

アジャイルな社会に向けて

丸山 宏[†]

(受付 2018 年 2 月 6 日；改訂 5 月 31 日；採択 6 月 1 日)

要 旨

筆者は 2011 年 4 月より 2016 年 3 月まで、統計数理研究所サービス科学研究センターのセンター長として勤務した。その中でいくつか一見関連のない研究活動を行ったが、それらを俯瞰してみると「変化にどのように向き合うか」という一貫したモチーフが見えてくる。我々はますます変化が激しくなる社会に直面していて、それに対して我々自身もアジャイルに変化していかなければならない。本稿では、サービス科学、情報技術の変遷、レジリエントなシステム、個人のキャリアとスキル、という 4 つの観点から、我々が日々直面する変化にどのように対応していくか、を議論する。

キーワード：Service Science, Statistical Machine Learning, Resilience, Data Scientists.

1. はじめに—変化にどのように向き合うか

我々は急速に変化する社会に生きている。我が国では主要先進国でも類を見ない速さで少子・高齢化が進んでいる。一方で、情報技術や生命科学などの技術革新が進み、それに応じて社会のインフラや仕組みも変化しつつある。グローバル化によって国の境界を超えて産業のエコシステムが複雑に絡みあうと同時に、特に 21 世紀に入ってからにはテロなどの宗教的・民族的な問題が世界を引き裂こうとしている。このような変化に対して我々はどのように向き合っていけばよいのだろうか。

筆者は 2011 年 4 月より 2016 年 3 月まで、統計数理研究所サービス科学研究センターのセンター長として勤務した。その中でいくつか一見関連のない研究活動を行ったが、それらを俯瞰してみると「変化にどのように向き合うか」という一貫したモチーフが見えてくる。本稿では、サービス科学、情報技術の変遷、レジリエントなシステム、個人のキャリアとスキル、という 4 つの観点から、我々が日々直面する変化にどのように対応していくか、を議論したい。

第 2 章では、産業構造の変化に対する取り組みとして、サービス科学とは何かを議論し、特にサービス科学研究センターで主要なテーマとした「データに基づく意思決定」について述べる。

製造業からサービス業への業態の変革を遂げた業種の 1 つが情報産業である。第 3 章では、情報産業が、いかに変化に適応していったかを概括し、さらに、統計的機械学習に基づく帰納的なシステム開発によって今後の開発がより適応的になっていくことを説明する。

そもそも変化に強いシステムとは何だろうか。サービス科学研究センターは 2011 年、東日本大震災の直後に立ち上がったので、災害にどのように対応するかをセンターの 1 つのテーマとすることは自然な発想だった。自然災害のような大きな擾乱が起きても、何らかの形で回復して機能を取り戻すシステムをレジリエントなシステムと呼ぶ。我々はレジリエンスとは何

[†] 株式会社 Preferred Networks：〒100-0004 東京都千代田区大手町 1-6-1 大手町ビル 2F

か、レジリエンスを実現するにはどのような方略があるかを、多分野のエキスパートを集めて4年間研究した。そこで得られた知見について第4章で議論する。

サービス科学研究センターではまた、2013年度から3年間「データサイエンティスト育成ネットワークの形成」という文部科学省委託事業を行った。少子・高齢化が進む社会では、個人が長い期間労働することが求められる。変化の激しい社会で長期間働くためには、我々のスキルもそれに合わせて変化していかなければならない。第5章では、この委託事業の知見を振り返りつつ、変化する社会で私たち個人が身につけなければならないスキルとは何かについて考える。

2. ビジネスの変化—サービス科学

18世紀後半に始まった産業革命から、20世紀後半になるまで、世界の産業・経済の仕組みは製造業を中心に構築されてきた。工場に大きな投資をし、工場労働者が製品を低コストで大量生産し販売する、という考え方である。そこでは、同じ製品が多くの顧客に、また長期間に渡って売れるだろうという「ものづくり」の前提があった。

消費者の観点からは、20世紀までは「ものを所有することが価値であった時代」と言えるかもしれない。高度経済成長期やそれに続くバブル経済においては、自家用車を所有することはステータスであり、所有することに価値があった。しかし、人々が物質的に豊かになるにつれ、所有することの価値が相対的に小さくなってきている。Rifkin (2014)は、生産性の向上が進んだことによって製造物の生産にかかる限界費用が限りなくゼロに近づいていく社会を描いている。限界費用がゼロであれば、製品を所有すること自体には価値がなくなっていくだろう。もし、所有すること自体が目的でないのであれば、自動車は人々を運ぶ、という機能を提供すればよいことになる。そのことに注目して新たなサービス業を始めたのが、例えば自動車の配車アプリで急成長したUberである。将来、産業の長い歴史を振り返ったとき、製造業を中心とした産業構造の時代は、産業革命の18世紀後半から20世紀後半までのたった200年だと記憶されることだろう。21世紀からは、サービス産業の時代である。

サービス科学は、このような産業構造の変化に対する必要から生まれてきた。現在、我が国の労働人口約5,800万人の7割以上がサービス産業に従事している。サービス科学を提唱したIBMは1980年代までは大型計算機を製造・販売する製造業であったが、1990年代に入ってサービス産業に大きく転換した。その転換の過程で、製造業に見られる工学的な知識体系をサービス産業にも導入しようとして提案したのがサービス科学と呼ばれる学問領域である。サービス科学は、情報科学、経営科学、組織論など複数の領域にまたがった学際領域と考えることもできる。

2.1 サービスの特質—文脈依存性

製造業における機械工学、材料工学などの知識体系に対比してサービス産業における知識の体系化を考えると、サービス産業には製造業と対比してどのような特質があるのかを考えてみよう。Parasuraman et al. (1985)は、サービスの品質を議論する上でサービスと製造物の主要な違いが、次の4つであると指摘している。

- 無形性(intangibility)—製品と違って、サービスで提供されるものは通常手に触れることができない。提供されるものは、サービス提供者の活動の結果としての効果・効能である。提供されるものが目に見えたり手で触れたりすることができないため、その価値を客観的に見極めるのが難しく、価格決定の困難さにつながる。
- 異質性(heterogeneity)—同じサービスでも、提供する人、提供される場所、利用者の置

かれている環境や心理状態により、サービスの効果や利用者の受け止め方が異なる。同じサービスでも利用者によって受け取る価値が異なるので、これも価格決定の難しさにつながる。

- **同時性 (inseparability)** — 製造物では、製品が製造され、それが顧客に販売されて所有権が移転してから、製造物が利用される。一方、サービス業では生産と消費が双方向的に、時間的・空間的に同時に起こる。このため、提供物の品質の事前チェックが難しい。
- **消滅性 (perishability)** — 製造物と違って、サービスは予め作って在庫しておくことができない。このため、需要の変動の影響を、製造業より強くうけることになる。

また、Vargo et al. (2008)は、サービスとは顧客との価値共創と述べている。これらの特質はいずれも、サービスの価値がその文脈に強く依存することを示している。文脈は変化するのであり、サービス提供者はその文脈に合わせてサービスの形態を変えたり、価格を変えたりしなければならない。

