

職業の自動化確率についての日米比較

Frey & Osborne モデルの再現と日本版 O-NET データへの拡張

富士通 Japan 株式会社 千葉 茂樹

国立社会保障・人口問題研究所 福田 節也

《要旨》

テクノロジーの発展により、我々が仕事において行っている様々なタスクのうち、どの程度が人の手を介することなく実行可能となるのかについての議論、いわゆる仕事の自動化に関する議論が注目を集めている。我が国における労働力人口は 2017 年の 6,720 万人から 2040 年には 5,846 万人にまで減少すると見込まれている。テクノロジーによる自動化により、これまでよりも少ない就業人口で、従来よりも高い生産性を達成できるか否かは、日本経済における喫緊の課題であると言える。本研究では、Frey と Osborne (2013, 2017) が構築した職業の自動化確率の推計モデルを再現し、米国の 2010 年と 2020 年における職業の自動化確率を推計した。さらに、このモデルを拡張することにより、2020 年の日本版 O-NET の職業情報データを用いて、日本における職業別自動化確率の推計を行った。

米国の 2010 年と 2020 年における職業の自動化確率を計算した結果、同期間における職業の自動化確率の平均値は 3.0%ポイントほど低下していた。この変化について要因分解を行ったところ、平均自動化確率の減少のうち約 9 割が、米国における就業人口が自動化確率の低い職業にシフトしたことに因るものと示された。なお、残りの約 1 割は職業大分類別の平均自動化確率の低下に因るものであった。また、この再現モデルを拡張したモデルにより、2020 年の日米の職業自動化確率について比較した結果、自動化確率が 70%以上である職業の就業者割合は日本が 41.1%、アメリカが 44.0%と推計された。両国における平均自動化確率の違いについて要因分解を行った結果、同一職業であっても日本の方が米国よりも自動化されにくい特性をもつことが示唆された。

(備考) 本論文は、執筆者個人の責任で発表するものであり、執筆者の所属組織や独立行政法人 労働政策研究・研修機構としての見解を示すものではない。

(連絡先) fukuda-setsuya@ipss.go.jp

目次

I	はじめに	1
II	先行研究	2
III	Frey & Osborne による職業別自動化確率の推計方法	6
IV	Frey & Osborne による分類モデルの再構築	7
V	日本版 O-NET データに対応する拡張モデルの構築	9
VI	拡張モデルの推計結果	14
<付録>	機械学習モデル実行手順の解説	25

I はじめに

コンピューターやロボット，人工知能（AI）等のテクノロジーの進展により，未来における仕事のあり方に注目が集まっている。なかでもこれらのテクノロジーの発展により，我々が仕事において行っている様々なタスクのうち，どの程度が人の手を介することなく実行可能となるのかについての議論，いわゆる仕事の自動化に関する議論が注目を集めている。この議論の嚆矢となったのはFreyとOsborneによる研究（Frey and Osborne 2013, 2017）である。彼らの研究では，米国労働省が公開している職業情報データベース（O*NET）の数値情報を基に，702の職業について各職業が将来的に完全に自動化される確率（probability of computerization）を推計した。彼らの推計結果によると，アメリカで自動化確率の高い職業に就業している人口割合は2010年時点で47%と驚くべくのものであった。この研究の結果は学術的にも社会的にも大きなインパクトを与え，職業の自動化確率について，その推計方法や解釈をめぐる様々な議論が行われることとなった。

こうした議論の背景にあるのは，“The Second Machine Age”（Brynjolfsson & McAfee 2014）とも言われるような急速な技術革新である。AIをはじめとする近年における技術革新により，これまで自動化は不可能と思われてきたタスクについても自動化が可能となるのではないかとの期待が高まりつつある。わが国は2008年以降，人口減少社会に突入しており，労働政策研究・研修機構（以後，JILPT）が行った推計（ベースラインシナリオ）によると，労働力人口は2017年の6,720万人から2040年には5,846万人にまで減少すると見込まれている（JILPT 2019）。テクノロジーによる自動化により，これまでよりも少ない就業人口で，従来よりも高い生産性を達成できるか否かは，日本経済における喫緊の課題であると言える。

一方，FreyとOsborne（2013, 2017）が示した職業の自動化確率は，後述するように，様々な仮定に基づいており，その推計方法についても多くの批判がある（Arntz et al. 2016; 2017; Brandes and Wattenhofer 2016; Stephany and Lorenz 2021）。当然のことながら，未来においてどのようなテクノロジーが現れ，それが仕事の自動化にどのような影響を与えるのかについては様々な不確実性があるため，どの職業のどのようなタスクがどの程度将来的に自動化されるのかを正確に推計することは，いかなる手法をもってしても困難である。そのため，かれらが示した職業の自動化確率については，社会科学的手続きの下に導かれた一種の思考実験的な数値であると解釈する必要がある。このような留意点はあるものの，仮定や手法を明らかにした上で職業の「自動化確率」を推計し，これらの数値を基にテクノロジーが労働市場や生産性に与える影響についてシミュレーションを行うこと，あるいはそのための手法を開発することには，学術的・政策的に一定の意義があるものと思われる。

わが国における先行研究では，野村総合研究所（NRI）とFrey・Osborne両氏による共同研究において，JILPTが作成した職業情報データ（JILPT 2012）を用いて，日本の職業

別自動化確率が推計されている（野村総合研究所 2015; Frey, Osborne and Nomura Research Institute 2015）。本研究では、厚生労働省が「職業情報提供サイト（日本版 O-NET)¹」において、2020年3月19日より新たに公開した職業情報データ²を用いて、日本における職業別自動化確率の推計を行う。また、推計に当たってはFreyとOsborne(2013, 2017)の機械学習モデルを再現し、このモデルに米国 O*NET と日本版 O-NET から得られる日米の職業特性データを入力することで職業別自動化確率の値を得た。

以下では、第II節において職業の自動化確率に関する先行研究を俯瞰するとともに、第III節にてFreyとOsborne(2013, 2017)が用いた職業別自動化確率の推計方法について詳述する。第IV節ではFreyとOsborne(2013, 2017)が用いた機械学習モデルの再現方法について解説する。さらに、第V節においてはFreyとOsborne(2013, 2017)の機械学習モデルを日本版 O-NET データ用に拡張したモデルについて解説し、第VI節でその推計データを用いた日米比較の結果について述べる。最後に、第VII節で得られた知見や課題についてまとめる。なお、本論文の付録には、FreyとOsborne(2013, 2017)のガウス過程分類モデルを再現し、日本版 O-NET データ用に拡張する際に利用したPythonコードを収録する³。今後、日米の職業情報データが更新された際もこれらのコードを利用すれば、FreyとOsborne(2013, 2017)のモデルに基づく最新の自動化確率を推計することが可能である。

II 先行研究

コンピューターなどの技術は、各職業における仕事の進め方にどのような影響を与えるのだろうか。Autorら(2003)は職業をタスクの集合として扱い、コンピューター技術が担うタスクの領域を定義した。彼らの研究においてタスクは5つの領域に分けられている。定型的(Routine)か非定型的(Non-routine)かと、肉体的(Manual)か頭脳的(Cognitive)かの2軸を用いた4つの領域。さらに非定型的(Non-routine)で頭脳的(Cognitive)の領域は、分析型(A analytical)か相互関連型(Interactive)かの2つの領域に区別されている。この5つの領域は「タスク分類」と定義されている。Autorら(2003)は、コンピューター技術は定型の2つの領域(定型的-肉体的タスク, 定型的-頭脳的タスク)を代替できると主張した。具体的には、定型的-肉体的タスクは部品の運搬や整理, 組み立てなどの業務を指す。また、定型的-頭脳的タスクは銀行の出納係や会計処理のような反復的な顧客サービスや計算などの業務を示している。一方で非定型の3つの領域(非定型的-

¹ 2022年3月4日から「job tag」の名称が使われている。

² 同サイトでは、JILPTの研究開発成果物である「職業情報データベース」の情報を活用している。

³ FreyとOsborne(2013, 2017)の機械学習モデルを再現するコードについては下記よりダウンロード可能である。

<https://drive.google.com/drive/folders/1xKIEsSuqWzVUHBEbLT11QJxsIcuOtrh5?usp=sharing>

肉体的タスク、非定型的－分析型タスク、非定型的－相互関連型タスク）は、人間の労働によって補完される。定型タスクは ICT 技術の発展と共に労働市場における需要が低下したのに対し、非定型タスクの需要は高まった。その結果、1970 年以降の欧米では、定型タスクを担うことが多い中間層に比べて、非定型タスクを多く担う傾向にある上位層の賃金が大きく上昇し、相対的に中間層と下位層の賃金格差は縮小したとされている（池永 & 神林 2010）。即ち、賃金水準の高い層と低い層とに労働の二極化が生じた。タスク分類を用いた労働の二極化に関する研究はわが国でも行われている（池永 2009; 2011, 池永 & 神林 2010）。わが国の場合、1960 年代以降に同様の傾向が、アメリカよりも緩やかに発生していたことが示されている。

