

別紙1

厚生労働科学研究費補助金
(地域医療基盤開発推進研究事業)

公的に標準化された医療情報を活用した感染症流行
状況と一般診療状況を把握するための分析手法の
開発および評価方法に関する研究

令和6年度 総括・分担研究報告書

研究代表者 佐藤 大介

令和6(2025)年3月

目 次

I. 別紙 3 総括研究報告

公的に標準化された医療情報を活用した感染症流行状況と一般診療状況を把握するための分析手法の開発および評価方法に関する研究・・・・・・・・・・・・・・・・・・ 1

佐藤 大介、渡邊 亮、村松 圭司、今村 知明

II. 別紙 4 分担研究報告

新興感染症の動向と一般診療への影響を把握するためのスキームの検討・・・・・・・・・・・・・・・・・・ 6

佐藤 大介、土井 俊祐、明神 大也、今村 知明、野田 龍也

DPC データを用いた感染症流行状況・診療状況の把握手法の開発・・・・・・・・・・・・・・・・・・ 13

高嶋 隆太、新城 大輔、伏見 清秀、佐藤 大介

厚生労働行政推進調査事業費補助金（地域医療基盤開発推進研究事業）

総括研究報告書

公的に標準化された医療情報を活用した感染症流行状況と一般診療状況を把握するための
分析手法の開発および評価方法に関する研究

研究代表者	佐藤大介（藤田医科大学大学院 病院経営学・管理学）
研究分担者	土井俊祐（千葉大学医学部附属病院）
研究分担者	明神大也（浜松医科大学 健康社会医学）
研究分担者	今村知明（奈良県立医科大学 公衆衛生学）
研究分担者	野田龍也（奈良県立医科大学 公衆衛生学）
研究分担者	谷口俊文（千葉大学医学部附属病院）
研究分担者	高嶋隆太（東京理科大学 創域理工学部経営システム工学科）
研究分担者	新城大輔（東京医科歯科大学大学院 医療政策情報学分野）
研究分担者	伏見清秀（東京医科歯科大学大学院 医療政策情報学分野）

研究要旨

COVID-19 対応では、HER-SYS による手入力による医療現場に大きな負担を強いており、今後の感染症対策にはデジタル技術を活用した効率的な情報収集と分析が不可欠である。そこで本研究は、新興感染症拡大時における医療体制維持のため、公的に標準化された医療情報（レセプト・DPC データ等）を用いて感染状況と地域医療需要を迅速に把握する仕組みを構築・評価することを目的とする。

第一に、感染症流行時に医療機関から日々収集されるレセプト情報を活用し、感染状況や医療資源使用のリアルタイム把握の可能性を検討した 1) システム処理への影響、2) ファイルサイズとストレージの必要量、3) 通常業務フロー、4) 病院機能の4点から次の収集頻度を提案した。

- ・特定機能病院・DPC 病院：週次（日次）
- ・一般病床：週次（日次）
- ・一般病床以外（精神除く）：月次（日次）
- ・診療所：月次（日次）

収集体制を実現するには診療報酬改定 DX の「共通算定モジュール」の導入が有効であることを示した。

第二に、DPC データに基づく SIRD（感受性-感染-回復-死亡）モデルを構築し、感染症流行状況の予測モデルを開発した。データの変数（入退院日・診療内容等）から、年齢や既往症などに応じた回復率・死亡率の推定が可能となり、感染拡大や医療資源需要を定量的に予測できる手法が示された。

本研究は、公的に標準化された医療情報を活用するために、日々レセプト導入の実現可能性と感染症情報の即時性の両立、上記データ活用した予測モデルの妥当性、今後のパンデミック対策に必要な情報基盤整備への知見を提供した。しかしながら、公的に標準化された医療情報を活用するにあたっては、死亡情報の欠落が課題であり、レセプト情報への入力や死亡個票等とのリンケージが必要である。

結論として、公的に標準化された医療情報を活用した感染症流行状況と一般診療状況を把握は十分実現可能であり、医療政策のエビデンスとなる情報基盤として有効であることを示した。

研究協力者
後藤 允 東京理科大学 創域理工学部
経営システム工学科 准教授
原田 拓 東京理科大学 創域理工学部
経営システム工学科 准教授
伊藤 和哉 東京理科大学 創域理工学部
経営システム工学科 助教

A. 研究目的

COVID-19 感染症は 2020 年 2 月 1 日に感染症法に基づく指定感染症に指定された後、2021 年 2 月 13 日に新型インフルエンザ等感染症に変更され、2023 年 5 月 7 日まで全数把握対象疾患であった。医療機関は COVID-19 の診断を受けた患者の情報を、HER-SYS と呼ばれる新型コロナウイルス感染者等情報把握・管理支援システム (Health Center Real-time Information-sharing System on COVID-19) に手動で入力する必要があった。日本においては延べ 3300 万人以上が COVID-19 に感染したが、COVID-19 感染を確認した医療機関が手動で HER-SYS に入力していたため、医療機関の負担が大きかったと言われている。

新興感染症等の感染症拡大時における医療提供体制の確保にあたっては、当該感染症による重症化率及び死亡率を下げる事が重要で、そのためには地域の医療需要や医療供給量の変化を迅速かつ的確にとらえ、医療体制を維持する施策が必要になってくる。

それとともに手入力を見直し、標準化されたデータを積極的に活用するデジタルトランスフォーメーションも不可欠である。

そこで本研究では、2つの研究目的を定める。第一の目的は、新興感染症等の感染症拡大時に必要な医療政策を実行するために、レセプト等の公的に標準化された医療情報を活用し、感染症流行状況と一般診療状況の動向から地域の医療需要と医療提供体制を迅速に把握する仕組みについて、収集情報および収集経路ならびに医療機関の負担を鑑み、全国に導入する方法の提案することである。

第二の目的は、第一の目的を達成し実現することを見据え、標準化された請求情報および診療情報等の一つである DPC データを基に、確率モデルや機械学習等の学習アルゴリズムを用いた予測モデルを構築し、感染症データ収集の頻度変化に伴う感染症流行状況の把握の精度に及ぼす影響について経営工学、オペレーションズ・リサーチ分野の工学的手法を用いて評価、分析を行うことである。

B. 研究方法

第一の目的のために、新興感染症に係る患者動向の迅速収集に関するレセプト情報や DPC データ等を医療機関から迅速に収集する仕組みを導入するために、対象医療機関・対象情報・収集頻度等について整理した。さらに、レセプト受入側の審査支払機関側の課題についても公表資料をもとに考察した。

また、第二の目的のために、感染症疫学研究において標準的な SIR モデルを応用したパндеミックリスク管理モデル (SIRD モデル) を開発し、これを DPC データから得られたパラメータを用いて症状別の回復率や死亡率を確認し、モデルの検証を行う。特に、乳がん患者の予後予測で用いられる学習分類子システムを適用することで、DPC データでの入院日数の予測の実現可能性について検討を行う。

(倫理面への配慮) 本研究は、DPC データ提出医療機関にて提供を受けた匿名化されたデータを用いている。データは初めから匿名加工情報 (特定の個人を識別することができないように個人情報を加工した情報) を用い