一方で、多くのサービスでは、製造業と異なり、構築に時間とコストのかかる生産設備を要しない。このため、文脈に合わせて手軽にサービスの内容を変化させていくことができる。特に、近年のサービスの多くは情報技術を使ってネット上の Web サービスとして提供されていて、それらはクラウドを使うことによって、変動する需要に弾力的に対応したり、サービスの内容をダイナミックに変化させていくことが容易である。

2.2 データに基づく意思決定

サービス科学には、経営、マーケティング、オペレーションズ・リサーチ、品質管理、イノベーション、組織論など多くの領域があり、全体を網羅的に研究することには無理がある。そこで、統計数理研究所サービス科学研究センターではそのテーマを「データに基づく意思決定」とした。

21世紀のサービス業は、Web やスマートフォンアプリで提供されたり、IoT (Internet of Things) によって大量のセンサーデータを集めるなど、情報技術に強く結びついている。折しもビッグデータという考えが注目を浴びてきていて、情報技術によって得られるデータをどのように経営の意思決定に結びつけるかをセンターの中心テーマに据えることは時流にもかなったものであった。

データ分析と一口で言っても、様々なタイプの分析手法があり、異なるビジネス局面では、異なるデータ分析が必要となる。どのような状況において、どの種のデータ分析が適しているのか、それが何を与えてくれるのか、そのためにはどのような前提が必要なのか、意思決定者は理解しておかなければならない。

我々は、Evans and Lindner (2012)に基づき、データ分析を目的によって Descriptive (説明的)、Predictive (予測的)、Prescriptive (指示的)の3つに分類して考える。

説明的データ分析 (Descriptive Data Analysis)

データ分析が教えてくれることの第一は、「何が起きたか」という事実に関するものである。ある会社で、中南米市場向けの在庫が急速に不足するようになった。経済の発展によって市場が拡大しているのだろうか。自社の生産や流通に問題があるのだろうか。それとも、何か特別な理由があって末端の小売店が自分の在庫を確保するために注文を一時的に増やしているのだろうか。何が起きたかを知るには、様々なデータを眺める必要がある。社内の生産・在庫・売上などのデータに加えて、中南米の経済状況、政治状況、流行している商品、人々の消費動向など、問題の在庫状況に影響を与える可能性のある要因はいくらでもある。このような様々なデータ・ソースを結びつけて、何らかの説明を見つけなければならない。

データ・マイニングは Descriptive なデータ分析のための強力なツールである。データ・マイニングは、データから何か「面白い」兆候を見つけてくれる。有名なのはビールとオムツの例である。スーパーマーケットの POS 端末データに基づいて、何と何が同時に売れる可能性が高いか、を調べると、もちろん、パンとミルク、パスタとパスタソースなどが同時に売れるのは、すぐにわかる。だが、データ・マイニングを用いると、ビールとオムツが同時に売れる傾向にあることもわかる。子供のいる若い男性がスーパーマーケットに来るときに、それらを同時に買うことが多いということなのかもしれない。

このようなデータ分析は自動化するのは難しい。何が「面白い」発見であるかを、予め決めておくことは、その性質上困難だからである。面白さを決めるのは多くの場合人間であり、そのため、Descriptive なデータ分析は通常は人間と機械の協調作業となる。統計データ分析パッケージで各社がデータの視覚化に力をいれているのはそのためである。

逆に、これらのツールを使いこなす人間の側に要求されるのは、データの裏にあるストーリーを描き出してみせる想像力である。例えば攻撃を受けた Web サイトの調査の場合、大量のログデータを分析し、攻撃者がいつどのような方法で攻撃を行い、どれだけの機密情報を盗み出したかを再構成するのは、想像力を働かせて仮説を立て、それをデータで検証する、という作業の繰り返しとなる。

予測的データ分析(Predictive Data Analysis)

「ある日にビールを買った人が 400 人、オムツを買った人が 350 人いて、そのうちの 300 人はオムツとビールの両方を買った」という面白い事実を教えてくれるのはデータ・マイニングである。しかし、別の日にビールを買う人が 250 人になったら、どうだろうか？ 1000 人になったら？ それらが 30 代の男性だったら？ ビールを買う人に関するパラメータに対して、それらのうちの何人がオムツを買うか、という予測をする数式を立てることは、予測的データ分析である。

データ・マイニングは確かに何か面白い事象をデータの中から探してきてくれるが、そのような事象が常に起きるかどうかについては、語ってくれない。あくまでも過去に起きたことを見せてくれるだけである。将来に何が起きるか、このまま行くと中南米の市場シェアは下がるのか、あるいは生産力を増強すれば利益があがるのか、そういうことを意思決定者は知りたいだろう。このためには、過去のデータから法則性を導き出し、それを使ってまだ見ぬデータを推測するしかない。この「データから法則性を導き出す」ことは統計モデリングに他ならない。

統計モデリングは、将来に対する予測を与えてくれると同時に、現在や過去のデータの欠損値を埋めてくれる(オムツのデータが今日に限って、システム故障のために得られなかった場合、など)。さらに、モデルがあれば、様々な戦略をシミュレーションしてみることができる。ある販促を行って、ビールの売上が 20% 増えたとすれば、オムツの売上也増えるだろうか？ 統計的機械学習は、統計モデリングとそれに基づく予測を行うための重要なツールである。深層学習など統計的機械学習の技術は近年急速に進歩していて、金融、製造、流通、行政などあらゆる分野での応用が始まっている。統計的機械学習による予測には、大量のデータ処理が必要なため、今までは高度なプログラミングのできるスキルを持つ組織などに限られていたが、現在では多くのツールがあり、手軽に利用できるようになっている。

もちろん、統計的機械学習の技術がいくら進歩しても、通常完璧なモデルはあり得ない。統計学者の George Box は、「本質的にすべてのモデルは正しくない。ただし、役に立つモデルはある」と言っている(Box, 1976)。世の中のすべての機序を書き下すことはできないのだから、モデルは常に世の中の近似値にすぎない。だから、モデルによる予測も外れることがある。しかし、過去のデータに基づくモデルがあれば、より合理的な予測ができることは間違いない。

指示的データ分析(Prescriptive Analytics)

データ分析を行う究極の目的はよりよい意思決定につなげるためである。ビールとオムツが同時に売れる傾向にあることがわかって、売上増や顧客満足度向上につながる意思決定ができなければ役に立たない。モデルがあればシミュレーションができる。だが、シミュレーションにどのような仮説を入れるか、すなわちどのようなシナリオを作りパラメーターを設定するかわからなければ、そもそもシミュレーションは成り立たない。

最適化はそのようなシナリオとパラメーターの設定の可能性、つまりビジネスにおける「次の一手」の中で、最も良いものを選んでくれる技術である。可能な指し手が数個であれば、それらを次々に予測モデルに入れて、それらを評価することで、最もよい指し手を見つけることができる。もし、可能な指し手の数が大きければ、その中からベストなものを見つけるのは容易でない。最適化の手法は、単純な数え上げの不可能な、非常に大きいパラメーター空間の中で最適な設定値を探してくれる。