一方で、Frey と Osborne (2013, 2017)（以下、F&O）は、コンピューターなどの技術による自動化は、Autor らが定義したタスク分類における非定型の領域においても実現可能になりつつあると主張した。かれらは、将来における仕事の自動化についてボトルネック（障害）となりうる領域を新たに 3 つ設定した。その領域とは、「知覚と巧緻性 (Perception & Manipulation)」、「創造的な知性 (Creative Intelligence)」、「社会的な知性 (Social Intelligence)」の 3 つである。彼らはこの 3 つの領域を構成する 9 つの指標を、米国労働省が公表している職業情報データベースである O*NET から選択し、この 9 つの指標を独立変数とする分類モデルを機械学習により構築し、自動化確率を推計した。分類モデルの学習データには 702 の職業から 70 の職業を選定した。この 70 種類の職業について、「この職業の（すべての）タスクはビッグデータの活用と最先端のコンピューター機器によって実行できるようになると言えるか」を機械学習の専門家グループに尋ねた。専門家らがある程度の自信をもってその職業のタスクをすべて自動化できると判断した場合は 1、そうでない場合は 0 の値を付与し、分類モデルの従属変数とした。したがって、F&O が定義した職業の自動化確率とは、職業を構成する全てのタスクが AI やロボットなどの技術によって完全に代替（自動化）される確率を指す。彼らの推計結果は、アメリカで自動化確率が 70% 以上の職業に従事している労働者は 47% とする衝撃的なものであった。

F&O の推計結果はマスコミで広く取り上げられ、技術的失業（technological unemployment）に対する世間や政策担当者の関心を引き付けることとなったが、その方法論には多くの批判が寄せられている。例えば Coelli と Borland (2019) は、学習データにおける従属変数の決定プロセスが不明確である点を指摘している。学習データにおける自動化の可否は、機械学習の専門家らの主観的な予測であり、かれらの予測が正しいという根拠はなく、またその再現性や一貫性にも疑問が呈されている。また Brandes と Wattenhofer (2016) は、自動化されやすいタスクがどれなのか、あるいはそのタスクが各職業の実務中でどれくらいの割合を占めているのかが不明確である点を挙げている。さらには、将来のいつの時点において、各職業が自動化されるのかについても情報が与えられていない。

過去における仕事の自動化は必ずしも職業の消失ではなく、職業を構成するタスクに変化をもたらしてきた (Spitz-Oener 2006)。昨今における技術の導入も同様であると仮定すれば、F&Oの結果は過大評価(本来の自動化確率は低い)の可能性があると指摘されている (Arntz et al. 2016; 2017)。実際に2010年から2018年までのアメリカにおける雇用の変化と、高リスク職業の自動化確率の関係を調べた研究 (Coelli & Borland 2019)では、自動化確率の高い職業ほど、雇用は減少する傾向が見られたが、統計的に有意ではなかった (有意確率は0.148)。

F&Oの研究以降、各国で自動化リスクの高い職業に従事する就業者割合を検証する研究が行われた。先行研究の検証方法は大きく2つに分けられる。1つは、国際標準職業分類 (International Standard Classification of Occupation: ISCO)に基づき、F&Oの職業別自動化確率をそのまま自国の職業別人口に当てはめようとするものである。その結果、リスクの高い職業の就業者割合は、フィンランドで35% (Pajarinen et al. 2015)、ノルウェーで33% (同左)、シンガポールで15% (Fuei 2017)、日本で49% (野村総合研究所 2015)とされている。しかし、職業とは一連のタスクの実行によって構成されるものであり、同じ職業でも職場が異なるだけで実行されるタスクの種類や比率が異なる (Autor & Handel 2013)。これらの論文における高リスク就業者割合の相違は、単に各職業に従事する人口割合の差を反映しているに過ぎず (Arntz et al. 2016; 2017)、国ごとに異なる職業特性の違いを反映しているとは言えない点に注意が必要である。

検証方法の2つ目は、職業の自動化確率を新たに推計するものである。Arntzら (2016; 2017)は米国の国際成人力調査 (Programme for the International Assessment of Adult Competencies : PIAAC)を用いて、F&Oの職業別自動化確率をY、PIAACにおいて測定されている個人の属性 (年齢階級や性別、学歴など)と職場における実行タスクの種類をXとする回帰モデルを実行し、「職場における個々のタスク」が自動化確率に与える影響 (各Xの係数)を推定している。この推定値を基に、職業ごとの平均的な実行タスクの種類と頻度、および個人属性から自動化確率の再推計を行ったところ、アメリカで高リスク (自動化確率70%以上)の職業に就業する人口割合はわずか9%と、F&Oの推計値よりもかなり低い値を示した。Arntzら (2016; 2017)の方法においては、回帰モデルによりF&Oの職業別自動化確率を実行タスクの種類と個人属性に分解している。また、PIAACはOECD加盟国を中心に40か国・地域以上で実施されていることから、国別に各職業におけるタスク構成割合や個人属性の平均値を計算することで、各国における職業特性の違いを考慮した自動化確率を推計することも可能となっている (Nedelkoska and Quintini 2018)。職業を構成する要素が、個人によって異なる様々なタスクの集合であるとする、Arntzら (2016; 2017)のモデルはF&Oによるモデルよりも精緻かつ理に適ったものであるといえる。しかし回帰式の従属変数にF&Oの職業別自動化確率が用いられていることから、完全なオリジナルではなく、F&Oモデルの拡張であると理解すべきであろう。

わが国においては、前述のように Frey と Osborne が野村総合研究所と共同で、日本の職業別自動化確率の推計を行っている（野村総合研究所 2015; Frey, Osborne and Nomura Research Institute 2015）。推計においては、JILPT が作成した職業情報データ（JILPT 2012）が用いられ、601 種の職業について機械学習による分類モデルが新たに構築されている。学習データには F&O（2013, 2017）で用いた 70 種の職業の内、日米で共通する 50 種が採用された。なお、日本独自の「有料道路料金収受員」を自動化可能な職業（ラベルの値は 1）として加え、日米共通の「ホールスタッフ」のラベルは 0（自動化不可能）から 1（自動化可能）へ変更されている。よって、学習には 51 種の職業が用いられ、自動化可能とした職業は 24 種であった。分類モデルの独立変数は「10 の最良の特徴を選択した」（野村総合研究所 2015: p. 10）とあるが、最も有意な 3 つの変数⁴以外はどのような職業情報を用いたのか明確な記述がない。推計の結果、わが国における高リスクの職業の就業人口割合は 49% と米国の値をわずかながら上回る結果であった。F&O と野村総合研究所（2015）による共同研究は、日本の職業情報データに合わせて機械学習を行い、日本独自の自動化確率を推計したものと評価できる。一方で、上述のように実際に機械学習に用いられた独立変数が明記されておらず、彼らの分類モデルの妥当性について子細に検討することができない。また、彼らが用いた職業情報データは米国 O*NET データとは測定している職業情報（独立変数）が異なるため、F&O（2013, 2017）が構築した分類モデルとは異なるモデルが設定されている。このことは、日米で異なる説明変数とモデルにより、職業の自動化確率が推定されていることを意味しており、たとえ同じ職業であっても日米で自動化確率を直接的に比較することはできないという欠点がある。

以上にみてきたように、F&O による研究（Frey and Osborne 2013, 2017）は、Autor ら（2003）以降のテクノロジーによる仕事の代替に関する一連の研究の中の一つとして位置づけられる。その最大の特徴は、仕事の自動化の「未来」を社会科学的な手法により大胆に予測したことであると言える。近年におけるテクノロジーの急速な発展と仕事の未来との関係について、人々の関心を引くとともに、将来における技術的失業の可能性について注意を喚起した点は評価に値する。しかし、その方法論については批判されるべき点も多く、先行研究の多くにおいて、F&O の推計値が「過大」とであると評価されている点は留意する必要がある。本論文では、以降において、F&O が構築した分類モデルの再現および日本版 O-NET データへの拡張を行い、日米における職業別自動化確率の比較を行う。これらに先立ち、次節において F&O（2013, 2017）で用いられた推計手法について詳細を述べる。

⁴ 彼らの論文では、この 3 つの変数は、「知識：芸術・人文科学」、「スキル：ヒューマン・スキル」、「職業関心：組織者（従来型の）」とあるが（野村総合研究所 2015; Frey, Osborne and Nomura Research Institute 2015）、具体的にそれぞれがどのような特徴を測定しているのかは明らかではない。

III Frey & Osborne による職業別自動化確率の推計方法

F&O は将来においてもテクノロジーが自動化することが難しい領域として、「知覚と巧緻性」、「創造的な知性」、「社会的な知性」の3つを挙げた。さらに、この3つの領域を構成する9つの指標を米国 O*NET から選択し、それらを独立変数とする分類モデルを機械学習により構築して、自動化確率を推計した。まずは彼らが設定した3つの領域と、それを構成する9つの指標について解説する。新しい領域の1つ目は「知覚と巧緻性」である。この領域は手先を使った細かい作業や災害現場などの規則性のない環境での作業を表している。彼らが研究で用いた 2010 年版 O*NET においては、「指先の器用さ (Finger Dexterity)」、「手先の器用さ (Manual Dexterity)」、「狭苦しい作業スペース、窮屈な姿勢 (Cramped Work Space, awkward positions)」の3つの指標で構成されている。2つ目の領域である「創造的な知性」は、0 から 1 を生み出す芸術性や既存にはない組み合わせや発想を指す。O*NET から採用した指標は「オリジナリティ (Originality)」と「芸術性 (Fine Arts)」であった。3つ目の領域は「社会的知性」である。これは相手の感情を読み取ったり、それを交渉や説得に生かしたりする行動を指す。これは O*NET における「社会的知覚 (Social Perceptiveness)」、「交渉 (Negotiation)」、「説得 (Persuasion)」、「他者の支援やケア (Assisting and Caring for Others)」の4つの指標で構成されている。これらの9つの指標は、F&O において、自動化に対する「ボトルネック変数 (bottleneck variables)」と名付けられている。

