大学

馬奈木 俊介
経済産業研究所



Research Institute of Economy, Trade & Industry, IAA

独立行政法人経済産業研究所
<http://www.rieti.go.jp/jp/>

自動運転の導入による走行距離への影響：家計への調査を用いた実証分析¹

岩田和之（松山大学） 馬奈木俊介（経済産業研究所・九州大学）

要 旨

自動運転は運転者の利便性を向上させると考えられるため、今後普及していくことが予想される。一方で、その利便性の向上は運転者の自動車需要の増加につながる可能性もある。そこで、本研究は家計への調査²を用いて、自動運転が家計の自動車需要にどのような影響を与えるかについて実証的に検証を試みた。自動運転の評価の際には、自動運転によって運転時の疲労と事故リスクが現状の半分になると仮定した。分析の結果、平均的家計では自動運転によって年間走行距離が約 630km～3,273km 増加することが示された。仮に、国内の全自動車が自動運転に置き換わると仮定すると、この走行距離の増分は年間約 650 万 t-CO₂～3,382 万 t-CO₂ の増加につながる。したがって、自動運転の普及に際しては、燃費の良い自動車から導入するというような温室効果ガス抑制の視点での議論も必要になる。

キーワード：自動車、自動運転、走行距離、家計への調査

JEL classification: L62, R41

RIETI ディスカッション・ペーパーは、専門論文の形式でまとめられた研究成果を公開し、活発な議論を喚起することを目的としています。論文に述べられている見解は執筆者個人の責任で発表するものであり、所属する組織及び（独）経済産業研究所としての見解を示すものではありません。

¹本稿は、独立行政法人経済産業研究所（RIETI）におけるプロジェクト「人工知能等が経済に与える影響研究」の成果の一部である。

² RIETI が 2017 年 3 月に実施した平成 28 年度「自動運転車の潜在需要に関する Web 調査」。

1. 人工知能と自動車

現在、IoT (Internet of Things)、ビッグデータ、人工知能 (AI: Artificial Intelligence) に代表される劇的な技術革新がもたらされている。いわゆる第 4 次産業革命である。日本でも 2015 年に経済産業省内で新産業構造審議会が設けられたように、これらの技術革新は従来の産業構造は大きく変化させることが予想されている。この産業構造の変化はインターネットやコンピュータ産業などの当該技術のブレークスルーが起きている産業のみに留まらず、製造、農業、観光、金融、医療、教育など全ての産業に影響をもたらす。なぜなら、データなどの情報やロボットといった人工知能は全ての産業の基盤技術であるからである。例えば、建築業界ではドローンを活用した施工管理、医療業界では人工知能を活用した医療診断支援システム、教育業界では個々の学生の学習理解度に応じたアダプティブラーニングなどが導入されつつある。これらの新しい技術やシステムが従来の雇用を大きく代替する可能性も指摘されている (Frey and Osborne, 2017)。

この技術革新は本研究で取り上げる自動車の利用にも大きな影響を与える。それは自動運転車 (autonomous car) の登場である。自動運転車に搭載される自動運転技術は大きく 6 段階 (2016 年 10 月改定版) に分けられる (National Highway Traffic Safety Administration, 2016)。レベル 0 は自動化によるシステム介入がなく、常に運転者が自動車の制御 (操舵、制動、加速) を行うことを指す。逆にレベル 5 は周囲の監視を含めた自動車の運転操作を全てシステムが行い、人による制御が介入しないことを指す。レベル 1 から 4 については程度の差はあれ、人とシステムとが自動車制御を分担して行うことになる (表 1)³。したがって、レベルの数字が大きくなればなるほど、システムによる自動制御の度合いが大きくなる。2017 年現在では、レベル 2 の技術を導入している自動車はいくつか存在する。また、一部の自動車メーカーがレベル 3 の自動運転技術を搭載した自動車を販売すると発表されている段階であり、人の手による運転がほとんど必要ないレベル 4 以上の自動運転技術を搭載した自動車は発売されていない。国内自動車メーカーではトヨタが 2020 年代前半を目途⁴に、ホンダは 2025 年頃⁵にレベル 4 の技術を備えた自動車を実現させることを表明している。

³ レベルの違いについては SAE International (2016) にまとめられている。

⁴ 日本経済新聞記事より

(https://www.nikkei.com/article/DGKKASDZ24HY5_U7A720C1MM8000/ 最終アクセス日 2017 年 9 月 6 日)

⁵ 日刊工業新聞記事より

(<https://www.nikkan.co.jp/articles/view/00431444> 最終アクセス日 2017 年 9 月 6 日)

表 1. 自動運転のレベル

レベル	名前	定義
0	自動化無し	人間がすべての自動車制御を行う。
1	運転者支援	自動運転システムが人の運転制御の一部をたまに支援する。
2	一部自動化	自動運転システムが運転制御の一部を行い、運転者は周囲の監視と他の運転制御を行う。
3	条件付き自動化	人が運転制御をすぐにできることを前提とし、特定の状況を除いて、自動運転技術が全ての運転制御、周囲の監視を行う。
4	高自動化	特定の状況を除いて、自動運転技術が全ての運転制御、周囲の監視を行う。人の制御はない。
5	完全自動化	全ての状況において自動運転システムが全ての運転制御を行う。

現時点では、人が全く運転を行う必要のない自動車は存在しないものの、近い将来に高レベルの自動化技術を搭載した自動車の登場が予測されており、各自動車メーカーもその開発競争に力を注いでいる。このような自動車が市場に出回り、普及をした場合、消費者（運転者）の自動車利用行動は大きく変わる可能性がある。そして、その利用の頻度は自動運転による利便性の向上によって増加することが予想される。なぜなら、それまでは自動車を運転することが怖い、あるいは面倒だと考えていたような人にとっては高レベルの自動運転車は魅力的であるからである。例えば、公共交通が充実していない地域でのお年寄りの人にとって、自動運転車の利便性は非常に高いと考えられるし、雨の日に運転するのが嫌なため、雨の日には徒歩で移動をする人にとっても自動運転車は使い勝手のよい新技術となると考えられる。したがって、高い自動化がなされた自動車の登場によって、交通手段としての自動車の利用がどのように変化するかを予測することは今後の自動車にかかわる政策立案にとって重要なこととなる。

その理由として、自動車の利用は渋滞と気候変動という大きな社会問題と密接に関係するからである。これらの問題以外にも燃料の燃焼に伴う大気汚染という環境被害も生じるが、日本での大気汚染状況を考えると、上記3つの社会問題と比較して相対的に重要度が下がる。また、利用増加に伴って交通事故の増加も起きるかもしれない。しかし、十分に自動運転車が普及した場合、人工知能による交通事故回避能力は人それよりも高いため、交通事故自体は減少するとも考えられる。