であるが、DPC データは診療録から作成された医事会計データを元に作成されているため、氏名や被保険者番号等の個人情報登録されていないものの、要配慮個人情報となる病歴が記載されていることから、匿名化されている場合でも、疾病別の集計結果の値が少ないなどで個人推定がされることが無いよう、データの組合せにより患者個人が特定されないような集計（具体的には、厚生労働省が公開している DPC データの基準に則り、最小集計単位を 10 以上）とするなど、十分配慮した上で分析を行うとともに、利用・保管場所のアクセス制限、利用・保管方法、データの廃棄、機器の保守は、東京科学大学の規定およびルールを遵守している。

C. 研究結果

分担研究者の明神、土井、今村、野田は日々レセプト出力システムを試験導入した結果、レセプトの報告頻度を月次から日々に変更するには、1)システム処理への影響、2) ファイルサイズとストレージの必要量、3)通常業務フロー、4) 病院機能の 4 点から次の収集頻度を提案した。

- ・特定機能病院・DPC 病院：週次（日次）
- ・一般病床：週次（日次）
- ・一般病床以外（精神除く）：月次（日次）
- ・診療所：月次（日次）

また、未知の感染症の場合は「実際に実施した医療行為」を網羅的に収集することができる日々レセプトが有効な収集方法であり、ICU への入室数や人工呼吸器の利用数、PCR の検査数等をリアルタイムに把握できることで、必要な機器や試薬等の試算をすることが可能となり、政策決定に有用なデータを提供する手段となり得ることを示した。そのためには診療報酬改定

DX における「共通算定モジュール」の普及が有効であることを提案した。

一方で収集が必須の項目として、未知の新興感染症を要因とする死亡転帰の重要性を示した。現状の DPC/PDPS 制度では退院転帰の入力は必須でなく、リアルタイムに把握するにはハードルが高い。特に、小児や妊婦での発生状況、発生地域別の状況等を想定し、レセプトや DPC と死亡情報の突合は重要な論点となることを提案した。

これらをもとに、以下 3 点を提言した。

1. 日々レセプトの開発負荷は大きくないが、プログラムの導入調整（既存プログラムのどこに挿入するか等）が鍵である。電子カルテ情報共有サービスのように情報システム改定のタイミングで導入するタイムスパンで考えると 5~7 年間程度の普及が目安となろう。
2. 長期的に見れば、日々レセプトが正となり、既存の本レセプトに置き換えることも診療報酬改定 DX の選択肢であろう。日々レセプトが随時更新され 10 日時点で確定すれば、月次処理そのものを見直す等は可能になるかもしれない。
3. しかし日々レセプトを正とする場合（日々レセプトに審査も行う場合）現在の診療報酬の体系再編も想定して検討を行うべきである。

また、第二の目的である SIRD モデルの開発および DPC データから得られたパラメータを用いた症状別の回復率や死亡率の推計については、高嶋、新城、伏見らにより DPC データを用いて SIRD モデルのパラメータを推定し、感染症流行状況を把握するための方法論を開発した。

具体的には、DPC データの変数のうち、入院日、退院日（死亡日）、レセプト電算コードのみから症状別に分類した SIRD モデルのパラメータ推定が可能となった。これらの成果を応用し、年齢、性別、既往症などの属性別に分析を深化することで、幅広い知見を得ることが可能であることが示唆された。また、将来、より強い新興感染症が発生した場合を想定して、感染症の拡がりを示すパラメータ β がどのくらい大きくなれば、どのくらい入院患者が増えて、どのくらい死亡者数が増えるのかについての予測や、治療方法が発展した場合を想定して、回復率を示すパラメータ γ がどのくらい大きくなれば、どのくらい死亡者数が減るのかが予測可能となることが示された。DPC データを用いることで粒度の高い分析結果が得られ、パンデミックリスクの定量的評価とパンデミックリスク管理が可能となり、DPC データを活用した入院患者数や死亡者数の予測とリスク管理は、十分に可能であると考えられた。

ただし、DPC データには死亡退院情報が含まれているが、レセプト情報には死亡情報が含まれていない可能性がある。その他のパラメータについてはレセプト情報で代替可能であると考えられるが、死亡情報についての取り扱いが課題となることが、第一の目的と同様に指摘された。

E. 結論

本研究を通じ、日々レセプトを活用した感染症情報の迅速な把握が可能であることを示し、導入にはシステム調整と運用上の工夫が必要であることが判明した。

また、これらが実現されれば、パンデミックリスクの定量的評価とパンデミックリスク管理に必要な入院患者数や死亡者数の予測とリスク管理が可能となり、公的に標準化された医療情報を活用した感染症流行状況と一般診療状況の把握は、十分に実現可能であると考えられた。

F. 健康危険情報

なし

G. 研究発表

1. 論文発表

2. 学会発表

1. **Tomoya Myojin**, Daisuke Sato, Daisuke Shinjo, Tomoaki Imamura, Examination of monitoring epidemic status through daily submission of insurance claim information in Japan, 10TH INTERNATIONAL CONFERENCE ON PUBLIC HEALTH 2024 (ICOPH 2024), Bangkok, Thailand

H. 知的財産権の出願・登録状況

1. 特許取得

なし

2. 実用新案登録

なし

3. その他

なし

(参考)

社会保険診療報酬支払基金 HP 診療報酬の審査・支払業務の流れ

<https://www.ssk.or.jp/shin-ryohoshu/gyomuflow/index.html>

社会保険診療報酬支払基金事業計画（令和7事業年度）

https://www.ssk.or.jp/aboutkin/jigyokeikaku/jigyokeikaku_01.files/keikaku_r07_01_j.pdf

別紙4

厚生労働行政推進調査事業費補助金（地域医療基盤開発推進研究事業）
「公的に標準化された医療情報を活用した感染症流行状況と一般診療状況を把握するための分析
手法の開発および評価方法に関する研究」
分担研究報告書（令和6年度）

新興感染症の動向と一般診療への影響を把握するためのスキームの検討

研究代表者	佐藤大介	（藤田医科大学大学院 病院経営学・管理学）
研究分担者	土井俊祐	（千葉大学医学部附属病院）
研究分担者	明神大也	（浜松医科大学 健康社会医学）
研究分担者	今村知明	（奈良県立医科大学 公衆衛生学）
研究分担者	野田龍也	（奈良県立医科大学 公衆衛生学）

研究要旨

本研究では、新興感染症流行時における医療需要と提供体制を迅速に把握する手法として、公的に標準化された医療情報、特に「日々レセプト」の活用可能性を検討した。COVID-19では医療機関によるHER-SYSへの手入力が必要な負担となっており、今後は標準化データの活用とデジタル化が求められる。本研究では、特定機能病院に日々レセプト出力システムを試験導入し、他の処理業務やストレージ容量、運用上の課題を検証した。

その結果、日々レセプト処理は技術的には可能であるが、医療機関の既存システムとの整合性や処理時間、バックアップ方式、運用時間の確保など、業務上の課題が多く存在することが明らかとなった。週次出力や月中～月末を避けた運用が現実的であり、長期的には全バッチ処理の見直しにより日々出力への移行も可能と考えられる。加えて、診療報酬の構造や審査体制の再構築も必要となる可能性が指摘される。