もう一つ、強力な最適化の手法として、「実際にやってみる」というものがある。最近 Web マーケティングの世界でよく使われる A/B テスティングというのはその一つである。A/B テスティングとは、たとえば Web ページの広告を A パターン、B パターンと分けてそれをランダムに表示し、どちらのほうの方がよりクリックされやすいか、を調べる。それによって自動的に Web ページのデザインを最適化するのである。より一般的には、強化学習と呼ばれる一連の手法があり、特に深層学習の普及によって広く使われるようになってきている。

もちろん、「何が最適か」は目的によって違う。クリック率を最大化したいのか、それとも売上を最大化したいのか、顧客満足度を上げたいのか、あるいは利益を上げたいのか、はたまたそれらの組み合わせかもしれない。「望ましさ」の尺度となる量を得る関数を、目的関数と呼ぶ(効用関数あるいは報酬関数と呼ばれることもある)。最適化アルゴリズムはこの目的関数を最大化するようにパラメーター空間の中を探索する。ただし、複雑な条件が絡み合う問題設定の中では、得られた解が必ずしも意思決定者にとってのぞましいものではないかもしれない。Dewey (2014) は強化学習における報酬関数の決め方の重要性と難しさを議論している。

ビジネスの状況に応じて、意思決定に必要なデータ分析は descriptive なものか、predictive なものか、それとも prescriptive なものであるかを見極めなければならない。データ分析は意思決定のために行うのであり、「どのような結果が得られれば意思決定できるか」を常に問い続けなければならない。統計数理研究所サービス科学研究センターでは、いくつもの企業との共同研究を行ったが、「何がわかれば意思決定できますか」という質問は、データ分析の手法を考える上で常に有効であった。

もちろん、同じ課題設定でも、場面によって部分問題として descriptive, predictive, prescriptive な分析の必要性が現れてくる。しかし、最終的に欲しいものは何か、それが説明なのか、予測なのか、最適化なのかを常に意識しておくことが重要であることがわかった。

本章の始めに述べた様に、サービスは変化する文脈に依存する概念であり、よりよいサービスを提供するにはその文脈の変化を理解し、予測し、それに合わせてサービスを最適化していかなければならない。深層学習など最新のデータ分析技術を利用することにより、今後もサービス産業はどんどん高度化していくことだろう。

3. 情報産業は環境変化にどのように対応するか

3.1 情報産業の変化

製造業からサービス産業への大きな転換を果たした産業分野の1つが情報産業である。情報技術が社会の様相を変化させ始めてからおよそ 50 年になる。最初は情報技術の利用は、主に既

存の社会の仕組みを効率化することに重点が置かれていた。昭和30年代の情報技術の普及していないオフィスの様子を想像してみるとよい。給与計算や経理の仕事がそろばんと手作業で行われていたビジネス現場に、情報技術が導入されることによって、飛躍的な生産性向上が図られたことは想像に難くない。同様に、金融・製造・物流など多くの産業、また企業会計・サプライチェーンマネジメント・顧客管理・オフィスの効率化など多くの職種において、情報技術が既存のビジネスを効率化させてきた。この効率化を主眼にした情報技術の利用(**Systems of Record**と呼ばれることがある)は、そろそろ社会の隅々まで行き渡って、これまでのような急速な生産性向上は望めなくなってきた。

Uberなど新たなサービス産業で現在起きているイノベーションは、既存ビジネス・プロセスの効率化ではなく、情報技術で顧客体験をダイレクトに作り出すことによって起きている(このようなシステムを**Systems of Engagement**と呼ぶことがある)。

Systems of Engagementは、第1世代の情報技術すなわち**Systems of Record**とどのように違うのだろうか。**Systems of Record**の開発においては、ものづくりの考えの延長で、事前に要件定義をきっちり行う、いわゆる「ウォーターフォール型」の開発が行われてきた。給与計算や銀行の勘定系システムのように、要件が長期にわたって安定しているシステムでは、このような考え方で問題なかった。一方、サービス・イノベーションを牽引する**Systems of Engagement**の開発では、ビジネス環境が刻々変化するため、短いサイクルで要件のバックログを見直すアジャイル開発¹⁾や、開発時と運用時の切り分けを行わないDevOps (Hüttermann, 2012)という運用が行われていて、こららの方法論がソフトウェア工学の知識として体系化されている。

このように、情報システムの開発手法は、環境の変化に追従するために変化してきた。これからますます変化が加速する社会において、今後のシステム開発はどうなっていくのだろうか。そのための切り札の1つが、統計的機械学習による帰納的开发である。

3.2 統計的機械学習による帰納的开发

システム開発の一例として、摂氏を華氏に変換するプログラムを考えてみよう。通常のプログラム開発では、まず「摂氏を入力として取り、それに対応する華氏を出力する」という要求仕様を定義し、その計算方法を我々が持つ先験的な知識(ここでは、 $F = 1.8 \times C + 32$ という変換式)に基づいてモデル化する。このモデルに基づいて設計を段階的に詳細化していき、実装を得る。これを、演繹的プログラミング(あるいはモデルベース開発)と呼ぶ。

一方、帰納的プログラミング(あるいはモデルフリー開発)においては、入出力の例を作ることから開発が始まる。例えば、摂氏と華氏の2つの温度計を調達して、時々それらの値を同時に読むことで訓練データセットを得る。訓練データセットに対して、統計的機械学習アルゴリズムを適用し、モデルを帰納的に求める。このモデルを用いて入出力の変換を行う。

これは統計モデリングに他ならない。ただし、パラメトリックな確率分布を仮定する伝統的な統計モデリングでは、モデル選択が正しく行われていることを前提としていて、このモデル選択が難しいことが知られている。一方、近年注目を浴びている深層学習においては、モデル選択がそれほどシビアでない。大量のパラメータを持つ深層ニューラルネットワークにおいても、實際上それほど過学習しないことが知られているからである。

深層学習の表現力はどうか。任意の計算可能関数について、それを十分な精度で近似できるニューラルネットワークが存在することが知られている(Cybenko, 1989)。このため、深層学習は擬似的にチューリング完全と考えることができる。この汎用計算機構は、今までのプログラミングとは異なり、入出力の例示により帰納的にプログラミングすることが可能である。

システム開発の方法論としてみたとき、統計的機械学習に基づく帰納的开发は、仕様を訓練データセットの形で表現し、実装は訓練(training)によって半自動的に行われる。もともと、

システム開発がウォーターフォール型で行われてきた背景には、一度システムを実装してしまうと、仕様など上流工程に戻ることが非常にコスト高である、という「モノづくり」と共通する制約があった。アジャイル開発では、要件が変化することを見越して小さなサイクルで開発を回すことで、手戻りのコストを最小化する。しかし、統計的機械学習に基づく帰納的開発では、新しい要件を表現する訓練データセットが低コストで用意できる限り、手戻りのコストは(訓練にかかる計算コストを除けば)ほとんどかからない、というメリットがある。このため、環境の変化に柔軟に対応できるシステムを開発できるという可能性がある。