一般的に、自動車の走行距離が増加すると渋滞は増加する。日本のデータは取り上げていないが、世界各国の都市別の渋滞ランキングを作成している INRIX(2016)によると、2016年に渋滞が起きているのはロサンゼルス、モスクワ、ニューヨーク、サンフランシスコなどの大都市である。東京や大阪などは地下鉄といった公共交通機関が発達しているため、諸外国よりも渋滞の程度は緩いかもしれない。しかし、国土交通省資料⁶によると渋滞による年間

6

http://www.meti.go.jp/committee/sankoushin/sangyougijutsu/chikyu_kankyo/yakusoku_souan_wg/pdf/005_07_00.pdf よりダウンロード可能（最終アクセス日 2017年9月6日）

の損失時間は約 50 億時間（一人当たり約 40 時間）と試算されており、現時点でも相当な時間が渋滞によって浪費されている。国土交通省（2008）によると、自家用車 1 台当たりの業務時間価値は 56.78 円／分と推計されている。したがって、この値を用いて渋滞によって生じる損失時間を貨幣換算すると、渋滞は年間で約 17 兆円もの（機会）費用をもたらしていることになる。自動運転による自動車利用増加の程度によってはこの損失がさらに膨れ上がる可能性もある。

日本の 2015 年の温室効果ガス排出量は約 12.3 億 t-CO₂ である（国立環境研究所、2017）。このうち、乗用車起因分は約 8.4%、貨物車起因分は約 6.2% となっており、併せて約 14.6% が自動車に起因するものとなっている。1990 年を 1 とした場合の、それぞれの排出量の推移を表したものが図 1 である。1990 年代の中盤以降、貨物車からの排出量は減少傾向にあり、1990 年と比較しても 2015 年の貨物車からの排出量は約 16% 減少していることがわかる。一方で、近年は自動車の燃費向上もあり、乗用車からの排出量は減少しているものの、1990 年比では 26% の増加という水準となっている。今後はプラグインハイブリッド車、電気自動車や水素自動車の普及が期待されていることから、乗用車からの温室効果ガスは減少するかもしれない。一方で、自動運転によって自動車の台数や走行距離が増加するのであれば、自動運転車はこれらのエコカーによる温室効果ガス削減効果を相殺してしまう可能性もある。

このように、自動運転車の増加は渋滞や気候変動を悪化させてしまうかもしれない。一方で、自動運転車の利便性によって、どの程度人々が自動車利用を増加させるかという研究は知る限り存在しない。そこで、本研究では 2017 年 3 月に筆者らが実施した家計への調査を用いて、家計の自動車利用に関する実態を把握する。そして、家計の状態の差から、自動運転車による走行距離増加の度合いを計量分析によって推計する。特に、レベル 5 の完全自動化による影響に着目する。したがって、本研究で分析する自動運転とは、運転者が何らの運転操作や周囲確認をする必要がないことを想定する。そして、どの程度の温室効果ガスが増加するかという点や、自動運転を考慮した自動車にかかわる政策についても簡潔に議論する。




図 1. 乗用車と貨物車からの温室効果ガス排出量の推移

2. 走行距離推計モデル

自動車利用に対する需要を推計するモデルは多くの研究で用いられている。なぜなら、既述したように、自動車の利用には渋滞や気候変動といった外部不経済が伴うため、適切な政策を作成するためにも、自動車利用の分析が不可欠だからである。また、1990年代頃まではでは大気汚染（窒素酸化物や硫黄酸化物）という外部性に対応するためにも走行需要を把握する必要があったという背景もある⁷。

例えば、都市計画と自動車走行需要との関係に着目し、人口（住宅）の高密化が人々の自動車の利用にどのような影響をもたらすかを検証した Brownstone and Golob (2009)では、居住地選択を考慮しつつ、自動車の走行需要関数の推定を行っている。2001年の米国カリフォルニア州での2,583世帯を対象に分析を行った結果、40%密度が上昇することで自動車の年間走行距離は4.8%増加し、ガソリン消費量も5.5%増加することを示している。

自動車の走行需要関数を推定しているという点では Brownstone and Golob (2009)と同じであるが、走行距離と自動車の燃費との関係に着目した研究も多数ある。いわゆる燃費改善の効果のうち、どれだけが走行距離の増加によって相殺されるかという自動車のリバウンド

⁷ 粒子状物質のうち、粒子の小さいPM2.5については現在でも対応が必要である (Kunugi et al., 2017)。

効果を検証する論文である。阿部、他（2017）では日本での790世帯のデータを用いて、大都市圏とそれ以外とでリバウンド効果が異なるかどうかを検証している。分析の結果、大都市圏でのリバウンド効果は確認されなかった一方で、それ以外の地域では約34%（燃費が1%改善すると0.34%の走行距離が増加）のリバウンド効果が存在することを示している。

本研究でも、上記の研究に倣い、走行需要関数を推定する。ただし、本研究で注目するのは、現在存在していないレベル5の完全自動運転である。そのため、レベル5の自動運転システムを搭載した自動車は従来の自動車（レベル2以下）と比較し、下記の特徴を持つと仮定する。

- ・運転者自らが運転操作、周囲確認をする必要がないため、運転に伴う疲労が小さい。
- ・人工知能が周囲を監視するため、交通事故に遭う（引き起こす）確率が小さい。

したがって、従来の自動車と本研究で扱う自動運転車との違いは、運転者の「運転による疲労」と「運転時の交通事故リスク」の2点となる。

個人*i*の自動車の年間走行距離を D_i とする。また、この個人の自動車運転時の主観的な疲労度合いを F_i 、交通事故に遭う主観的なリスクを R_i とする。そして、年間走行距離（ D_i^* ）が主観的な疲労（ F_i ）と主観的な事故リスク（ R_i ）、この個人と所有する自動車の様々な属性ベクトル X_i によって決定されると仮定すると、走行需要関数は(1)式のように表すことができる。

$$D_i^* = \alpha_0 + \alpha_1 F_i + \alpha_2 R_i + X_i \alpha_3 + \varepsilon_i \quad \dots (1)$$

ここで、 α_0 、 α_1 、 α_2 、ベクトル α_3 は推定すべきパラメータである。また、 ε_i は誤差項である。

個々人が自動車を運転する際に、どの程度疲労を伴うかという情報を変数（ F ）として得るために、家計への調査では「あなたが高速道路で長時間（1日中）、自動車を運転すると想定してください。このとき、あなたは何分に1回休憩を取りますか。」という質問を行った。回答者には30分、45分、60分と15分刻みで回答するように求めている。「休憩をしない」と回答した人は、999分という数値を代入している。仮にある人が自動車の運転が好きで、運転に伴って疲労をほとんど感じないのであれば、休憩をとるタイミングは長くなると考えられる。逆に、運転の疲労を非常に感じる人であれば、30分に1回という高頻度で休憩をとると想定される。したがって、休憩をするタイミング（時間）が大きければ大きいほど、運転による疲労は小さいということになる。ただし、「休憩をしない」と回答した人の扱いの頑健性を確認するため、分析では999分と代入した分析と、「休憩をしない」と回答した人を除いた分析を行う。

