ご挨拶

2024 年 3 月吉日

第 41 回日本麻酔・集中治療テクノロジー学会を 2023 年 11 月 24 日 (金) から 25 日 (土) の 2 日間、ホテル日航奈良にて開催いたしました。歴史ある本学会を開催させていただけたことを大変光栄に思っております。会員の皆様に心から感謝申し上げます。本学会は 1983 年 11 月に麻酔・集中治療コンピュータ研究会として発足し、その後、現在の名称に変更して活動を行ってきました。麻酔・集中治療の領域での安全で質の高い医療を提供するためには、テクノロジーの進歩は必須であり、本学会のこれまでの歴史を踏まえ、今後この領域は大きく発展していくものと期待しております。

今回のテーマは、「新時代の医療とテクノロジー」とさせていただきました。麻酔法やモニタリングなどの医療機器の進歩のほか、働き方改革に向けた AI 戦略なども必須の課題であります。医療の未来像として、医療分野での DX (デジタルトランスフォーメーション) を通じた医療サービスの効率化・質の向上の実現は、患者さんだけでなく医療スタッフにも重要な恩恵があり、今後が期待されています。特別講演 1 として、奈良先端科学技術大学院大学・先端科学技術研究科　荒牧英治先生に「医療 DX:医療テキストの臨床応用の可能性」のご講演をしていただきました。また、特別講演 2 として、国立循環器病研究センター予防医学・疫学情報部尾形宗士郎先生に「AI・機械学習を活用する疾患の発症予測と予後予測-利点と困難点-」のご講演をしていただきました。その他、共催セミナー、共催シンポジウムについても未来のテクノロジーや医療像を想像できる大変興味深い内容でありました。優秀演題を含め、一般演題は 22 演題ご投稿いただきました。皆様のご協力に心より感謝いたします。

新型コロナ感染症も終息に向い、本学会では会員間の交流と活発な議論が行うことができたと喜んでおります。奈良の地で、未来の医療を感じることができるひと時を皆様と共有できたことを感謝いたします。今後ともご指導・ご鞭撻のほどよろしくお願いいたします。

第 41 回日本麻酔・集中治療テクノロジー学会
会長 川口 昌彦
(奈良県立医科大学麻酔科学教室 教授)

memo:

第41回 日本麻酔・集中治療テクノロジー学会

テーマ 新時代の医療とテクノロジー

プログラム・抄録集

2023

11/24 Fri > 11/25 Sat

会　場　ホテル日航奈良
〒630-8122 奈良県奈良市三条本町 8-1

会　長　川口 昌彦（奈良県立医科大学麻酔科学教室　教授）

https://plaza.umin.ac.jp/jsta41/

memo:

目　次
編集途中経過です．ページは確定していません．

第 41 回日本麻酔・集中治療テクノロジー学会論文集

特別講演：

1. 医療 DX：医療テキストの臨床応用の可能性 1
荒牧 英治 (奈良先端科学技術大学院大学 教授)

2. AI・機械学習を活用する疾患の発症予測と予後予測 –利点と困難点– 4
尾形 宗士郎 (国立循環器病研究センター 予防医学・疫学情報部)

共催シンポジウム１：

新時代の呼吸モニタリングを提供する EIT 11
岡原 修司 (岡山大学病院 集中治療部)

共催シンポジウム２：

麻酔記録装置への入力用携帯端末の導入 19
上山 博史 (関西労災病院 麻酔科)

進化するストレスモニタリング：High Frequency
Variability Index が可視化する新しい麻酔の世界 96
田中 暢洋 (奈良県立医科大学 麻酔科学教室)

ランチョンセミナー

「術中低血圧と予後 〜テクノロジーの活用方法〜」 31
内藤 祐介 (奈良県立医科大学 麻酔科学教室)

アフタヌーンセミナー：

周術期における運用の現状課題と IT ソリューションの現状 38
米澤 亮 (富士フイルム メディカル IT ソリューションズ)

優秀演題セッション：

AneXam-GPT 構築：麻酔科専門医認定筆記試験を ChatGPT が解く！ 45
佐和 貞治 (京都府立医科大学附属病院)

vspace3mm 空液検知機能も兼ねた，重量センサによる輸液速度自動記録装置の開発 50
西村 一樹 (KKR 札幌医療センター 麻酔科)　他

Creating a Program for Visibility in Surgical Departments' Operational Efficiency 53
小原 伸樹 (福島県立医科大学 外科部門)　他

一般演題 1：

舌下神経刺激装置植込術における術中神経モニタリングの報告 63
高谷 恒範 (奈良県立医科大学附属病院 麻酔科)　他

顕微鏡の機能を利用した術中神経モニタリングシステムの使用経験 68
曽碩 真弘 (奈良県立医科大学附属病院 医療技術センター)　他

一般演題 2：

手術時間管理システム (いいね・わるいね) の開発 73
讃岐 美智義 (NHO 呉医療センター 麻酔科)　他

全身麻酔維持中の患者状態の数値化の試み 76
讃岐 美智義 (NHO 呉医療センター 麻酔科)　他

汎用シミュレーションソフトを利用した輸液調節アルゴリズムの評価法の開発 83
森主 絵美 (東京大学医学部附属病院 麻酔科・痛みセンター)　他

一般演題 3：

Postoperative complications after gastrointestinal surgery under general anesthesia 89
Kenta Takeda (Anesthesiol. Hyogo Medical University)　et al.

すべての物質は非線形波動である 97
横山 博俊 (国立病院機構 金沢医療センター 麻酔科)

心臓は機械的ポンプとして血液を大動脈へ押し出すことはできない 106
横山 博俊 (国立病院機構 金沢医療センター 麻酔科)

特別寄稿：

臨床診断と機械学習二値分類モデル：COVID-19 急性低酸素性
呼吸不全のデータセットを用いた Python プログラミング 112
佐和 貞治 (京都府立医科大学附属病院)　他

特別寄稿：二酸化炭素中毒事故を酸欠事故とするのは誤り 127
佐藤 暢 (鳥取大学 麻酔学教室)

第 41 回日本麻酔・集中治療テクノロジー学会抄録抜粋 129

特別講演 1

医療 DX：医療テキストの臨床応用の可能性

荒牧 英治

1．はじめに

自然言語処理の医療への応用 (医療言語処理と呼ばれることもある) に注目が集まっている．すでに，画像や映像について人工知能 (以降，AI) の発展は目覚ましいものがある．一方，診療記録や読影所見などの電子カルテ中の医療テキストの解析については， 健康アドバイス，医学 QA といった患者向けサービス，診断支援やカルテの執筆支援といった医師向けサービス，電子カルテの自動データベース化や症例検索などの研究者向けサービスなど様々なサービスが提案されつつも，明確化されていない部分がある．本稿では，読者の興味と合わないと思われる患者向けサービスを除き，医師向けと研究者向けサービスに絞って議論する (表 1).

表 1: 医療言語処理のタスクと分類

	目的	概要	手法
医師向け（一次利用）	診断支援・症例検索	蓄積された症例から入力となっている症例と類似したものを提示	検索 文書類似度
	見落とし防止	対象としている文書中における重要文（読影所見における悪性所見など）を抽出し，ハイライト	重要文判定 文類似度
	カルテ入力支援	読影レポート，退院サマリなどカルテ文書の自動作成	文書生成 文生成
	カルテ生成	自動問診	
研究者向け（二次利用）	副作用シグナル抽出	蓄積された電子カルテを用いて大規模な症例研究を調査 （例）自社が販売している医薬品の副作用報告を集めたい．転倒につながる意外な原因を調査したい	文書分類 文分類
	悩み不安調査	患者の記録から悩みを抽出	重要文抽出
	個人情報匿名化	電子カルテ中の個人情報を匿名化	NER
	研究発想支援	臨床データの自動研究データベース化	NER

大まかには医師向け AI はデータの一次利用，研究者向け AI は二次利用と対応している．ここでいう一次利用とは，診療現場で直接，医師をサポートするサービスであり，二次利用とは蓄積されたデータを後から別目的のため再利用するサービスである．一昔前にビッグデータ解析で議論さ

奈良先端科学技術大学院大学 教授

れていたのは二次利用である．ただし，二次利用は，その場で利益を享受できないため，普及が思うようにいかないことが多い (あとあとの研究のためだと分かっても，今の労力を投資するのに億劫になるのは想像に難くない)．このため，徐々にではあるが，一次利用の実用化にシフトしつつあるように思える．しかし，まだ，主な対象は 2 次利用であり，そこで十分な信頼性を獲得してのち，臨床の現場に降りてくると思われる．特に，時間のかかる定型的な業務，同意取得 (I C) やサマリやレポートの作成などから開始され，診療ブースでの会話からカルテ入力，手術などの研究性が高い現場へのサポートになると思われる．おそらく，10 年はかかるであろうと見ている．本稿では，これらのシステムの基本となる技術を 2 章にて紹介し，3 章にて展望を述べる．

2．医療言語処理の手法

2.1 パイプライン処理

自然言語処理は，これまで，形態素解析，構文解析や意味解析という処理単位ごとに研究されてきた．これと似た形で，医療言語処理においても，処理単位での処理，用語特定，事実性判定や正規化を組み合わせたパイプライン処理と考えられることが多かった．例えば，「食欲がない」の形態素解析結果として，「食欲—が—ない」が得られ，「食欲がない」という塊をまとまった表現と認識し，さらに正規化する．正規化先の概念は，例えば，疾病コードの ICD-10「R630」であったり，有害事象の用語集である MedDRA の「Anorexia (食欲不振)」など種々あり，目的に依存する．

実際にパイプラインで解析する様子を図 1 に示す．「病変」「部位」「特徴」「 変化」「時間表現」「検査」「薬品」「治療」といった多種多様な表現を抽出し，事実性とよばれる実際にあったのか，なかったのかを属性として持つ (図中では，(＋) と (—) で表現されている)．例えば，病変 (D で示されている) であれば，患者に起こったのか症状であれば D+，否定された病変であれば D ーと

- 病変・症状 (Diseases and symptoms)
- 臓器・部位 (Anatomical parts)
- 特徴・尺度 (Features and measurements)
- 変化 (Change)
- 時間表現 (TIMEX3)
- 検査・問診 (Test)
- 薬品 (Medicine)
- 治療 (Remedy)

図 1 医療言語処理のコーパス
様々な表現と関係がアノテーションされており，機械学習の対象となっている．

表現されている．用語間の関係を推定する場合もある．これは表現と表現の間をアーク (矢印) で結ぶような処理に相当する．例えば，時間表現と投薬表現の関係として，投薬期間といった関係を定義したり，症状と投薬表現の関係として医薬品有害事象 (一般でいう副作用) という関係を定義することができる．この関係をあてること (関係抽出) により，投薬情報や副作用情報を抽出できる．このような表現や関係の情報は，通常は XML や JSON 形式で表現されており，医療言語処理の実態は，タグの種類と位置を決定するタスクと定式化される．

2.2 深層学習ベースの手法

現在では，パイプライン処理は過去のものなりつつあり，多数の層からなる人工ニューラルネットワーク (NN) を用いた機械学習や大規模言語モデルを用いて，直接，入力から出力を得る方式が主流となっている．これは特に次の 2 つの要因が大きい．

- End-to-End によるパイプラインの不要：入力ベクトルと出力ベクトルの関係を直接学習でき，パイプラインが不要になった．この結果，処理の結合での精度劣化を心配する必要がなくなった．
- 汎用モデルの導入：汎用モデルを導入できる．汎用モデルの代表例は Bidirectional Encoder Representations from Transformers

(BERT) である．masked language modeling(単語穴埋め式言語モデリング) と next sentence prediction(連続文判定) といった教師なしで自動的に作成できるデータを用いて BERT は作成でき，劇的な精度の向上ができる．BERT に変わって，大規模言語モデル (LLM; Large Language Models) を用いることも最近注目されているが，訓練に大きな計算コストがかかるため，まだ，使い所が限定されている．今後，数年以内には主流となるである．

3．今後の展望

本稿では，パイプライン処理から BERT などの汎用モデルを用いた NN による研究動向を紹介した．NN を医療言語処理を大幅に簡略化し，特に専門的な知識はなくともシステムを構築できるようになりつつある．表 1 に提案したようなサービスが実現するのも近いであろう．しかし，それでもまだ，今後，以下のような大きな課題が残っている．

知識の利用：

医学知識はデータから獲得できることも多いが，しかし，すでに過去の膨大な研究が明らかにした知識の蓄積がある．いわゆる常識的 (または教科書的な) 知識である．また，ガイドラインの変更により，新しく推奨される治療などもデータから学ぶのではなく，陽にシステムに教育させたい．このような，たかだか一度しか記述されない知識をいかに NN で扱うかは重要な課題である．

モダリティの融合：

言語処理は線形なテキストを扱い，画像処理は二次元の画像を扱うため，これまで分野が分断されていた．しかし，今や NN の登場により，両分野のスキルはかなり近いものとなっている．この結果，画像とテキストの両方を入力とした処理，画像からテキスト生成の生成，検査データからテキスト生成といったモダリティを超えた処理が研究され始めている．最終的には，医師-患者の音声記録から電子カルテの生成といった，現場で生産されているデータをそのまま利用した研究も可能である．言語処理の範囲を超えた融合も重要な課題である．

まだしばらく医療言語処理の発展はとどまることはないであろう．

特別講演 2

AI・機械学習を活用する疾患の発症予測と予後予測 – 利点と困難点 –

尾形 宗士郎

背景と目的

近年，機械学習モデルや深層学習モデルを初めとする人工知能 (AI) の研究が著しく発展し，医療分野の研究や医療現場への活用が進んでいる．しかし，多くの医療者はデータサイエンスに関する教育を受けておらず，AI の作成方法やその利点と弱点を把握していないと考えられる．そのため，本稿では医療分野の研究や医療現場へ応用しやすい疾患の発症予測や予後予測に関する AI 予測モデルの作成方法の要点と注意点を記載する．

AI とは知的なコンピュータープログラムを作る技術と科学といえる．近年，医学領域に頻繁に適用されているものとして，機械学習，ディープラーニング，生成 AI があげられる．いずれもコンピューターがデータのパターンをアルゴリズムに基づいて学習し，それを基に予測や分類や生成を実施する技術である．ディープラーニングも生成 AI も，機械学習の一種と捉えることができるが，それぞれの特徴は下記通りである．機械学習は特定のタスクを実行するために，人間がどの情報が重要かを特徴量 (予測変数) としてコンピューターに与える．一方で深層学習では，コンピューターがデータから特徴量を抽出するため，人間が特徴量を与える必要がない．そして，生成 AI は学習に基づいて，文字・画像・数値・音・動画等を生成する技術である．人間が普段使用している言語，つまり自然言語でコンピューターに質問や指示をすることで，それに対応する答えを返してくるような大規模言語モデル (ChatGPT 等) が有名である．

本稿では比較的少数のデータであっても学習可能なことが多い数値データを扱う機械学習のうち，アウトカム情報をコンピューターに与えて学習をさせる教師有学習に焦点をあてる．医学では様々な健康状態を数値化し，検査値や神経心理検査スコアにして，診療及び研究が実施されているので，数値を扱う機械学習とは比較的相性がよいと考えられる．特に，教師有の機械学習が適用される場面が多いのは，患者の予後予測モデルや疾患を有しているかどうかの判別モデルである．これは，学習済みの機械学習予測モデルに，予後を予測したい患者の情報 (そのモデルに特徴量として使用されている情報) を与えることで，その患者の死亡・再発や該当疾患を有しているか予測することができる．