このような新しいスタイルのプログラミングにおいて、効率的に品質の良いソフトウェアを開発するにはどうしたらよいのだろうか。統計的機械学習を取り入れたシステム(本稿では機械学習応用システムと呼ぶ)の開発はまだ発展途上にあり、このような方法論(我々はソフトウェア工学に習って機械学習工学と呼んでいる)の議論は新たにスタートしていて、今後の発展が望まれる(Maruyama and Kido, 2017)。

4. レジリエンス—そもそも変化に強いシステムとは何か

サービス科学や帰納的システム開発は、それぞれ特定の分野で変化に対応するための手法だと言える。分野に関わらず、そもそも変化に強いシステム(我々はレジリエントなシステム、と呼ぶ)というものは考えられるだろうか。あるとしたら、それらの共通戦略はなんだろうか。我々は、サービス科学研究センターの活動の一環として、システムのレジリエンスを科学的に解明するため、情報・システム研究機構の領域横断的研究プロジェクト「システムズ・レジリエンス」を2012年度から2015年度にかけて実施した(システムズ・レジリエンス・プロジェクト, 2016)。本章では、その主要な成果を概括する。

4.1 レジリエンスのタクソノミ

多くのレジリエンスに関する先行研究を調査した結果、我々はレジリエンスを、少なくとも1)擾乱のタイプ、2)対象とするシステム、3)回復のタイプの3つの軸に整理した(Maruyama et al., 2014)。

1) 擾乱のタイプ

意図の有無：意図を持たない擾乱(例：自然災害)、意図的な攻撃(例：戦争)

頻度：高頻度な擾乱(例：交通事故)、極めて稀な事象(巨大隕石の衝突)

予測可能性：かなりの精度で予測できるもの(例：台風の進路)、事前に正確に予測することが不可能なもの(例：巨大地震)

継続時間：発生から終了までが極めて短時間な擾乱(例：落雷)、継続時間が極めて長い擾乱(例：地球温暖化)

内部性：システム外部からの擾乱(例：自然災害)、システムの内部から発生する脅威(例：複雑さで自己崩壊するシステム(Per Bak and Wiesenfeld, 1987))

2) 対象システム

対象領域：生態学、生物学、金融、社会コミュニティ、組織など

粒度：個別システム(例：個人)を対象とするのか、集合体(例：社会全体)か

能動性：擾乱に対する回復のメカニズムを内在的に持つ(例：生態系)か、その維持に人間の知的作業による能動的な介入が必要か(例：組織)

機能：目的関数が明確(例：営利組織)か、多数のステークホルダのためシステム全体の目的関数が不明確(例：コミュニティ)か

3) 回復のタイプ

工学的レジリエンス：システムが擾乱の前と全く同じ構造に戻る場合(例：制御工学によるフィードバック制御，故障時の部品交換など)

機能的レジリエンス：異なる構造で，同等以上の機能に回復する場合(例：製造業からサービス業に転換した IBM. 企業として利益を上げるという機能は同じだが，内部構造が異なる)

適応的レジリエンス：別の機能・目的を持った新たなシステムとして生まれ変わる場合(例：戦前・戦後の日本. 全体主義から民主主義へと価値観は転換したが，民族・文化などのアイデンティティーは保たれた)

4.2 レジリエンス戦略

システムをレジリエントにする戦略は様々なものが考えられる。我々は，それらの戦略を，図 1 に示すレジリエンス・サイクルに沿って整理する。

設計時のレジリエンス戦略

冗長性：マージンの増大(例：より高い津波に耐える防潮堤を作る)，多重化(例：データセンターにおいて電源やネットワークを多重化)，相互運用性(バックアップ資源間の相互運用性により，少ないバックアップ資源で多重化の効果を出す)，など

多様性：多様性指標管理(例：マイノリティ従業員の割合を管理)，ポートフォリオ(例：金融の世界でリスク分散)など。なお，システムに多様性を導入するための戦略として，収穫逓減則の効果があることが知られている(Akashi et al., 2012)。

資源・管理の分散化：資源や管理を 1 点に集中しておく，そこが被害を受けた時にシステム全体が止まってしまう。このため，資源や管理を分散化しておくことが望ましい(例：インターネット)。

リスク転移：リスクを他者に転移することはリスク管理でよく知られた手法である(例：保険をかける)。

運用時のレジリエンス戦略

訓練：訓練には，事前に通告して行うスケジュールされた訓練と，抜き打ちで行う訓練がある。Google などのデータセンターにおいては，“Game Day” と称して抜き打ちで意図的に障害を注入する訓練も行っている(Limoncelli et al., 2012)。

マネジメントサイクル：環境の経時変化に対して，システムの本来設計された機能を維持するためには，PDCA サイクルを回す。

抑止：意図的な攻撃に対しては，防護手段や報復手段を見せることで抑止する。

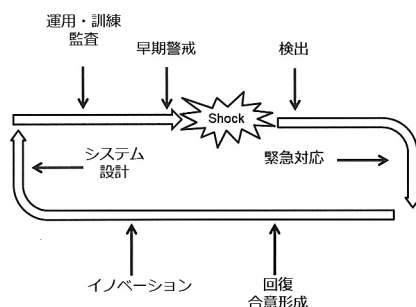


図 1. レジリエンス・サイクル。

早期警戒に関するレジリエンス戦略

擾乱の予測：擾乱が来ることが事前に予測できればそれに応じた対応を取ることができる（例：台風の上陸予測）。

早期対策：擾乱が来ることが確実でなくても、擾乱の可能性が高まった場合には、早期対策が有効である（例：テロに対する警備）。

緊急時のレジリエンス戦略

擾乱の検出・損害の評価：まずは発生した擾乱を検出しなければならない。擾乱の検出には、予測と同様にデータの収集とその分析が必須である。

ダメージコントロール：被害拡大防止（例：ウイルス汚染されたPCの切断）

ポリシーの切替：緊急時には、通常時と異なるポリシーを適用する必要があるかもしれない（例：緊急時に個人情報保護よりも人命救助に必要な情報アクセスを優先する（Maruyama et al., 2013））。

現場への権限委譲：現場で危機対応を行う第一応答者（first responder）にかなりの自由裁量を与える（例：危機対応の国際規格であるISO22320では、「意思決定は、可能な限り低い階層で行うことを許可し、連携及び支援は必要とされる中で最も高い階層から提供することを許容することがのぞましい」としている）。

回復時のレジリエンス戦略

資源割当の最適化：システムの回復のためには資源を投入する必要がある。しかし、地震などの広域災害の場合、資源の配分が必ずしも最適に行われるわけではない。このため、資源の割当を最適化することが重要である。

利他主義：自分の利益を後回しにして他人を助けることで、コミュニティ全体の復興を促進する（例えば2011年に行われた慶応大学の調査によれば、震災後に日本人の利他性が高まったとしている²⁾）。

境界拡大：対象システムが救えない時に、スコープを上げて上位のシステムの回復を目指す（例：ある企業のビジネス継続が難しくなったときに、問題をその会社のレジリエンスではなく親会社のレジリエンスの問題と捉え直し、親会社に吸収することで事業の一部や従業員の雇用を救済する）。