運転時の主観的な事故リスク（ R ）については、回答者の過去の交通事故経験を用いている。具体的には、「あなたはこれまでにご自身の過失がゼロではない事故（自動車保険を利用した事故）を何回起こしたことがありますか。自損事故、対人・対車両事故全てを含めた

回数をお答えください」という質問を行っている。回答者には0回、1回、以下1回刻みの選択肢を提示し、そこから回数を選ぶように依頼している。したがって、本研究では過去の事故回数が多い人ほど、運転時の事故リスクが大きいとみなす。

ただし、自動車の走行距離については実際の年間走行距離 (D^*) を尋ねるのではなく、「あなたが主に使用する乗用車（二輪車を除く）について伺います。年間でどの程度の距離を走行しますか。主なお仕事が自動車の運転である方は、個人として私的に使用される乗用車についてお答えください。」という質問を行っている。この回答の年間走行距離を D とする。回答者は1~999km、1,000~1,999km と1,000km刻みで回答してもらっている。選択肢の最大値は40,000km以上である。実際の年間走行距離 (D^*) ではなく範囲で回答してもらっている理由は、個々人が厳密に年間走行距離を把握してないと考えられるためである。

自動車の年間走行距離は自動車による移動サービスの需要量と考えることができる。一方で、運転時の疲労はその移動サービスの費用の一つ（機会費用）としてとらえることができる。したがって、運転時の疲労を多く感じる人や事故リスクの高い人ほど運転時の機会費用が高いため、自動車の運転を控える、つまり年間走行距離が短くなると考えられる。そのため、運転時の疲労 (F) と事故リスク (R) の推定された係数 $\hat{\alpha}_1$ 、 $\hat{\alpha}_2$ はそれぞれマイナス、プラスとなることが予想される。

年間走行距離 (D) は年間走行距離が1~999kmの場合には1、1,000~1,999kmの場合には2、2,000~2,999kmの場合には3、以下1000km刻みで1ずつ増加するように。したがって、 D_i^* と D_i は次のような関係にある。

$$D_i = 1 \text{ if } D_i^* \leq 999$$

$$D_i = 2 \text{ if } 999 < D_i^* \leq 1999$$

...

$$D_i = 42 \text{ if } 39999 < D_i^*$$

そのため、推定の際にはこの変数はカテゴリー変数として扱う必要がある。そこで、カットポイントを未知のパラメータとする順序プロビットモデルと、質問文で用いている数値をカットポイントとして採用する区間回帰モデルを用いて推定を行う⁸。

ただし、これらの推定では、説明変数が全て外生であることが必要となる。しかし、説明変数のうち、事故リスク (R) は内生変数である可能性が高い。なぜなら、事故リスク (R) は過去の事故回数を用いているため、事故回数は自動車を多く運転する人ほど多くなるこ

⁸ $D_i = m$ となる確率を $P(D_i = m)$ とする。このとき、この確率を (1) 式を用いて $P(D_i = m) = P(\mu_{m-1} < D_i^* \leq \mu_m)$ と表記する。ここで、順序プロビットモデルでは、(1) 式のパラメータ α_0 、 α_1 、 α_2 、ベクトル α_3 に加えて、 μ_{m-1} と μ_m も同時に推定するパラメータとなる。一方、区間回帰モデルでは μ_{m-1} と μ_m をパラメータとして同時に推定するのではなく、質問の選択肢の範囲（ただし、対数変換をしたもの）を用いる。例えば、 $P(D_i = 2) = P(\ln(999) < D_i^* \leq \ln(1999))$ というように扱い、最尤推定を行う。

とが予想されるからである。そこで、事故リスク (R) を内生変数として扱うために、2SRI 推定 (Terza et al., 2008) を導入する。

2SRI 推定は、通常の 2SLS 推定 (二段階最小二乗法) と同様のステップで推定する手法である。ただし、2SLS 推定は線形モデルのみに適用可能であるのに対し、2SRI 推定は最尤推定量のような非線形モデルにも適用が可能である。第一ステップとして、被説明変数を事故リスク (R) とする推定式を考える。事故リスク (R) は 0、1、2...、のような非負の整数値を取るカウントデータであるため、事故リスク (R) がポアソン分布に従うと仮定し、その期待値を r と表記すると、推定式は (2) 式のように表される。これはいわゆるポアソン回帰モデルとして知られている。

$$r_i = \exp(\beta_0 + \beta_1 IV_i + \beta_2 F_i + \mathbf{X}_i \beta_3) \cdot \cdot \cdot (2)$$

β_0 、 β_1 、 β_2 、ベクトル β_3 は推定すべきパラメータである。 IV は事故リスク (R) には影響を与えるものの、自動車の年間走行距離 (D^*) には影響を与えない操作変数である。本研究では、この変数として性格を尋ねている。調査では、「あなたの性格は、のんびりですか、せっかちですか。のんびり (1) ~ せっかち (10) の 10 段階でお答えください。」という質問を行っている。せっかちな人ほど事故を起こしやすい (Oña, et al., 2014)。一方で、自動車をどれだけ運転するかという意思決定については、個々人の生活・経済状況に大きく依存するため、運転者がせっかちだからといって自動車を多く運転するとは考えにくい。

第一ステップをポアソン回帰で推定し、事故リスクの予測値 (\hat{R}) と残差 ($e = R - \hat{R}$) を求める。そして、第二ステップとして、(1) 式の説明変数にこの残差 (e) を加え、(3) 式のように推定式を書き換える。

$$D_i^* = \gamma_0 + \gamma_1 F_i + \gamma_2 R_i + \gamma_3 e_i + \mathbf{X}_i \gamma_4 + \mu_i \cdot \cdot \cdot (3)$$

γ_0 、 γ_1 、 γ_2 、 γ_3 、ベクトル γ_4 は推定すべきパラメータである。(3) 式を推定することによって、自動車をより運転する人ほど事故を起こしやすいという事故リスク (R) の内生性問題に対応が可能となる。

そのほかの変数 (\mathbf{X}) のうち、自動車属性に関するものは、自動車の単位走行距離当たりの費用 (= ガソリン価格 / 実燃費)、エンジン排気量、自動車カテゴリー、購入年の 4 つの変数を用いている。自動車の実燃費については、「あなたが主に使用される乗用車 (二輪車を除く) の実際の燃費 (実燃費) に最も近い値をお選びください。自動車の運転をお仕事にされている方は、あなたが個人として私的にもっとも利用する乗用車についてお答えください。」というように、回答者の主観的な実燃費を尋ねている。自動車の燃費については実燃費とカタログ燃費の 2 種類が存在し、両者には差があり、実燃費はカタログ燃費よりも小さいことが指摘されている (阿部. 他, 2017)。そのため、カタログ燃費を用いる場合には、