AI・機械学習による予測モデルの構築の概要

教師あり学習にて AI・機械学習によって予測モデルを開発するための一般的な手順は下記通りである (表 1)[1,2]．① AI・機械学習に予測させたい事象 (疾患有病予測，疾患発症予測，予後予測等) を明確にする．② モデルを構築するための訓練データセット (training dataset) と，モデルの予測精度を評価するためのテストデータセット (testing dataset) を収集する．③ データクレンジングと前処理をする．④ training dataset にて変数間の関連を把握するために，探索的な解析を実施する．⑤ training dataset にて予測モデルを構築する (アルゴリズムの選定，ハイパーパラメータチューニング，評価指標の設定，特徴量の選択，不均衡データ時の工夫)．⑥ 予測モデル構築に使用していない testing dataset を利用して，構築した予測モデルの予測精度を検証する．

国立循環器病研究センター 予防医学・疫学情報部

表 1. AI・機械学習で教師あり学習によって予測モデルを開発するための一般的な手順

No	項目	注意点
1	モデルを構築するための訓練データセットと，モデルの予測精度を評価するためのテストデータセットを収集する．	・異なるデータリソース，時間による分割，ランダムに分割する
2	データクレンジングと前処理をする．	・データの重複，欠損値，異常値，入力ミス等を修正・削除する ・データの変換，正規化，標準化，連続変数のカテゴリ化，カテゴリカルデータの数値変換，特徴量エンジニアリング，次元削減等を適宜する．
3	Training dataset にて変数間の関連を把握するために，探索的な解析を実施する．	・要約統計量，可視化，次元削減，二変量データ間の関係（散布図，相関係数行列，一般化線形モデルの実施）を確認する．
4	アルゴリズムの選定	・分類問題か回帰問題か？ ・サンプルサイズ，予測変数の次元数，欠損値の扱いは？ ・予測精度の評価指標は？ ・モデル構築に費やせる時間は？ ・モデルの解釈性はどの程度必要か？ ・上記を踏まえて複数のアルゴリズムの候補をだす．
5	ハイパーパラメータチューニング	・グリッドサーチ，ベイズ最適化 ・クロスバリデーションの利用
6	評価指標の設定	・分類問題：感度，特異度，陽性反応的中度，陰性反応的中度，F1 スコア，Area Under the Curve ・回帰問題：Root Mean Square Error, Mean Absolute Error，Mean Absolute Percent Error 等
7	特徴量 (予測変数) 選択	・Recursive Feature Elimination，Boruta，Lasso 等
8	アウトカム発症割合が小さい時の対策	・オーバーサンプリング ・アンダーサンプリング ・コスト感応学習 ・アンダーサンプリングと bagging の組み合わせ
9	Testing dataset を利用して，構築した予測モデルの予測精度を検証する．	・Testing dataset は予測モデルに一切使用していないデータで構成する．

Training dataset と testing dataset

Training dataset とは AI にデータを学習させる，つまり AI 予測モデルを構築するために使用する．学習データを使用することで，AI・機械学習アルゴリズムがデータからアウトカム変数と予測変数の関係性，つまりデータに基づいて予測を行うためのルールを抽出する．一方で，testing dataset とは，構築された AI 予測モデルが，どの程度うまく新しいデータに対して予測や分類ができるかを評価するために用いられるデータセットである．重要な点として，testing dataset は，モデル構築に使用されていないデータで構成する必要があることである．

Training dataset と testing dataset の作成方法には通常次の方法がとられる．① 異なるソースからデータを収集する．例えば，複数の病院から患者データを集めることがこれに該当する．② 時間による分割を実施する． ある一定期間のデータを training dataset 用に，別の期間のデータを testing dataset 用に分ける．この際，testing dataset は未来側のデータで構成する．③ 手元にあるデータを testing dataset と testing dataset にランダム分割する．この割合を適宜調整する慣習としては 70∼80%を学習データ，残りの 20∼30%をテストデータに割りあてることが多い．データセットの N によって testing dataset の割合を増やすこともある．

データクレンジングと前処理

データクレンジング[1]と前処理を適切に実施するには時間を要することが多いが，AI 予測モデルの妥当性と予測精度に大きく影響を与える．データクレンジングとは，データセットから入力エラーや論理エラーを排除し，後の分析段階でのデータの品質を保証するために実施する．例えば，データセット内にある重複 (同一患者が複数回ふくまれている)，欠損値，異常値など，入力ミス等を発見し，それを修正あるいは削除することである．

一方で前処理とは，データを AI・機械学習アルゴリズムにとって扱いやすい形式に変換させることである．これにより，予測モデルの予測精度を向上させることができる．例えば，データの変換 (累乗や対数変換等)，正規化 (ある変数の値を，その変数の最大値で除算すること)，標準化 (ある変数の値を，その変数の平均値で減算し，その変数の標準偏差で除算すること)，連続変数のカテゴリ化，カテゴリカルデータの数値変換，特徴量エンジニアリング (新たな特徴量の作成すること．例えば身長と体重から body mass index を算出する等)，次元削減 (不要な特徴量の排除やデータ圧縮) がある．

注意点として，データクレンジングや前処理の手続き方法は，training dataset でルール化しておくことである．理由は，testing data から予測モデル構築に関するルールを構築してしまうと，testing dataset の情報がリークしてしまい，予測モデルの予測精度を正しく評価できなくなるためである．

探索的データ分析 (Exploratory Data Analysis, EDA)

EDA は training dataset に含まれている変数の特徴や変数間の関連構造を事前に把握することが目的である．これにより，どのような AI・機械学習アルゴリズムや統計モデルが適用可能か，更なるデータ分析のためにどのように前処理を追加すべきかについて考えていく．

具体的には，各変数の要約統計量 (平均，中央値，標準偏差，四分位範囲，最小値，最大値等) を求めたり，可視化したり，(ヒストグラム，箱ひげ図，度数分布表など)，次元削減をしたり (クラスター分析や主成分分析等)，二変量データ間の関係を確認したり (散布図や相関係数行列)，データの特性に応じた一般化線形モデル (例：重回帰分析，ロジスティック回帰，ポアソン回帰等) を適用し，アウトカム変数と関連のある予測変数の候補

[1] data cleansing

を挙げるといったことがある．機械学習モデルのうちパラメータチューニングが比較的シンプルなランダムフォレストを使用し，どの変数が予測に寄与するかを事前に確認することも有用である．

アルゴリズムの選定

最適な予測モデルを構築するのに適したアルゴリズムを選定する．予測問題, training dataset の特性，予測精度の評価指標，モデル構築にかかる計算時間，解釈のしやすいモデルといった観点から，アルゴリズムを選定する [3]．

A: カテゴリカルなアウトカムを予測する分類問題か，連続値のアウトカムを予測する回帰問題か決める．

B: Training dataset のサンプルサイズ，予測変数の次元数，欠損値の扱い方を決める．

C: 予測精度の評価指標 (感度，特異度，AUC，陽性反応的中度，陰性反応的中度，F1 スコア等) を選択する．

D: モデル構築に費やせる時間を見積もる．

E: 求められる解釈性を把握する．

F: 上記から複数のアルゴリズムをあげ，クロスバリデーションなどを用いてモデルの性能を比較する．

例えば，決定木ベースモデル (ランダムフォレスト，勾配ブースティング等)，ニューラルネットワーク，サポートベクターマシン，Least Absolute Shrinkage and Selection Operator (lasso) 回帰，ridge 回帰等がある．決定木ベースモデルは決定木が 1 つなら解釈はしやすいが，ランダムフォレストや勾配ブースティングは決定木を多数構築するので解釈は困難になる．ニューラルネットワークは非常に柔軟で複雑な問題に対応できるが，そのブラックボックス性と計算コストの高さが課題である．lasso 回帰と ridge 回帰は予測変数とアウトカム変数の関連の強さを示す回帰係数を得ることができるので，モデルの解釈性は高い．また，lasso 回帰は一部の回帰係数をゼロにすることで，不要な予測変数をモデルから取り除くことでよりシンプルな予測モデルを構築することができる．

ハイパーパラメータチューニング

ハイパーパラメータとは，AI・機械学習アルゴリズムにおいて予め設定する必要のあるパラメータである．予測モデルを構築している以外のデータに対しても高い予測精度を持つモデルを構築するために，AI・機械学習モデルのハイパーパラメータを探索し最適化することが，ハイパーパラメータチューニングの目的である．これにより，training dataset に過剰に適合することなく，未知のデータに対しても予測性能が高い，つまり汎化能力が高いモデルを構築する．

ハイパーパラメータの探索方法には，グリッドサーチやベイズ最適化等がある．グリッドサーチは，ハイパーパラメータの探索空間を格子状に分割し，あらかじめ定義されたハイパーパラメータの組み合わせごとにモデルを評価する方法である．ハイパーパラメータ数と各ハイパーパラメータの粒度次第では, 組み合わせ数が膨大になり, 計算コストが高くなるといった欠点がある．一方でハイパーパラメータの粒度を細かくしていると，ハイパーパラメータの探索漏れを防ぐことができる．

ベイズ最適化は，ハイパーパラメータの評価結果に基づいて確率モデルを構築し，そのモデルを使って次に試すべきハイパーパラメータを効率的に選択する方法である．Optuna などのツールはベイズ最適化を利用しており，過去の試行の結果から学習してハイパーパラメータの有望な領域を探索する．つまり，効率的に有望なハイパーパラメータを探索できるので，計算コストを抑えることができる．

グリッドサーチもベイズ最適化も，ハイパーパラメータごとにモデルの性能を評価する際には, k-fold クロスバリデーションが用いられることが多い [3]．これは，データセットを k 個のサブセットに分割し，k-1 個のサブセットでモデルを訓練し，

残りの 1 個でモデルを評価する手法である．このプロセスを k 回繰り返し，k 回の評価結果の平均を取ることで，training dataset を効率的に使用してモデルの性能を評価することが可能となる．ハイパーパラメータチューニングとクロスバリデーションを組み合わせることで，training dataset に過剰適合を回避しながら，testing dataset を含む外的データに対するモデルの汎化能力を向上させる．

評価指標の設定

AI・機械学習モデルの性能を定量的に測定し比較するために，予測モデルの目的に合致する評価指標を用いる．評価指標とは，モデルの予測がどれだけ実際のデータに合致しているかを示す数値である．具体的には，分類問題に対しては感度，特異度，陽性反応的中度，陰性反応的中度，F1 スコア，Area Under the Curve (AUC) といったように多数ある．回帰問題に対しては Root Mean Square Error (RMSE) や Mean Absolute Error (MAE) 等が一般的に使用されている．各指標の意味や定義を解説することは，本稿の目的とは異なるので，他文献を参照頂きたい．

これらの評価指標は，モデルの性能を異なる側面から評価するために用いられる．感度と特異度は，特に医療分野でよく用いられる指標であり，疾患のスクリーニングテストの性能を評価するのに適している．AUC はモデルの識別能力全体を評価するのに有用で，1 に近づくほど良い性能を示す．陽性反応的中度と陰性反応的中度は，予測結果の信頼性を評価する．RMSE と MAE は，回帰問題の予測値と実測値の差 (連続値の予測誤差) を評価する．これらの指標を適切に選択し，適用することで，モデルの性能を全面的に理解し，改善のための洞察を得ることができる．

特徴量 (予測変数) の選択

適切な特徴量 (予測変数) を選択することで，モデルの複雑さを減らし，学習時間を短縮し，予測性能を向上させることができる．特にサンプルサイズが小さい場合には，不必要な特徴量を取り除くことで，モデルの汎化能力を高めることが期待できる．予測変数選択は，データセットからノイズとなる予測変数を除外し，アウトカムに関連性の高い予測変数を残すことによって，予測にとって有用な予測変数のみを選択する．

予測変数選択の具体的な方法の例として，Recursive Feature Elimination (RFE)，Boruta，先述の Lasso がある．RFE はモデル構築を繰り返し実施していき，その中で最も重要度が低いと評価された予測変数を取り除き，指定された予測変数の数に到達するまでこのプロセスを繰り返しことで，予測変数を選択する方法である．Boruta は先述のランダムフォレストアルゴリズムを用いて予測変数の重要度を評価する方法である．まず，乱数値で予測変数 (シャドウ特徴量) を生成する．次に，このシャドウ特徴量と全ての予測変数 (実測値の特徴量) を用いて，ランダムフォレストによって予測モデルを構築する．そして，構築したランダムフォレストの特徴量重要度ランキングを作成し，シャドウ特徴量よりも重要度ランキングが低い特徴量を除外することで，重要な特徴量を選定する．

不均衡データへの工夫

分類問題においてアウトカム発症数が非発症数に比較して大幅に少ない状況，つまり不均衡データにおいては，AI・機械学習モデルの学習過程で多数クラスに偏った予測を行ってしまうことがある．例えば，手元に 1 万症例のデータがあり，アウトカム発症は 100 症例で，非発症は 9,900 症例とする．この場合，すべて非発症と予測するだけで，正答率が 99%となる．AI・機械学習アルゴリズムは予測精度が高くなるようにモデルを構築する性質があるため，どんなデータが入力されても非発症と予測するモデルができあがってしまう．しかし，このモデルは現実社会では役にたたない．この問題をクラス不均衡問題と呼ばれる．

クラス不均衡問題の対策として，アンダーサンプリング，オーバーサンプリング，コスト感応学習等がある．アンダーサンプリングとは，多数クラスからランダムにサンプルを削除することで，データセットのサイズを減少させ，クラス不均衡を改善し，モデルが少数クラスを過小評価することを防ぐための技術である．最も単純な方法として，多数クラスからランダムにサンプルを削除する方法がある．オーバーサンプリングとは，少数クラスのサンプル数を人工的に増やすことで，クラス不均衡を改善し，モデルが少数クラスを過小評価することを防ぐための技術である．単純な方法として，少数サンプルをそのまま複製することで実施できる．コスト感応学習とは，クラスの不均衡を直接扱う代わりに，モデルの学習アルゴリズムにクラスの重みを導入し，少数クラスの誤分類コストを高く設定することで，モデルが少数クラスをより重視するようにする技術である．

アンダーサンプリングと bagging の組み合わせ

先述のアンダーサンプリングの懸念点として，多数例側からランダムに抽出した症例に偏りが生じる可能性があったり，多数例側のクラスの情報量を十分に利用できていなかったりといった問題が生じる．これらの問題を解決するために bagging を使用する [4,5]．Bagging とは予測モデルを多数作成し，各モデルの予測結果を平均化する技術である．つまり，特定のデータのみに依存しないよう学習をすすめ，外的データにも対応可能なように汎化性能を向上させる．アンダーサンプリングと bagging を組み合わせ，① 多数例側をランダムに抽出し予測モデルを構築し，② それを複数回実施し，③ 複数モデルの予測結果を平均し予測結果とすることである (図 1 参照)．

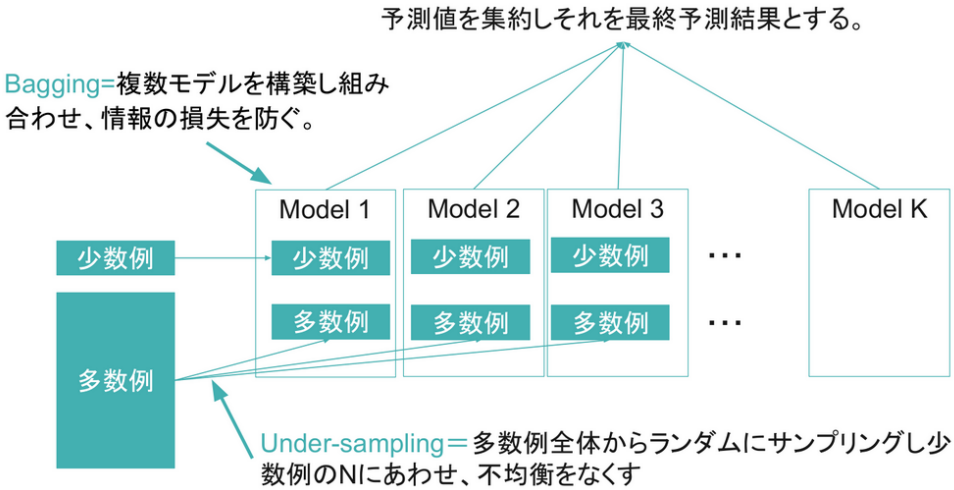

図 1．アンダーサンプリングと bagging の組み合わせによるクラス不均衡への対応

結　論

本稿では AI・機械学習アルゴリズムを用いて教師あり学習によって予測モデルを構築するためのステップと注意点について記載した．現状，色々なソフトウェアが機械学習アルゴリズムを比較的簡単に実装できる環境が整っている (Python や R のパッケージ等)．予測モデルを構築するのに有用なステップは，ガイドライン等が報告されているので，それらを活用するのも効率的と考える．

参考文献

1. Luo W, Phung D, Tran T, et al. Guidelines for developing and reporting machine learning pre-

dictive models in biomedical research: A multidisciplinary view. J Med Internet Res 2016; 18: 1-10.
2. Moons KGM, Altman DG, Reitsma JB, et al. Transparent Reporting of a multivariable prediction model for Individual Prognosis Or Diagnosis (TRIPOD): Explanation and Elaboration. Ann Intern Med 2015; 162: W1.
3. Phillips R V, van der Laan MJ, Lee H, Gruber S. Practical considerations for specifying a super learner. Int J Epidemiol 2023; 52: 1276-85.
4. Wallace BC, Small K, Brodley CE, Trikalinos TA. Class imbalance, redux. In: Proceedings - IEEE International Conference on Data Mining, ICDM. 2011: 754-63.
5. Ogata S, Takegami M, Ozaki T, et al. Heatstroke predictions by machine learning, weather information, and an all-population registry for 12-hour heatstroke alerts. Nat Commun 2021; 12. DOI:10.1038/S41467-021-24823-0.