感染症情報収集としては、初期は週次、拡大期には日次の頻度が望ましく、特にICU入室数やPCR検査数といった指標のリアルタイム把握により政策決定への有用性が期待される。また、未知の感染症に起因する死亡把握にはDPCやレセプト情報との突合が重要である。

最終的に、本研究班は以下の3点を提言する：(1)日々レセプト導入は導入時の調整が鍵であり、5～7年をかけた普及が現実的、(2)診療報酬DXの一環として日々レセプトが標準となる可能性、(3)体系的審査を行うには診療報酬制度の再編が必要、である。

A. 研究目的

COVID-19感染症は2020年2月1日に感染症法に基づく指定感染症に指定された後、

2021年2月13日に新型インフルエンザ等感染症に変更され、2023年5月7日まで全数把握対象疾患であった。医療機関はCOVID-19

の診断を受けた患者の情報を、HER-SYS と呼ばれる新型コロナウイルス感染者等情報把握・管理支援システム（Health Center Real-time Information-sharing System on COVID-19）に手動で入力する必要があった。日本においては延べ 3300 万人以上が COVID-19 に感染したが、COVID-19 感染を確認した医療機関が手動で HER-SYS に入力していたため、医療機関の負担が大きかったと言われている。

新興感染症等の感染症拡大時における医療提供体制の確保にあたっては、当該感染症による重症化率及び死亡率を下げる事が重要で、そのためには地域の医療需要や医療供給量の変化を迅速かつ的確にとらえ、医療体制を維持する施策が必要になってくる。

それとともに手入力を見直し、標準化されたデータを積極的に活用するデジタルトランスフォーメーションも不可欠である。

そこで本研究では、新興感染症等の感染症拡大時に必要な医療政策を実行するために、レセプト等の公的に標準化された医療情報を活用し、感染症流行状況と一般診療状況の動向から地域の医療需要と医療提供体制を迅速に把握する仕組みについて、収集情報および収集経路ならびに医療機関の負担を鑑み、全国に導入する方法の提案を目的とする。特に令和 6 年度においては医療 DX および診療報酬改定 DX に関連し開発が進んでいる「日々レセプト」、「電子カルテ情報共有サービス」、「標準型電子カルテ」の活用が期待されることから、これらの導入と関連付け、提案を行う。

B. 研究方法

新興感染症に係る患者動向の迅速収集に関するレセプト情報や DPC データ等を医療機関から迅速に収集する仕組みを導入するために、対象医療機関・対象情報・収集頻度等に

ついて整理した。具体的には、病床数 800 床程度、平均外来患者数 2000 人規模の特定機能病院に日々レセプト出力システムを試験導入した場合のシミュレーションを行い、以下の観点で評価をした。

- (1) 他のシステム処理への影響
- (2) ファイルサイズとストレージの必要量
- (3) 通常業務フロー
- (4) 医療機関機能との兼ね合い

この検討を通じ、全国の医療機関に導入する場合の方法とそれに関する課題について考察した。

さらに、レセプト受入側の審査支払機関側の課題についても公表資料をもとに考察した。

（倫理面への配慮）本研究は個人情報を扱わないため、倫理的配慮を必要としない。

C. 研究結果

日々レセプト出力システムを試験導入した結果、レセプトの報告頻度を月次から日々に変更するにはいくつかの課題があげられた。方法で挙げた (1) ~ (4) の観点は相互に影響し合うため、包括して課題を記載した。また可読性の関係上、結果に考察の一部を含めた。

当該医療機関において 20 日頃に日々レセプト出力システムを稼働させたところ、処理に要した時間は約 1 時間 50 分であった。これは、同時期に実施した本レセプト出力処理とほぼ同じ所要時間である。同日に実施するのであれば日々レセプト出力と、本来実施している本レセプト出力の処理内容は同じであるから、当然の結果であると言える。毎月末日まで処理するデータ量は増え続けるので、毎月末日から翌月の 10 日のレセプト確定日までの間は、さらに所要時間がかかることが想定された。

医療機関におけるレセプト請求業務については、通常月末日締め、翌月 10 日までの確定・修正処理がある。昨年度の研究報告書では夜中にシステム処理を実施する等の運用を提案したが、実際の業務を詳細に検証した結果、別表 1 に示すようにレセプト請求に関連する処理以外にも、日次・週次・月次・臨時のバッチ処理等が多数計画されており、日々レセプト処理を行うために他の処理と重複しない一定の時間帯を毎日確保することが困難であることが明らかとなった。これは、多くの情報システムに共通することだが、システム間の影響が出ないようにそれぞれの処理を順次追加していった結果であると考えられた。これを短期間で見直して日々レセプト出力処理を導入することは、医療機関の通常業務に影響を与えるリスクが大きいと結論するに至った。たとえば「この処理業務を停止して良いのか」「この処理業務と並列で実行して良いのか」「追加の処理業務を動かすと、既存の処理業務にどのような影響があるのか」といった検証が必要となる。そのため、システム運用部門や医事課による検証負担が導入の障壁となり得る。ただし、今回検証で実施した当該医療機関では、他の処理と並行して日々レセプト出力処理を試行したが、特に問題なく出力することができたため、事前の検証のもと導入することは可能であると考えられた。

上記をまとめると、短期的に多数の医療機関で日々レセプト出力システムを導入・運用することは難しいかもしれないが、例えば本レセプト処理に影響を与えないことを優先すると、本レセプトが確定する毎月 10 日以降に出力を開始し、その後は一定頻度で動かし、再び翌月の本レセプト処理が始まる月末頃には出力を止める

等の頻度が運用上のトラブルが最も少ないことが示唆された。その一方で、長期的（1～2年程度を想定）には全バッチ処理を見直し、日々レセプトに移行することは必ずしも不可能ではないとは考えられるが、電子カルテ入れ替えや各種部門システムの導入・更新、診療報酬改定対応等を十分に踏まえる必要がある。現状 HER-SYS はシステム化されておらず、調査・手入力負担が大きいため、日々レセプトを活用した週次報告はシステム化されることで効率的な収集が期待できるのは明らかで、収集頻度を日次ではなく週次でも許容されると思われる。

日々レセプトに必要なストレージ容量については、当該医療機関が日々レセプトデータを 2 か月分保有した場合、約 500GB 程度と試算された。ファイルサイズについては、月初めは少なく、月末に近づくにつれ日々更新されるためは逡増することが見込まれる。一日あたりでは最大で 8GB～9GB であるものの、レセプトが確定する翌月 10 日頃までは前月分と当月分の両方を出力する必要があるため、必要なストレージ容量は想定より大きくなった。なお、日々レセプトはバックアップのために日々保管するが、毎日作成できるとは限らないことや削除も発生することから、バックアップ形式はフルバックアップや増分バックアップではなく差分バックアップが望ましいとされた。

診療所については、クラウド型電子カルテ（標準型電子カルテを含む）が普及していることや DPC 調査の対象外であること、外来データ加算算定している診療所でも日々レセプトのファイルサイズを小さく抑えることができること等から、システム処理への影響は軽微である。