その影響を過小評価することになる。そこで、本研究では直接実燃費を尋ねるという方法を用いている。エンジンの排気量については 660cc 以下（軽自動車）、661～1,000cc 以下、1,001～1,500cc 以下というように 500cc 刻みで保有する自動車の排気量を選んでもらった。

家計に関する属性ベクトル X としては、回答者の年齢、性別、最終学歴、職業、自動車に関する職であるかどうか、自分で運転することに対する好み、他の人が運転する自動車に乗ることに対する好み、家計の所得、家族人数、自動車保有台数、居住都道府県の 11 変数を用いている。好みを捉える 2 変数については、10 が「とても好き」、1 が「とても嫌い」という 10 段階で回答をしてもらっている。

3. データ

分析に用いるデータは独立行政法人経済産業研究所が株式会社日経リサーチに委託して 2017 年 3 月に実施した平成 28 年度「自動運転車の潜在需要に関する Web 調査」である。同調査では、全国の 18 歳から 69 歳の人を対象とし、18,526 人から回答を得ている。都道府県別のサンプル数は各都道府県の人口に応じて確保している。18,526 人から回答を得ているものの、自動車を保有していない人（4,545 人）や実燃費や排気量などの一部の変数を回答していない人がいるため、分析時のサンプル数は 10,456 人へと減少している。

各変数の記述統計を載せたものが表 2 である。表 2 を見ると、走行距離 (D) の平均は 7.87 となっている。この変数のデータは、年間走行距離が 1~999km の場合には 1、1,000~1,999km の場合には 2 というような扱いのため、7.87 という平均値は、年間走行距離がおおよそ 7,000km であるということになる。日本自動車工業会（2016）でも同様に、乗用車の平均年間走行距離 7,000km であるとしており、本研究でのデータと整合的である。

休憩間隔 (F) の平均は約 121 となっている。したがって、平均的家計は、高速道路で 2 時間に 1 回休憩を取っていることになる。ただし、この変数の最大値は 999 となっている。これは、「全く休憩をしない」と回答した人を意味する。そのように回答した人は 165 人（約 1.6%）存在しており、この回答者の存在は平均値を引き上げることになる。この回答者を除いた場合の平均値は約 107 となる。「全く休憩をしない」という回答者の扱いが難しいため、第 4 節ではこの回答者を含める場合と含めない場合の 2 パターンの分析を行う。

自動車の主観的な実燃費については約 13.8km/L となっている。日本自動車工業会（2016）でも平均燃費は 13km/L となっているため、燃費の悪い自動車に乗っている人が多いといったサンプリングバイアスは発生していないものと考えられる。自動車のカテゴリーについては、軽自動車を基準（全体の 24%）としている。全体のうち、22%がコンパクトカー、19%がミニバンとなり、スポーツ/SUV の自動車を保有している人は全体の 9%と最も少なくなっている。性格 (IV) については平均値が 6.0 であることから、ややせっかちな人が多くなっている。

表 2. 記述統計量

変数名	平均	標準偏差	最小値	最大値
走行距離(D)	7.87	5.88	1	41
休憩間隔(F)	121.36	118.22	30	999
事故回数(R)	0.74	1.27	0	25
性別(男性=1)	0.69	0.46	0	1
年齢	49.75	11.94	18	69
家族人数	1.93	1.18	0	4
自動車にかかわる職(Yes=1)	0.03	0.17	0	1
選好:運転すること	6.79	2.19	1	10
選好:他の人が運転する車に乗車	5.66	2.06	1	10
自動車保有台数	1.48	0.76	1	5
ln(走行費用)	2.34	0.40	0.94	4.89
排気量	3.24	1.61	1	11
自動車購入年	2010.78	5.11	1980	2017
性格(IV)	6.00	2.04	1	10

注) サンプル数は 10,456 である。分析時には所得ダミー、最終学歴ダミー、職業ダミー、自動車カテゴリーダミー、都道府県ダミーを用いているが、ここでは紙面の関係上、割愛している。

図 2 は走行距離 (D)、休憩間隔 (F) と事故回数 (R) のヒストグラムである。走行距離では最も多い回答が 6 (5,000km~5,999km) であり、次いで 11 (10,000km~10,999km) との回答が多くなっている。平均では 7.87 (年間走行距離で 7,000km 程度) ではあるものの、回答者の約半数は年間走行距離が 5,000km 未満となっている。休憩間隔については全体の約 35%が 120 分と回答している。国土交通省や日本自動車連盟 (JAF) でも少なくとも 2 時間に 1 回の休憩を推奨していることから⁹、120 分を選択する人が多くなったと推察される。事故回数 (R) については、平均では 0.74 回であるものの、約 62%の人が 0 回となっている。4 回以上と回答した人は全体の 2%程度になっており、多くの人がほとんど事故を起こしていないことがわかる。

⁹ 下記の国土交通省と日本自動車連盟の WEB ページを参照されたい。

http://www.mhlw.go.jp/seisakunitsuite/bunya/koyou_roudou/roudoukijun/dl/kousokubus-03_05.pdf (最終アクセス日 2017 年 10 月 28 日)

<http://qa.jaf.or.jp/drive/careful/05.htm> (最終アクセス日 2017 年 10 月 28 日)




図2. 走行距離 (D)、休憩間隔 (F) と事故回数 (R) の分布
 注) サンプル数は 10,456 である。

4. 分析結果

(3) 式に表している年間走行距離 (D_i^*) を被説明変数として 2SRI による推定を行った第二ステップの結果が表 3 である。第一ステップの結果は補論に載せている。推定では全モデルで所得ダミー¹⁰、最終学歴ダミー¹¹、職業ダミー¹²、自動車カテゴリーダミー¹³、都道府県ダミーを説明変数として組み入れているが、ここでは表 2 と同様にそれらは割愛している。

¹⁰ 所得は 18 のカテゴリーからなる。世帯所得が「年間 100 万円未満」なら 1、「100 万円台」なら 2、「200 万円台」なら 3、以下同様に「1,200 万円台」なら 14 となっている。それ以降は、「1,300 万円～1,500 万円未満」なら 15、「1,500 万円～2,000 万円未満」なら 16、「2,000 万円～3,000 万円未満」なら 17、「答えたくない」との回答は 18 としている。

¹¹ 最終学歴は「小・中学校」、「高校・旧制中学校」、「高等専門学校」、「専修学校」、「短期大学」、「大学」、「大学院」、「その他」、「答えたくない」の 9 区分から構成されている。