イノベーション時のレジリエンス戦略

システムに擾乱があったとき、それはリスクでもあるが、同時にシステムを再構成し、より良いシステムに発展させるチャンスでもある。我々はこれを、通常の回復によるレジリエンスを表現する“bounce back”という言葉に対して、“bounce forward”という言葉で表現することがある（Yamagata and Maruyama, 2016）。“Bounce forward”のための戦略もいくつか考えることができる。

事後調査：擾乱の事後調査を行い、再発を防ぐ（例：サイバー攻撃が起きた場合に侵入経路など原因の調査を行い、対策する）。

合意形成：“bounce forward”させるために、どのようなシステムに回復させるか、合意形成を行わなければならない。

研究開発投資：擾乱をきっかけにシステムをより良くするために、長期的にイノベーションを起こすために研究開発に投資する。

以上、様々なレジリエンス戦略を概括したが、これらの戦略は常に有効であるとは限らない。それぞれの文脈に応じて、効果のある戦略もあれば、そうでない戦略もある。このため、我々は戦略選択の支援ツールとして、レジリエンスの文脈と戦略との対応表を作成した（図2）。

アジャイルな社会に向けて




図 3. SR Model.

4.3 レジリエンスの数理モデル

複雑かつ大規模なシステムのレジリエンス性を評価するためには、汎用的な数理モデル上で様々な動的特性を解明する計算論的手法が不可欠である。我々は、計算機科学の知見を元に、レジリエンスの原始的な数理モデルを提案し、そこからいくつかの性質を論理的に導びいた。

4.3.1 SR Model

我々は図3に示すようにシステムの状態が、有限の記述で表現できると仮定する。このことは、システムの状態を長さ n のビット列で表すことができる、と言い換えることができる。システムは、 2^n 通りの異なる状態を持つことができる。

システムはある時点で、環境に適応している。環境への適応性は、これらのビット列に対する制約という形で表現することにする。環境(制約) C は、システムの状態空間の部分集合として表す。一般にシステムの状態 s の環境 C に対する適応度はシステムの状態空間における適応度関数で定義できる。ここでは説明を簡略化するため、状態 s が環境 C に適応 ($s \in C$) しているかまたは不適応 ($s \notin C$) であるかの2値を考慮する適応度関数を考えることにする。システムの状態 s が環境 C に適応しているとは、 $s \in C$ が成り立つと定義する。

さて、環境 C が変化して、 C' になったとしよう。もし、今のシステム状態 s が新たな環境に適応していない、すなわち $s \notin C'$ とする。その場合、システムは新しい環境に適応すべく、システム状態を変化させなければならない。例えば、一度に1ビットを反転させて $s \in C'$ になるにはどれだけのステップがかかるか、という問題を考えよう。もし、環境の変化に対して常に k ステップ以内で $s \in C'$ とすることができれば、このシステムは k -レジリエントと呼ぶことにする。

これは非常にシンプルな数理モデルであるが、我々はこの考えを拡張してレジリエンスの数理モデル SR-Model を構築した(Schwind et al., 2013)。このモデルでは、レジリエンスは、外界の擾乱とシステム管理者の対応が交互に行われる、2プレイヤーのゲームの軌跡(System State Trajectory, SST)として解釈される(図4)。この軌跡のコスト(あるいはコストの移動平均)がある閾値を超えない場合、システムはこの軌跡に関してレジリエントだったと定義する。

4.3.2 レジリエンスの指標

このモデルから得られる帰結の一つは、レジリエンスの指標に関するものである。レジリエンスの指標としてよく知られているのは、Bruneau et al. (2003)による、Resilience Triangle というものである(図5)。これは、起きた事象に対して、システムのパフォーマンスを計測し、本来あるべきパフォーマンスとの差を積分したもの(図でいえば三角形の部分の面積)をレジリエンスの指標とするものである。これを、事後レジリエンス指標(performance metric)と呼




図 4. System State Trajectory.




図 5. Resilience Triangle.

ぶ。図 4 における軌跡に対してコスト関数を割り当てることに相当する。

事後レジリエンス指標は、起きてしまった事象に対してシステムのレジリエンスを評価するのには使えるが、将来起きうる事象に対して、システムがレジリエントにふるまうかについての知見を与えてくれるわけではない。我々が欲しいのは多くの場合、将来に起きうる事象に対して、システムがレジリエントであるかどうかの指標である。これを我々は事前レジリエンス指標(**competency metric**)と呼ぶ。事前レジリエンス指標を客観的に求めることは難しい。将来にどのような事象が生起するかわからないからである。このため、事前レジリエンス指標は多くの場合、ドメインに依存した主観的な指標となる。例えば都市におけるレジリエンスの評価においては、市民一人あたりの GDP、教育水準、失業率などの指標を組み合わせ、どの都市が将来の擾乱に対してよりレジリエントであるかを判断する、ということが行われている。このため、事後レジリエンス指標と事前レジリエンス指標を明確に結びつけることができない。

我々の SR-Model を用いると、事前レジリエンス指標は、「起きうるすべての将来に対しての事後レジリエンス指標の最大値」のような形で、事後レジリエンス指標と事前レジリエンス指標の間の関連付けを行うことができる。SR-Model において、「今後起きうるすべての将来事象を数え上げられる」ことを仮定しよう。図 6 において、現在から将来に向かってすべての軌跡を数え上げることができれば、それらの軌跡の代表値(コストの最大値、平均値など)を求めることができる。この値をシステムの現時点での事前レジリエンス指標と考えれば、事後レジリエンス指標と事前レジリエンス指標を結びつけることができる。

4.3.3 レジリエンスの時間地平線

このモデルから理論的に得られる一つの帰結は、レジリエンスを語るには、有限の時間地平線を設ける必要がある、ということである。図 4 において、外界の擾乱は 1/2 の確率でシステムのコストを +1 し、それ以外はコストを変えないとしよう。同様にシステム回復の試みは




図 6. Set of Possible Trajectories.

1/2 の確率でシステムコストを -1 すると仮定する。そうすると、システムのコストの軌跡はランダムウォークとなる。ランダムウォークの結果、コストが最終的に取る値は、このランダムウォークを無限回試行すれば初期コストを中心とした正規分布になることが知られている。

このことは、どんな有限の閾値を設定しても、時間軸を無限に取る限り、ゼロでない確率でシステムのコストが閾値を超えることを意味する。したがって、時間軸を無限に取る限り、レジリエンスを保証するシステムは実現できないことが理論的に示される。

レジリエンスを実際に議論する時には、時間地平線について意識することは少ないと思われるが、我々が狙うレジリエンスとは、次の 10 年なのか、100 年なのか、1,000 年なのか、というタイムスケールを意識してレジリエンスを議論することが重要である、というのが我々の数理モデルから言えることの一つである。

4.3.4 SR-Model の限界

以上のように、SR-Model はレジリエンスに関する原始的な数理モデルとして用いることができる。しかし、SR-Model には限界もある。1 つには、上記の議論は静的なコスト関数を仮定していることである。システムが“Bounce Back”する工学的レジリエンスや機能的レジリエンスの場合には、コスト関数は変化しないが、擾乱をきっかけに全く新しい価値観を持つシステムに生まれ変わるようなシステムについては、SR-Model はうまくモデル化できない。