F&O の研究で使用したデータは「The 2010 version of O*NET」と記述がある。本研究ではこれに対応するデータを米国版「O*NET Database 15.1」と解釈し、以下に解説を行う。米国版 O*NET Database 15.1 では、標準職業分類 Standard Occupational Classification (略称 SOC) をベースとして、903 種の職業についての情報が掲載されている。SOC は連邦政府共通の職業分類であり 6 桁の数字で構成されている。しかし、O*NET の職業分類は SOC に 2 桁のコードを付け加えることで、さらに細かい分類を行っている。例えば Accountants (会計士) は 13-2011.01, Auditor (会計監査人) は 13-2011.02 に分けられており、それぞれに職業情報が割り当てられている。F&O では、1つの SOC に1つの職業情報となるように、O*NET から平均化したスコアを割り当てている。先の例の場合、13-2011.01 と 13-2011.02 のスコアの平均値が 13-2011 の職業情報として扱われる。また、職業情報が欠損している値は除外している。その結果、F&O は 702 種類の SOC を推計で扱っている。

分類モデルの学習データには 702 種の職業から 70 種が選定された。学習を行うための独立変数には前述の9つのボトルネック変数が採用された。学習データの従属変数は、その職業におけるすべてのタスクが将来的に自動化可能であるか否かである。前述のように、この従属変数の値は「この職業のタスクはビッグデータの活用と最先端のコンピューター機器によって実行できるようになると言えるか」という問いに対する機械学習の専門家グ

ループの回答に準拠しており、職業のタスクをすべて自動化できる場合は 1、そうでない場合は 0 の値が振られている。

機械学習においては、ガウス過程による分類モデル (Gaussian process classifiers) が用いられた。モデル構築においては 70 種の職業からなる学習データのうち、ランダムに半数を選択し、選択されたデータにおいてボトルネック変数から自動化の可否を予測するガウス過程分類モデルを構築する。このモデルを未選択の学習データに当てはめて、どれだけ実際の従属変数を正しく予測できたかを判定する。3 つの異なる共分散関数 (covariance function) によりガウス過程分類モデルを構築し、機械学習により予測精度を上げつつ、この作業を 100 回反復した。この作業によって、最終的に exponentiated quadratic 関数を用いた分類モデルが最も良い当てはまりを示したため (AUC(Area under the ROC curve)=0.894)、このモデルを用いて、残りの 632 種の職業の自動化確率の推計 (予測) を行った。

IV Frey & Osborne による分類モデルの再構築

F&O によって推計された職業別自動化確率は、彼らの論文 (Frey and Osborne 2013, 2017) の付録に掲載されており、その後続く研究において用いられてきた。しかし、ボトルネック変数から自動化確率を計算するプロセスである分類モデルについては、ブラックボックスであり、これまで全くと言ってよいほど関心が払われてこなかった。ボトルネック変数と自動化確率との複雑な関係性を規定しているのは分類モデルである。F&O が構築した分類モデルを再構築することができれば、新たに更新された米国 O*NET データあるいは日本版 O-NET データのボトルネック変数の値から、新しい自動化確率を推計することが可能となるはずである。そこで本研究では、ガウス過程回帰モデルによる機械学習を行い、F&O による分類モデルの再構築を試みた。以下にその手順について説明する。本研究におけるモデル作成の手順は以下である。

1. 学習に用いるデータを選択する
2. 学習データの独立変数 x (ボトルネック変数) と従属変数 y (自動化確率) を決める
3. 学習データの従属変数 y をロジット変換する
4. 複数のカーネル関数を用いて機械学習を行い、モデル構築を行う
5. モデルを評価して最終モデルを決定する
6. 従属変数 y の予測値を逆ロジット変換して、自動化確率の推定値を得る

ガウス過程回帰モデルの学習データは F&O と同様に、米国版 O*NET Database 15.1 (2022 年 12 月 28 日ダウンロード) を採用した。学習データの独立変数 x は、前節に記載

した9つのボトルネック変数とした。前述のように、O*NET データにおける職業分類は、SOC よりも細かいものが用いられている。そのため、F&O は1つのSOC に1組のボトルネック変数となるように、各ボトルネック変数の値について平均化の作業を行っている。そのため、本研究でも各ボトルネック変数の値について平均化を行った⁵。これらの作業の結果、学習データは695種類⁶の職業を扱うこととなった。なお、平均化したスコアは小数点第3位を四捨五入し、小数点第2位までの値としている。従属変数 y は、F&O により推計された上記695種の職業における自動化確率である。

モデルを実行する前に、以下の式により従属変数 y の値にロジット変換を行った。ロジット変換により範囲0~1の値 y を、範囲 $-\infty \sim \infty$ の値 z に変換する。

$$z = \ln\left(\frac{y}{1-y}\right)$$

ロジット変換した値 z を学習データに投入することで、その予測値の範囲も $-\infty \sim \infty$ となる。 $-\infty$ から ∞ の範囲で得られた予測値 \hat{z} は、以下の逆ロジット変換を行うことで、0から1までの値をとる自動化確率の推計値 \hat{y} にすることができる。

$$\hat{y} = \frac{\exp(\hat{z})}{1 + \exp(\hat{z})}$$

上記695種の職業におけるロジット変換したF&Oの自動化確率 y とボトルネック変数 x を用いて、モデルの学習を行った。学習の結果は4つの方法で評価を行う。1つ目は決定係数 r^2 である。決定係数は残差の2乗和を平均値からの偏差の2乗和で割り、それを1から引いた値である。そのため、1に近い程モデルの精度が良いと言える。2つ目は Root-Mean-Squared Error (RMSE) である。RMSE は y の誤差の2乗における平均値の平方根を表す。3つ目は Mean-Absolute Error (MAE) である。MAE は y の誤差の絶対値の平均値を表す。RMSE と MAE は0に近い程モデルの精度が良いとされている。4つ目は散布

⁵ 但し、F&O の Appendix A における「25-1000: Postsecondary teachers」, 「29-1060: Physicians and surgeons」, 「45-2090: Miscellaneous agricultural workers」は複数のSOCコードから合成されていると推測されたため、この3つについては該当すると思われる職業を用いて平均化を行った。

⁶ Acemoglu と Restrepo (2019) では698種とあるが、本研究でマッチングができなかった職業は以下の7種だった。「19-3099: Social scientists and related workers, all other」, 「25-3999: Teachers and Instructors, all other」, 「29-9799: Healthcare practitioners and technical workers, all other」, 「47-4799: Construction and related workers, all other」, 「49-9799: Installation, maintenance, and repair workers, all other」, 「51-8099: Plant and system operators, all other」, 「51-9399: Production workers, all other」。

図の作成である。実測値と推定値の散布図を作成し、目視で大きな誤差が無いかを確認する。

分類モデルを非線形のノンパラメトリック関数で拡張するため、11個のカーネル関数を用いて推定を行った。最も評価の良かったカーネル関数は以下であった。

$$K_{GPR}(x^i, x^j) = \theta_0 \exp\left(-\frac{\sqrt{\sum_{k=1}^m (x_k^i - x_k^j)^2}}{\theta_1}\right) + \theta_2$$

K_{GPR} …カーネル関数（GPR は Gaussian Process Regression）

x …独立変数

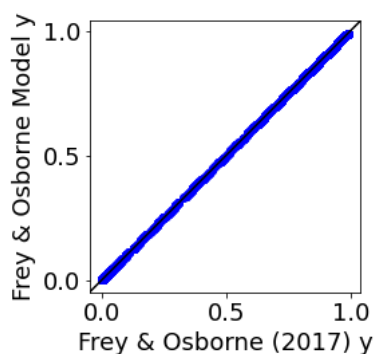
i, j …職業（ x^i は職業 i の x ）

m …独立変数（次元）の数

k …独立変数の任意の次元（ k 次元目の x ）

$\theta_{0\sim 2}$ …ハイパーパラメータ（デフォルトの値を使用）

また、このカーネル関数によるモデルの評価は以下の通りである。決定係数 r^2 はほぼ1であり、RMSEとMAEは0に近いと言える値であった。図1は、F&O（2013, 2017）が公表した自動化確率をX、我々が新たに推計した自動化確率をYとする散布図を示している。この図から、両者はほぼ一致していることも確認できる。よって、以上の手順により、F&Oによる分類モデルをほぼ完全に再現することができたといえる。



r^2	0.9999999988
RMSE	0.0000945642
MAE	0.0000647569

図1. Frey & Osborne Model の定量的比較

V 日本版 O-NET データに対応する拡張モデルの構築

前節でみたように、米国 2010 年版 O*NET データを用いた F&O の分類モデルはほぼ完全に再現することができた。我々の目的は、このモデルに米国 2020 年版 O*NET データや日本版 O-NET データのボトルネック変数を投入して、新たな職業別自動化確率を推