収集目的を鑑み、診療所を対象に含めるかについては考慮する必要がある。

また、日々レセプトの実現にあたっては、レセプト受入側のシステム・人的体制整備も必要となる。日々レセプトに審査をするかどうかで検討事項が異なると考えられ、それぞれにおいて検討する。

まず、日々レセプトで審査せず、審査は従来通り月次となる場合、必要なのは情報システムの開発である。医療機関がオンラインで提出したレセプトは、審査支払機関におけるレセプト振替機能に関するシステムで資格確認していると推察される。その場合、レセプト振替機能に関するシステムに改修を行い、日々レセプトに対応するか、その前に日々レセプト収集システム（仮）を新規開発する必要がある。そして同システムで収集した日々レセプトを、厚生労働省や国立健康危機管理研究機構等が管理するシステムに出力し、分析を行うことになると推察される。

日々レセプトで審査も行うとなった場合、

(1) 情報システムの開発・改修、に加え、
(2) 審査体制の見直し、(3) 診療報酬の考え方の見直しも必要と考えられる。具体的には、(1) では毎回レセプト振替機能に関するシステムで資格照会を行うが、おそらく処理量の拡張を検討しなければならない。また、できるだけ迅速に感染症発生・医療資源投入の動向を見るために、厚生労働省や国立健康危機管理研究機構等が管理するシステムに出力するタイミングを検討する必要がある。さらに、現行の審査関連システムや NDB（匿名医療保険等関連情報データベース）に係るシステム改修も必要になる。(2) では診療翌月の 10～25 日に審査

を実施しているとされているが、この審査を日々または週次に近い形に移行することの検討も必要かもしれない。(3) では医療機関側・審査支払機関側どちらも課題になるが、毎月算定している管理料等をどのタイミングで算定（審査）するかや、同月内に重複算定できない診療行為をどう除外する（どのタイミングで審査するか）か、日々レセプト請求時に誤って請求した場合にどう修正するかが課題である。多くの医療機関（特に病院）では月初に集中的にレセプトチェックを行い、算定できる加算・管理料、算定できない診療行為、漏れている病名などを確認して、保険医（臨床医）へ確認する等、十分な吟味を行ったうえでレセプト請求している。日々レセプトになると、この確認を十分行うことができないため、大きな運用変更が必要となる。第 1 章 基本診療料並びに第 2 章 特掲診療料の第 1 部医学管理等及び第 2 部在宅医療、は月次算定が多いため、特に影響が大きいと考えられる。現在の診療報酬の体系の根本的な見直しが必要かもしれない。

D. 考察

結果をもとに、収集情報、収集頻度、収集形式から日々レセプトによる報告対象医療機関に係る論点を別紙図表にまとめた。

これらの図表から、1)システム処理への影響、2) ファイルサイズとストレージの必要量、3)通常業務フロー、4)病院機能の 4 点から考えると、下記の収集頻度を提案する。

- ・ 特定機能病院・DPC 病院：週次（日次）
- ・ 一般病床：週次（日次）
- ・ 一般病床以外（精神除く）：月次（日次）
- ・ 診療所：月次（日次）

通常、未知の新興感染症情報収集にかかる業務フローを考慮すると、発生当初は疑似症等を疑い報告することが想定されるが、このとき症例数は少ないと考えられ、人手による入力・集計でも対応できると考えられる。そのため、感染症情報収集の目的のみを考慮するのであれば、システムや運用に通常時から負荷をかけ続ける必要はなく、定点報告と同じ週次程度の頻度でも問題ないように考えた。しかしながら、拡大期にあたっては、毎日相当数の発生が見込まれることから、日次まで頻度を上げることができるよう準備しておく必要はある。

また、既存感染症であれば、レセプトでなくとも既存の遺伝子検査（PCR）のコード等を集計することで比較的容易に発生数を把握することができるかもしれない。しかしながら未知の感染症の場合は、そもそも集計対象がわからない可能性があるため、「実際に実施した医療行為」を網羅的に収集することができる日々レセプトは有効であると考え。例えば、呼吸器系の感染症であれば、ICUへの入室数や人工呼吸器の利用数、PCRの検査数等をリアルタイムに把握できることで、必要な機器や試薬等の試算をすることが可能となり、政策決定に有用なデータを提供する手段となり得る。現在「診療報酬改定DX」で計画されている「共通算定モジュール」が普及すれば、より集計が容易になることにも期待できる。

さらに追加的に集計できるようにすべき点として、未知の新興感染症を要因とする死亡数の把握があげられる。現状DPCでも退院転帰の入力は必須でなく、死亡診断書や検案書との連携も考えられるが、リアルタイムに把握するにはハードルが高い。特に、迅速には実態把握が必

要となる小児や妊婦での発生状況、発生地域別の状況等、層別集計が必要となることが想定されることから、レセプトやDPCと死亡情報の突合は重要な論点となることを付記しておく。

※1)特定機能病院に対しては、電子カルテ情報共有サービスで登録される感染症情報が活用できる可能性。ただし患者の口頭同意が必要であり、医師の操作によりそれが確認されていないと電子カルテ情報共有サービスにアップロードされない他、既存の感染症検査にしか対応できないという欠点もある。そのため、日々提出のデータに抜け漏れが生じるリスクがある。この点の効率的な運用の整理が課題。

※2)診療報酬加算等で、「体制を整えておくこと」「提出実績があること」等でシステム負担を評価できれば普及の可能性はあるのではないかと。

※3)診療所に対しては、ORCAや標準型電子カルテに組み込む方法が妥当ではないか。また、審査支払機関側に対してもC.結果で述べた影響が考えられることから、実施にあたっては十分な同意と事前の影響調査が重要となる。その一方で、改定のたびに様々な加算が付き、診療報酬の構造も電子レセプトの構造も複雑化している現在の診療報酬体系を一度根本から見直すいい機会になるかもしれない。

以上をもとに、本研究班からの以下3点を提言する。

1. 日々レセプトの開発負荷は大きくないが、プログラムの導入調整（既存プログラムのどこに挿入するか等）が鍵である。電子カルテ共有サービスのように情報システム改定のタイミングで導入するタイムスパンで考える

と5~7年間程度の普及が目安となろう。

2. 長期的に見れば、日々レセプトが正となり、既存の本レセプトに置き換えることも診療報酬改定DXの選択肢であろう。日々レセプトが随時更新され10日時点で確定すれば、月次処理そのものを見直す等は可能になるかもしれない。
3. しかし日々レセプトを正とする場合（日々レセプトに審査も行う場合）現在の診療報酬の体系再編も想定して検討を行うべきである。

E. 結論

本研究を通じ、日々レセプトを活用した感染症情報の迅速な把握が可能であることを示し、導入にはシステム調整と運用上の工夫が必要であることが判明した。長期的には診療報酬制度の見直しも必要かもしれない。

F. 健康危険情報

なし

G. 研究発表

1. 論文発表
2. 学会発表
1. **Tomoya Myojin**, Daisuke Sato, Daisuke Shinjo, Tomoaki Imamura, Examination of monitoring epidemic status through daily

submission of insurance claim information in Japan, 10TH INTERNATIONAL CONFERENCE ON PUBLIC HEALTH 2024 (ICOPH 2024), Bangkok, Thailand