もう 1 つの限界は、本質的に閉世界を仮定していることである。回復の戦略の中には、システムの境界そのものを見直して、より上位のシステムを救う、というものもある。このようなレジリエンスは、SR-Model では扱えない。

4.4 終わりのない対話

瀬名・鈴木 (2009) は、パンデミックのような重大な擾乱に向き合った時、我々は「真実へ至る対話」「合意へ至る対話」「終わりのない対話」という 3 つの対話を繰り返していかなければならないのだ、と述べている。「真実へ至る対話」とは、擾乱の際に「何が起きたのか」に関する理解であり、この理解が得られれば“bounce back”するような対策を考えることができる。「合意に至る対話」とは、SR-Model におけるコスト関数を決めるものであり、私たちがどのように多様なステークホルダの間で、優先順位をつけて回復していくかを導いてくれる。そして「終わりのない対話」こそ、私たちが“bounce forward”するレジリエンス、すなわち人類社会の価値をどのように再定義していくか、という価値観の議論に他ならない。これらの対話に真摯に取り組むことがレジリエントな社会を作っていく本質なのではないだろうか。

5. 個人のキャリア—変化の時代を生き抜くスキル

変化が激しい社会においては、個人もその変化に対応してスキルを磨いていかなければなら

い。2章, 3章で見てきたように, サービス産業, またその根幹を支える情報技術の変化は, 特にデータ分析の領域において顕著である。このような変化に対して, サービス産業, 情報産業に従事する者はデータ分析のスキルを身につける必要があるだろう。本章では, まず, このような変化を先導すべき専門家としてのデータサイエンティスト育成の試みについて述べる。その上で, 情報技術やデータ分析が広く行きわたった社会で, 一般の市民がどのようにリテラシーを身につけるべきかについて考える。

5.1 データサイエンティストの育成

サービス科学研究センターで「データに基づく意思決定」の研究活動を行う中で, 実際にビジネス環境の中でデータ分析ができる人材をどのように育成したらよいか大きな課題として浮き上がってきた。このために, 文部科学省からの委託事業として「データサイエンティスト育成ネットワークの形成」を2013年度から2015年度までにかけて実施した(丸山, 2014)。

この事業が始まってから, 我が国のデータサイエンティストを取り巻く環境は大きく変化した。データサイエンティストという言葉が広く浸透し, データサイエンティストに関する多くの書籍が刊行され, データサイエンティストを育成する多くの教材が現れた。滋賀大学においては, 本邦初のデータサイエンス学部が平成29年度より設置され, 進学を考える高校生と, 人材を求める企業の双方から注目されている。新しい職種であるデータサイエンティストの育成と業界の健全な発展を目指す民間団体であるデータサイエンティスト協会は2018年1月現在50を超える法人会員と, 数千名の個人会員を擁するようになった。データサイエンティストとしての実務を経験する, データサイエンティスト向けのインターンシップ・プログラムも, 民間の営利事業として軌道に乗り始めている。産官学の有識者からなる「ビッグデータの利活用に係る専門人材育成に向けた産学官懇談会」は, 我が国におけるビッグデータ利活用人材育成の青写真とも言える提言を2015年7月に公開し³⁾, その提言に沿った施策の検討が行われた。これらの動きの多くには, 直接・間接に本事業で形成されたネットワークが関わっていて, その意味で本事業は一定の成果を挙げたと考える。

本事業期間全体を通して得られた主要な知見は以下の3点にまとめることができる。

(1) データサイエンティスト像の多様性

データサイエンティストという概念は米国で発生したものであるが, 「ビッグデータをビジネス上の価値に変えることのできるプロフェッショナル」という観点で見ると, 共通に求められる資質はあるものの, その専門性のレベル(見習い, 独り立ち, 棟梁クラス, 業界代表レベル, など), そのためのバックグラウンド(自然科学, 情報科学, 統計学, 経済学, 経営学など)や働き方(サービスプロフェッショナル, 部署内での専門家, フリーランスなど), キャリアの形成には多くのバリエーションがあることがわかった(Maruyama et al., 2015)。これらの多様性をサポートする育成を考える必要がある。

(2) 現場体験の重要性

データサイエンティストには, 統計学や統計的機械学習を中心とするデータサイエンス力, 情報科学やソフトウェア工学を中心とするデータエンジニアリング力, さらにビジネスを理解し推進するビジネス力という分野横断型のスキルが求められる。特に後者の2つは, 現場での経験から学ぶ割合の大きい分野であり, このためPBLなど現場体験型の育成が不可欠になる。本事業でも現場体験を推進するため「人材ローテーション」を柱の1つに掲げてインターンシップ・プログラムなどを実施したが, そのフィードバックからも, 現場体験の重要性は確認することができた。また, PBLとしては, データ分析ハッカソンを行った(丸山 他, 2016)。

(3) データサイエンティスト利用側のリテラシー・洞察

初年度におけるデータサイエンティスト現状調査や、その後実施した利活用ベストプラクティス調査などを含め、事業全体を通して繰り返し感じられたのは、データサイエンティストを育成するだけでなく、データサイエンティストを雇用し利用する側のリテラシーの重要性である。そのためには、社会全体のデータ・リテラシーも向上させる必要がある。

3番目の、利用側のリテラシーは社会全体の課題であり、情報技術やデータ分析の専門家だけの問題ではない。この問題について、次の節でより詳しく議論する。

5.2 リベラルアーツ

現代社会は、個人の自由と基本的人権を普遍的な価値と認める、という理念にもとづいている。個人の自由とは、様々な事柄について自分で決められる、ということだ。それを実践するスキルを「リベラルアーツ」という。私たちは社会の中で生きているので、「自分で決める」ということは社会の中で合意形成するということに他ならない。多人数間での合意形成は時として非常に難しいものになるが、科学における方法論や民主主義など、長い人類の歴史の中で私たちは「社会的動物の生きる知恵」としての合意形成の仕組みを作り上げてきた。一方で、情報技術、特にデータ分析の急速な発展が、それら人類の叡智とも言える合意形成の仕組みの前提を揺るがしている。人工知能の時代になっても、「自由人」であるためのアーツ(技芸)とは何か、を考える必要がある。

5.2.1 合意に関する人類の叡智

人類の長い歴史の中で築き上げられた「合意形成の叡智」として、科学と民主主義について考えてみよう。

科学において、何かが真であるということが認められるのはどういうときだろうか。最も古い科学の方法論の1つが、実験や観察を行い、その中から共通の原理を帰納的に見つけていくやり方であり実験科学と呼ぶ。19世紀の終わりになって提案された統計的仮説検定によって定量的な尺度を与えられるようになった。統計的仮説検定は帰無仮説を仮定すると実験結果が確率的にありそうもない時に、帰無仮説を棄却することで対立仮説を示す。この際、「確率的にありそうもない」値として、5%あるいは1%などの有意水準が使われる。これは極めて強力な推論ツールであり、これによって帰納的な実験科学は初めて、客観的でかつ定量的な裏付けを得ることができた。現在も、多くの科学の分野において、統計的仮説検定に基づく推論が行われている。統計が「科学の文法」(Pearson, 1900)と言われる所以である。