計することである。米国 2020 年版 O*NET データは、2010 年版データと同じ変数を含むため、前節で再構築した分類モデルをそのまま適用して、自動化確率を推計することが可能である。しかし、日本版 O-NET データについては、ボトルネック変数の測定方法が、米国 O*NET データと部分的に異なる。そのため、前節で再構築した分類モデルを、そのまま日本版 O-NET データに適用することはできない。この問題に対処するため、日本版 O-NET データに対応するモデル（以後、拡張モデル）の構築を行った。以下では、米国 O*NET データと日本版 O-NET データの違い及び拡張モデルの作成方法について述べる。

2020 年 3 月、厚生労働省より職業情報提供サイトが開設された。同サイトは日本版 O-NET とも呼ばれており、JILPT による委託研究として、米国 O*NET をモデルに職業情報データの開発が進められた。約 500 の職業の解説、求められる知識やスキルなどの数値データ（厚生労働省 2020）を閲覧できるようになっている。日本版 O-NET は米国 O*NET と共通の指標を多くもつが、米国 O*NET よりも利用可能な指標が少ない。例えば、9 つのボトルネック変数の内、日本版では Originality, Finger Dexterity, Manual Dexterity の 3 変数が測定されていない。そこで、拡張モデルを構築するにあたり、日米で共通する指標から、これらに代わる指標について検討を行った。米国 O*NET Database 15.1 におけるこれら 3 変数の解説は以下である。

- Originality

The ability to come up with unusual or clever ideas about a given topic or situation, or to develop creative ways to solve a problem.

- Finger Dexterity

The ability to make precisely coordinated movements of the fingers of one or both hands to grasp, manipulate, or assemble very small objects.

- Manual Dexterity

The ability to quickly move your hand, your hand together with your arm, or your two hands to grasp, manipulate, or assemble objects.

これらの代替指標には、日米で共通する指標の中で最も乖離が小さいと推測される「Thinking Creatively（創造的に考える）」、「Handling and Moving Objects（手と腕を使って物を取り扱い動かす）」、「Performing General Physical Activities（全身を使って身体的な活動を行う）」をそれぞれ採用することとした。これらの指標についての、米国 O*NET Database 15.1 と日本版 O-NET の解説は以下の通りである。

- ・ Thinking Creatively (創造的に考える)
 - 【米国 O*NET】 Developing, designing, or creating new applications, ideas, relationships, systems, or products, including artistic contributions.
 - 【日本版 O-NET】 既存のものにとらわれず、新しく何かを開発、設計、創造する。これには芸術的な観点での関与・貢献を含む。例：アイデア、広報、システム、ソフトウェア、製品、芸術作品など。

- ・ Handling and Moving Objects (手と腕を使って物を取り扱い動かす)
 - 【米国 O*NET】 Using hands and arms in handling, installing, positioning, and moving materials, and manipulating things.
 - 【日本版 O-NET】 全身を使わずに持ち上げられる程度の大きさ・重さのモノの運搬、据え付け、設置、移動のため、もしくはそれらの物を扱うために、手と腕を用いる。

- ・ Performing General Physical Activities (全身を使って身体的な活動を行う)
 - 【米国 O*NET】 What activities using the body and hands are done to perform this job?
 - 【日本版 O-NET】 登る、持ち上げる、バランスをとる、歩く、かがむ、資材を運搬するなど、手足をかなり使って全身を動かす必要がある身体的な活動を行う。

米国 O*NET データより Originality と Thinking Creatively, Finger Dexterity と Handling and Moving Objects, Manual Dexterity と Performing General Physical Activities の Pearson 相関係数 (重要性指標により算出) を確認したところ、いずれも 0.6 から 0.8 と高い相関を示しており、代替指標として妥当であると判断した⁷。

もうひとつ重要な点として、日米の O-NET データにおける指標の測定方法の違いを挙げることができる。米国 O*NET の能力やスキル、知識の指標には、職務遂行に必要とされるレベル (LV) と重要性 (IM) の 2 種類の測定値が与えられており、F&O の分類モデルではこのうちのレベル指標を用いて推計が行われている⁸。一方で日本版 O-NET では、1 つの指標について、レベルと重要性のいずれか 1 種類の値でしか測定されていない。この点について、日本版 O-NET データにおいて、各ボトルネック変数にどの種類の値が与えられているのかを表 1 に整理した。

⁷ 上記 3 変数 (Originality, Finger Dexterity, Manual Dexterity) の代替指標との相関係数は、Database 15.1 における重要性指標でそれぞれ 0.813, 0.643, 0.756 であった。また、2020 年の Database における相関係数は重要性指標でそれぞれ 0.760, 0.723, 0.776 であった。

⁸ ただし、後述のように、「狭苦しい作業スペース、窮屈な姿勢 (Cramped Work Space, awkward positions)」については頻度の値を用いている。

表 1. 日本版 O-NET におけるボトルネック変数の測定について

日本版O-NET		(参考) 米国O*NET	
重要性	手と腕を使って物を取り扱い動かす	IM	Handling and Moving Objects
1. 関係あるが重要でない 2. ある程度重要 3. 重要 4. とても重要 5. きわめて重要		1. Not Important 2. Somewhat Important 3. Important 4. Very Important 5. Extremely Important	
重要性	全身を使って身体的な活動を行う	IM	Performing General Physical Activities
1. 関係あるが重要でない 2. ある程度重要 3. 重要 4. とても重要 5. きわめて重要		1. Not Important 2. Somewhat Important 3. Important 4. Very Important 5. Extremely Important	
頻度	窮屈な仕事の場所、居心地が悪い姿勢	CX	Cramped Work Space, Awkward Positions
1. 年に1度未満、あるいは全くない 2. 年に1度以上 3. 月に1度以上 4. 週に1度以上 5. ほぼ毎日		1. Never 2. Once a year 3. Once a month or more 4. Once a week or more 5. Everyday	
重要性	創造的に考える	IM	Thinking Creatively
1. 関係あるが重要でない 2. ある程度重要 3. 重要 4. とても重要 5. きわめて重要		1. Not Important 2. Somewhat Important 3. Important 4. Very Important 5. Extremely Important	
重要性	芸術	IM	Fine Arts
0. 現在の仕事とは無関係 1. 関係あるが重要でない 2. ある程度重要 3. 重要 4. とても重要 5. きわめて重要		1. Not Important 2. Somewhat Important 3. Important 4. Very Important 5. Extremely Important	
レベル	他者の反応の理解	LV	Social Perceptiveness
0. 1. 2. 待ち時間が長すぎるために顧客が起きていることに気づく 3. 4. ある部下を昇進させることが他のメンバーの心情に及ぼす影響に気がつく 5. 6. うつ病患者にカウンセリングを行い、危険な兆候を見逃さない 7.		0. 1. 2. Notice that customers are angry because they have been waiting too long 3. 4. Be aware of how a coworker's promotion will affect a workgroup 5. 6. Counsel patients who are depressed during a crisis period 7.	
レベル	交渉	LV	Negotiation
0. 1. 2. 上司と交渉して、出勤予定日を変更する 3. 4. 一定の価格で商品を販売するため、卸売業者と契約交渉を行う 5. 6. 他社との合併に向けて交渉を行う 7.		0. 1. 2. Present justification to a manager for altering a work schedule 3. 4. Contract with a wholesaler to sell items at a given cost 5. 6. Work as an ambassador in negotiating a new treaty 7.	
レベル	説得	LV	Persuasion
0. 1. 2. 食事を注文した顧客にサイドメニューを勧める 3. 4. 予算削減が求められている中で、新しいコピー機を買うよう上司を説得する 5. 6. 保育園の建設に反対している地域住民の理解が得られるよう説得する 7.		0. 1. 2. Solicit donations for a charity 3. 4. Convince a supervisor to purchase new office equipment 5. 6. Change the opinion of the jury in a complex legal case 7.	
重要性	他者に対する支援とケアを行う	IM	Assisting and Caring for Others
1. 関係あるが重要でない 2. ある程度重要 3. 重要 4. とても重要 5. きわめて重要		1. Not Important 2. Somewhat Important 3. Important 4. Very Important 5. Extremely Important	

LV：レベル，IM：重要性，CX：頻度

表 1 のうち、「狭苦しい作業スペース、窮屈な姿勢 (Cramped Work Space, awkward positions)」については、日米ともレベルや重要性ではなく、頻度 (CX) により測定されている。指標の値は原則として、レベルが 0~7 の連続変数、重要性と頻度が 1~5 の連続変数となっている。表 1 で示されているように、各指標に付されている数値ラベルは「説得」の一部ラベルを除き、日米でほぼ同等と解釈することができる。ただし、日本版の芸術 (知識) 指標のみ、重要性の値の範囲が 1~5 ではなく、0~5 の連続変数となっている。日本版の調査票には「1: 関係あるが重要でない」の下位に「0: 現在の仕事とは無関係」という選択肢が含まれているためである。本来であれば米国 O*NET データの形式に合わせて、日本版 O-NET の芸術指標についても、再コード化した上でスコアを修正し、モデルに使用するのが望ましいが、日本版 O-NET の元データにアクセスすることはできないのでその