H. 知的財産権の出願・登録状況

1. 特許取得
なし
2. 実用新案登録
なし
3. その他
なし

(参考)

社会保険診療報酬支払基金 HP 診療報酬の審査・支払業務の流れ

<https://www.ssk.or.jp/shin-ryohoshu/gyomuflow/index.html>

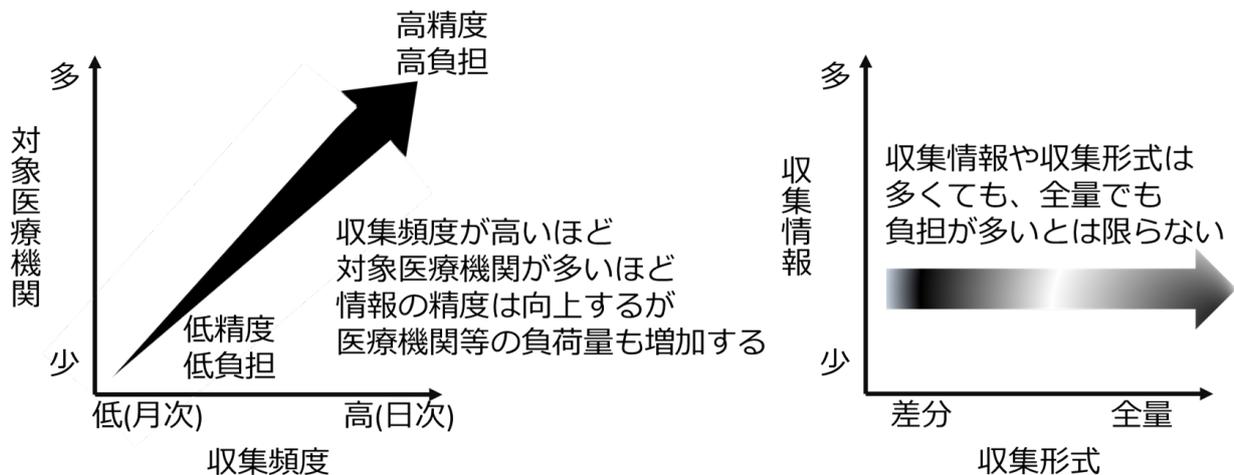
社会保険診療報酬支払基金事業計画（令和7事業年度）

https://www.ssk.or.jp/aboutkin/jigyokeikaku/jigyokeikaku_01.files/keikaku_r07_01_j.pdf

対象医療機関	対象病床	収集頻度	収集情報	収集形式
特定機能病院	DPC算定病床	日次	全レセプト	差分
DPC病院	急性期一般病床 (DPCを除く)	週2回以上 日次未済	入院のみ (DPCを含む)	全量
病院 (DPC病院 以外)	一般病床 (急性期 を除く)	月2回以上 週次未済	外来のみ	
有床診療所		月次	SI/IY/SY等に限定	
無床診療所				

※特定機能病院がDPC病院に包含されている等、必ずしも全項目独立しているわけではない

表：日々レセプトによる報告対象医療機関別の収集方法一覧



図：日々レセプトによる報告対象医療機関に関する論点整理イメージ

令和 6 年度厚生労働科学研究費補助金
地域医療基盤開発推進研究事業

「公的に標準化された医療情報を活用した感染症流行状況と一般診療状況を把握するための分析手法の開発
および評価方法に関する研究」
分担研究報告書

DPCデータを用いた感染症流行状況・診療状況の把握手法の開発

研究分担者	高嶋 隆太	東京理科大学 創域理工学部経営システム工学科 教授
研究分担者	新城 大輔	東京医科歯科大学大学院 医療政策情報学分野 准教授
研究分担者	伏見 清秀	東京医科歯科大学大学院 医療政策情報学分野 教授
研究代表者	佐藤 大介	藤田医科大学大学院 病院経営学・管理学 教授

研究要旨:

○研究目的

本研究は、SIRD モデルをベースとしたパンデミックリスク管理モデルを開発することを目的とする。特に、モデルのパラメータ推定に DPC データを用いることで、症状別の回復率や死亡率を把握する。また、入院日数等の予測に対する機械学習の適用可能性について検討する。

○研究方法

2020 年～2022 年の DPC データを用いて、人口の状態を S(感受性)、I(感染性)、R(回復)、D(死亡)に分けてその推移を微分方程式で表した SIRD モデルのパラメータを推定し、入院患者数や新規陽性者数等を示した。また、DPC データを用いた患者の入院日数の予測のシステムを構築し、乳がんに関する基礎データを用いて、本システムの検証を行なった。

○研究結果

SIRD モデルのパラメータ推定から、軽症、中等症、重症それぞれに対する回復率、死亡率は整合的であることが示された。また、入院患者数と新規陽性者数それぞれの推移の比較から、重症化率をモデルに組み込むことの重要性を明らかにした。さらに、機械学習をベースとした予測システムにより、乳がん患者の予後予測、その予測根拠をルールによって説明することが可能となり、DPC データを用いた入院日数予測への応用可能性を示した。

○結論

DPC データにより SIRD モデルのパラメータを推定し、感染症流行状況を把握するための方法論を開発した。また、学習分類子システムを用いることにより、入院日数の予測や特徴量の評価が可能であることが示唆された。

研究協力者
後藤 允 東京理科大学 創域理工学部
経営システム工学科 准教授
原田 拓 東京理科大学 創域理工学部
経営システム工学科 准教授
伊藤 和哉 東京理科大学 創域理工学部
経営システム工学科 助教

A. 研究目的

2019年12月1日に中国の武漢で最初の感染者が発見された新型コロナウイルス感染症 (COVID-19) は、その後またたく間に世界中に拡大し、2020年3月11日にWHOがパンデミック (世界的大流行) を宣言するに至った。2023年5月のWHO緊急事態宣言終了時点におけるわが国の累計感染者数は3,380万人、累計死者数は7万4千人にのぼる。社会生活や経済に甚大な影響が及んだことは明白で、2023年の経済産業省発表によると、日本経済の損失は対GDP比でマイナス6.1%であり、約30兆円以上であると推定されている。また、2024年7月には第11波を記録したことは記憶に新しく、新型コロナウイルス感染症は今後も注視すべき脅威のままである。

今回の事態に対して日本政府がとった政策は、医療体制の確保やワクチン接種などの感染症に直接的なもの以外は、給付金や助成金、キャンペーンなどであり、経済政策といえるものは実質無利子・無担保融資、いわゆる「ゼロゼロ融資」くらいである。このような未曾有の状況下では、政府が事前に政策対応することは難しく、事後的な補償が中心にならざるを得ない。病院の立場としては、政府に頼るだけでなくパンデミックに対するリスク管理を自ら実行することが肝要であり、定性的な評価だけでなく定量的な評価も欠かすことができないが、これらの実行は非常に困難である。