科学の方法論が「Xは真である」という形の命題についての合意であるのに対して、集団の意思決定の合意についての人類の知恵の一つが民主主義である。民主主義とは、市民による統治であり、独裁者や一部のエリート階級による支配ではない。民主主義においては、すべての構成員が平等に政策決定に参画する権利を持つ。ある政策が特定の個人やグループには有利だが、別の個人やグループに不利に働くとき、エリート政治家やエリート官僚がそれを決めるのではなく、民主主義においては全員参加で議論を尽くし、最終的には投票で決定する。この合意形成の方略は常にうまく働くわけでは無いし、民主主義が唯一無二の政治形態というわけでもない。しかし、人類の長い歴史の中で今のところもっともうまく機能している政治形態と言って良いだろう。

5.2.2 情報技術による「前提の崩壊」

科学や民主主義は、合意形成に関する人類の叡智と言えるが、その根底にある前提はしかし、情報技術の急速な発展によってくずれつつある。

まず、科学のプロトコルである実験科学について考えてみよう。情報技術のある世界では、統計的仮説検定は、Excel上でマウスクリック一つで行うことができる。だから、1回の実験に対していくらかでも複雑な仮説を生成して、試してみることができる。そういう世界で、前出の統計的有意水準を5%としてたくさんの仮説を試してみるとどういうことになるだろうか。p値が5%ということは、仮説が成り立たないにも関わらず間違っただけで統計的仮説検定を通過してしまうことが、20回の実験で1回くらいありそうだと、いうことである。互いに関係の無さそうな(独立な)仮説を20個試せば、その仮説が成り立っていないにも関わらず一つくらいの仮説は、よく認められた「科学の文法」によって、正しいものと認められてしまうのである。

英エコノミスト誌は2013年10月19日号の「なぜ科学が間違えるのか」という記事⁴⁾の中で、がん研究で「画期的な成果」とされた研究論文のうち、たったの11%が追実験によって再現可能だったと報じている。この理由の一つは、上述の有意水準から説明することができる。(半)自動化された実験・観測装置から大量のデータが得られ、それらに対してまた大量の異なるモデルを適用し、組み合わせ的に統計的仮説検定が行われる世界では、このような擬陽性も数多く生産されることを我々は知っていなければならない。このような問題を受けて、2016年に米国統計学会はp値の利用に関して注意を呼びかける声明を出している⁵⁾。情報技術を前提とした科学においては、19世紀の終わりに確立された文法では不十分であるのは明らかだ。

情報技術がもう一つの人類の叡智、民主主義に及ぼす影響について考えてみよう。民主主義においては、団体の構成員がすべて政治的に平等に意思決定に参画できなければならず、そのことは「全員が質問、議論、熟考をすることによって集団にとっての問題点を知る機会を十分に持っているという仮定」に基づく(Dahl, 2008)。Webなどの情報技術によって、市民一人ひとりが最新の情報にアクセスし、Blogなどを通して自分の考えを世に問うことができるようになり、その結果民主主義がより理想に近いものになるという期待がある。そこには、各人がそれぞれ普遍的な「理性」を持ち、他人に強制されるのではなく、自分自身の合理的な推論によって判断ができる、という啓蒙思想に基づいた前提がある。

しかし、私達は常に合理的な判断が下せるかというところでもないようだ。そこにも情報技術、特に統計的機械学習を始めとするデータ分析技術の進化の影響がある。データ分析は強力な技術だが、悪用すれば人々の心に内在する認知バイアスを操作することができる。人々の行動は合理的ではなく、様々な認知バイアスに晒されていることが知られている。Kahneman(2011)は、人間の合理的な判断を司る「システム2思考」は意識の集中を必要とするために、人々は努力しなくて済む直感的な思考「システム1思考」に頼りがちだという。だがシステム1思考には様々な認知バイアスがあることが今では知られている。

TwitterやFacebookなどのソーシャルメディアでは、同じ意見を持つ人どうしがコミュニティを作ることが容易で、これによってすべての人が同じ意見を持つと錯覚してしまう「エコーチャンバー効果」が知られている。これには人々の認知バイアスの一つである確証バイアスが影響している。また、コマーシャルに人気のある俳優を使うことも認知バイアスを利用したものである。このような、人々が持つ認知バイアスをビジネスに積極的に利用することは、主に広告業界でよく知られたテクニックである。

特に近年では統計的機械学習に代表される人工知能技術が進化していることもあり、「この商品を買った人はこれも買っています」のようなりコメンテーションなどが広く利用されている。人々の購買行動に影響を与えるだけならまだ良いが、このような認知バイアスを政治の世界でも利用しようとする動きがあり、Gore(2017)やHeath(2014)などが、警鐘を鳴らしている。ビッグデータ・統計的機械学習の進歩によって、啓蒙思想に対する新たな脅威が訪れていることを看過すべきでない。

5.2.3 ビッグデータ時代を生きるリベラルアーツ

このように、情報技術が意思決定の前提をあちこちで崩しつつある社会にあって、それでは私達が自由人として行動していくためにはどのようなスキルが必要なのだろうか。

まず私達は、今の世の中がなぜそうなっているかを知っておかねばならない。科学には科学の方法論、プロトコルがある。政治にもプロトコルがある。今の時代には合わずに、欠陥だらけのものに見えることもあるだろう。だが多くの場合それらの仕組みは、長い歴史の中で必然として現れてきたものだ。民主主義は確かに効率の悪い政治形態かもしれないが、圧政やそれに起因する戦争・飢餓を避けるための人類の叡智と見ることもできる。歴史を理解し、今の世の中の仕組みが何を乗り越えようとしてそうなったかを理解する、それが自由人として必要な知識の第1である。

もし情報技術が私達の自由意思を阻害しているのだとすれば、情報技術で何ができるのか、できないのかを知らねばならない。自由を脅かす敵を知る、それが自由人として必要な知識の第2である。「人工知能」という言葉が独り歩きしているが、マスコミ等で喧伝される擬人化された「人工知能」はまだ技術的には遠く、我々の社会に影響を与えるとしてもだいぶ将来のことになるはずである。一方で、デジタルゲリマンダーと呼ばれる、人間の認知バイアスを操作する技術は急速に発展している。その裏にある技術は統計的機械学習であり、基本的には大量のデータから、その確率分布を推定する統計の理論を元に行っている。統計は、データから人が気が付かなかったパターンを見出すことが得意であるが、一方で、常に過去のデータに基づいて未来を予測するので、過去と未来が基本的に変わらない(統計的には同じ確率分布からサンプルされる)場合にしかうまく働かない(Silver, 2012)。「人工知能」という言葉に惑わされず、ビッグデータの本質が統計であることを知れば、情報技術に過剰に期待したりむやみに恐れたりする必要はない。

同時に私達は、自分たちの「弱さ」も知っておかねばならない。特に自分の認知バイアスに気づくことが重要である。ここに難しさがある。認知バイアスとは、自分が気づいていないことだからである。ただし、どうしたらより自分のバイアスに気づけるか、についてのテクニックがいくつかある。それらについては、知識として理解しておくとともに、普段から実践することが重要ではないか。例えば Heath (2014)は、合理的思考であるシステム2には時間がかかるので、重要な意思決定は瞬間に判断せず、わずかでもよいから時間をかけるのが良いとしている。

6. おわりに

5年間にわたる統計数理研究所サービス科学研究センターの活動を振り返った。そこには「変化にどのように向き合うか」という共通のテーマがあった。

「変化に対応する知恵」としてサービス科学研究センターの活動を振り返った時、そこには常に統計の考え方があった。もちろん、統計数理研究所の組織であったので統計が主要な道具立てであることは当然なのだが、それだけではなさそうだ。統計とは畢竟、観測される現象に起きる小さな変化(ノイズ)を捨象して、その裏にある本質を捉える手法と考えることができる。その意味で、統計が「変化に対応する」ための手法として普遍的に現れるのは自然なことと思える。

注.