¹² 職業は「会社員」、「団体・組合・諸法人」、「公務員」、「専門職（医師、弁護士、教員など）」、「自営業」、「自由業」、「会社経営・役員」、「農林水産業」、「パート・アルバイト」、「専業主婦・主夫」、「学生」、「無職」、「その他」の 13 区分である。

¹³ 自動車のカテゴリーは「軽自動車」、「ミニバン」、「コンパクト」、「セダン」、「ワゴン」、「スポーツ/SUV」の 6 区分としている。

既述したように、推定は2つの方法を用いている。表3のモデル(1)と(3)は順序プロビットを、モデル(2)と(4)は区間回帰を採用して分析した結果である¹⁴。また、モデル(1)と(2)は全サンプル(10,456)を用いて分析した結果であり、モデル(3)と(4)は休憩間隔の質問に対して、「全く休憩をしない」と回答した人を除いたサンプル(10,291)を用いて分析した結果である。

事故回数(R)の係数は、全てのモデルで有意にマイナスの値が得られている。このことは、事故回数が多い人、つまり事故リスクが高い人ほど走行距離が短くなっていることを示している。また、残差(e)の係数も全モデルで有意になっていることから、事故回数(R)は内生変数であることが示されており、かつ、補論の結果からも操作変数が機能していることがわかる。したがって、この内生問題(逆因果の存在)については適切に対応できていることがわかる。

自動運転のもう一つの特徴である疲労に関しても、全モデルで休憩間隔(F)の係数は1%水準で有意にプラスの値を取っている。このことは、休憩の間隔が長い人ほど走行距離が長くなることを示している。本研究での自動運転車の特徴は、従来の自動車に比べて運転に伴う疲労が小さいとしている。したがって、自動運転車が導入された場合には、休憩する間隔が長くなることになる。そのため、自動運転の導入は運転時の疲労を軽減することを通じて、走行距離の増加をもたらすことになる。したがって、自動運転が導入された場合、事故リスクと運転時の疲労が共に減少することを通じて、走行距離が増加することが示された。

その他の回答者に関する変数については、性別(男性=1)の係数がプラスに有意となっている。したがって、女性よりも男性の方が長く自動車を運転するといえる。また、年齢と自動車にかかわる職に就いているという変数の係数もプラスに有意な値を示していることから、高齢で自動車にかかわる職に就いている人ほど年間走行距離が長くなるといえる。さらに、自分で運転することが好きな人や、他人が運転する車に乗ることが嫌いな人ほど、走行距離が増加することも示されている。これらの結果は直観的にも整合的なものとなっている。

自動車属性に関する推定結果としては、走行費用が小さくなるほど走行距離が増加することが全てのモデルで示されている。このことはリバウンド効果として知られている(Khazzoom, 1980)。モデル(2)と(4)の区間回帰では、走行距離(D)と走行費用は対数変換を行っている。そのため、走行費用の係数は直接リバウンド効果を示すものとなる。したがって、リバウンド効果は31~32%程度存在している。ただし、日本のリバウンド効果を扱った研究を見ると、阿部.他(2017)のリバウンド効果は20%、Iwata & Matsumoto(2016)は23%となっており、本研究の推定値はそれらの値よりも大きいものとなっている¹⁵。この

¹⁴ 走行距離が1~999kmの場合には、走行距離の変数は1を取っている。したがって、変数が1の場合の区間は下限値1、上限値999となる。走行距離の変数が2を取る場合の下限値は1,000、上限値は1,999である。区分回帰の際には、この区間に関するデータを対数変換して推定を行っている。

¹⁵ リバウンド効果の推定値は短期と長期が存在する。本研究は一時点のクロスセクション

理由として、これらの先行研究では実燃費ではなくカタログ燃費を用いていることが考えられる。日本自動車工業会（2013）で述べられているように、実燃費はカタログ燃費よりも低いことが多い。そのため、カタログ燃費を用いた推定値は実燃費を用いたものと比べて過小となってしまう。

表3. 走行距離（D）の推定結果

	モデル(1) 順序プロビット 全サンプル	モデル(2) 区間回帰 全サンプル	モデル(3) 順序プロビット 一部サンプル	モデル(4) 区間回帰 一部サンプル
事故回数(R)	-0.187* (0.109)	-0.222** (0.0889)	-0.260** (0.105)	-0.285*** (0.0841)
残差(e)	0.258** (0.109)	0.277*** (0.0889)	0.333*** (0.105)	0.340*** (0.0842)
休憩間隔(F)	0.000430*** (0.000102)	0.000358*** (8.45e-05)	0.00293*** (0.000322)	0.00256*** (0.000264)
性別（男性=1）	0.224*** (0.0403)	0.214*** (0.0334)	0.219*** (0.0390)	0.209*** (0.0322)
年齢	0.00239 (0.00196)	0.00419** (0.00164)	0.00309* (0.00187)	0.00474*** (0.00156)
家族人数	-0.0173* (0.0104)	-0.0168** (0.00856)	-0.0174* (0.0106)	-0.0173** (0.00863)
自動車にかかわる職（Yes=1）	0.160*** (0.0588)	0.134*** (0.0458)	0.165*** (0.0586)	0.133*** (0.0453)
選好：運転すること	0.0718*** (0.00609)	0.0654*** (0.00509)	0.0687*** (0.00592)	0.0622*** (0.00490)
選好：他の人が運転する車に乗車	-0.0246*** (0.00543)	-0.0206*** (0.00449)	-0.0231*** (0.00543)	-0.0190*** (0.00445)
自動車保有台数	0.173*** (0.0204)	0.141*** (0.0165)	0.183*** (0.0204)	0.150*** (0.0163)
ln(走行費用)	-0.434*** (0.0351)	-0.319*** (0.0296)	-0.430*** (0.0349)	-0.312*** (0.0292)
排気量	0.100*** (0.0124)	0.0761*** (0.0101)	0.0983*** (0.0125)	0.0739*** (0.0101)
自動車購入年	0.0168*** (0.00228)	0.0139*** (0.00192)	0.0163*** (0.00226)	0.0133*** (0.00188)
ln(sigma)		-0.191*** (0.00877)		-0.199*** (0.00881)
定数項		-19.51*** (3.892)		-18.51*** (3.819)
対数尤度	-30486	-12942	-28355	-29941
Wald値	1902.4***	791.2***	1832.9***	2001.0***
サンプルサイズ	10456	10456	10291	10291

注) 括弧内の値は頑健な標準誤差である。*、**、***はそれぞれ10%、5%、1%水準で有意

データを用いているため、長期の推定値となる。そこで、ここで比較している先行研究は長期のリバウンド効果を推定しているものを挙げている。

であることを示している。推定では全モデルで所得ダミー、最終学歴ダミー、職業ダミー、自動車カテゴリーダミー、都道府県ダミーを入れているが、ここでは表 2 と同様にそれらの推定結果は割愛している。