新型コロナウイルス感染症に対するリスク管理が難しい原因のひとつとして、パンデミックの予測が困難であったことが挙げられる。新型コロ

ナウイルス感染症の分析で広く知られるようになった感染症疫学モデルとして、人口の状態をS (感受性)、I (感染性)、R (回復) に分けてその推移を微分方程式で表したSIRモデルが挙げられる。SIRモデルは、Kermack and McKendrick [2] によって開発され、現在に至るまで多種多様な応用が研究されている。

しかしながら、新型コロナウイルスのような未知の感染症の予測は不確実性が高く、標準的なSIRモデルでは十分に対応できなかったといえる。SIRモデルの応用の中でも不確実性に着目し、拡散項を導入した確率的疫学モデルを分析したのがJi and Jiang [3]、Dieu et al. [4]などである。これらの確率的疫学モデルを利用すればパンデミックに対するリスク分析が可能となるが、そのような例はまだ見当たらない。

本研究の目的は、確率的SIRモデルをベースとしたパンデミックリスク管理モデルを開発することである。特に、モデルのパラメータ推定にDPCデータを用いることで、症状別の回復率や死亡率を把握することが可能となる。これによって、パンデミックリスクの定量的評価とパンデミックリスク管理が可能となり、予測不可能なリスクに対して頑健な経営システムの確保につながる。

また、DPCデータを用いて患者の入院日数を予測することは、医療施設での病床の確保計画の基礎データとして有用であり、パンデミックリスク管理の一助となる。そこで、このための基礎として、まず、乳がんに関する基礎データを用いて乳がん患者の予後予測を行い、さらに、その予測根拠をルールによって説明する。

B. 研究方法

厚労省オープンデータを用いた確率的SISモデル

ベンチマークとして人口状態のうちR (回復) を除いたSISモデルによる分析を行う。データは厚労省が提供するCOVID-19の新規陽性者数の日次データを用いる。確率的SISモデルは

$$dS_t = -(\beta S_t - \gamma)I_t dt - \sigma S_t I_t dW_t$$

$$dI_t = (\beta S_t - \gamma)I_t dt + \sigma S_t I_t dW_t$$

と表すことができる。ただし、 β は感染率、 γ は回復率、 σ は拡散パラメータ、 W_t は標準ブラウン運動である。SIS モデルの状態推移をまとめたのが図1である。

データ期間は 2020/02/01–2022/09/08 であり、COVID-19 の回復には平均して 14 日かかるため、回復率には日次 1/14、月次 2.17 を用いる。データを加工した感染者数の推移は図2のとおりであり、各ピークを捉えた結果となっている。

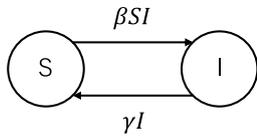


図1 SIS モデルの状態推移

図2 確率的 SIS モデルの感染者数推移

表1 確率的 SIS モデルの月次パラメータ

感染率 β	2.59
回復率 γ	2.17
拡散パラメータ σ	0.39

感染率と拡散パラメータの推定には、R 言語の YUIMA パッケージによる擬似最尤法を用いる。推定結果は表1のとおりである。このとき、基本再生産数は

$$R_0 = \frac{\beta - \sigma^2/2}{\gamma} = 1.01 > 1$$

となり、感染拡大のリスクがあることが分かる。

DPC データを用いた SIRD モデル

次に、人口状態に D (死亡) を加えた SIRD モデルによる分析を行う。DPC データを用いることによって、症状別の回復率や死亡率を把握することが可能となる。確定的 SIRD モデルは

$$dS_t = -\beta S_t I_t dt$$

$$dI_t = (\beta S_t - \gamma - \delta)I_t dt$$

$$dR_t = \gamma I_t dt$$

$$dD_t = \delta I_t dt$$

と表すことができる。ただし、 δ は死亡率である。

DPC データは入院患者のみを対象としているため、人口状態を I (入院)、R (退院) と読み替える。さらに、症状別に入院者を軽症 I^l 、中等症 I^m 、重症 I^h と分類し、

$$dS_t = -(\beta_1 + \beta_2 + \beta_3)S_t dt$$

$$dI_t^l = (\beta_1 S_t + \alpha_{21} I_t^m + \alpha_{31} I_t^h - (\alpha_{12} + \alpha_{13} + \gamma_1 + \delta_1)I_t^l) dt$$

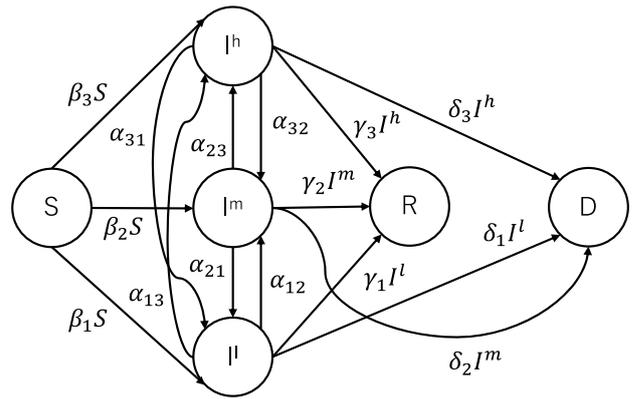


図3 症状別に分類した SIRD モデルの状態推移

(S: 感受性、 I^l : 軽症、 I^m : 中等症、 I^h : 重症、R: 退院、D: 死亡、本来 α_{ij} には推移元の I がかかる)

$$dI_t^m = (\beta_2 S_t + \alpha_{12} I_t^l + \alpha_{32} I_t^h - (\alpha_{21} + \alpha_{23} + \gamma_2 + \delta_2)I_t^m) dt$$

$$dI_t^h = (\beta_3 S_t + \alpha_{13} I_t^l + \alpha_{23} I_t^m - (\alpha_{31} + \alpha_{32} + \gamma_3 + \delta_3)I_t^h) dt$$

$$dR_t = (\gamma_1 I_t^l + \gamma_2 I_t^m + \gamma_3 I_t^h) dt$$

$$dD_t = (\delta_1 I_t^l + \delta_2 I_t^m + \delta_3 I_t^h) dt$$

と書き換える。ただし、パラメータの添え字は 1 が軽症、2 が中等症、3 が重症を表す。また、 α_{ij} は症状の変化を表し、 $i < j$ ならば悪化を、 $i > j$ ならば良化を表す。症状別に分類した SIRD モデル

の状態推移をまとめたのが図3である。

学習分類子システム

これまでの、機械学習モデルを適用した結果に

注目が集まっていたが、最近、その結果が得られた根拠を説明することに対するニーズが急速に高まっている。この説明は、機械学習モデルがブラックボックスであったため、得られた結果の信

表2 確定的 SIRD モデルのパラメータ

	S	I^l	I^m	I^h	R	D
S	0.999996	2.64E-06	6.70E-07	7.54E-08	0	0
I^l	0	0.8888	0.0238	0.0019	0.0828	0.0027
I^m	0	0.1035	0.8421	0.0049	0.0452	0.0043
I^h	0	0.0674	0.0402	0.8627	0.0223	0.0074