新時代の呼吸モニタリングを提供する EIT

岡原 修司

はじめに

Electrical Impedance Tomography (EIT) は，ベッドサイドで非侵襲的に胸腔内の局所換気を評価できるツールとして，急性呼吸不全に限らず臨床の様々なシーンに活用されつつある．EIT は胸腔内の位置情報を含む電気抵抗情報を高い時間分解能で測定することで，我々に胸腔内のエアレーションの状態を提供してくれる．臨床における EIT の主な用途とその可能性について触れていく．

EIT の測定原理

EIT は胸部第 4 肋間から第 6 肋間に 16 もしくは 32 個の電極付きのベルトを装着し，1 つの電極から微弱な電流を流し，残った電極にてインピーダンスを測定することで胸腔内の電気抵抗値を得る．通常の肺組織は空気成分が多いため電気抵抗が高く，さらに呼吸性の変動が見られるが，胸水や無気肺領域は電気抵抗が低く，呼吸性変動も乏しい．加えて通電する電極を 1 周させることによって，胸部を水平断した画面において，32 電極であれば 32 × 32=1024 ピクセルごとにマッピングすることができる．この位置情報を 1 秒間に 50 フレーム取得することで，時間分解能の高い動的な換気分布を可視化することができる．EIT 内ではこのような膨大な情報を処理し，医療従事者が直感的に理解しやすいイメージ画像に可視化している (図 1).

コンプライアンスや食道内圧のような肺全体を代表する 1 つの値ではなく，EIT は肺の局所の情報を提供できることが最大の長所と言えるため，急性呼吸不全の人工呼吸器設定のみならず，手術室や術後症例の呼吸管理など様々なシーンに応用することができる．また測定のために移動の必要性がなく，ベッドサイドにて評価が完了することも利点である．

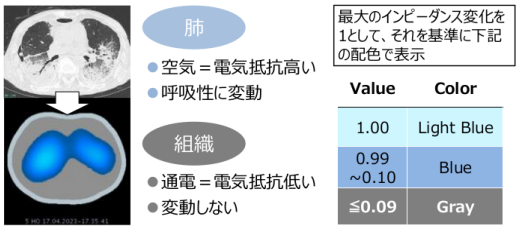

図 1．EIT の測定原理について

EIT の表示形式は，まず基本画像としての Dynamic image があり，背側・腹側もしくは左右に分けた換気分布の%表示と各領域の換気状態の経時的な変化を示すプレチスモグラムが存在する．また換気状態の詳細な評価を行うためのツールとして Impedance/Pressure Change Map がある．この機能は任意で選択した 2 点でのピクセルごとのインピーダンス変化を比較するものであり，何らかの介入を行った際にその前後を選択し，各領域において換気が改善したか否かを比較することができ，主に PEEP titration 中の虚脱もしくは過膨張の判断に利用されている．

EIT による PEEP 滴定

EIT による PEEP titration は虚脱再開通だけでなく，局所の過膨張に留意した方法として注目されている．その代表的な方法は ODCL(Overdistension and collapse) と呼ばれ [1)]，一旦リクルートメントが得られる high PEEP を掛けた後に，PEEP を漸減していき，腹側・背側の各領域のピクセル毎のインピーダンス変化を評価していく．それぞれのピクセルごとに最大インピーダンスとなる PEEP が決定され，それをもとにインピーダンス変化が乏しい領域を過膨張もしくは無気肺と推測する．最終的に全領域で両者の

岡山大学病院 集中治療部

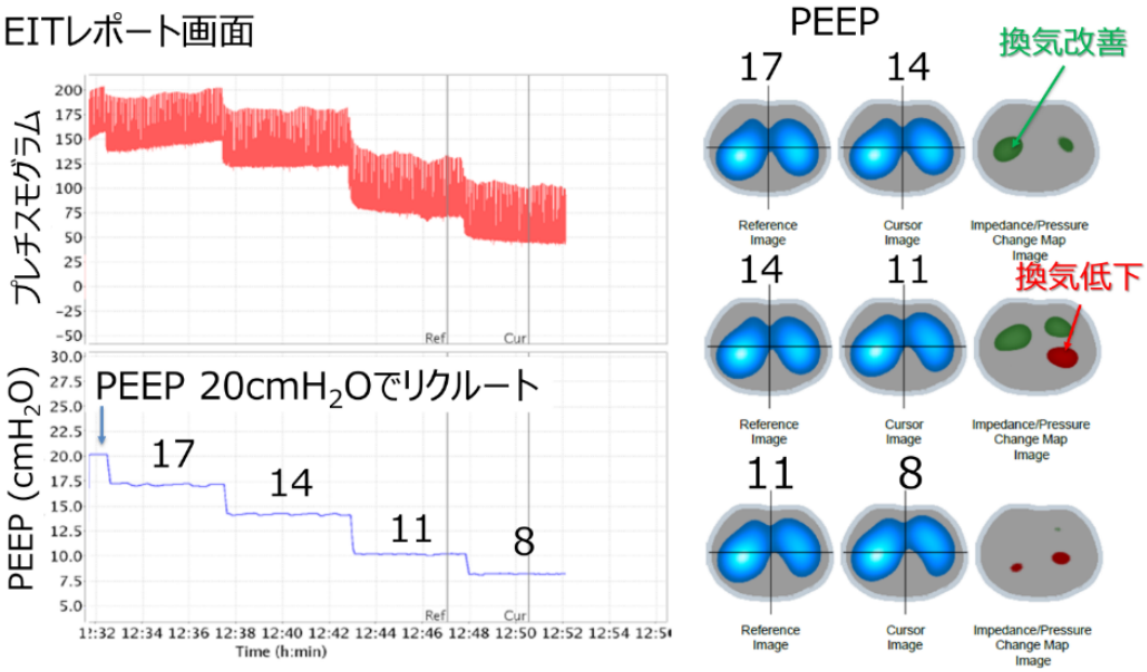

図 2. EIT を用いた PEEP titration の実際

領域が最小となる PEEP を Optimal PEEP として選出する．本邦の EIT には 2023 年において ODCL の自動解析機能は導入されていないため，上述の Impedance/Pressure Change Map を用いて，PEEP 変更の前後で比較していき，最終的に過膨張が最小で，さらに無気肺が大きく増加しない PEEP を選ぶことで代用することができる．その PEEP titration 中の画像を図 2 に示す．

これまで PEEP titration には様々な方法が存在し，コンプライアンスに注目した Best compliance 法や食道内圧測定をもとにした経肺圧ガイド法があり，無作為ランダム比較試験にても評価が行われているが，生存率や ventilator-free-days の改善には至っていない．またどの方法を選択するかによって得られる Optimal PEEP の値にはばらつきがあり [2–4]，Optimal PEEP にはさらなる研究が必要である．その中で EIT による PEEP titration は肺局所の過膨張の評価が可能であるため，人工呼吸器関連肺傷害の回避が期待できるため，今後の研究結果が待たれる．

体位変換の評価

人工呼吸中の肺理学療法は重要であり，その 1 つとして腹臥位を含む体位変換は各施設で差はあるが，日々取り組まれている．EIT による換気の定量化はこの体位変換の是非を判断する上でも有用である [5]．

COVID-19 による Acute Respiratory Distress Syndrome (ARDS) 症例に対する体位変換の効果を EIT にて検討した研究において，わずか 30 分の側臥位にて両側の換気改善が報告されている [6]．当院においても PEEP が奏功しない症例に対して腹臥位を積極的に実施している．EIT にて評価したところ腹臥位中の換気改善だけでなく，仰臥位に戻った後も換気改善が継続する症例を経験している．その反面，腹臥位中でも背側の換気が全く改善しない症例も認めており，それ以降の腹臥位療法を継続するかどうかを EIT の結果を参考に決定することができる．

自発呼吸の評価

人工呼吸管理におけるもう 1 つの課題は自発呼吸による肺傷害を回避することである．重症 ARDS において，強制換気から補助換気に移行した際の過剰な呼吸努力は肺傷害を進行させることが報告されており [7]，COVID-19 パンデミック以降さらに自発呼吸関連肺傷害の認識が広まっている．その 1 つである Pendelluft 現象は吸気早期に強い吸気努力によって背側肺が急激に拡張し，その後に腹側肺に換気がシフトする現象であり，虚脱領域が原因となり局所的な時定数の違いや動的な胸膜圧差から生じるものとされている．この Pendelluft は時相的な不均一換気パターンとして描出される．また時相だけでなく，空間的に不均一な換気 (一部の肺に換気が集中) にも注意が必要である．最近の研究において，Pendelluft 現象の存在は血清サイトカインの上昇などの全身性の炎症の惹起だけでなく，人工呼吸管理日数にも関連していることが報告されている [8,9]．

またその換気の不均一性は人工呼吸器離脱時にも注意すべき所見である．人工呼吸離脱前の自発呼吸トライアル中に EIT を装着し，離脱の指標を検討した研究において，EIT における換気の不均一性の指標である Inhomogeneity Index が高い症例ほど抜管失敗に至りやすいことが報告されている [10]．臨床的にはすべての症例に必須ではないが，人工呼吸器離脱困難症例において，動的な画像診断として有用となる可能性がある．

まとめ

EIT は食道内圧やグラフィックスモニタリングでは得られなかった肺局所の換気様式を動的に評価できるツールとして様々なシーンに用いることができる．これまでは肺全体を代表する 1 つの値をもとに呼吸管理を展開してきたが，人工呼吸器関連肺傷害や自発呼吸関連肺傷害を回避するためには，肺胞の不均一性や局所の情報を考慮に入れた呼吸管理が必要となってくるため，今後の新しい呼吸管理における強力な武器となり得る．

引用文献

1. Costa EL, Borges JB, Melo A, et al. Bedside estimation of recruitable alveolar collapse and hyperdistension by electrical impedance tomography. Intensive care medicine. 2009;35(6):1132-1137.
2. Yoshida T, Piraino T, Lima CAS, et al. Regional Ventilation Displayed by Electrical Impedance Tomography as an Incentive to Decrease Positive End-Expiratory Pressure. Am J Respir Crit Care Med. 2019;200(7):933-937.
3. Gibot S, Conrad M, Courte G, et al. Positive End-Expiratory Pressure Setting in COVID-19-Related Acute Respiratory Distress Syndrome: Comparison Between Electrical Impedance Tomography, PEEP/FiO2 Tables, and Transpulmonary Pressure. Front Med. 2021;8:720920.
4. Sella N, Zarantonello F, Andreatta G, et al. Positive end-expiratory pressure titration in COVID-19 acute respiratory failure: electrical impedance tomography vs. PEEP/FiO2 tables. Critical Care. 2020;24(1):540.
5. Mlček M, Otáhal M, Borges JB, et al. Targeted lateral positioning decreases lung collapse and overdistension in COVID-19-associated ARDS. BMC Pulm Med. 2021;21(1):133.
6. Roldán R, Rodriguez S, Barriga F, et al. Sequential lateral positioning as a new lung recruitment maneuver: an exploratory study in early mechanically ventilated Covid-19 ARDS patients. Ann Intensive Care. 2022;12(1):13.
7. Brochard L, Slutsky A, Pesenti A. Mechanical Ventilation to Minimize Progression of Lung Injury in Acute Respiratory Failure. Am J Respir Crit Care Med. 2017;195(4):438-442.
8. Wang D, Ning Y, He L, et al. Pendelluft as a predictor of weaning in critically ill patients: An observational cohort study. Front Physiol. 2023;14:1113379.
9. Cornejo RA, Arellano DH, Ruiz-Rudolph P, et al. Inflammatory biomarkers and pendelluft magnitude in ards patients transitioning from controlled to partial support ventilation. Scientific Reports. 2022;12(1):20233.
10. Longhini F, Maugeri J, Andreoni C, et al. Electrical impedance tomography during spontaneous breathing trials and after extubation in critically ill patients at high risk for extubation failure: a multicenter observational study. Ann Intensive Care. 2019;9(1):88.

スマートグラスを活用した次世代見守り (ナースコール) システム

花谷 行雄

1．はじめに

ナースコール・システムの多くは, 患者がスタッフを呼び出す通知専用ツールとして使用されている．特に信頼性が要求される病院のシステムでは, 病棟ごとに専用の制御装置があり, ナースコール・ボタンが有線接続される．この為, 病棟ごとの閉域ツールとして稼働するものが多い．また, 一部にはスマートフォンやスマートウオッチ, ネットワークカメラ等を端末とするシステムもあるが, ナースコールの上流から下流に至るコミュニケーションに係るプロセスまでカバーできておらず, 看護師の心理的負荷軽減や, 作業効率の改善, 品質改善等への貢献度は低い.

更に, システム自体を更新, 進化させることが難しい．例えば, 新規に AI 機能を搭載したネットワークカメラが海外メーカから安価で発売された場合も, システムで利用する為には高額な改修コストが発生する等, 現場への適用は難しいケースが多い．そこで, 今後の IoT, AI 技術の技術革新を医療現場に享受すべく, コミュニケーションのあり方から働き方を改革し, 将来の基盤システムとなるコンテナベースの見守りアプリケーションを開発した．無停止型サーバを採用し, 将来のハイブリッドクラウド化も検討し段階的な実証実験を開始した.

2．対象とする看護業務の課題と解決策

次の課題を抽出し, 解決策を検討した.