排気量の係数も、全てのモデルで有意にプラスの値を取っている。この結果は阿部・他 (2017) や De Borger et al. (2015) の結果と同様である。したがって、排気量の大きな自動車を保有している人ほど、走行距離が長くなっている。また、自動車購入の係数もプラスとなっている。このことは、新しい車ほど走行距離が長くなることを示している。このことも Su (2012) や Ficano and Thompson (2014) の結果と整合的である。

5. 自動運転導入による走行距離と温室効果ガス排出量変化

この節では、第 4 節での推計結果を用いて、高レベルの自動運転車が登場した場合、走行距離および温室効果ガスがどの程度増加するかを試算する。自動運転が未導入の状態は現在の状況であるとし、表 3 の推定結果からそれぞれの走行距離の予測値を計算した。ただし、順序プロビットモデルを採用しているモデル (1) と (3) についてはカテゴリーデータである \hat{D} が予測値となり、区間回帰モデルのモデル (2) と (4) の予測値は走行距離 \hat{D}^* となる。モデル別の予測値の分布を示したものが図 3 である。水色のバーが、自動運転が無い現状の走行距離予測値の分布である。これは表 3 の推定結果による予測値である。

一方、白色のバーは自動運転が導入された場合の走行距離予測値の分布を示している。ここでは、自動運転が導入された場合、運転時の疲労と事故リスクが半減するものと仮定する。疲労については休憩間隔 (F) を、事故リスクについては過去の事故回数 (R) をそれぞれの代理変数として分析では用いている。そのため、この自動運転導入による疲労と事故リスクが半減するということは、休憩間隔 (F) が倍に、事故回数 (R) が半分になることを意味する。そこで、休憩間隔 (F) と事故回数 (R) の値を外生的にそれぞれ 2 倍、半分に変化させた後に、走行距離の予測値を計算している。

自動運転が無い場合とある場合の走行距離の分布を比べると、全てのモデルにおいて自動運転がある場合の分布は無い場合の分布よりもやや右方に位置していることが見て取れる。これは、表 3 の推定結果にあるように、休憩間隔 (F) が走行距離に対してプラスの影響を、事故回数 (R) はマイナスの影響を与えているからである。モデル (1)、(2) と (3)、(4) とでは後者の休憩をしないとの回答者を除いた分析結果のほうが自動運転による影響が大きいことが図から見て取れる。

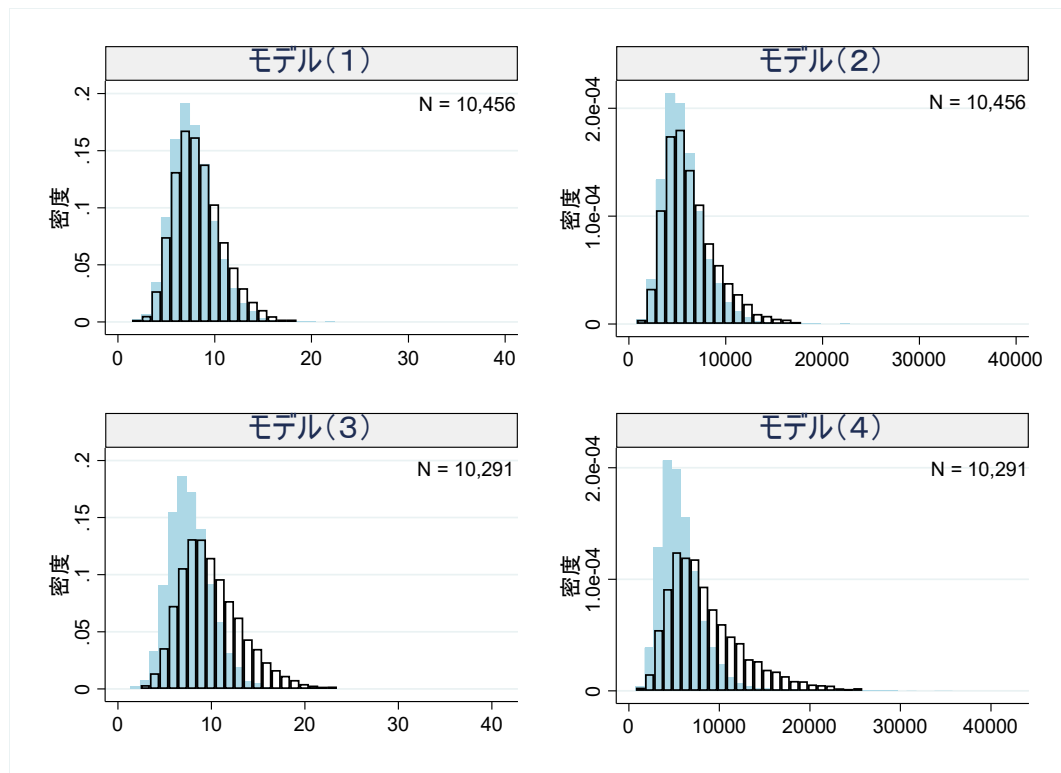


図3. 自動運転の有無別の走行距離 (D および D^*) の分布

注) 推定モデルの違いによって、モデル (1) と (3) については走行距離 (D) の分布を、モデル (2) と (4) については走行距離 (D^*) の分布を表している。

表 4 には自動運転が無い現状のケースと、導入されたケースでの走行距離予測値の平均値を載せている。モデル (1) と (3) は順序プロビットモデルのため、走行距離はカテゴリー変数である D であるため、区間回帰モデルを用いたモデル (2) と (4) の走行距離 (D^*) とは直接比較はできない点に注意が必要である。モデル (1) では自動運転が無い現状では平均で 7.80 (D は 1 増えると D^* が 1,000km 増加するため、おおよそ年間走行距離で 6800km) であるのに対し、自動運転がある場合には 8.43 へと 0.63 (約 8%) 増加している。したがって、モデル (1) では自動運転によって年間走行距離が約 630km 増えることを意味している。同じ推定手法を用いているモデル (3) では自動運転による年間走行距離の増分は増え、約 2,300km (約 30%) となっている。区間回帰モデルを用いているモデル (2) では、自動運転によって年間走行距離が 1,000km 弱 (約 17%) 増加し、モデル (4) では約 3,300km (約 58%) も増加することが示されている。以上から、自動運転によって運転時の疲労と事故リスクが減少することによって、モデルによって幅があるものの平均的な家計では年間走行距離が約 600km~3,300km 増加することが示された。

ただし、モデル (1)、(2) と (3)、(4) では図 3 の分布からわかるように、自動運転による平均的な家計の走行距離増加は後者の方が大きくなっている。このことは、高速道路で運