1) <http://agilemanifesto.org/>

2) https://www.keio.ac.jp/ja/press_release/2011/kr7a430000094z75-att/120215_1.pdf

- ³⁾ http://www.rois.ac.jp/open/pdf/bd_houkokusho.pdf
⁴⁾ <https://www.economist.com/news/leaders/21588069-scientific-research-has-changed-world-now-it-needs-change-itself-how-science-goes-wrong>
⁵⁾ <http://amstat.tandfonline.com/doi/abs/10.1080/00031305.2016.1154108>

謝 辞

サービス科学研究センターでの研究の機会を与えてくださった北川源四郎前情報・システム研究機構機構長、樋口知之統計数理研究所所長に感謝します。また、本稿では取り上げることができなかった多くの研究を推進してくださったサービス科学研究センターメンバーの方々に感謝いたします。

参 考 文 献

- Akashi, H., Osada, N. and Ohta, T. (2012). Weak selection and protein evolution, *Genetics*, **192**(1), 15–31.
- Box, G. E. P. (1976). Science and statistics, *Journal of the American Statistical Association*, **71**(356), 791–799.
- Bruneau, M., Chang, S. E., Eguchi, R. T., Lee, G. C., O'Rourke, T. D., Reinhorn, A. M., Shinozuka, M., Tierney, K., Wallace, W. A. and Von Winterfeldt, D. (2003). A framework to quantitatively assess and enhance the seismic resilience of communities, *Earthquake Spectra*, **19**(4), 733–752.
- Cybenko, G. (1989). Approximations by superpositions of sigmoidal functions, *Mathematics of Control, Signals, and Systems*, **2**(4), 303–314.
- Dahl, R. A. (2008). *On Democracy*, Yale University Press, New Haven & London.
- Dewey, D. (2014). Reinforcement learning and the reward engineering principle, *2014 AAAI Spring Symposium Series*, AAAI Publications, Palo Alto, California.
- Evans, J. R. and Lindner, C. H. (2012). Business analytics: The next frontier for decision sciences, *Decision Line*, **43**(2), 4–6.
- Gore, A. (2017). *The Assault on Reason: Our Information Ecosystem, from the Age of Print to the Era of Trump*, Bloomsbury Publishing, London.
- Heath, J. (2014). *Enlightenment 2.0*, Harper Collins, Toronto.
- Hüttermann, M. (2012). *DevOps for Developers*, Apress, New York.
- Kahneman, D. (2011). *Thinking, Fast and Slow*, Penguin Books, London.
- Limoncelli, T., Robbins, J., Krishnan, K. and Allspaw, J. (2012). Resilience engineering: Learning to embrace failure, *Communications of the ACM*, **55**(11), 40–47.
- 丸山宏 (2014). 我が国におけるデータ分析人材の育成と活用(特集 ビッグデータへのアプローチ), *Estrela*, No.244, 8–13.
- Maruyama, H. and Kido, T. (2017). Machine learning engineering and reuse of AI work products, *The First International Workshop on Sharing and Reuse of AI Work Products*.
- Maruyama, H., Watanabe, K., Yoshihama, S., Uramoto, N., Takehora, Y. and Minami, K. (2013). ICHIGAN security—a security architecture that enables situation-based policy switching, *2013 Eighth International Conference on Availability, Reliability and Security (ARES)*, 525–529, IEEE, Regensburg, Germany.
- Maruyama, H., Legaspi, R., Minami, K. and Yamagata, Y. (2014). General resilience: Taxonomy and strategies, *2014 International Conference and Utility Exhibition on Green Energy for Sustainable Development (ICUE)*, 1–8, IEEE, Pattaya City, Thailand.
- Maruyama, H., Kamiya, N., Higuchi, T. and Takemura, A. (2015). Developing data analytics skills in Japan: Status and challenge, *日本経営工学会論文誌*, **65**(4E), 334–339.

- 丸山宏, 神谷直樹, 宮園法明 (2016). クラウド環境を利用したデータ分析ハッカソンの計画と実施, *Estrela*, No.272, 30–37.
- Parasuraman, A., Zeithaml, V. A. and Berry, L. L. (1985). A conceptual model of service quality and its implications for future research, *the Journal of Marketing*, **49**(4), 41–50.
- Pearson, K. (1900). *The Grammar of Science*, Adam and Charles Black, London.
- Per Bak, T. and Wiesenfeld, K. (1987). Self-organized criticality: An explanation of $1/f$ noise, *Physical Review Letters*, **59**, 381–384.
- Rifkin, J. (2014). *The Zero Marginal Cost Society: The Internet of Things, the Collaborative Commons, and the Eclipse of Capitalism*, St. Martin's Press, New York.
- Schwind, N., Okimoto, T., Inoue, K., Chan, H., Ribeiro, T., Minami, K. and Maruyama, H. (2013). Systems resilience: A challenge problem for dynamic constraint-based agent systems, *Proceedings of the 2013 International Conference on Autonomous Agents and Multi-agent Systems*, 785–788, International Foundation for Autonomous Agents and Multiagent Systems, Saint Paul, Minnesota.
- 瀬名秀明, 鈴木康夫 (2009). 『インフルエンザ 21 世紀』, 文藝春秋, 東京.
- Silver, N. (2012). *The Signal and the Noise: Why So Many Predictions Fail—but Some Don't*, Penguin, London.
- システムズ・レジリエンス・プロジェクト (2016). 『システムのレジリエンス—さまざまな擾乱からの回復力』, 近代科学社.
- Vargo, S. L., Maglio, P. P. and Akaka, M. A. (2008). On value and value co-creation: A service systems and service logic perspective, *European Management Journal*, **26**(3), 145–152.
- Yamagata, Y. and Maruyama, H. (2016). *Urban Resilience*, Springer, Switzerland.

Towards Agile Society

Hiroshi Maruyama

Preferred Networks, Inc.

The Institute of Statistical Mathematics operated the Service Science Research center from April 2011 to March 2016. We conducted several seemingly unrelated projects during this period, but in retrospect there has been a common theme, which is how to deal with changes. In this manuscript we discuss our insights on how we make ourselves more agile in order to survive changes. These insights were acquired from these projects, namely, service science, new programming paradigm, systems resilience, and individual career development.