S : 感受性、 I^l : 軽症、 I^m : 中等症、 I^h : 重症、 R : 退院、 D : 死亡

例: I^l から D への推移確率 0.0027 は、軽症患者の死亡率が 0.27%であることを示す。

頼性を説明し難いという問題点を解決するものである。このような、機械学習結果の説明を行う枠組みのことを説明可能 AI と呼ぶ。

本研究では、乳がんデータに対する機械学習結果が得られた根拠を説明するために、学習分類子システムを適用する。学習分類子システムは、if-then ルールを分類子と呼ばれる形式で表現する。分類子とは、入力データを条件として、その入力データから得られる結果を推定するルールである。また、分類子を生成する際には、分類子毎に適合度という分類子の評価値が計算される。適合度を参照することで、ルール集合内での各分類子の評価を確認することができるため、有用なルールを見つけやすいという特徴がある。

複数の特徴量、および、あるクラスの値をもつ患者データに対して、学習分類子システムを適用して If-Then ルールを生成する(図4)。予測とは、ある特徴量の値を持った患者がどのクラスに属するのかを識別することを意味する。従って、基本的には、得られた分類子 (If-Then ルール) は、多くの各患者のデータに当てはまるものとなっている。

C. 研究結果と考察

SIRD モデルによる分析

データ期間は 2020/02/11–2022/02/08 であり、図5~9はそれぞれ、全体の I_t 、症状別の I_t と、 S_t 、 R_t 、 D_t を表している。DPC データによる入院患者数の推移を表した図4と全新規陽性者数の推移を表した図5を比較すると、おおまかな傾向は同じであるが、第5波の入院患者比率が顕著に低いこ



図4 学習分類子システムによる予測 (例)

とが分かる。これは、第5波では重症化率が低下したことも整合的であり、分析結果に齟齬はないといえる。

パラメータ推定にはマルコフ推移確率行列

$$P = \begin{pmatrix} * & \beta_1 & \beta_2 & \beta_3 & 0 & 0 \\ 0 & * & \alpha_{12} & \alpha_{13} & \gamma_1 & \delta_1 \\ 0 & \alpha_{21} & * & \alpha_{23} & \gamma_2 & \delta_2 \\ 0 & \alpha_{31} & \alpha_{32} & * & \gamma_3 & \delta_3 \end{pmatrix}$$

を用いる。ただし、1行目は感受性、2行目は軽症、3行目は中等症、4行目は重症を表し、1列目は感受性、2列目は軽症、3列目は中等症、4列目

は重症、5列目は退院、6列目は死亡を表す。各パラメータは行から列への推移確率を表す。また、*は行和が1になるような残余項を表す。

DPCデータの加工については、以下のとおりである。

- 対象病院の人口カバー率が約80%であることから、Sの初期値を1億人とする
- 患者が入院するごとに症状に応じてSからI, I^m, I^hに追加する
- 症状の判定は別表のとおり
- 診療行為に応じて症状別にI, I^m, I^hを移動する
- 患者が退院するごとにI, I^m, I^hからRに追加する
- 患者が死亡するごとにI, I^m, I^hからDに追加する

パラメータ推定結果は表2のとおりである。

まず、 $\beta_1 > \beta_2 > \beta_3$ であることから、軽症、中等症、重症の順に入院率が高く、その差はそれぞれ10倍程度であることが分かる。また、 $\gamma_1 > \gamma_2 > \gamma_3$ であることから、軽症、中等症、重症の順に回復



図7 感受性者数の推移

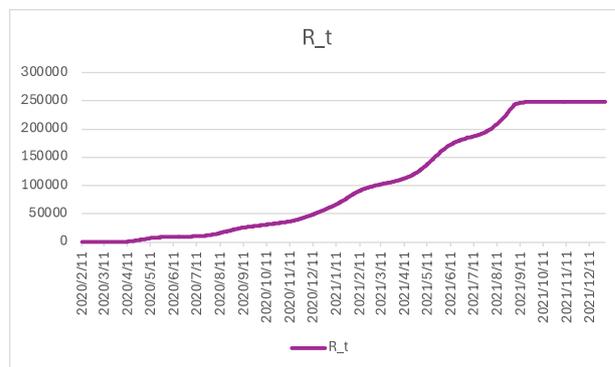


図8 退院者数の推移

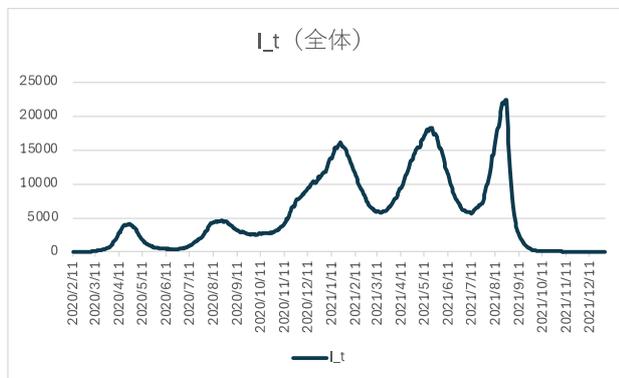


図5 全体入院者数の推移

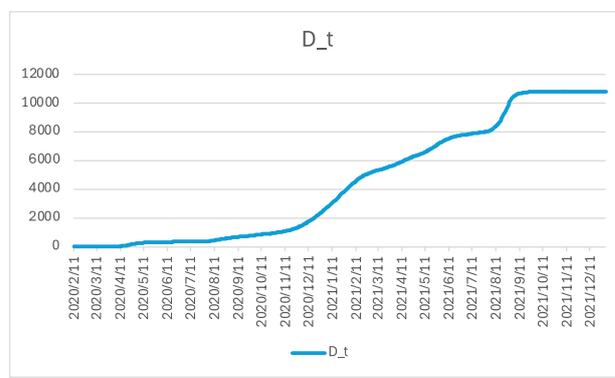


図9 死亡者数の推移

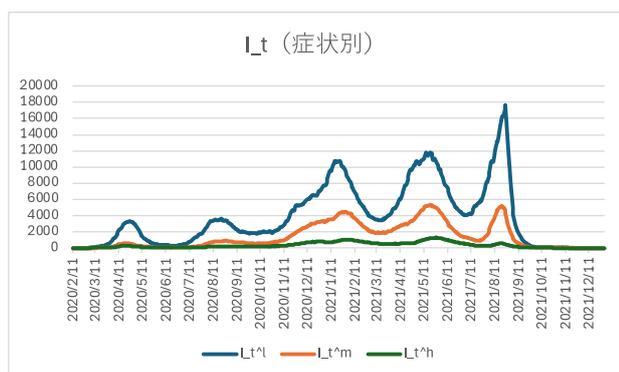


図6 症状別入院者数の推移

率が高いことが分かる。さらに、 $\delta_3 > \delta_2 > \delta_1$ であることから、重症、中等症、軽症の順に死亡率が高いことが分かる。以上のことから、推定結果に齟齬はないといえる。

次に、 α_{ij} の比較から、悪化よりも良化の傾向が強くと、特に重症から中等症よりも重症から軽症のほうが、傾向が強いと分かる。このことから、適切な措置を施せば症状は良化していくといえる。