転時に「休憩をしない」と回答した人の扱いが重要であることを示している。なぜなら、モデル (1) と (3) での走行距離の増分は約 3.7 倍も差があり、モデル (2) と (4) では約 3.4 倍になっているからである。過度に休憩を取らない人（運転時の疲労が極端に少ない）にとっては自動運転による疲労軽減の効果はそうではない人に比べて小さくなってしまう。そのため、「休憩をしない」と回答した人を除いた場合のモデル (3) と (4) はモデル (1) と (2) よりも大きな増分が確認されたと考えられる。

表 4. 一台当たりの走行距離予測値の平均値

	サンプル サイズ	自動運転 無し	自動運転 あり	走行距離 増分	ガソリン 消費量増分
モデル(1)	10456	7.80	8.43	0.63	45.5
モデル(2)	10456	5663.9	6630.3	966.4	70.0
モデル(3)	10291	7.79	10.13	2.33	168.9
モデル(4)	10291	5679.0	8951.8	3272.7	236.7

次に、この走行距離の増分を用いて温室効果ガス排出量がどれだけ増加するかを試算する。平均的家計の走行距離の増分を主観的燃費で除算したガソリン消費量の増分を表 4 の最右列に載せている。主観的燃費の平均値は約 13.8km/リットルであるため、約 600km～3,300km の走行距離の増分は、ガソリン消費量に直すと約 46 リットル～237 リットルとなる。

自動車登録情報協会によると、2017 年 3 月末時点で国内の乗用車は 61,253,300 台登録されている。もし、自動運転によって自動車登録台数が変化しないのであれば、ここで試算した 1 台当たりのガソリン消費量増分とガソリンの温室効果ガス排出量原単位¹⁶を用いて、自動運転が国内で 100%搭載された場合、どの程度の温室効果ガス増加がもたらされるかが試算できる。モデル (1) の場合の計算式は以下になる。

$$\text{温室効果ガス排出量増分} = 61,253,300 \text{ (台)} \times 45.5 \text{ (リットル/台)} \times 2.332 \text{ (kg-CO}_2\text{/リットル)} = \text{約 } 650 \text{ 万 t-CO}_2$$

試算の結果、モデル (1) では自動運転によって年間 650 万 t-CO₂が増加することになる。また、自動運転の影響が最も大きいモデル (4) の場合には、約 3,382 万 t-CO₂の増加となる。したがって、自動運転を導入すると、走行距離の増加を引き起こし、結果として温室効果ガスの増大をもたらすことになる。そして、その増分はモデルによって異なるものの、自動運転が全ての車に搭載された場合には、少なく見積もっても年間 650 万 t-CO₂にも及ぶこ

¹⁶ ガソリンの単位当たり二酸化炭素排出量のデータは下記の環境省 WEB サイトより引用している。<https://www.env.go.jp/council/16pol-ear/y164-04/mat04.pdf> (最終アクセス日 2017 年 10 月 29 日)

とが示された。

6. 政策含意と今後の課題

本研究では高レベル自動運転が導入された場合、どの程度の走行需要が増加し、その結果としてどの程度の温室効果ガス排出量が増加するかの試算を行った。高レベル自動運転搭載車量は現時点で未登場のため、本研究では、「高レベル自動運転搭載車に乗ると、運転者の運転時の疲労と事故リスクが現状の半分になる」との仮定を導入し、計量分析を通じてそれらの変化を推定した。

2017年3月に実施した平成28年度「自動運転車の潜在需要に関するWeb調査」を用いて、運転時の疲労（休憩間隔）が自動車走行距離に与える影響を分析した。調査では10,456人から回答を得ることができた。分析の結果、運転時の疲労が大きいほど走行距離は少なくなることが頑健に示された。したがって、自動運転の導入によって運転時の疲労が半減することは、走行距離を増加させることにつながることを示された。また、事故リスクが高い人ほど走行距離が短くなることも確認された。したがって、自動運転によって事故リスク減少を通じて走行距離が増加することはいえる。自動運転による疲労と事故リスクの半減は、平均的家計の走行距離を年間で600～3,300km増加することにつながる。そして、この増加はガソリン消費量を約45リットル～237リットル増加することになる。もし、国内の全車両に自動運転が導入された場合には、この走行距離の増分は650万t-CO₂～3,382万t-CO₂の増加をもたらすことになる。つまり、高レベルの自動運転は少なくない走行距離と温室効果ガスの増加をもたらすことになる。

また、本研究では取り上げなかったが、走行距離の増加によって温室効果ガス以外の外部費用も増加する可能性も十分に考えられる。例えば、都市部での渋滞や窒素酸化物や硫黄酸化物、粒子状物質などの大気汚染などがあげられる。これらは走行距離と関係していることが指摘されている（金本、他、2006）。

本研究での結論から、今度の高レベル自動運転の導入に関して2つの政策含意を導くことができる。第1に、燃費の悪い自動車ではなく、ハイブリッド車やプラグインハイブリッド車、電気自動車などの燃費の良い自動車に優先して自動運転車を導入する必要がある。なぜなら、燃費の悪い自動車に自動運転を導入してしまうと、温室効果ガスの排出量がさらに増大してしまうからである。第2に、今後の自動車の総台数にも依存するが、走行距離の増加によって交通状況が変わってくる（渋滞の増加の）可能性があるため、道路を含めた交通インフラの状況も注視する必要がある。

最後に、本研究での分析の改善点について言及する。第1に、本研究では現在自動車を保有している人の行動から、現在未導入である自動運転車による走行需要の変化を推測している。そのため、自動運転車の購買行動については考慮することができていない。もし、自動運転車の登場によって、現在自動車を保有していない人も自動車を保有するようになる

とすれば、自動運転車によってもたらされるマイナスの影響はさらに大きなものとなる。第2に、自動運転車と既存の自動車との違いを、運転時の疲労の度合いで測っていることがあげられる。自動運転車は、交通事故を引き起こす、あるいは遭遇する確率が既存の自動車よりも低いと考えられる。そのため、交通事故確率に関する違いも分析に組み入れる必要がある。ただし、交通事故確率を考慮した場合には、自動運転車の走行距離増加の影響はさらに大きなものとなる。本研究の分析結果は、これらの点を考慮していないため、影響を過小評価していると考えられる。これらの点を考慮することは今後の課題である。第3に、本研究では、自動運転導入による走行距離の増加は、個々人の生活のどの移動部分によってもたらされるものであるかは明らかにしていない。例えば、電車で通勤していた人が自動車で通勤するようになるのか、自宅周辺の店舗で買い物をしていた人が自動車で遠くの店舗に行くようになるのか、それらの違いを区別していない。このためには、人々の詳細な目的別トリップデータの分析が必要となる。

参考文献

Brownstone, D. and Golob, T. F. (2009) “The impact of residential density on vehicle usage energy consumption,” *Journal of Urban Economics*, 65, pp. 91-98.