まま使用することとした。このような日米におけるデータの違いのため、拡張モデルのボトルネック変数については、日本で測定している指標に合わせてモデル構築を行った。

以上のように、ボトルネック変数 x について、日本版 O-NET に合わせた形で変更を加え、前節と同様に米国 2010 年版 O*NET Database 15.1 を用いた機械学習を行い、自動化確率を推計する新たな分類モデルを構築した。選択したカーネル関数は F&O の分類モデルと同様である。拡張モデルの評価を図 2 に示した。

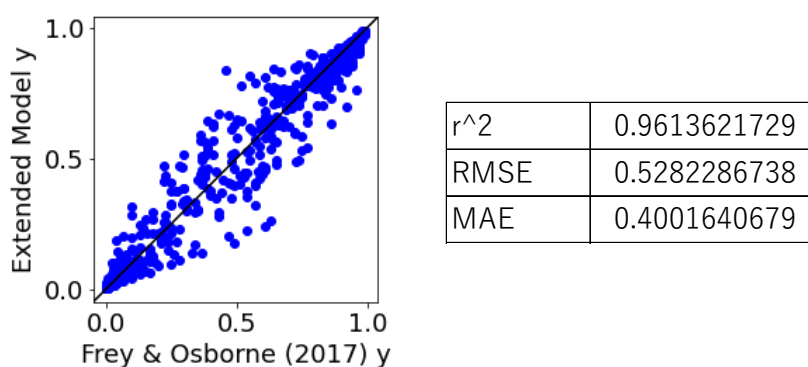


図 2. 拡張モデルの定量的評価

決定係数は前節で再現したモデルより低下して 0.961 となった。図 2 に示す散布図では自動化確率が低い職業において拡張モデルの推計値が過大であり、自動化確率が高い職業ではこれが過少である傾向が認められるが、概ね良好な結果を得たものと判断し、本モデルを拡張モデルとして採用することとした。

このモデルでは、日米両方の職業情報データにより自動化確率を推計することができる大きな利点である。なお、日本版 O-NET における職業分類は、厚生労働省編職業分類 (ESCO) の細分類をベースとしている。ESCO の細分類は国勢調査における職業小分類 (日本標準職業分類 (JSCO) に準拠) に原則として準拠しているものの、職業紹介業務における必要性を考慮して項目を一部より細かい分類に補正している (JILPT 2017)。日本のデータについては、JSCO による平均化などは行わず、そのまま分類モデルによる推計を行った。この拡張モデルによる日米両国の職業別自動化確率を本論文の付録に示す。次節では、この拡張モデルに 2020 年の米国 O*NET⁹ と日本版 O-NET の職業情報を投入

⁹ アメリカの 2020 年のデータについては、米国版 O*NET は Database 25.0, 25.1, 25.2, 25.3 の統合データを採用した。統合の際、重複する職業は最新版 (25.3) に統一した。また、1 つの SOC に 1 組のボトルネック変数となるように、2010 年と同様に平均化を行った。その結果、811 種類の SOC が推計の対象となった。

し、職業別自動化確率の日米比較を行った¹⁰。

VI 拡張モデルの推計結果

はじめに、拡張モデルにより得られた日米の自動化確率が最も高いあるいは最も低い10種の職業を表2と表3に示した。

両国における職業分類は完全には一致しないため、単純な比較は難しい。しかし表中の職業の大分類を参照すると、自動化確率の低い上位10種は日米ともに専門的・技術的職業であり医療関連と教育分野が半数以上を占めていた。一方、自動化確率の高い職業10種は、米国では事務的職業に偏っていたが、日本では生産工程業やサービス業、販売業に分散していることが判明した。

表2 日米における自動化確率の高い職業：上位10種

	日本		米国	
	職業	自動化確率	職業	自動化確率
1	建具製造	0.962	Mathematical Technicians	0.986
2	ホールスタッフ（レストラン）	0.959	Sewers, Hand	0.984
3	木材製造	0.946	Credit Analysts	0.982
4	経理事務	0.944	Telemarketers	0.981
5	飲食チェーン店店員	0.939	Brokerage Clerks	0.981
6	カフェ店員	0.928	Camera and Photographic Equipment Repairers	0.979
7	CDショップ店員	0.926	Bookkeeping, Accounting, and Auditing Clerks	0.977
8	電子機器組立	0.922	Bill and Account Collectors	0.976
9	ビデオレンタル店店員	0.917	File Clerks	0.975
10	和菓子製造、和菓子職人	0.917	Office Machine Operators, Except Computer	0.974

¹⁰ 独立行政法人労働政策研究・研修機構（JILPT）作成「職業情報データベース 簡易版数値系ダウンロードデータ ver.2.02」 職業情報提供サイト（日本版 O-NET）より 2022 年 12 月 31 日にダウンロード（<https://shigoto.mhlw.go.jp/User/download>）を加工して作成。

表3 日米における自動化確率の低い職業：下位10種

	日本		米国	
	職業	自動化確率	職業	自動化確率
1	作業療法士 (OT)	0.003	Therapists, All Other	0.003
2	医学研究者	0.005	Recreational Therapists	0.003
3	言語聴覚士	0.006	Community Health Workers	0.004
4	理学療法士 (PT)	0.006	Ophthalmologists, Except Pediatric	0.004
5	外科医	0.006	Dentists, General	0.004
6	特別支援学校教員、特別支援学級教員	0.007	Healthcare Social Workers	0.006
7	舞台美術スタッフ	0.007	Surgeons	0.006
8	助産師	0.007	Occupational Therapists	0.007
9	高分子化学技術者	0.008	Mental Health Counselors	0.007
10	バイオテクノロジー研究者	0.008	Mental Health and Substance Abuse Social Workers	0.007

次に、拡張モデルにより得た職業別自動化確率について、就業人口の分布をみてみよう。前述のように、我々が推計した職業別自動化確率は、米国 O*NET もしくは日本版 O-NET の職業分類に基づいている。そのため、まずこれらの職業分類を両国のセンサスデータにおける職業小分類にマッチングさせる作業を行った。就業人口については、両国センサスの職業小分類別人口を用いた。なお、日本については、ひとつのセンサス職業小分類に複数の O-NET 職業が含まれることがあったため、その場合にはセンサスの職業小分類別就業人口を重複する O-NET 職業の数で割り均等に割り振った¹¹。さらに、視認性向上のため、F&O (2013, 2017) に従い、これらの職業小分類を米国は 12 の日本は 13 の職業カテゴリーにまとめた¹²。こうして求めた日米両国における自動化確率別の就業人口分布を図 3 と図 4 に示した。また、これらのグラフから F&O (2013, 2017) の分類に基づき、自動化確率が 30%未満を低リスク (Low Risk)、30%以上 70%未満を中リスク (Middle Risk)、70%以上を高リスク (High Risk) とした場合のリスク別就業人口割合を表 5 に示した。

¹¹ 日本のデータにおける作業については、小松・麦山 (2021) を参考にした。なお、米国はセンサスと O*NET の職業がほぼ 1 対 1 で紐づいていたため、この作業は不要であった。

¹² 日米の職業カテゴリーの違いは、日本では「保安職業従事者」のカテゴリーがあるのに対し、米国ではこのカテゴリーがないことによる。ESCO の「保安職業従事者」には警察官、自衛官、消防士、刑務官、警備員、道路パトロール隊員、雑踏・交通誘導警備員等の職業が含まれる。しかし、今回用いた米国の職業 12 カテゴリーには、軍人は含まれておらず、また一部保安職業従事者は「Service」等の他の職業カテゴリーに含まれている。