＜課題＞

(1) 気の抜けない見守りによる心理的負担

認知症患者の徘徊による転倒防止や, ナースコールコールを押せない重篤な患者の昼夜問わない継続的な看護による心理的負担が大きい

(2) 加齢性難聴による音声コミュニケーションが難しい患者への対応

現地の駆け付けが必須となり身体的負担が大きい

(3) 複数鳴動するナースコールへの対応や優先順位付け

状況確認のため現地に行く必要があり心理的・身体的な負担が大きい

(4) ケア中は手が塞がりスマートフォンを利用できない

＜解決策＞

@ 駆け付けないで遠隔監視ができれば・・
@ 徘徊検知できれば転倒防止に・・
@ スタッフステーションでなく手元で通知を確認できれば・・
@ コールが連続した場合に遠隔監視できれば・・
@ 容易に他のナース・医師に相談・依頼できれば・・
@ ハンズフリーのコミュニケーション

3．次世代見守りシステムの採用機器

● スマートグラス
・ 1280 万画素, オートフォーカスカメラ
・ 暗所でもはっきり見える有機 EL ディスプレイ
・ 高音質なノイズキャンセリングマイク
・ 屋外利用の防水, 防塵機能
・ 音声コマンド対応

● ナースコール・ボタン
・ 920MHz 無線通信
・ 通知データをロスしない送信プロトコル
・ 防水＆電池交換不要 (10 年) 設計
・ 押下通知, ステータス管理 (スマホ, 管理 PC)

株式会社スマートゲート 代表取締役

・ Apple watch アプリ (押下通知・ステータス管理)

● 監視カメラ
・ ＡＩ動体検知 (徘徊・境界他)
・ 音声通話 (マイク＆スピーカ)
・ 暗視モード
・ スマートグラス連携 (映像共有)
・ 動体検知通知，ステータス管理 (スマホ，管理 PC)
・ Apple watch アプリ (動体検知通知・ステータス管理)

● Apple Watch，スマホ／タブレット
・ Apple watch アプリ (押下通知・ステータス管理)
・ Apple watch アプリ (動体検知通知・ステータス管理)

● 管理端末 大型モニタ
・ タッチパネル
・ 43 インチ～86 インチ
・ マイクロ PC，web カメラ，マイク，スピーカ・病室，カメラ，スマートグラス管理機能
・ web 会議対応

● 無停止型サーバ
・ 高可用性 (99.99999%)，ダウンタイム：年間平均 3 秒 (運用上は 100%の可用性，ダウンタイム 0 秒を実現する無停止型サーバ)

4．次世代見守りシステムの改善対象

3 年間に渡り年度ごとに「ステップ 1」,「ステップ 2」,「ステップ 3」と段階的なゴールを設定し，第一弾となる「ステップ 1」では，次の 4 項目を改善対象とした．

(1) 看護師の心理的負担軽減

看護師が必要に応じて他の看護師へ相談できる等，安心して業務に従事できる環境を実現することにより看護師の心理的な負担を軽減する．

(2) 患者への看護品質の改善

ナースコール・ボタンの押下だけをトリガーとするのでなく，カメラ映像による動体検知により看護要請する等，看護品質を改善する．

(3) 看護業務の効率改善

ナースコール・ボタンを押下した一人の患者に複数の看護師が駆け付ける様な看護師間で重複する作業を軽減し，結果として看護業務の効率を改善する．

(4) 高可用性とコスト削減

見守り (ナースコール) システムのコストを削減する．

5．次世代見守りシステムに採用する要素技術

病院で継続的に使用するシステムとして, セキュリティ，システムの更新とメンテナンスが容易な他，信頼性，可用性，拡張性，柔軟性等，考慮すべき要点は多岐に渡る．当該システムを実現する為に採用する要素技術を以下に記述する．

(1) 無停止型サーバ

冗長化構成の無停止型サーバは，ハードウェアの障害が発生しても，自動的にバックアップシステムが作動し，連続したサービス提供が可能です．医療現場では，患者情報の即時アクセスが保証され，ナースコール通知の遅延や欠落を防ぎます．また，汎用的な産業用無停止型サーバを採用することにより，既存の病棟ごとに設置する専用のナースコール制御装置に比較しコスト削減が可能です．

(2) コンテナベースのアプリケーション

コンテナベースのアプリケーションでシステムを構築することで，環境の一貫性と移植性が確保できます．今後の開発を伴う継続的な機能改善から，規模の拡大に伴うアプリケーション管理を効率的に実施でき，医療システムに求められる高い可用性と拡張性を実現する為にもコンテナ技術を活用した．

(3) ハイブリッドクラウド化

病棟ごとの閉域ツールとして構成される既存のナースコール・システムに対し，オンプレミスの現状のシステムも病棟間の情報を連携できます．更に，今後のハイブリッドクラウド化したナース

コール・システムでは，オンプレミスとクラウドリソースを最適に活用することで，高い可用性と拡張性を実現できる様になります．

オンプレミスとクラウドでデータを保持することで，例えば，災害時のデータ損失を防ぎビジネスの継続性を高め，また，緊急時にはクラウドのリソースが追加の負荷を吸収し，連続的なサービスを実現します．コンテナベースのアプリケーションとした事でハイブリッドクラウド環境に適しており，今後のステップでハイブリッドクラウド化を検討する．

6．目的に対する機能実装

相互に影響しあい，全ての機能実装は全ての目的の改善に貢献する．近々には，話者認識の音声入力からの AI 要約他の情報の登録・収集に係る機能実装等により，更なる改善を見込む．

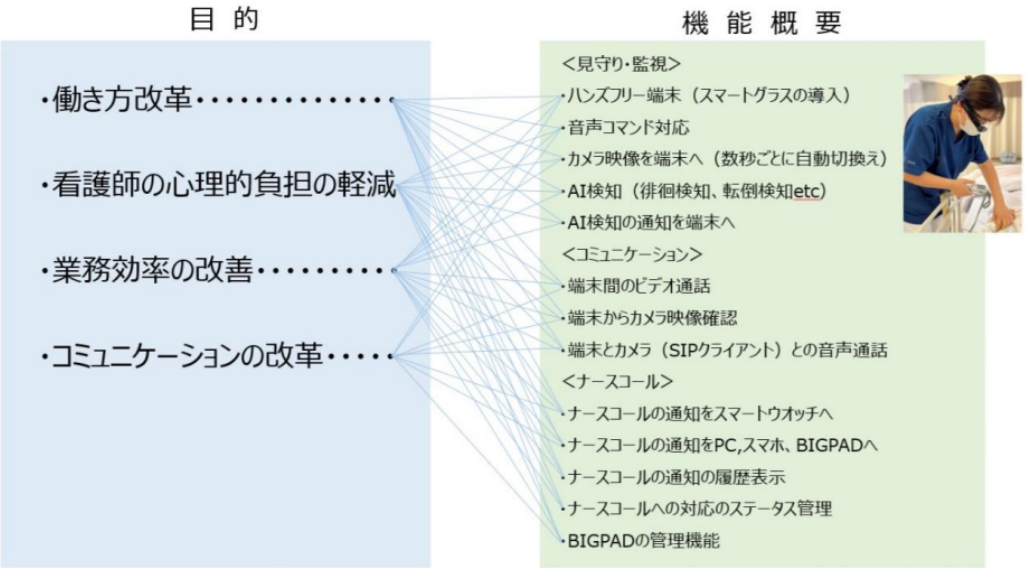

図 1．目的と機能実装

7．システムの運用イメージ

最新の ICT 技術を活用し，従来のアナログ管理から，いつでも，どこでも，だれとでもつながるデジタル管理が可能な環境を提供する．オンライン診療システム「スマートキュア」をベースとして開発に着手し，コミュニケーションを改善する目的にてスマートグラス，ネットワークカメラ，スマホ等の利用を可能とし，更にはナースコール機能を実装し，次世代見守りシステム「ウェアセーフ」を開発した．(図は次項)

汎用製品を多用することでシステム導入・運用コストを削減した．

8．実証実験の中間結果

ご協力頂く医療機関様の実証実験では，機能的にはスマートグラスによるコミュニケーションとネットワークカメラの映像の共有機能を実装した開発当初の段階で (大きく重いバッテリーを装着するスマートグラスであったにも関わらず)，看護師 17 名に実施したアンケート調査では次の結果を得た．

- 82%の看護師が夜勤帯の転倒転落に対する不安が軽減した
- 70%の看護師が疲労度 (ストレス) が減り，負担軽減に寄与した
- 76%の看護師が以前より訪室件数が少なくなった

図 2.「カメラの動体検知」「ボタンの押下」からの業務フロー

図 3．スマートグラスの視点映像を共有したコミュニケーション

・ 70%の看護師が夜勤帯にデスクワークできる時間が増えた

9．おわりに

次世代見守りシステムは，スマートグラスを活用しハンズフリーで患者をケアしながら，他の病室のカメラ映像の確認の他，他の看護師に自身のスマートグラスのカメラ映像を共有し相談する等の運用が可能になった．機能実装が整わない中で実施した中間アンケートの結果から，訪室回数を削減できた等の効果が確認できた．今後は効果を

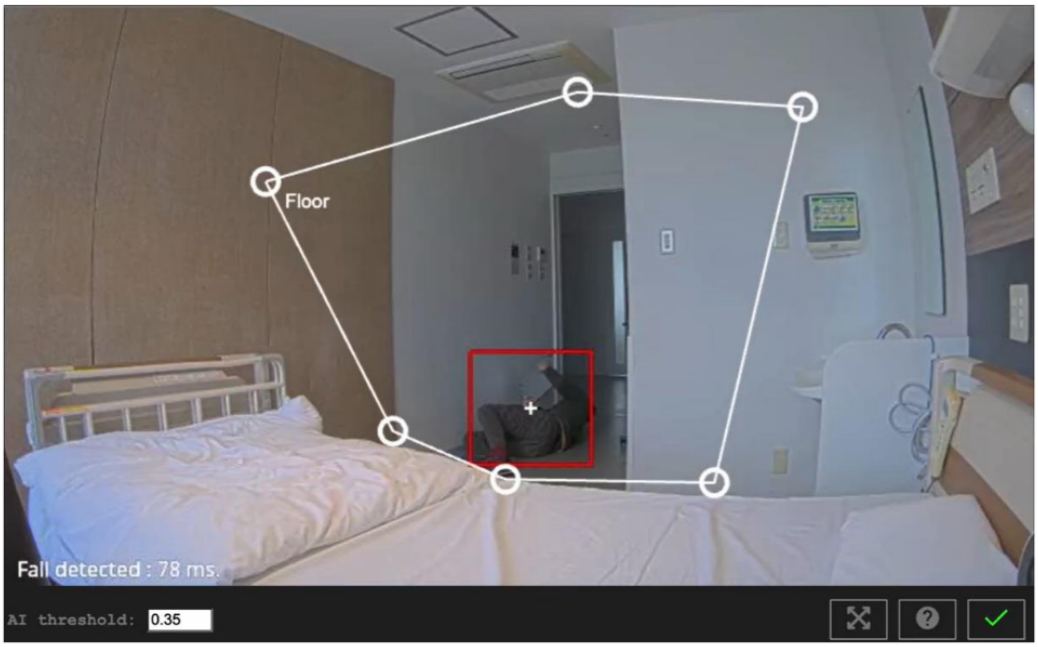

図 4．AXIS Q9307 ネットワークカメラの転倒検知 (AiDANT Care)

数値化し，AI による患者の動体検知や音声認識のモニタリングからの異常検知等の機能改善に取り組む他，患者の見守りに特化せず，病院内外の様々な用途への適用の他，今後の超高齢化社会の様々な課題に対する解決策の一つとなるべく検討する．

共催シンポジウム 2

麻酔記録装置への入力用携帯端末の導入

上山 博史

要旨：
アンドロイド OS を搭載した 6 インチスマートフォン上で動作する自動麻酔記録装置の入力用アプリケーションを開発し, ORSYS-G4 において運用を開始した．従来のマウスとキーボードによる入力方法の問題点として，入力が煩雑で，リアルタイム入力に難があること, 麻酔導入時と手術終了後に入力が集中することがあげられる．今回開発したアプリケーションは, 携帯端末上でタッチパネルによる直感的な操作が可能であり，ほぼリアルタイム入力と入力手数の削減が実現した．さらに，入力画面にチェックリストを導入したことにより，安全性が向上した．現在開発中の看護用アプリケーションと麻酔用アプリケーションを連携することで，さらに入力手数を削減できると考えている．携帯端末入力は，従来の入力の問題点を克服し，自動麻酔記録装置の操作性と安全性を向上させる革新的な方法である．今後の普及が期待される．

はじめに

わが国の自動麻酔記録装置は，1987 年 8 月に北海道手稲渓仁会病院に導入されたシステムを起源としている．しかし，このシステムで使われた米国 apollo コンピュータ社のワークステーションは，現在の基準からみてマシンパワーが低く，予定していた機能の一部しか実現しなかった．この約 10 年後に, 北海道大学附属病院手術部に導入された, 現在のフィリップス・ジャパン社製 ORSYS の元となった Windows NT 上で動くシステムによって，ようやく，今日に近い機能が実現し, 自動麻酔記録装置が次第に全国に普及していく．それから約 30 年が経過した今日，わが国では, 数社から自動麻酔記録装置が販売されているが，いずれの機種も使い勝手がいいとは言えない．その原因の一つが, 原型機の登場以来使われてきたパーソナルコンピューター入力 (PC 入力) にある．マウスとキーボードによる PC 入力は, マウスによってポインターを指定されたエリアまでピンポイントで移動させる必要があり，さらに昔ながらのユーザーインターフェイスが使われているため，ロクロニウム 10mg 投与のような，単純な入力でさえ複数の手順を必要とする．これらの理由から, PC 入力は必ずしも快適な入力手段とは言えない．特に，全身麻酔では，麻酔科医の手が塞がる麻酔導入時と手術終了後に入力が集中するため, 挿管や抜管のようなイベントのリアルタイム入力はほぼ不可能である．正確な記録のためだけでなく，今後, 導入されるであろう, 血圧予測などのインテリジェントな機能に対応するためにも, イベントや薬剤入力を素早く入力可能な方法が必要である．そして何より, 使い勝手の悪さにフラストレーションを感じてきた麻酔科医にとって，操作性の向上は悲願である．このような背景から PC 入力に代わる新たな入力方法が求められてきた．新たな入力方法として, 手術室に設置したカメラの映像から麻酔科医の動作を類推してイベントを入力する映像入力や, 麻酔科医の声による音声入力が候補に上がるが，映像の自動認識を行うシステムには多額の開発費がかかること，音声入力にも継続的にソフトウエアのライセンス料が発生することから現実的ではない．そこで, われわれはアンドロイド OS を搭載した 6 インチスマートフォン (携帯端末) 上で動作する自動麻酔記録装置の入力用アプリケーションを開発した．この方法は, 開発費が低く，ハードウェアの導入経費も安価であるというメリットがある．さらにスマートフォンサイズの携帯端末は持ち運びが容易で, どこからで

関西労災病院 麻酔科

も入力が可能であるため，作業の効率化に寄与する．このアプリケーションを使った麻酔入力を，周術期患者情報システム ORSYSG4(フィリップス・ジャパン社製) 上で稼働してから約 2 年が経過したが，麻酔科医に好意的に受け入れられている．その概要について解説する．

システムの概要

入力用アプリケーション：入力には，画面上に配置したタッチインターフェイス (入力ボタン) を使う．入力ボタンは，図 1 に示すように，挿管や手術開始などのイベント，確認事項のリマークス，薬剤の 3 つに分類し，これらを色分けして縦並び 3 列で入力項目を配置した．入力ボタンの上には，患者名と血液型，身長と体重，入力ボタンの下には静脈ルートと輸液を表示する．

入力画面は，入室，導入，術中，手術終了の 4 場面にわけ，横方向のスワイプか，手術開始などの主要イベントの入力で自動的に切り替わる (図 2)．そして，この 4 場面の入力ボタンで，JSA-PIMS 入力や輸液を含む，入室から退室に至る，麻酔に関するほぼすべての入力を実現した．この携帯端