De Borger B., Mulalic, I. and Rouwendal, J. (2015) “Measuring the rebound effect with micro data. Tinbergen,” *Institute Discussion Paper*, 15-39/VIII

Ficano, C. C. and Thompson, P. (2014) “Estimating rebound effects in personal automotive transport: gas price and the presence of hybrids,” *American Economists*, 59(2), pp. 167-175.

Frey, C. B. and Osborne, M. A. (2017) “The future of employment: How susceptible are jobs to computerization?,” *Technological Forecasting and Social Change*, 114, pp. 254-280.

Khazzoom, J.D. (1980) “Economic implications of mandated efficiency in standards for household appliances,” *Energy Journal*, 1(4), pp. 21-40.

Kunugi, Y., Arimura, T. H., Iwata, K., Komatsu, E. and Hirayama, Y. (2017) “Cost-efficient strategy for reducing particulate matter 2.5 in the Tokyo Metropolitan area: An integrated approach with aerosol and economic models,” *WINPEC Working Paper Series*, No.E1709.

Iwata K. and Matsumoto, S. (2016) “Use of hybrid vehicles in Japan: An analysis of used car market data,” *Transportation Research Part D, Transport and Environment*, 46, 200-206.

INRIX (2016) *INRIX Global Traffic Scorecard*.

(<http://www.sciencedirect.com/science/article/pii/S0959652617319728> 最終アクセス日 2017 年 9 月 6 日)

Linn, J. (2013) “The rebound effect for passenger vehicles,” *RFF Discussion Paper*, 13-19.

National Highway Traffic Safety Administration (2016) *Federal Automated Vehicles Policy: Accelerating the Next Revolution in Road way Safety*.

(https://one.nhtsa.gov/nhtsa/av/pdf/Federal_Automated_Vehicles_Policy.pdf 最終アクセス日 2017 年 9 月 6 日)

Oña, J., De Oña, R., Eboli, L., Forciniti, C and Mazzulla, G. (2014) “How to identify the key factors that affect driver perception of accident risk: A comparison between Italian and Spanish driver behavior,” *Accident Analysis and Prevention*, 73, pp. 225-235.

SAE International (2016) *Automated driving: Levels of driving automation are defined in new SAE International standard J3016*.

(http://www.sae.org/misc/pdfs/automated_driving.pdf 最終アクセス日 2017 年 9 月 6 日)

Su, Q. (2012) “A quantile regression analysis of the rebound effect: Evidence from the 2009 National Household Transportation Survey in the United States,” *Energy Policy*, 45, 368–377.

Terza, J. V., Basu, A. and Rathouz, P. J. (2008) “Two-stage residual inclusion estimation: Addressing endogeneity in health econometric modeling,” *Journal of Health Economics*, 27, pp. 531-543.

阿部達也、松本茂、岩田和之（2017）「大都市圏と地方部の自動車のリバウンド効果：家計調査を用いた実証分析」『環境科学会誌』30(3)、203-214 頁。

金本良嗣、蓮池勝人、藤原徹（2006）『政策評価のマイクロモデル』、東洋経済新報社。

国土交通省（2008）『時間価値原単位および走行経費原単位（平成 20 年価格）の算出方法』。

(<https://www.mlit.go.jp/road/ir/ir-council/hyouka-syuhou/4pdf/s1.pdf> 最終アクセス日 2017 年 9 月 6 日)

国立環境研究所（2017）『日本国温室効果ガスインベントリ報告書 2017 年』。

(http://www.gio.nies.go.jp/aboutghg/nir/2017/NIR-JPN-2017-v3.1_J_web.pdf 最終アクセス日 2017年9月6日)

日本自動車工業会 (2016) 『2015年度乗用車市場動向調査』。

(http://www.jama.or.jp/lib/invest_analysis/pdf/2015PassengerCars.pdf 最終アクセス日 2017年10月28日)

溝渕健一 (2011) 「乗用車のリバウンド効果—マイクロパネルデータによる推定—」『環境経済・政策研究』4(1)、32-40頁。

補論

付表1は2SRI推定の第一ステップである事故回数(R)の推定結果である。事故回数(R)はカウントデータのため、ポアソン回帰モデルで推定を行っている。モデル(1)と(2)はそれぞれ全サンプル、運転時に「休憩をしない」と回答した人を除いたサンプルを用いて分析した結果である。したがって、下記のモデル(1)の推定結果は、表3でのモデル(1)と(2)に用い、下記のモデル(2)は表3のモデル(3)と(4)に用いている。表3にある分析結果のサンプルサイズよりも付表1のものは多くなっているが、これは走行距離(D)に欠損値があるためである。

2SRI推定の内生性対応では、第一ステップでの操作変数の係数が有意であることが必要である。付表1の推定結果を見ると、性格(IV)は両モデルともに1%水準で有意に事故回数(R)にプラスの影響を与えていることがわかる。したがって、内生性については適切に対処できているといえる。また、性格(IV)の係数がプラスであることから、せっかちな性格である人ほど事故を起こしやすいという事前の予想と同じ結果が得られている。

付表 1. 事故回数 (R) の推定結果

	(1) 全サンプル	(2) 一部サンプル
性格(IV)	0.0255*** (0.00853)	0.0269*** (0.00856)
休憩間隔(F)	0.000272 (0.000194)	0.00202*** (0.000406)
性別 (男性=1)	0.336*** (0.0528)	0.314*** (0.0534)
年齢	0.0208*** (0.00157)	0.0202*** (0.00159)
家族人数	-0.0238 (0.0172)	-0.0310* (0.0162)
自動車にかかわる職 (Yes=1)	0.0841 (0.0944)	0.0383 (0.0947)
選好：運転すること	0.0416*** (0.00840)	0.0380*** (0.00847)
選好：他の人が運転する車に乗車	-0.0106 (0.00917)	-0.00853 (0.00932)
自動車保有台数	0.143*** (0.0233)	0.149*** (0.0215)
ln(走行費用)	0.203*** (0.0506)	0.194*** (0.0505)
排気量	9.72e-05 (0.0225)	0.00134 (0.0226)
自動車購入年	0.0108*** (0.00357)	0.00924*** (0.00350)
定数項	-23.88*** (7.227)	-20.82*** (7.090)
対数尤度	-13240	-12942
Wald値	787.0***	791.2***
サンプルサイズ	10678	10504

注) 括弧内の値は頑健な標準誤差である。*、**、***はそれぞれ10%、5%、1%水準で有意であることを示している。推定では全モデルで所得ダミー、最終学歴ダミー、職業ダミー、自動車カテゴリーダミー、都道府県ダミーを入れているが、ここでは表2と同様にそれらの推定結果は割愛している。