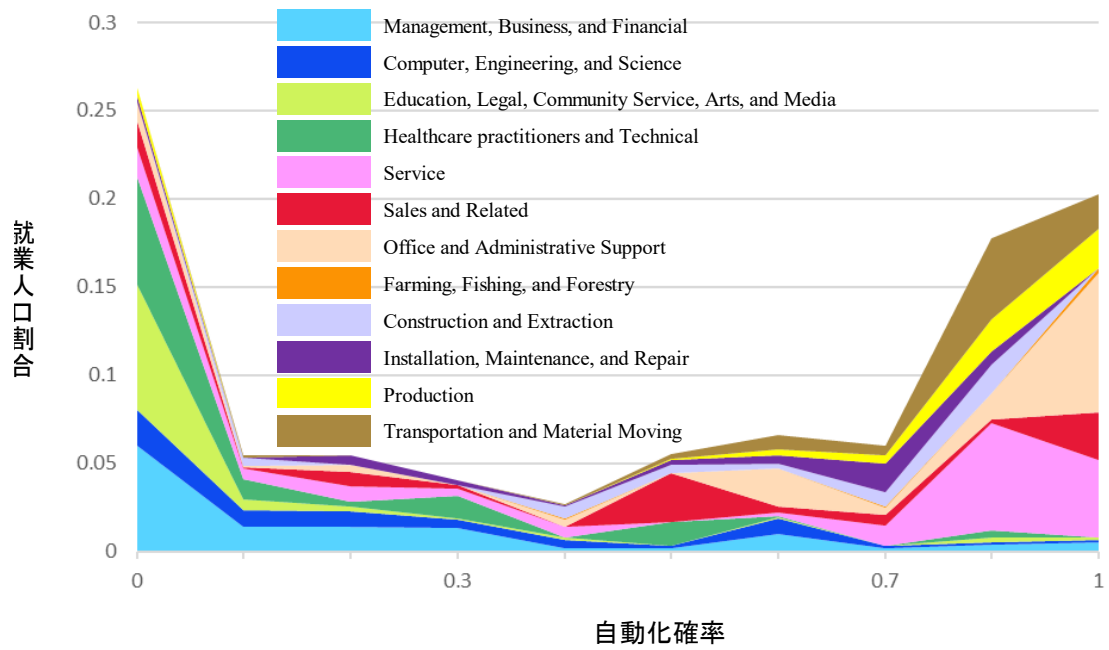


図 3. 2020 年におけるアメリカの拡張モデル




図 4. 2020 年における日本の拡張モデル

表 5. 拡張モデルの自動化確率別就業人口割合 (2020 年) (%)

	低 ($x < 0.3$)	中 ($0.3 \leq x < 0.7$)	高 ($x \geq 0.7$)	マッチング
日本	39.0%	19.8%	41.1%	93.2%
米国	37.2%	18.8%	44.0%	93.9%

注：割合の分母はセンサスと O-NET のマッチングができた就業人口となっている。日本では 93.2%，米国は 93.9% に就業人口が今回の推計結果とマッチした。

2020 年のアメリカと日本のリスク別就業人口割合 (表 5) を比較した所、日本の方が高リスクの職業に従事している人口が 2.9%ポイントほど少なく、中リスクと低リスクの職業の就業者割合は多かった。実際に、職業小分類別人口で重み付けして、両国における職業別自動化確率の平均値を算出すると、日本が 0.485 で米国が 0.520 であった。Frey と Osborne が野村総合研究所と共同で行った研究 (野村総合研究所 2015; Frey, Osborne and Nomura Research Institute 2015) においては、日本における高リスク就業者の割合は 49% であり、今回の研究で示された 41.1% と比べると、高めに推計されている。かれらの研究とは異なり、本研究における自動化確率は、日米とも同一のモデルから職業のボトルネット変数の値に応じて推定される。そのため、自動化確率の平均値に日米で相違が生まれた要因は、両国における職業特性の違いと職業別就業人口分布の差の 2 つの要因による。

日米両国における職業特性の違いあるいは職業別の就業人口分布が、両国の平均的な自動化確率にどのような差異をもたらしているのかを考察するため、日米の自動化確率の平均値を先に示した 12 もしくは 13 職業カテゴリー別に算出し、その結果を表 6 に示した。

この表をみると、輸送・機械運転職業を除くすべてのカテゴリーで、米国の方が日本よりも自動化確率が高いことが明らかである。とりわけ日米で就業者割合が高い「医療関連」、 「サービス職業」、 「販売職業」、そして「事務的職業」において日本の方が米国よりも自動化確率が低いことが両国の自動化確率の平均値に反映されている。

各職業カテゴリーを構成する職業は日米で異なるため、厳密な比較はできないが、今回の推計結果は、同じような職業であっても日本のほうが米国よりも自動化が困難であるケースが多いことを示唆している。このことは、同じ職種でも日本の方が、職務の遂行において、総じて知覚と巧緻性、創造的知性、あるいは社会的知性のいずれかについて米国より高い水準が求められることを意味しているように思われる。

表6 日米における職業12(13)カテゴリー別自動化確率と就業者割合(%)

職業大分類	日本		米国	
	自動化確率	就業人口割合	自動化確率	就業人口割合
管理的職業従事者	0.295	1.9%	0.238	12.5%
専門的・技術的職業 (技術者・ICT関連)	0.158	5.2%	0.294	6.3%
専門的・技術的職業 (教育・法律・経営・メディア・アート)	0.039	5.2%	0.092	8.6%
専門的・技術的職業 (医療関連)	0.053	7.9%	0.194	10.7%
サービス職業従事者	0.450	12.5%	0.698	16.0%
販売従事者	0.465	12.3%	0.576	9.2%
事務従事者	0.573	21.4%	0.785	13.9%
農林漁業従事者	0.821	3.4%	0.887	0.4%
建設・採掘従事者	0.591	4.4%	0.657	4.5%
輸送・機械運転従事者	0.685	3.6%	0.597	4.2%
生産工程従事者	0.700	12.6%	0.801	5.3%
運搬・清掃・包装等従事者	0.695	7.6%	0.813	8.4%
保安職業従事者	0.421	2.1%	-	-
総計	0.484 (0.485)	100.0%	0.520	100.0%

*各職業カテゴリーにおける自動化確率は、職業小分類別就業人口による重み付け平均値。

*総計の値は保安職業従事者を含めた平均値が0.484、除外した平均値が(0.485)。

最後に、今回推計した自動化確率を用いて、米国の2010年から2020年までの10年間の時系列変化と、2020年における日米間の差異について、簡単な要因分解を行った。具体的には、米国の10年間における自動化確率の変化あるいは日米間の自動化確率の差異を、1)同一職業カテゴリーにおける自動化確率の変化(差異)と2)職業分類別就業人口分布の変化(差異)の2つの要因に分解し、どちらの要因が上記の変化や差異を説明する上で、より大きいのかを定量的に示した。なお、SOCは2018年に改訂されているため、米国の時系列変化の分析では、SOCに基づいて各職業の変化量を捉えるのは難しい。同様に、日米比較においても、米国SOCと日本版O-NETとでは職業分類が異なるため、最も細かい職業分類での比較が困難である。そこで以下では、F&Oが用いた12カテゴリーの職業分類別の自動化確率と就業人口を用いて要因分解の計算を行った¹³。

まず、米国の自動化確率の2010年から2020年までの変化について比較を行う。ここでは、拡張モデルではなく、我々が再現したF&Oの分類モデルによる推計結果を用いた。

¹³ このことは、日米で12カテゴリーの職業大分類については比較可能であることを仮定している。また、日米の比較においては、日本の「保安職業従事者」は除外して計算を行っている。

F&O が用いた 12 カテゴリーの職業大分類 j の t 年における自動化確率を P_t^j 、就業人口を W_t^j とすると、職業大分類別自動化確率 P_t^j は、大分類を構成するセンサスの職業小分類 i 別就業人口 w_t^i による職業小分類別自動化確率 p_t^i の加重平均値としている。計算式は以下の通りである。

$$P_t^j = \frac{\sum(p_t^i \times w_t^i)}{\sum w_t^i}$$

こうして計算した 12 職業カテゴリー別の自動化確率 P_t^j について、各カテゴリーの就業人口 W_t^j で加重した平均をとり、 t 時点の平均自動化確率 P_t を算出する。

$$P_t = \frac{\sum(P_t^j \times W_t^j)}{\sum W_t^j}$$

計算した平均自動化確率 P_t について、2010 年から 2020 年までの変化量を計算した。この時、2020 年の平均自動化確率 P_{2020} について、1) 職業大分類別就業人口 W_t^j を 2010 年に固定したまま職業大分類別自動化確率 P_t^j のみ変化させた(就業人口を統制した)場合と、2) 職業大分類別自動化確率 P_t^j を 2010 年に固定したまま職業大分類別就業人口 W_t^j のみを変化させた(自動化確率を統制した)場合の 2 つの仮想的な値を計算した。この時、前者を P_{2020}^1 、後者を P_{2020}^2 と表すとすると、

$$\text{職業大分類別自動化確率の変化による寄与分 (\%)} = \frac{(P_{2020} - P_{2020}^1) * 100}{P_{2020} - P_{2010}}$$

$$\text{職業大分類別就業人口の変化による寄与分 (\%)} = \frac{(P_{2020} - P_{2020}^2) * 100}{P_{2020} - P_{2010}}$$

として表すことができる。計算の結果 P_{2010} は 0.584、 P_{2020} は 0.554 であった。変化量は -0.030 とわずかではあるが、10 年間で米国の職業についての自動化確率は低下する方向に変化していた。この変化量について、前述の手法で要因分析を行った。その結果(表 7)、米国における時系列的变化の約 9 割は就業人口の変化に因るものと判明した。即ち、米国の過去 10 年間の職業における自動化確率の低下は、職業特性の変化による職業別自動化確率の低下ではなく、自動化確率の高い職業から低い職業へと就業人口分布が変化したことが主因と言える。なお、寄与率の合計が 100% とならないのは、自動化確率の変化と就業人口構造の変化の交互作用による寄与分があるためである。

表7. 米国における自動化確率の時間的変化の要因分析

	2010年と2020年の 自動化確率の差	自動化確率の 差による寄与率	就業人口構造の 差による寄与率
差分	-0.030	-0.003	-0.028
寄与率	-	8.6%	90.9%