図 1．携帯端末画面の入力ボタンの配置

入力ボタンは，手術開始などのイベント，確認事項のリマークス，薬剤の 3 つに分類し，これらを色分けして縦並び 3 列で入力項目を配置

図 2．入力場面の切り替え

手術を，入室，導入，術中，手術終了の 4 場面に分け，麻酔の進行によって，横方向のスワイプでそれぞれの場面の切り替える

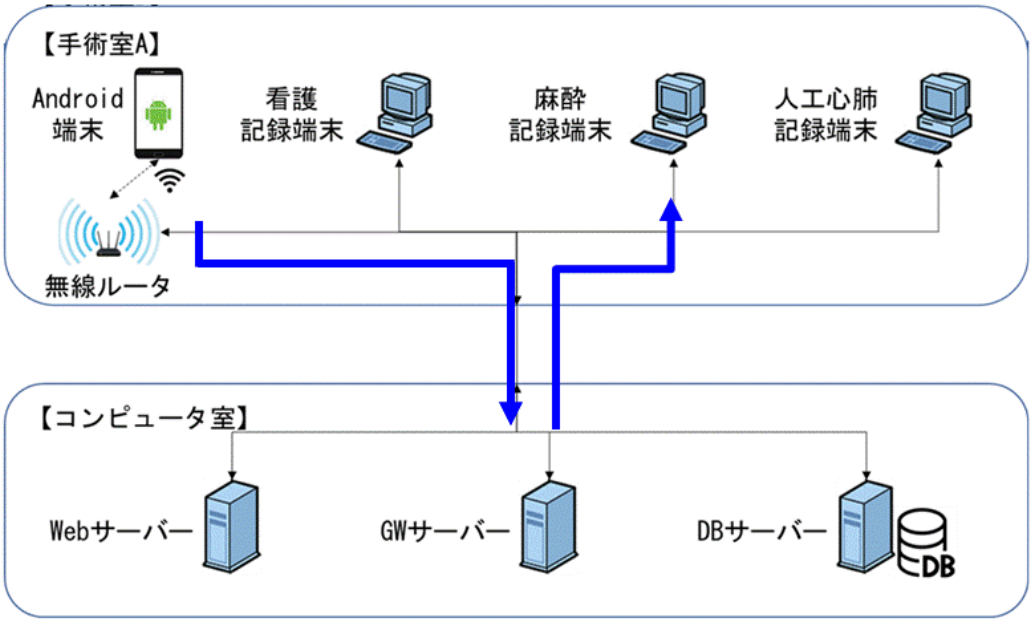

図 3. システム構成

携帯端末から入力した事項は，手術室の無線 LAN ルーターを介して，サーバーに記録し，その後，サーバーから手術室の麻酔記録端末にデータを送って表示する

末の機能は入力に特化したものであり，入力の修正や削除は PC から行う．

システム構成：携帯端末は，日常生活で使い慣れている携帯電話サイズの 6 インチアンドロイド端末 (arrows BZ01：富士通社製) である．携帯端末から入力した項目は, 直接, 手術室の麻酔記録端末に書き込むのではなく, 手術室の無線 LAN ルーターを介して，サーバーに記録し，その後，サーバーから手術室の麻酔記録端末にデータを送って表示する (図 3).

入力画面の工夫

1. 入力の分散と簡素化

従来の PC 入力は，入力インターフェイスが悪く，しかも, 麻酔導入や覚醒の時期に多くの入力が集中する．挿管を例に上げると，導入方法, マスク換気や挿管の難易度，チューブの種類，合併症など, 多くの項目を, 挿管直後の忙しい時期に，まとめて入力する必要がある (図 4)．そこで, 画面

図 4. 従来の PC 入力のユーザーインターフェイス

挿管を例に上げると，挿管直後の多忙な時期に，導入方法や挿管チューブの情報など, 多数の項目を一気に入力する必要がある

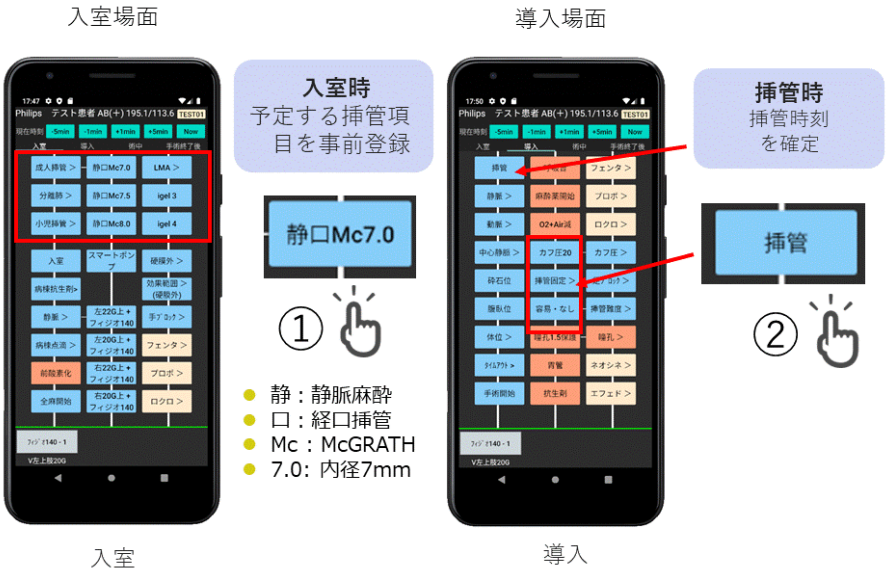

図 5．入力の分散と簡素化

気管内挿管では，① 入室時に事前登録し，② 気管内挿管時に挿管ボタンで時刻を確定することにより，入力の分散化を図った．さらに，頻用する入力パターンは，1 つの入力ボタンにまとめて，1 手で入力できるように簡素化した

を設計する上で, 入力の簡素化と分散を図った (図 5)．まず, 入力の簡素化については, 頻用する挿管パターンは，1 つの入力ボタンにまとめた．例えば, 静口 Mc7.0 のボタンを押すだけで, 静脈麻酔下に内径 7mm の気管内チューブを McGRATH^{TM} ビデオ喉頭鏡で経口挿管することが入力される．入力の分散については, 患者入室後に, この 1 つの入力ボタンにまとめた予定挿管方法を 1 手で事前登録し，挿管時に挿管ボタンを押すことにより，挿管時刻を確定するように改めた．

2．多階層化を避ける

入力ボタンが深い階層に及ぶと，入力の混乱を招くだけでなく，素早い入力が困難となる．そのため，入力ボタンの配置は，極力, 2 階層にとどめた．薬剤投与を例にとると，導入，術中などの各場面の表層に薬剤名を配置し, その下の層に投与量を配置した．また, 頻度の高い, ロクロニウム 10mg 投与や，フェニレフリン 0.1mg 投与は, 画面表層に 1 手で入力するボタンを配置した．

3．リアルタイム入力の実現

われわれの施設では, 麻酔器からの揮発性麻酔薬, 空気, 酸素の投与やシリンジポンプからの薬剤投与データは，自動的に記録装置に取り込まれるので，術中にこれらの入力が滞ることはない．結局のところ，イベントでは挿管と抜管，薬剤投与では, 導入時にボーラス投与するプロポフォールやロクロニウム, フェンタニルの投与が正確に入力できれば，ほぼリアルタイムの入力が実現することに気づいた．そこで，入力を実時間に確実に行うため，麻酔科医の手が塞がる麻酔導入と覚醒時の薬剤投与と挿管と抜管の入力は，看護師に入力を行ってもらうことにした．

携帯端末の効果

1．リアルタイム入力

図 6 は，従来の入力方法による，導入時のロクロニウムが投与された時刻と，入力時刻の差をみたデータであるが, 携帯端末導入以前は，ほぼ実時刻に入力されている例は全体の約 30 % しかな

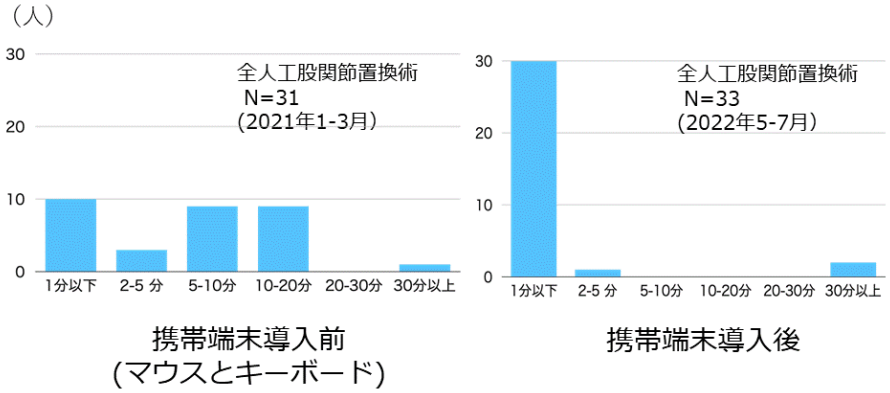

図 6．麻酔導入時のロクロニウム投与の記録時間のずれ

携帯端末導入前は，投与 1 分以内に入力が行われた例は，31 名中 10 例と 1/3 に満たなかったが，携帯端末導入後は，33 例中 30 例で 1 分以内に入力されている．このデータは携帯端末導入直後に，看護師ではなく，麻酔科医が入力したデータであるが，手元で簡単に入力できる端末端末の効果がはっきりと表れている

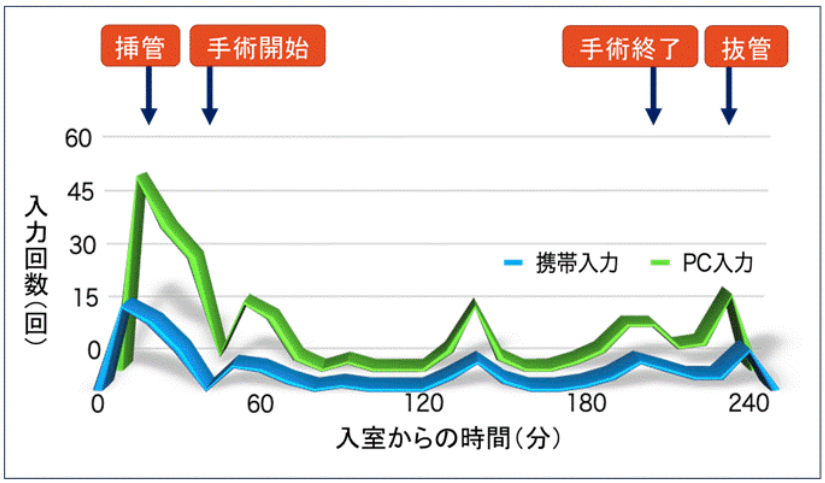

図 7．PC 入力と携帯入力の時系列の入力タッチ数の違い

従来の PC 入力では，麻酔導入時と手術終了後に入力が集中している．携帯端末の導入により，全体の入力手数が減少し，導入時と手術終了後の入力集中もある程度解消できた

く，多くの例で投与 5 分から 20 分後に入力が行われている．これは，筋弛緩薬を投与しても，すぐに入力しない麻酔科医自身の問題でもあるが，マウスとキーボードの入力が慌ただしい導入時には不向きであるということを如実に示している．一方，携帯端末導入以降では，ほぼ全例で投与 1 分以内に入力が行われていた．なお，この図 6 の携帯端末導入後の例で投与 30 分後に入力が行われた症例は，実時間入力で誤入力があったため，30 分後に修正入力が行われた例である．これらの点から，看護師の入力補助と携帯入力によって，ほぼリアルタイムの入力が実現したと考えている．

2．入力の省力化

図 7 に，4 時間の婦人科開腹手術における PC 入力と携帯入力の手数を示す．この図では PC 入力ではマウスのクリックとキーボード入力を 1 手とし，携帯入力では入力タッチを 1 手として，どの時間帯にどれだけの入力が行われたのかを示してい

る．携帯端末の導入後も，導入時と手術終了後に入力が集中しているが, 携帯入力によって，導入時の入力手数は 47 手から 15 手と 1/3 に低下し，全体の入力数も 250 手から 106 手に低下し，特に導入時と覚醒時の入力は, 1/3 に減少した．これらの点から携帯入力によって, 入力の省力化が図れたことがわかる．

3. チェツクリストの導入

今回の携帯入力の導入で，入力の省力化以外に進歩した点として, 導入時のチェックリストが実現したことがあげられる．図 8 に示すように，挿管後は, 携帯端末上のリスト順に, 呼吸音の確認や固定長，挿管の難易度などのチェツク項目を看護師が読み上げ，麻酔科医の返事を看護師が入力する．このチェツクが終了した時点で，導入時の麻酔入力は, 完全に終了する．今後, 退室時のチェックリストを導入する予定であるが，挿管や退室時の確認を携帯端末上のチェックリストに従って行うことは，安全性の観点から見て，大きな成果であったと考えている．

まとめ

1988 年の自動麻酔記録装置の原型機以来, 今日まで約 40 年間使われてきたキーボードとマウスにかわる新たな入力法として, 携帯入力が可能なアンドロイド OS 上で作動する麻酔用入力アプリケーションを開発した．このアプリケーションによって入力の簡素化，リアルタイム入力が実現した．現在，看護用アプリケーションを開発中であるが，麻酔科医と看護師の入力の重複を解消することによって，さらに入力の簡素化が図れると考えている．携帯入力を含むモバイル端末は，電子カルテの入力方法として，我が国でも医療現場に徐々に取り入れられているが [1)], 手術だけでなく，定型的な処置が行われる，分娩, カテーテル治療, 内視鏡治療, 集中治療の現場でも有用な方法と考えられる．今後，麻酔・集中治療の分野でこの携帯入力が普及し，その他の分野にも広く普及することを願っている．

図 8. チェックリスト

気管内挿管後，携帯端末上の確認項目を看護師が読み上げ，麻酔科医の返事を看護師が入力する，導入時チェツクリストが実現した

引用文献

1. 山崎友義, 鈴木斎王, 奥村智子, 電子カルテと一体化したモバイル端末の導入効果の検討, 14 巻 3 号, 147-150, 2013, 日本医療マネジメント学会雑誌

ABSTRACT

Development and Implementation of a Mobile Handheld Device for Automated Anesthesia Record Keeping: Enhancing Operability, Safety, and Workflow Efficiency

Hiroshi Ueyama, MD, PhD

This paper presents a novel mobile phone-based input for automated anesthesia recording systems. The device utilizes a 6-inch Android smartphone and addresses the limitations of conventional mouse and keyboard input, which include cumbersome operation, difficulty in real-time data entry, concentrated input during specific periods, and poor user interface design.

The handheld device offers intuitive touch-screen operation, facilitating real-time data entry and minimizing input steps. It also incorporates an electronic checklist to enhance patient safety.

Future plans include developing a similar handheld device for nurses, enabling seamless data collection across the care team. This innovative input method overcomes the limitations of traditional interfaces, improving both operability and safety in anesthesia recording. We anticipate widespread adoption within clinical settings.

Keywords: Anesthesia record, Mobile handheld device, Real-time input, Electronic checklist, Workflow efficiency, Safety

Department of Anesthesiology, Kansai Rosai Hospital

共催シンポジウム 2：

進化するストレスモニタリング：High Frequency Variability Index が可視化する新しい麻酔の世界

田中 暢洋

1. はじめに

本稿では, High Frequency Variability Index(以下，HFVI) について解説する．HFVI は心拍変動から副交感神経の活動を解析し，周術期の acute pain を含むストレスを可視化する可能性を秘めている．2022 年 7 月より本邦で発売されたが，その原理，臨床への適用も含めて述べていきたい．

2. 侵害受容 (Nociception) とは?