学習分類子システム

乳がん患者の予後予測への学習分類子の適用

医療データとして METABRIC データセット [1]を使用する。METABRIC データセットは乳がん患者の臨床データと遺伝子データを含んでいる。データは原発性乳房腫瘍を持つ患者 2509 個で構成されており、数値データとカテゴリーデータが混在している。データセット内の特徴量の例としては、診断時の年齢、細胞の状態、乳がんに対しての治療の有無、腫瘍の状態などがある。本研究では予後予測を目的としているため、目的変数は全生存期間(Overall Survival (Months))を用いた。なお患者によって診断時期が異なるがデータの収集終了時期は同じため、診断時期が遅いため他の患者に比べて健康であっても全生存期間が短いことになっている患者も存在する。このような患者データを用いると適切に学習できなくなる可能性があるため、データ前処理で該当データを除外した。

クラス定義を表 3 に示す。今回は、予後を 10 年

表 3 クラス定義

クラス	予後
0	10 年未満
1	10 年以上

表 4 使用した特徴量

Age at Diagnosis
Type of Breast Surgery
Cellularity
Chemotherapy
Pam50 + Claudin-low subtype
ER Status
Neoplasm Histologic Grade
HER2 Status
Tumor Other Histologic Subtype
Hormone Therapy
Inferred Menopausal State

Integrative Cluster
Primary Tumor Laterality
Lymph nodes examined positive
Mutation Count
Nottingham prognostic index
Oncotree Code
PR Status
Radio Therapy
TMB(nonsynonymous)
Tumor Size
Tumor Stage

表 5 分類精度

LightGBM	XGBoost	Ours
0.6591	0.6248	0.6277

未満と 10 年以上の 2 クラスとして定義した。さらに、使用した特徴量を表 4 に示す。

評価実験の結果、得られた分類精度を表 5 に示す。比較対象として決定木学習モデルである LightGBM および XGBoost による結果も示す。

さらに、学習分類子システムを適用した結果、得られたルールを表 6 に示す。Fitness は適合度であり、ルールが予測に貢献している程度を表している。Accuracy は正答率であり、ルールの条件に当てはまるデータの目的変数とルールの予測が一致している割合を表している。Match Count は、データの一致数であり、ルールに当てはまるデータの総数を表している。

表 6 得られたルール

Age at Diagnosis	32.80119999999999 94, 81.87880000000000 1
Neoplasm Histologic Grade	3
Lymph nodes examined positive	-3.375, 3.375
Mutation Count	-

	6.425000000000000 1, 26.425
TMB (nonsynonymous)	-8.98918420975、 35.13953828975
Tumor Size	-33.435, 61.435
Tumor Stage	1
Type of Breast Surgery_MASTECTO MY	TRUE
Pam50 + Claudin-low subtype_Normal	FALSE
Tumor Other Histologic Subtype_Medullary	FALSE
Tumor Other Histologic Subtype_Mucinous	FALSE
Tumor Other Histologic Subtype_Other	FALSE
Inferred Menopausal State_Pre	FALSE
Integrative Cluster_2	FALSE
Integrative Cluster_3	FALSE
Integrative Cluster_4ER+	FALSE
Integrative Cluster_5	FALSE
Integrative Cluster_6	FALSE
Integrative Cluster_7	FALSE
Integrative Cluster_9	FALSE
Oncotree Code_IMMC	FALSE
Oncotree Code_MDLC	FALSE
<u>Overall Survival Status (Months)</u>	0
<u>Fitness</u>	0.556119545
<u>Accuracy</u>	1
<u>Match Count</u>	20

D. 結論及び今後の展開

SIRD モデルによる分析

DPC データにより SIRD モデルのパラメータを推定し、感染症流行状況を把握するための方法論を開発した。具体的には、DPC データの変数のうち、入院日、退院日（死亡日）、レセプト電算コードのみから症状別に分類した SIRD モデルのパラメータ推定が可能となった。ここから、さらに変数として年齢、性別、既往症などの属性別に分析を深化することで、幅広い知見を得ることが可能である。

今後の方向性として、推定した各パラメータを用いたシミュレーションによる入院患者数や死亡者の予測、パラメータを変更した際の感度分析などが挙げられる。例えば、より強い感染症が発生した場合の想定として、 β がどのくらい大きくなれば、どのくらい入院患者が増えて、どのくらい死亡者数が増えるのかが予測可能となる。または、治療方法が発展した場合の想定として、 γ がどのくらい大きくなれば、どのくらい死亡者数が減るのかが予測可能となる。

これらを実行することで、DPC データを用いた粒度の高い分析結果が得られ、パンデミックリスクの定量的評価とパンデミックリスク管理が可能となる。したがって、本研究の分析により、DPC データを活用した入院患者数や死亡者数の予測とリスク管理は、十分に可能であると考えられる。

ただし、DPC データには死亡退院情報が含まれているが、レセプト情報には死亡情報が含まれていない可能性がある。その他のパラメータについてはレセプト情報で代替可能であると考えられるが、死亡情報についての取り扱いが課題となろう。

DPC データに対する学習分類子システムの適用

DPC データでの入院日数の予測に学習分類子システムを適用することを検討している。これは、例えば、入院日数を1週間単位でクラス定義し、入院時のレセプトデータを特徴量として、入院時点や入院中の時

点において、その後の入院日数のクラスを予測するルールを生成するものである。クラス定義の例を表 7 に示す。さらに、特徴量定義の例と表 8 に示す。

入院日数の予測のためのルールを生成することによって、予測した入院日数の根拠を説明することができる。さらに、重要な特徴量を評価し、これによって、入院中の治療計画の立案に寄与することが期待できる。

表 7 クラス定義(例)

クラス	入院期間
0	1 日間～7 日間
1	8 日間～14 日間
2	14 日間以上

表 8 特徴量定義(例)

特徴量1	ICUbed 系資源利用の有無
特徴量2	呼吸器関連資源利用の有無
特徴量3	薬剤資源利用の有無

参考文献

- [1] cBioPortal FOR CANCER GENOMICS, “Breast Cancer (METABRIC、Nature 2012 & Nat Commun 2016)”
- [2] W.O. Kermack and A.G. McKendrick, “A contribution to the mathematical theory of epidemics,” *Proceedings of the Royal Society of London. Series A, Containing Papers of a*

Mathematical and Physical Character, Vol. 115, No. 772, pp. 700-721 (1927).

- [3] Ji, C. and Jiang, D. “Threshold behavior of a stochastic SIR model,” *Applied Mathematical Modelling*, 38 (2014) 5067-5079.
- [4] N. T. Dieu, D. H. Nguyen, N. H. Du, and G. Yin, “Classification of Asymptotic Behavior in a Stochastic SIR Model,” *SIAM Journal on Applied Dynamical Systems*, Vol. 15, pp. 1062-1084 (2016).

E. 健康危険情報

特になし

F. 研究発表

該当なし

G. 知的財産権の出願・登録状況

1. 特許取得

特になし

2. 実用新案登録

特になし

3. その他

特になし

別紙4

研究成果の刊行に関する一覧表

書籍

著者氏名	論文タイトル名	書籍全体の編集者名	書 籍 名	出版社名	出版地	出版年	ページ
該当なし							

雑誌

発表者氏名	論文タイトル名	発表誌名	巻号	ページ	出版年
該当なし					