続けて、同様の手法を用いて、拡張モデルによる日米の職業別自動化確率について要因分解を行った。2020年における平均自動化確率は日本が0.485、米国が0.520であった。比較の基準を米国とすると、日米の差は-0.035であり、日本の方が米国よりも自動化確率の平均値が低いという結果を得ている。この差についての要因分解の結果を表8にまとめた。その結果、職業大分類別の就業人口分布の違いよりも、自動化確率の違いの方が両国における平均自動化確率の差をより多く説明することが明らかとなった。ただし、要因分析の結果は、日本の方が米国よりも同じ職業カテゴリーの自動化確率が低い傾向にある一方、自動化されやすい職業カテゴリーに就業している人口割合は日本の方が米国よりも多いことを示している。このことは同一の職業であっても、国によって職業の自動化のされやすさが異なること、ならびに、職業別の就業人口分布は職業の自動化確率による影響を受けている可能性があることを示唆している。

表8. 日本と米国における自動化確率の差の要因分析

	日本と米国の 自動化確率の差	自動化確率の 差による寄与率	就業人口構造の 差による寄与率
差分	-0.035	-0.136	0.081
寄与率	-	394.3%	-234.0%

VI おわりに

本研究では、F&O (Frey and Osborne 2013; 2017) の研究で用いられた職業の自動化確率の推計モデルをガウス過程による非線形回帰モデルにより再現した。我々の研究によって再現されたモデルの決定係数は0.999であり、F&Oらが構築したモデルをほぼ完全に再現できたと言える。このモデルを使って米国の2010年と2020年における職業の自動化確率を計算したところ、同期間における職業の自動化確率の平均値は3.0%ポイントほど低下していた。この変化について要因分解したところ、平均自動化確率の減少量は就業人口構造の変動（自動化確率の低い職業カテゴリーへの移動）に因る寄与分が約90%と示された。なお、残りの約10%は職業大分類別の自動化確率（職業スコア）の低下に因るもので

ある。また、この再現モデルを拡張して、日本版 O-NET データに対応したモデルにより日米の職業自動化確率を推計し、2020 年データに基づく日米比較を行った。その結果、高リスクの職業の就業者割合は日本が 41.1%、アメリカが 44.0%と推計され、日本の方が低い値を得た。この日米の乖離は、自動化確率を決定する職業特性について、同一職業カテゴリーであっても日本の方が米国よりも自動化されにくい特性をもつためであることを示唆している。日本の方が同じような職業でも自動化されにくい特徴があるとすれば、それはどのような要因が影響しているのであろうか。例えば、日本における職の無限定性によるものか、顧客に求められるサービスの質による違いか、それとも職業特性に対する認識と回答傾向についての国民性の違いによるものか、今後両国の O-NET データ等を用いて詳細に検討していく必要があるだろう。

本研究では F&O による推計モデルの再現と拡張を目的とした。そのため、F&O らの研究に向けられた批判は、ほぼそのまま我々の研究にも当てはまることとなる。特に、自動化確率の妥当性そのものに対する疑問と、職業の自動化がいつ、どのようなプロセスで生じるのかについて考慮していない点については、今後の課題として十分に留意する必要があるだろう。

また、本研究に独自の課題として以下の 2 つについて触れておきたい。1 つ目は、自動化確率とボトルネック変数の詳細な関係性が未だに不明確な点である。ボトルネック変数間の関係性を決めるカーネル関数は明らかになったが、どの変数がどれくらい自動化確率に寄与しているのか、あるいは各ボトルネック変数の間にはどのような交互作用があるのかは、我々の方法では明らかになっていない。この点について明らかにするには、本研究で採用したガウス過程による機械学習とは別のアプローチが必要である。2 つ目は自動化確率の高い、あるいは低い職業に就いている人の特徴が解明できていない点である。F&O では学歴と自動化確率に負の相関が確認されている。職業の自動化確率に関連のある就業者の属性をより詳細に明らかにすることで、自動化確率のインパクトや妥当性について検証することが可能となるだろう。最後に、職業の将来は自動化による失業の増大というネガティブな側面だけではない点について指摘しておきたい。Acemoglu と Restrepo(2019)によれば、技術革新によって技術の利用可能性が広がると、補完関係にある労働需要は減少するが、新たに生まれるタスクに対する労働分配率は増加する。無くなるタスクや職業に焦点が当たりやすいが、自動化によって新しく生まれるタスクや雇用に目を向けることもまた重要である。また、人口減少に直面しているわが国においては、タスクの自動化により生産性を向上させていくとともに、新たに生まれるタスクや職業に人的資源を振り向けていけるよう労働市場や教育制度を整備していくことが重要である。

謝辞

本論文の執筆にあたり、金子弘昌氏、小松恭子氏、松倉力也氏、眞野隼輔氏から分析手法及び結果の解釈等について助言やコメントをいただいた。また、本論文のベースとなった千葉の修士論文については、明治大学大学院政治経済学研究科の安藏伸治教授よりご指導いただいた。ここに記して感謝申し上げます。

参考文献

- Acemoglu, Daron, & Restrepo, Pascual (2019) "Automation and New Task: How Technology Displaces and Reinstates Labor," *Journal of Economic Perspectives*, Vol. 33, pp. 3-30.
- Autor, H. David, Frank Levy, & Richard J. Murnane (2003) "The Skill Content of Recent Technological Change: An Empirical Exploration," *The Quarterly Journal of Economic*, Vol. 118, No. 4, pp. 1279-1333.
- Autor, H. David, & Michael J. Handel (2013) "Putting tasks to the test: Human capital, job tasks and wages," *NBER Working Paper*, No. 15116.
- Arntz, Melanie, Terry Gregory, & Ulrich Zierahn (2016) "The Risk of Automation for Jobs in OECD Countries: A Comparative Analysis," *OECD Social, Employment and Migration Working Papers*, No. 189. Retrieved from https://www.oecd-ilibrary.org/social-issues-migration-health/the-risk-of-automation-for-jobs-in-oecd-countries_5j1z9h56dvq7-en
- Arntz, Melanie, Terry Gregory, & Ulrich Zierahn (2017) "Revisiting the Risk of Automation" *Economics Letters*, Vol. 159, pp. 157-160.
- Brandes, Philipp, & Roger Wattenhofer (2016) "Opening the Frey/Osborne Black Box: Which Tasks of a Job are Susceptible to Computerization?" *European Association for Theoretical Computer Science*, 120.
- Brynjolfsson, Erik & Andrew McAfee (2014) *The Second Machine Age: Work, Progress, and Prosperity in a Time of Brilliant Technologies*. W. W. Norton & Company.
- Brynjolfsson, Erik, Daniel Rock, & Chad Syverson (2017) "Artificial Intelligence and the Modern Productivity Paradox: A Clash of Expectations and Statistics," *The Economics of Artificial Intelligence: An Agenda*, p. 23-57.
- Coelli, Michael & Borland, Jeff (2019) "Behind the headline number: Why not to rely on Frey and Osborne's predictions of potential job loss from automation," *Melbourne Institute Working Paper*, No. 10/19.
- Frey, Carl B. & Michael A. Osborne (2013) "The future of employment," *WORKING PAPER*. Retrieved from

- https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf
- Frey, Carl B. & Michael A. Osborne (2017) “The future of employment: How susceptible are jobs to computerization?” *Technological Forecasting & Social Change*, 114 254-280.
- Fuei, K. Lee (2017) “Automation, Computerization and Future Employment in Singapore,” *Journal of Southeast Asian Economic*, 34, 2 388-399.
- Nedelkoska, Ljubica and Glenda Quintini (2018) “Automation, skills use and training,” *OECD Social, Employment and Migration Working Papers*, No. 202. retrieved from https://www.oecd-ilibrary.org/employment/automation-skills-use-and-training_2e2f4eea-en
- Pajarinen, Mika, Petri Rouvinen, and Anders Ekeland (2015) “Computerization Threatens One-Third of Finnish and Norwegian Employment,” *ETLA Briefs*, 34. Retrieved from <https://www.etla.fi/wp-content/uploads/ETLA-Muistio-Brief-34.pdf>
- Spitz-Oener, Alexandra (2006) “Technical Change, Job Task, and Rising Educational Demands: Looking outside the Wage Structure,” *Journal of Labor Economics*, Vol. 24, No. 2, pp. 235-270.
- Stephany, Fabian and Lorenz, Hanno (2021) “The Future of Employment Revisited: How Model Selection Determines Automation Forecasts“. Available at SSRN: <https://ssrn.com/abstract=3835759> or <http://dx.doi.org/10.2139/ssrn.3835759>
- 池永肇恵 (2009) 「労働市場の二極化：IT の導入と業務内容の変化について」『日本労働研究雑誌』 No.584, pp.73-90.
- 池永肇恵 (2011) 「日本における労働市場の二極化と非定型・低スキル就業について」『日本労働研究雑誌』 No.608, pp.71-87.
- 池永肇恵 & 神林龍 (2010) 「労働市場の二極化の長期的推移：非定型業務の増大と労働市場における評価―」一橋大学経済研究所世代間問題研究機構, IRDB Technical report, pp. 1-35.
- カール・ベネディクト・フレイ & マイケル A. オズボーン (2015) 『日本におけるコンピュータ化と仕事の未来』 野村総合研究所.
- 厚生労働省 (2020) 「職業情報提供サイト (日本版 O-NET)」
<<https://shigoto.mhlw.go.jp/User/download>>.
- 小松恭子 & 麦山亮太 (2021) 「日本版 O-NET の数値情報を使用した応用研究の可能性：タスクトレンド分析を一例として」 JILPT Discussion Paper 21-11 <<https://www.jil.go.jp/institute/discussion/2021/21-11.html>>. (2021/9/4 閲覧) .
- 総務省統計局 (2020) 『令和 2 年国勢調査の集計体系及び結果の公表・提供等一覧』
<<https://www.stat.go.jp/data/kokusei/2020/pdf/schedule.pdf>>.