HFVI は二極のセンサーを貼付するのみの非侵襲性と相まって，「痛みのモニター」と説明すると患者の受容は良い．(図 1) ただし，医療者として用語や概念を正しく理解する必要がある．「痛み」は，「痛みの定義 2020」(日本疼痛学会 2020 年 7 月 25 日発表) によると，「実際の組織損傷もしくは組織損傷が起こりうる状態に付随する，あるいはそれに似た感覚かつ情動の不快な体験」と定義される [1]．同文書には「痛みと侵害受容とは異なる現象」であると付記されている．一方，「侵害受容」は国際疼痛学会痛み用語 2011 年度版リストによると，「侵害刺激を符号化する神経プロセス」であり，「その結果，自律神経反応あるいは行動が起こる」とされているが，ここでもやはり「必ずしも痛みを伴わない」と表現されている [2]．これらから解釈するに，「痛み」はあくまで主観を伴い，客観的かつ定量的な評価は困難であるが，「侵害受容」はその限りではない可能性があると考えられる．侵害受容と鎮痛のバランスを手術麻酔中に観察することができれば，どのような可能性が広がるか考えていきたい．

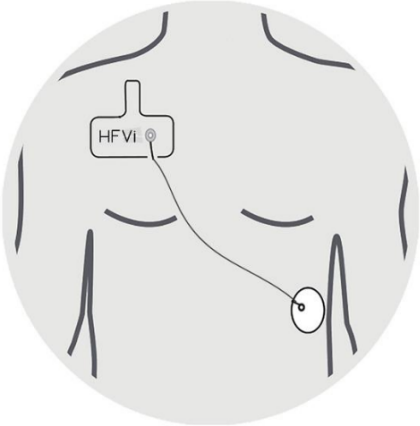

図 1. HFVI センサーと貼付のイメージ

麻酔の三要素は，「鎮静」「筋弛緩」「鎮痛」から成り立つが，鎮静は脳波モニター，筋弛緩は加速度感知式または電位感知式モニターが複数社から発売され，既に臨床で広く使用されている．

一方，鎮痛に関しては，心拍数の増加，血圧の上昇，手術侵襲の程度や進行状況から麻酔科医が総合的に，かつ主観的に判断して行うことが一般的であり，鎮痛に関するモニターは一般的ではなかった．

鎮痛を客観的に評価する難しさを示すエピソードを示したい．近年, 話題となった「全静脈麻酔支援シリンジポンプ制御ソフトウェア」は 2022 年 8 月に厚生労働省審議会が製造販売を承認し，2023 年 5 月よりプロモーションが開始された．本ソフトウェアは鎮静を Bispectral Index(BIS), 筋弛緩を TOF でモニターするが，鎮痛に関しては適切な鎮痛を「急激な循環変動が生じていない状態」と

奈良県立医科大学 麻酔科学教室

定義した．具体的には収縮期血圧と心拍数の 4 分間の平均値から 20%以上増加した状況を鎮痛不足と判断してレミフェンタニルを調整しており，治験の段階では 0.7∼1.2μg/kg/min の濃度で投与されることがしばしば起き，2μg/kg/min まで増量されてしばらく投与速度が下がらなかったこともあったようである[3]．本ソフトウェアの是々非々を述べる意図は毛頭なく，あくまで鎮痛を客観的に評価する難しさを感じる点で共有したい．

世界に目を向けると，侵害受容と鎮痛のバランスを評価するモニターは複数発売されているが，次項で HFVI の原理に触れながらその特徴を考えていきたい．

3. HFVI の原理

HFVI は数ある自律神経活動から心拍変動に焦点を当て解析している．正常な脈波形においても心電図上の R-R 間隔は常に変動しており，この心拍数の周期性変動を心拍変動と呼ぶ．R-R 間隔を抽出し，その変動から自律神経活動を捉えて解析するが，心拍変動には低周波 (Low Frequency：以降 LF:) 成分と高周波 (High Frequency：以降 HF) 成分が含まれている．LF 成分は 0.04∼0.15 Hz の帯域で，交感神経・副交感神経の両者の活動を反映していると考えられる．圧受容体反射を介する血圧変動の Mayer 波が心拍変動に反映されるが，おおよそ 0.1Hz の帯域と考えられており，交感神経活動の影響を受けるのはこのためである．HF 成分は 0.15∼0.4 Hz の帯域で副交感神経活動を反映していると考えられている．呼吸性洞性不整脈に起因する心拍の揺らぎを定量的に反映するが，その条件として呼吸回数が HF 帯域にあることが必須である．ゆえに，麻酔中に HFVI を観察するにあたり呼吸回数が重要で，9 回/分 (=0.15 Hz) よりも呼吸回数を多く設定することが重要である．(図 2)

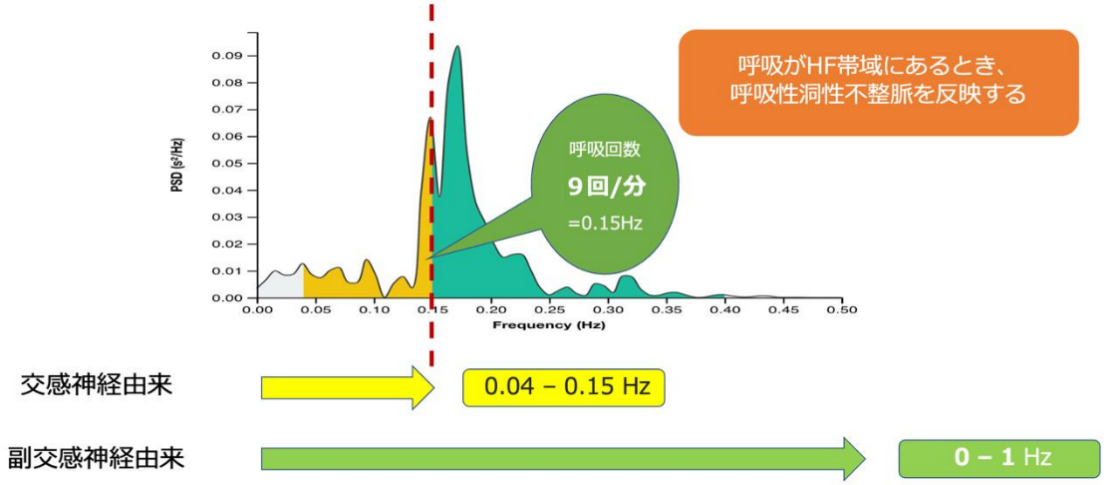

図 2. High frequency 成分と Low frequency 成分の概念図ならびに影響を与える因子.
(平和物産株式会社社内資料をもとに改編)

ここで実際の HFVI の測定原理について考えていきたい．HFVI の測定・表示手順としては大まかに四つに分類される．

i) R-R 間隔正規化

HFVI は年齢や疾患による心拍変動幅の個人差を排除して R-R 間隔の正規化を行う．具体的には過去 64 秒間における RR 間隔の移動平均値 M を計算する．$M = \frac{1}{n}\sum_{i=1}^{n} RR_i$

次に過去 64 秒間の各 RR 間隔における M を基準とした変動幅の総和 N を計算する．$N = \sqrt{\sum_{i=1}^{n}(RR_i - M)^2}$

その後，移動平均 M に対する R-R 間隔の変動

幅の割合 ($\frac{RR_i - M}{N}$) に変換することで正規化が可能となる．

ii) ウェーブレット変換を用いた HF 成分の分離

HFVI では R-R 間隔という非定常な生体信号の時間－周波数解析手法としてウェーブレット変換を採用している．

iii) Area under curve 計算

縦軸に R-R 間隔の standardized unit，横軸に時間 (64 秒) の図の中で，HF 成分由来の波形の呼気を表す緑実線の上の線と吸気を表す下の線を結んだ線で構成される包絡線の Area under curve(AUC) から HFVI を算出している (図 3)．この 64 秒間の包絡線を 4 分割し，この中で最も小さい面積を AUC_{min} として計算する．64 秒間のウインドウ全体の面積は 0.2(standardized unit) × 64(秒)=12.8 であるが，これらの数値を用いて，HFVI は以下のように算出する．

$$HFVI = 100 \times \frac{(\alpha \times AUC_{min} + \beta)}{12.8}$$

α, β はそれぞれ先行研究から算出された数値値 ($\alpha = 5.1,\ \beta = 2$) を代入し，

$$HFVI = 100 \times \frac{(5.1 \times AUC_{min} + 1.2)}{12.8}$$

で算出が可能となる．

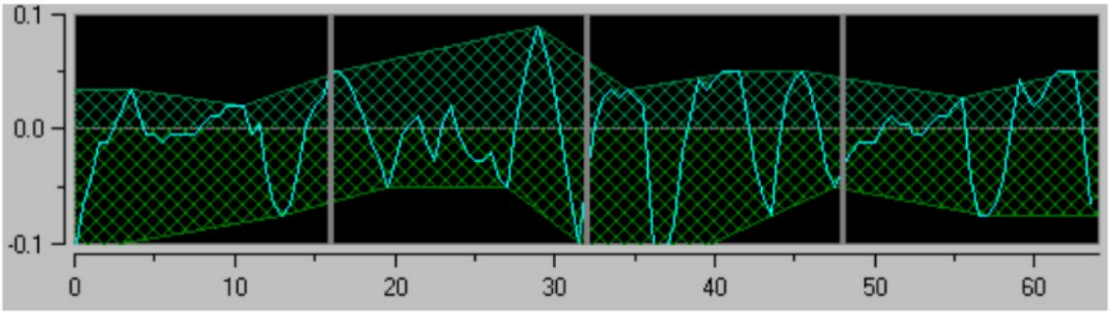

図 3. High frequency 成分で単独で心拍変動を再波形化した図．(平和物産株式会社社内資料より)

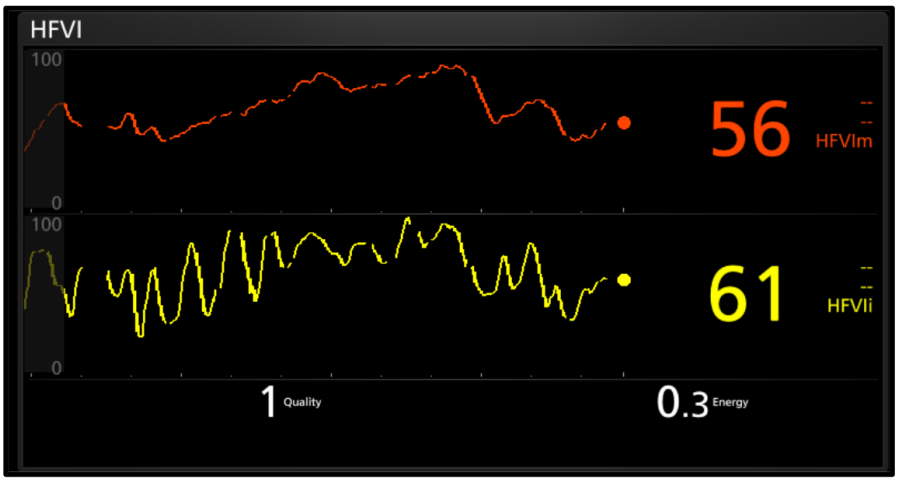

図 4. HFVI モニターの実際の画面表示．

iv) HFVI i と HFVI m の表示

HFVI i は 120 秒間の平均，HFVI m は 240 秒間の平均として表示される．その他，表示画面には Quality(シグナル状態：0, 取得不可; 1, 良好) や Energy(Energy Index：自律神経活動の総和：0.05-2.5) も表示され，各項目は理解しておきたい (図 4).

Energy Index は上記の適正範囲内であれば，表示されている HFVI は妥当性が担保されている．適正範囲を外れている場合，HFVI が体動や抗コリン薬などの薬剤による影響を受けていると判断され，適正範囲に収まるまで測定を待つことが推奨されている．

現段階では 50≤HFVI≤70 が至適範囲と考えられ，HFVI m<50 で鎮痛薬の増量や追加投与を考慮，HFVI m>70 で鎮痛薬の減量も考慮できると考えられるが，HFVI とその他の状況を基に麻酔科医が鎮痛薬の増減を決定すべきである．

4. 心拍変動解析を用いた臨床研究

心拍変動解析を用いた臨床研究はすでに世界では実施されており，ここでは HFVI と似た原理と考えられている 'Analgesia Nociception Index' (ANI：Mdoloris, フランス) を用いた研究を紹介する．

Upton HD らは腰椎椎間板切除，椎弓切除術において ANI を指標としてオピオイドを投与した場合，対照群と比較して，post-anesthesia care unit (PACU) における痛みの numerical rating scale (NRS) が 1.3 (95%信頼区間, -0.4 to -2.4; p=0.01) 改善したと報告した [4]．急性期の痛みの NRS の臨床的意義のある最小変化量 (minimal clinically important difference：MCID) が 1 であることも考慮すると非常に有意義な知見である．PACU におけるフェンタニル総投与量が 64%削減できたとも報告され，侵害受容モニターの有効性が示唆された．

Sabourdin らは婦人科手術を対象に ANI を指標としてレミフェンタニルを調節すると，対照群と比較して，レミフェンタニルの使用を約 24%節減することが可能であったと報告した [5]．しかし，この研究は，開腹手術，腹腔鏡手術のいずれも含まれた研究であり，結果におけるレミフェンタニル使用量も 4.4 対 5.8 μg/kg/h と通常我々が管理している μg/kg/min と単位が違うことに注意されたい．つまり，群間差の 1.4 μg/kg/h は 0.023 μg/kg/min であり，臨床上意義のある群間差 (数値) かと問われれば，疑問である．術後早期のアウトカムや術後モルヒネ使用量も差は出なかった．その一方，術後 3 ヶ月時点の慢性痛の発生率には 18.8% vs 30.8%と有意差が出ている点は注目に値する．

面白い視点として，抜管直前の ANI と PACU 到着後 10 分以内の痛みの NRS の相関を調査した研究も存在する．Boselli E らは耳鼻咽喉科・整形外科下肢手術を受けた患者 200 名を対象に検討し，統計的に有意な負の相関関係 (ANI=68.1-4.2*NRS, r^2=0.33; p=0.01) が認められた [6]．NRS が 3 以上となる患者を識別するのに ANI=50 を閾値とすると ANI の感度 86%(95%CI: 75-93)，特異度 86%(95%CI: 79-92), 陽性的中率 77%(95%CI: 66-89)，陰性的中率 (95%CI:85-96) であった．

このように ANI の有用性を示唆する文献は多数ある中で，手術中のオピオイド使用量節減が術後のオピオイド使用量節減にまでは至っておらず，痛みの NRS や postoperative nausea and vomit (PONV) などの評価項目を多岐にわたり改善させたという報告は現段階ではない．しかし，術中の侵害受容の強弱などに合わせてオピオイドを調節する moment-to-moment control が有効である可能性があり [7]，より大規模な調査が期待される．

5. 今後の展望

HFVI については，最近発表された総説において，ICU 領域，血行動態の変化予測，緩和ケア，日帰り手術，無痛分娩，区域麻酔の効果判定など今後多岐にわたって使用される可能性が指摘されており，今後の臨床適用に注目したい [8]．

HFVI の登場で，侵害受容と鎮痛のバランスを客観視できようになったことでいわゆる麻酔の三要素の「鎮痛」のモニタリングが可能となると考える．麻酔の三要素を全てモニタリングすることで臨床研究のデザインの質が均一化され，ひいては向上することになるとも考えられる．逆に言えば，侵害受容モニターを使用していない臨床研究に対する評価が低くなる可能性もある．

HFVI を通して可視化された，侵害受容によるストレスを考えながら，新しい視点で患者に有益な麻酔を模索されてみてはいかがだろうか．

謝辞

本稿における HFVI の測定原理に関して資料，情報を提供してくださった平和物産株式会社ならびに同社マーケティング部　上利修平氏へ感謝申し上げます．

引用文献

1. 日本疼痛学会理事会. 改訂版「痛みの定義：IASP」の意義とその日本語訳について．https://jasp.pain-research-jasp.org/pdf /notice_20200818.pdf (2024 年 3 月 9 日閲覧)
2. 日本ペインクリニック学会用語委員会．国際疼痛学会　痛み用語　2011 年版リスト (日本ペインクリニック学会用語委員会翻訳). https://www.jspc.gr.jp/Contents/public/pdf /yogo_itami2011.pdf (2024 年 3 月 9 日閲覧)
3. 石黒芳紀．自動麻酔の治験に参加して-慈恵医大での有用性-. 日臨麻会誌.2021;41:530-4.
4. Upton HD, Ludbrook GL, Wing A, et al. Intraoperative “analgesia nociception index”- guided fentanyl administration during sevoflurane anesthesia in lumbar discectomy and laminectomy: a randomized clinical trial. Anesth Analg. 2017;125:81-90.
5. Sabourdin N, Burey J, Tuffet S, et al. Analgesia nociception index-guided remifentanil versus standard care during propofol anesthesia: a randomized controlled trial. J Clin Med. 2022;11:333.
6. Boselli E, Bouvet L, G Bègou, et al. Prediction of immediate postoperative pain using the analgesia/ nociception index: a prospective observational study. Br J Anaesth.2014;112:715-21.
7. Santa Cruz Mercado LA, Liu R, Bharadwaj KM, et al. Association of Intraoperative Opioid Administration With Postoperative Pain and Opioid Use. JAMA Surg 2023; 158: 854-64.
8. Yoshida K, Obara S, Inoue S. Analgesia nociception index and high frequency variability index: promising indicators of relative parasympathetic tone. J Anesth. 2023;37:130-7.

ランチョンセミナー

術中低血圧と予後
～テクノロジーの活用方法～

内藤 祐介, 川口 昌彦

術中低血圧について我々は何を知っているのか

全身に酸素を供給し代謝物を排除するためには心拍出量の維持が重要である．しかしながら，我々は一部の特殊な症例を除くと心拍出量を連続的にモニタリングすることが困難であるため，血圧を代替指標として用いることが多い．全身麻酔中の血管抵抗は一定でないため，実際には血圧を心拍出量の代替指標として使用するには大きな制限があるものの，血圧低下の一部は心拍出量低下を反映していることから我々は術中低血圧 (Intraoperative Hypotension; IOH) を可能な限り避けるような戦略を採用してきた．一方でどの程度の IOH が患者に負のアウトカムをもたらすかについては現段階でも明らかになっていない部分が多く，臓器障害と低血圧についての数多くの研究が今日に至るまで実施されている．

脳虚血との関連性を示した論文では 48,241 人を対象とした症例対照研究が有名である [1]．脳卒中症例 42 例 (0.09 %) を対照患者 252 例と年齢および手術の種類でマッチさせロジスティック回帰分析を用いて，IOH の持続時間が術後の脳梗塞の発生に及ぼす影響を検討したところ，平均動脈圧 (Mean arterial pressure ; MAP) がベースラインから 30 %以上低下した累積時間は，術後脳梗塞の発生と統計学的に有意な関連を示した．急性腎障害 (Acute Kidney Injury: AKI) および心筋虚血 (MINS: Miocardial Injury after non-cardiac surgery) との関連性を 253,555 件の非心臓手術を対象に検討した後方視的研究では MAP < 65mmHg もしくはベースラインからの 20%低下は MINS, AKI と関連していた [2]．

一方，前述の研究と同様に MINS, AKI をターゲットとした 368,222 件の後方視的検討において術中血圧は低いほど臓器障害と関連があり，MAP < 75mmHg でも臓器障害と関連していることが示されており [3] 研究により導き出されている結論が異なる．また，臓器別ではなく患者の長期予後との関連性を明らかにすることを目的とした研究も多く実施されている．1064 人を術後 1 年にわたりフォローアップした前向き観察研究 [4] では術後 1 年以内の死亡率に影響を与える因子として患者の術前合併症，麻酔時間，収縮期血圧 (systolic blood pressure; SBP) > 80mmHg を関連する因子としてあげている．

このセクションをあえてまとめるのであれば，ベースラインから 10 %以上の血圧低下は脳虚血との関連が指摘されている．MINS, AKI と関連するとされる血圧は MAP > 65mmHg であるが，別の研究では MAP > 75mmHg でも MINS, AKI との関連が見出されており個別化が必要であろう．臓器特異的に考察することなく全体の死亡率との関連を検討した場合は SBP > 80mmHg は死亡率と関連していることが判明している．本稿を執筆するにあたり，上記の論文を導入として引用したが，これらはレビューした論文の一握りでありこの背景には膨大な論文が存在し，それらは時に相反する結果を示している．このように IOH と患者アウトカムについては 1950 年代から盛んに研究されているが，明確なエビデンスが導かれてお

奈良県立医科大学 麻酔科学教室

図 1．AKI と IOH の関連

らず，使用している血圧もカットオフ値も様々で混乱を招いている状況である．

術中低血圧はなぜ複雑なのか

IOH 研究において相反する結果が得られる一因に研究手法が挙げられると筆者は考える．図 1 には例として AKI をアウトカムとして IOH との関連性を検討する場合に考慮すべき因子について記載した．まずは研究対象者を選択するが，AKI の発生メカニズムは心臓手術と非心臓手術で異なるため，いずれかに大別される．非心臓手術の場合でも，腹部外科など術式によらず対象を選定することも可能であるし，クリニカルクエッションによっては腹腔鏡手術，食道手術，結腸切除術など特定の術式を抽出することもある．術式で層別化しない場合は，高齢者，妊婦，高血圧症患者など患者の特徴から対象者を選択する．

患者の選定の次に必要なのがアウトカムの定義である．AKI の臨床的な診断指標には RIFLE や KDIGO 分類などが存在するため，これらを用いてもよい．血清クレアチニン値や糸球体濾過量は入院前後で一般的に測定される項目であるため，後ろ向き研究などで使用されることが多い．その他の候補としては NGAL, L-FABP など特殊な生化学検査，グローバルアウトカムとして腎代替療法が必要となった割合など多くの定義が可能である．

ここまでは IOH に限らずに臨床研究を行う上で発生しうるバリエーションになるが，IOH 研究の場合，ここに低血圧の定義が加わることとなる．まず, IOH の定義として SBP を用いるのか, MAP を用いるのかの検討が必要となる．その後，IOH を絶対値で評価するのか (例：SBP > 80mmHg など)，ベースラインからの相対的低下で定義するのかも検討すべき課題である．次に IOH の定義を満たした場合，低血圧の持続時間を合算するのか，低血圧の中でも最低値を採用するのか，イベントの頻度でカウントするのかなど集計方法を考慮する．一部の研究ではこのような複雑性を避けるため，合計輸液量や使用した昇圧薬の使用量などを代替指標として用いている研究もある．これらの患者組入基準，アウトカムの定義，術中低血圧の統計学的な処理方法を組み合わせると同じような研究が無数にできることとなる．

IOH の定義

IOH の定義が様々な方法で可能であることについて述べた．これらの定義は時として複合して使用 (SBP > 80mmHg もしくは MAP < 55mmHg など) されいる．実際に IOH の定義について文献レビューを行なった論文が存在する [5]．同報告で

表 1

Criteria	(%)
Decrease in SBP > 20% from baseline	12.9
SBP < 100 mmHg or > 30% decrease from baseline	7.9
SBP < 80 mmHg	7.1
SBP < 100 mmHg or > 20% decrease from baseline	5.7
SBP < 90 mmHg or > 30% decrease from baseline	5.7

は Anesthsiology, Anesthesia and Analgesia, Anesthesia, British Journal of Anesthesia の 4 つの雑誌において 2000 年から 2006 年の間に掲載された IOH に関する論文を調査している．対象となった論文は 140 編存在し，その中で 130 の IOH の定義が存在していた．表 1 には代表的な 5 つの IOH の定義について記載した．この研究結果によると上位 5 つの定義を足し合わせても 40%にも満たない．言い換えるのであれば多くの研究者は独自で考案した方法で IOH を定義し，それを用いて解析していることになる．中には同じ著者らが別の研究では別の指標を用いて発表するなども行われており，科学的妥当性の検証が必要な状況である．

科学的フェアな IOH の定義とは

近年，IOH の定義を統一した統計学的処理方法について検討されている．その中でも IOH を時間積分値で評価するという試みが多くの論文で採用されつつある．図 2 には時間積分値の概念を掲載した．時間積分値で評価することにより頻度や最大低下度合い，持続時間といった集計方法の問題を吸収可能である．一方で指標となる指標を SBP, MAP のいずれにするのか，カットオフ値をどうするのかなどの問題は解決していない．また，評価時間に応じて時間積分値は増加する傾向にあるため麻酔時間などで標準化が必要であるが，その方法が現在のところ定められていないなど今後に向けた課題も存在するが少なくとも現段

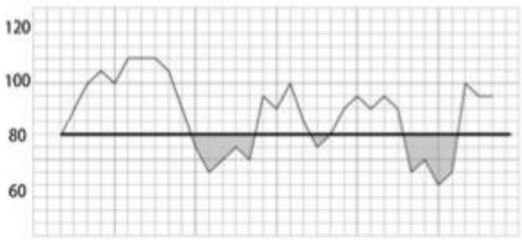

図 2．術中低血圧の時間積分値評価法

階では最も妥当性の高い方法として IOH 研究での採用が増加している．我々の研究グループでは時間積分値を算出する独自のプログラムを開発し，いくつかの報告を行なっている [6]．近年，A-Line から得られた圧波形を元に MAP > 65mmHg の時間積分値をオフライン解析可能な商用プログラムも販売され今後も本法による解析は増加するものと思われる．

IOH が減らない原因 そもそも IOH は治療対象であるか

前セクションにおいて IOH と臓器障害が関連していることについて言及したが，IOH が患者の予後を悪化させるかどうかは議論が必要である．その最大の理由は多くの論文は後方視的研究であるため，因果関係が証明できないという点である．すなわち IOH が発生したことによりアウトカムが悪化したのか，元々アウトカムが悪化する素因がある患者が IOH の頻度が高いのかが研究手法上明らかにすることができない．例えば Sessler らは吸入麻酔薬濃度低値 (Low MAC), Bispectrum Index 低値 (Low BIS), 平均動脈圧低値 (Low MAP) の 3 つの条件を同時に満たす症例 (triple low) は入院期間が延長し，死亡率が高いことを後方視的研究において報告した [7]．別の研究グループらによる後方視的研究においても概ね同様の結果が得られるものの，前向き研究として Triple Low を回避する戦略を採用したプロトコールは患者のアウトカム改善に寄与しなかった [8]．一方で数が少ないながらも Randomized Controlled Study (RCT) により術中低血圧が患者のアウトカムを悪化させ

るとするエビデンスも存在する．298 人の患者を対象とした RCT で Intervention Group の患者は収縮期血圧がベースラインの 10%以内の低下に抑えられるようノルアドレナリンを必ず持続投与するプロトコールを採用したところ，術後の臓器障害が減少したことを報告している [9]．

診断から治療までのタイムラグ

IOH が減少しない理由を考察する上で非侵襲的連続的血圧モニタリングを実施した研究を紹介する [10]．この研究では非侵襲的連続的血圧測定技術 (クリアサイト®) を用いて IOH の発生率について検討を行っている．Control 群ではマンシェットによる血圧測定の結果のみ提示されるのに対して，Intervention Group では連続的にモニタリングされている値を提示した．その結果，IOH は Control 群の方が多かった．この結果から，血圧が非連続的にしか測定されていないことが IOH の診断の遅れにつながっていることが示唆された．この研究では興味深いことに Intervention 群においても IOH は存在していた．我々は血圧のトレンドなどを参考にし，治療が必要な IOH が発生すると判断してから昇圧薬を投与するが実際に薬効が発現するまでにはタイムラグがあり IOH を完全に予防し得ていないことが考察されている．

術中低血圧とテクノロジー

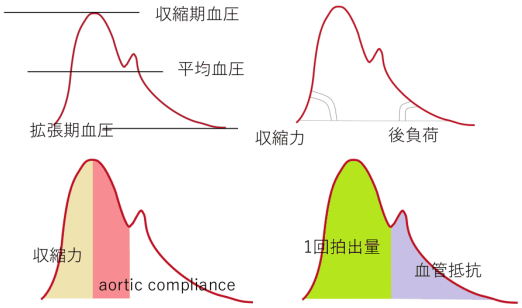

図 3．A-Line 波形から得られる特徴量

機械学習と Hypotension Prediction Index

現段階では血圧のトレンドなどから我々が IOH に陥ると判断し治療を開始してもタイムラグにより IOH がなくならないことを解説した．それでは我々が臨床的に予測しうるよりもより早期に低血圧を予測することはできないのだろうか?このような取り組みは機械学習の黎明期である 2010 年ごろより活発に行われている．低血圧を予測するアルゴリズムが多く提唱されているが，様々なアルゴリズムの中で最も使用されている特徴量 (機械学習モデルの説明変数) に A-Line 波形が挙げられる．A-Line 波形からは収縮期血圧，平均動脈圧，拡張期血圧といった普段我々がモニターで観察している項目以外にも，後負荷，1 回拍出量，前負荷などを推測可能である (図 3)．

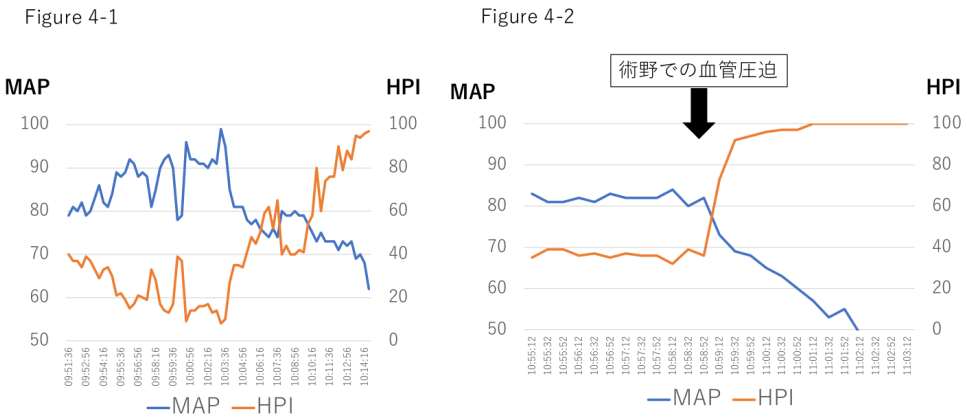

図 4．HPI と MAP の関係性

近年，この A-Line 波形から得られる特徴量を用いて IOH を予測するツールとして Hypotension Prediction Index (HPI) が商用利用可能となった[11]．HPI は無単位の指数であり低血圧イベントが起こる可能性を 0-100 の数値として算出する．0 が 15 分以内に低血圧になる確率がほぼ 0 であるのに対して HPI 100 はすでに低血圧であることを示している．ちなみに HPI で定義している術中低血圧は MAP > 65mmHg であり，それ以外 (収縮期血圧や MAP > 55mmHg など) は予測できない．自験例 1(図 4-1) は時間にして約 20 分の平均動脈圧と HPI の変化について記述したものである．MAP が上昇トレンドの際は HPI は低下していき，逆に MAP が下行しているときは HPI が上昇しており，MAP と HPI は鏡像のような関係となっている．そのため，MAP のトレンドさえ注意深く観察すれば HPI を参照しなくても IOH を予測可能とも解釈可能である．しかしこの Clinical Question に関しては 2020 年に出版された研究によれば否定的である[12]．この中で著者らは 2 施設における 292,025 セットの血圧データおよびその時点での HPI, CO, SV, SVV, Δ MAP, PP, HR, Shock Index を用いてどの指標がその後の術中低血圧を最もよく予測するかについて検討している．その結果，HPI はそのほかのどの臨床的指標よりも高い精度で低血圧を予測することが示されている．これは前述のとおり HPI は A-Line 波形を元に多くの特徴量から算出される値であり SVV や CO など単一の指標も内包しているためであると考察されている．