独立行政法人労働政策研究・研修機構（JILPT）（2012）『職務構造に関する研究：職業の数値解析と職業移動からの検討』労働政策研究報告書 No. 146.<<https://www.jil.go.jp/institute/reports/2012/documents/0146.pdf>>.

独立行政法人労働政策研究・研修機構（JILPT）（2019）『労働力需給の推計：労働力需給モデル（2018年度版）による将来推計』労働政策研究報告書 No. 209.<<https://www.jil.go.jp/institute/siryu/2019/209.html>>.

独立行政法人労働政策研究・研修機構（JILPT）（2017）『職業情報の整備に関する基礎的研究：マッチング効率の高い職業分類策定のための課題』JILPT 資料シリーズ No. 187<<https://www.jil.go.jp/institute/siryu/2017/documents/187.pdf>>.

<付録>

機械学習モデル実行手順の解説

1. はじめに
2. Python の準備
3. ファイルのダウンロード
4. コードの実行

1. はじめに

本解説では千葉・福田論文 (2023) において実行した 2 つの機械学習モデルである①Frey & Osborne モデルの再現と、②このモデルを日本版 O-NET データで実行するための拡張モデルの構築、を行うための Python コードの実行手順について解説する。

2. Python の準備

本論文内でのプログラムの実行環境として Python 3.10.7 を利用した。プログラムに必要なパッケージとそのバージョンは以下の通りである。各パッケージのバージョンが下記と異なる場合はプログラムが正常に動作することを保証しない¹⁴。

matplotlib: 3.6.2

numpy: 1.23.5

pandas: 1.5.2

sklearn: 0.0

scikit-learn: 1.1.3

¹⁴ 各パッケージは pip や Anaconda を使ってインストールすることができる。Python の実行環境を持っていない初学者には Google Colab が便利である。Google Colab の初期環境は Python3.7.14 であり、各パッケージのバージョンは本解説とは異なる (2022 年 9 月 20 日時点)。Google Colab を利用する場合、Python のバージョンをアップデートする必要があるが、matplotlib はアップデート (ver. 3.5.3)、sklearn と scikit-learn は新規でインストールする必要がある。

3. ファイルのダウンロード

以下のリンクから、推計に必要なファイルをダウンロードする。

<https://drive.google.com/drive/folders/1xKIEsSuqWzVUHBEBLT11QJsxIcuOtrh5?usp=sharing>

・「01_Frey_Osborne_Model.zip」

Frey & Osborne (2013, 2017)のガウス過程分類モデルを再現する機械学習（第IV節）に用いた以下のファイルを格納。

- ・ 学習データ：Frey_Osborne_Model_2010_America_traindata.csv
- ・ 実験データ：Frey_Osborne_Model_2010_America_testdata.csv
Frey_Osborne_Model_2020_America_testdata.csv
- ・ Python ファイル：Frey_Osborne_Model.py
- ・ アウトプットデータ：Frey_Osborne_Model_Score_of_Model_gpr_7_kernel.csv
Frey_Osborne_Model_train_scatter_AutoProb.png
Frey_Osborne_Model_train_gpr_7_kernel.csv
Frey_Osborne_Model_2010_America_test_gpr_7_kernel.csv
Frey_Osborne_Model_2020_America_test_gpr_7_kernel.csv

*なお、zip ファイルと同名のフォルダーには上記と同じファイルが格納されている。

・「02_Extended_Model.zip」

Frey & Osborne (2013, 2017)のガウス過程分類モデルを日本版 O-NET データで実行するための拡張モデルを構築する機械学習（第VI節）に用いた以下のファイルを格納。

- ・ 学習データ：Extended_Model_2010_America_traindata.csv
- ・ 実験データ：Extended_Model_2010_America_testdata.csv
Extended_Model_2020_America_testdata.csv
Extended_Model_2020_Japan_testdata.csv
- ・ Python ファイル：Extended_Model.py
- ・ アウトプットデータ：Extended_Model_Score_of_Model_gpr_7_kernel.csv
output/Extended_Model_train_scatter_AutoProb.png
Extended_Model_train_gpr_7_kernel.csv
Extended_Model_2020_America_test_gpr_7_kernel.csv
Extended_Model_2020_Japan_test_gpr_7_kernel.csv

*なお、zip ファイルと同名のフォルダーには上記と同じファイルが格納されている。

4. コードの実行

ダウンロードした Python ファイルを作業環境で実行する。コードの実行に必要なファイルは、以下の3つである。

- ① Python ファイル (ファイル名は「xx_Model.py」)
 - ② 学習データ (ファイル名は「xx_Model_2010_zz_traindata.csv」)
 - ③ 実験データ (ファイル名は「xx_Model_20yy_zz_testdata.csv」)
- ※ 「xx」はモデル、「yy」は西暦の下2桁、「zz」は国名を表している。

以下「Frey_Osborne_Model.py」を例に、Python ファイルの実行内容について解説する。「Extended_Model.py」においても内容はほぼ同一だが、使用するデータファイルの数が異なるため、下記に記載の行とは一致しない点に留意されたい。

1 ~ 8 行目	使用するパッケージの読み込み
10 ~ 23 行目	学習データと実験データの読み込みと欠損値の除外処理
25 ~ 44 行目	変数の設定とオートスケーリング
46 ~ 61 行目	モデル構築に使用するカーネル関数の記述
63 ~ 65 行目	モデルが収束しなかった場合の対応に関する記述
67 ~ 76 行目	ガウス過程回帰による再現モデルの構築
78 ~ 91 行目	モデルの評価 (r^2 , RMSE, MAE)
93 ~ 96 行目	逆ロジット変換
98 ~ 115 行目	モデルの評価 (散布図)
117 ~ 124 行目	構築したモデルに学習データを投入した結果とその保存
126 ~ 160 行目	構築したモデルに実験データを投入した結果とその保存

論文における推計では11種の関数から評価が最も良いモデルを選択している。11種のカーネル関数の値は0~10で定義されている。Frey & Osborne モデルの60行目、拡張モデルの66行目の値を変更するとカーネル関数を変更され、異なるカーネル関数による推計モデルの評価結果が算出される。

また、作業中のフォルダーの中に、コードで記載したファイル名と同じファイルがあった場合、上書き保存がされる。そのため、異なる推計結果を出力する際は、ファイル名を書き変えた後に実行をする必要がある。例えば、論文と異なるカーネル関数を選択して実行する際は、ファイル名の数字(カーネル関数の番号)を変える必要がある。

実行の結果、順に以下の内容が出力される。

- ① モデルの評価 (決定係数, RMSE, MAE) (ファイル名は「xx_Model_Score_of_Model_gpr_7_kernel.csv」)

- ②モデルの評価（散布図）（ファイル名は「xx_Model_train_scatter_AutoProb.png」)
 - ③学習データとモデル推計値の誤差（ファイル名は「xx_Model_train_gpr_7_kernel.csv」)
 - ④ 実験データによる自動化確率の推計結果（ファイル名は「xx_Model_20yy_zz_test_gpr_7_kernel.csv」)
- ※ 「xx」はモデル, 「yy」は西暦の下2桁, 「zz」は国名を表している

②は png 形式のファイル, ①と③と④は csv ファイルとして作業フォルダーに保存される。但し, ①は csv ファイルとは別で文字列として標準出力に表示される。

最後に, 最新の日本版 O-NET あるいは米国版 O*NET が公開された場合の対応について記述する。まず, 最新版データのクリーニングを行い, 新しい実験データを作成する。具体的には, SOC や ESCO に対して1種類以上の職業が紐づけられる場合, それらの職業のボトルネック変数について「平均化」の処置を行う（詳細は千葉・福田論文（2023）を参照）。実験データは csv 形式で作成し, Python ファイルと同じフォルダーに保存する。次に, 実験データを差し替える。Python ファイル内に記述された実験データ用のファイル名を最新版データのファイル名に書き変える。実験データのファイル名は, Frey & Osborne モデルであれば22行目, 拡張モデルであれば22行目と26行目がそれに該当する。Frey & Osborne モデルの再現もしくは拡張が目的である場合は, 学習データ (train data) のファイル名は変更しなくてよい。最後に, 本解説書と同様の手順で Python ファイルを実行する。

以上
(2023年1月9日)