HPI の限界

IOH を予測するうえで強力なツールである可能性を秘めている HPI であるが，限界も存在する．低血圧イベントは機械学習によってそのモデルが作成されているが，モデル作成時に含まれたデータは気腹による影響，肝授動，血管クランプ・デクランプなどによる変動を学習させていない．そのため，外的要因が加わって発生する低血圧を予測することは困難である．図はロボット支援下食堂切除術を実施中に IVC を外科医が圧迫したときの MAP と HPI の推移について示している．この場合は MAP が先に低下しはじめ，HPI がその後，遅れて上昇していることが見て取れる．そのため，現段階では麻酔薬による血管拡張など内的要因による低血圧を最も反映しやすいモデルであるといえる．そのほかの注意点として，安定して HPI が計測できるようになるまで約 10 分のデータ収集が必要であることが挙げられる．

麻酔導入中など測定開始直後に表示される HPI 値は参考値となることに留意すべきである．A-Line をあらかじめ挿入し 10 分間データを収集したのちに麻酔導入した場合にどのような予測精度になるかについては興味深いところであるが，現在のところその Clinical Question を解決する研究は存在しない．また予測可能な低血圧は MAP > 65mmHg のみであり収縮期血圧や MAP > 55mmHg などは予測できない．そのため，小児など MAP 65mmHg 以外が循環維持のターゲットとなるようなシチュエーションでは使用が困難である．最後に HPI は麻酔中の低血圧を予測するモデルである．そのため，術中に使用してそのまま ICU に帰室する場合においても ICU では使用しないように推奨されている．

テクノロジーの使用上の注意点

HPI を例としてテクノロジーが IOH を低下させる可能性について触れた．機械学習などの新しいテクノロジーは有効に活用すれば非常に強力なツールであるものの，一定の注意が必要である．本稿の最後のセクションでは現在，我々が実施中の術後機能障害発生に関する前向き観察研究を例に解説する．

本学では 2016 年より非心臓手術を受ける 55 歳以上の患者を対象とした機能障害発生の有無に関するコホート研究を実施している．1 年後の機能障害に影響を与える因子を解析したところ年齢，BMI > 30，Cerebral vascular disease，糖尿病，悪

表 2 Confusion Matrix for random forest model

		Reference	
		0	1
Prediction	0	2075	221
	1	0	0

性腫瘍, 閉塞性呼吸器疾患, ステロイドの内服, 血清アルブミン値, 血清クレアチニン値, 低栄養, 術中出血量などが機能障害と関連する因子であった[13]．我々はこの結果を発展させ, 5 年後の機能障害を予測する機械学習モデルの構築に現在挑戦中である．機械学習にはさまざまなモデルが存在するが, その中から Support Vector Machine, Random Forest, Logistic Regression, Neural Network などを現在試験的に検証中である．その中で，Random Forest を用いてモデルの確立を試みたところ，Accuracy : 0.90 (95% CI : 0.89 - 0.92) という結果が得られた．この結果のみ提供されると一見，高い精度で予後予測ができているように感じる．しかし，Confusion Matrix を参照しモデルを確認すると True Positive が予測できていないことがわかる (表 2)．すなわち 10%前後の機能障害がある患者を無視しどのような条件を与えられてもすべて陰性と割り振るモデルが一番精度が高いと判断されている．極端な例として精度の問題を挙げたが，その他にも Imbalanced Data の取り扱い方法，特徴量の標準化，過学習に対する対応などモデル作成時には多くの検討すべき課題が存在する．R や Python を用いて学習させるだけであれば比較的簡単にモデルの作成ができるものの，作成されたモデルの妥当性を評価可能な人材が今後必要となってくると思われる．また，機械学習で作成されたモデルは与えた特徴量がどのように活用されたか外部から判断しづらい．機械学習モデルによって得られた結果と我々の臨床的な判断の間に乖離がある場合，どのように折り合いをつけるのかも今後の課題であると考える．

結　語

術中低血圧は患者の予後悪化と関連している．新しいテクノロジーにより低血圧を予防可能であることが示唆される．今後, 機械学習や AI などを応用した臨床応用が期待されるが評価できる人材の育成が必要であると思われる．

引用文献

1. Bijker JB, Persoon S, Peelen LM, Moons KG, Kalkman CJ, Kappelle LJ, van Klei WA: Intraoperative hypotension and perioperative ischemic stroke after general surgery: a nested case-control study. Anesthesiology 2012, 116(3):658-664.
2. Salmasi V, Maheshwari K, Yang D, Mascha EJ, Singh A, Sessler DI, Kurz A: Relationship between Intraoperative Hypotension, Defined by Either Reduction from Baseline or Absolute Thresholds, and Acute Kidney and Myocardial Injury after Noncardiac Surgery: A Retrospective Cohort Analysis. Anesthesiology 2017, 126(1):47-65.
3. Gregory A, Stapelfeldt WH, Khanna AK, Smischney NJ, Boero IJ, Chen Q, Stevens M, Shaw AD: Intraoperative Hypotension Is Associated With Adverse Clinical Outcomes After Noncardiac Surgery. Anesth Analg 2021, 132(6):1654-1665.
4. Monk TG, Saini V, Weldon BC, Sigl JC: Anesthetic management and one-year mortality after noncardiac surgery. Anesth Analg 2005, 100(1):4-10.
5. Bijker JB, van Klei WA, Kappen TH, van Wolfswinkel L, Moons KG, Kalkman CJ: Incidence of intraoperative hypotension as a function of the chosen definition: literature definitions applied to a retrospective cohort using automated data collection. Anesthesiology 2007, 107(2):213-220.
6. Nakatani H, Naito Y, Ida M, Sato M, Okamoto N, Nishiwada T, Kawaguchi M: Association between intraoperative hypotension and postoperative nausea and vomiting: a retrospective analysis of 247 thyroidectomy cases. Braz J Anesthesiol 2023, 73(5):635-640.
7. Sessler DI, Sigl JC, Kelley SD, Chamoun NG, Manberg PJ, Saager L, Kurz A, Greenwald S: Hospital stay and mortality are increased in patients having a ”triple low” of low blood pressure, low bispectral index, and low minimum alveolar concentration of volatile anesthesia. Anesthesiology 2012, 116(6):1195-1203.
8. Sessler DI, Turan A, Stapelfeldt WH, Mascha

EJ, Yang D, Farag E, Cywinski J, Vlah C, Kopyeva T, Keebler AL et al: Triple-low Alerts Do Not Reduce Mortality: A Real-time Randomized Trial. Anesthesiology 2019, 130(1):72-82.
9. Futier E, Lefrant JY, Guinot PG, Godet T, Lorne E, Cuvillon P, Bertran S, Leone M, Pastene B, Piriou V et al: Effect of Individualized vs Standard Blood Pressure Management Strategies on Postoperative Organ Dysfunction Among High-Risk Patients Undergoing Major Surgery: A Randomized Clinical Trial. Jama 2017, 318(14):1346-1357.
10. Maheshwari K, Khanna S, Bajracharya GR, Makarova N, Riter Q, Raza S, Cywinski JB, Argalious M, Kurz A, Sessler DI: A Randomized Trial of Continuous Noninvasive Blood Pressure Monitoring During Noncardiac Surgery. Anesth Analg 2018, 127(2):424-431.
11. Hatib F, Jian Z, Buddi S, Lee C, Settels J, Sibert K, Rinehart J, Cannesson M: Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis. Anesthesiology 2018, 129(4):663-674.
12. Davies SJ, Vistisen ST, Jian Z, Hatib F, Scheeren TWL: Ability of an Arterial Waveform Analysis-Derived Hypotension Prediction Index to Predict Future Hypotensive Events in Surgical Patients. Anesth Analg 2020, 130(2):352-359.
13. Ida M, Naito Y, Tanaka Y, Inoue S, Kawaguchi M: Factors associated with functional disability or mortality after elective noncardiac surgery: a prospective cohort study. Can J Anaesth 2022, 69(6):704-714.

Correspondence to:
奈良県立医科大学　麻酔科学教室
奈良県橿原市四条町 840
TEL: 0744-22-3051
FAX: 0744-23-9741
内藤祐介 (naito623@naramed-u.ac.jp)

周術期における運用の現状課題と IT ソリューションの現状

米澤　亮

1. はじめに

当社の IT 事業は医療機関向けに画像系 IT(PACS や 3D の生成や手術シミュレーションに用いられる画像診断ワークステーション，AI 技術を活用して設計した画像診断支援)，基幹系 IT(医療データを統合し参照する仕組みや文書管理システム) そして部門系 IT(生理検査や内視鏡部門，手術用部門システムや重症部門システム等) を中心として多種多様なシステムを導入している．これらのシステムは単体で動作するが，それぞれのシステムを連携させることで各診療フェーズでの運用が効率化されることや，医療の質や安全性の向上に寄与することも少なくない．今回は手術 IT をテーマに当社システムだけではなく他社システムも取り上げつつ各システムの連携を実現することで周術期における各フェーズでいかに効率的なシステムを構築することができるかを検討してみた．今後の手術室 IT 化を検討する際に参考に少しでも寄与できれば幸甚である．

2. 周術期における課題

全国の医療機関に訪問した際によく伺う周術期における運用の課題を術前・術中・術後のフェーズにわけ整理した．

1) 術　前

- 術前外来や術前問診を行う際のチェックリスト運用が複雑且つ抜け漏れが発生してしまい手術スケジュールに影響を与えてしまう．
- 術前カンファレンスにおけるデータ収集の非効率．
- 手術スケジュール管理の効率化とズレの防止が困難．

2) 術　中

- 正確な麻酔記録や看護記録の作成および神経ブロックエコーのエビデンス管理．
- 会計取り漏れの防止．
- 映像による手術の録画運用．

3) 術　後

- 手術室退室から ICU 入室におけるデータ連携．
- 術後疼痛管理など術後に発生する手術起因の加算取り漏れの防止．

以上の課題を IT の力を使ってどのように有用な解決提案を行うことができるかが悩みどころとなっている．

3. 術前における課題解決

3 - 1. 術前チェックリスト

術前チェックリストは紙を使って多職種のメンバーが一人の患者にアクセスし実施するケースがある．紙を使う場合，多職種間での共有が困難となり，ある患者に「同じ質問」が重複することや「抜けが発生」するケースが想定しうる．最終的に誰かがまとめたチェックリストを手術室看護師が入室前に確認するなどが運用上あるが，このタイミングで抜け・漏れが発生したり電子カルテとの突合などに手間がかかったりすることで入室の遅延が起こるといった課題があげられる．

当社では CITA という情報の集中管理，一括閲覧が可能なシステムがあるがそのオプション機能であるクリニカルフローを利用することで電子カルテや文書システム，部門システムの情報をまとめて表示，さらに必要な文書の有無などがわかるチェックリストにすることができる (図 1)．

富士フイルム メディカル IT ソリューションズ

図 1. CITA での術前チェックリスト事例

図 2. CITA のチェックリスト運用における効率化の事例

図 3．統合閲覧システムを利用した各データの統合参照．

レイアウトは診療科やシーンでデフォルトをセットすることができる．

本画面は多職種間で供覧でき，二重質問を無くし，抜け漏れを防ぐことができる．手術室看護師も本画面を供覧できるため入室時のチェックについても効率的に行うことができる (図 2).

3 - 2．術前カンファレンスや術前外来

術前カンファレンスや術前外来では各患者の症例に合わせ，CT やエコー，胸部画像やカルテ記事，心電図やスパイロなどの生理検査，血液検査結果，内視鏡データなど様々なデータを参照している．その際，カルテから 1 件 1 件様々な部門システムを開く必要などがあり煩雑となる．統合的な診療データ閲覧システム (当社では CITA) が導入されている環境では電子カルテや各部門システムと連携しており様々なデータの最新データを一度に閲覧することができ，効率的なデータ参照が可能となる (図 3)．さらに AI 技術を用いて開発された画像システムを用い，統合閲覧システムで表示された胸部撮影データを利用し，気胸や肺浸潤などをサジェストすることができる．術前外来では各検査やこのサジェストを元に患者に説明を行い，その場で統合閲覧システムから文書システムを起動し同意書の記入をお願いする．といった運用も可能となる．

一般撮影データからシステムを起動し気胸や肺浸潤などの見つけ出し支援などを行うこともできるシステムもある (当社 CXR-AID).

3 - 3．手術スケジュール管理

多くの施設で伺うのは手術スケジュール管理問題である．予定時間と実施時間の乖離が内容としては多く，術式別の乖離データの集積やその原因分析が手術部門システムのトレンドとなっている．このフェーズではリアルタイムなズレ時間の把握

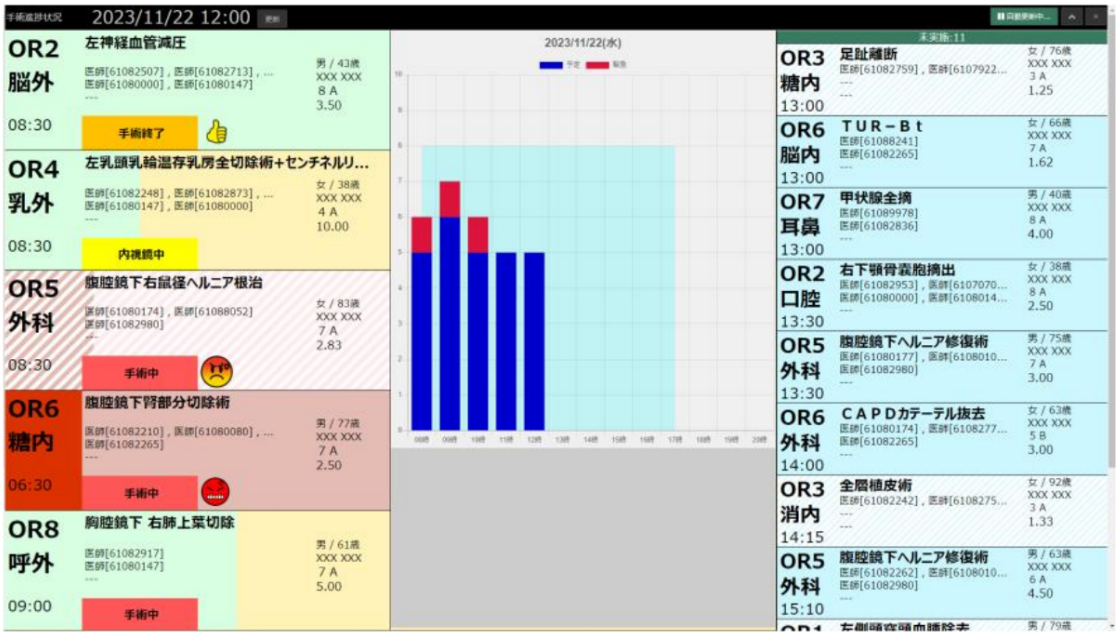

図 4. 国立病院機構呉医療センター様麻酔科医控室の大型モニタに表示されたリアルタイムスケジュール画面

やズレを把握するためのシステム設計が重要となる．手術部門システムの中には予定時間に対しての実施時間のズレを計算し，管理画面上に状況を表示することができるものもある．当社の Prescient では手術予定時間の 90%～100%で「いいねマーク」，予定時間から 120%乖離した段階で「怒りマーク」，200%を超えると「激おこマーク」というマーク (名称は通称) で示すことができるようになっている (図 4)．マークについては機能的に OFF にすることができ，色のみで表すことが可能である．こうしたデータの蓄積から正確な予定時間を把握，院内に共有，スケジューリングに反映し，予定通り手術室が運営できるようにするといったことが重要と考える．また手術予定時間については麻酔導入時間と手術時間を明確にわけられるよう設計し，さらに時間の入力インターフェースも「半角：分」で統一するなど事前に設計していることが重要と考える．

3 - 4. 術前におけるシステム連携案

ここまで述べてきた術前におけるシステム設計を連携図として記載した (図 5)．このように術前における様々な運用は基幹システムや PACS，手術部門を中心とした各部門システムと連携することで効率性を上げることが可能と思われる．

4. 術　中

4 - 1．正確な麻酔記録や看護記録

術中における正確な記録は重要である．現在様々な医療機関で麻酔記録システムは生体モニタや麻酔器，シリンジポンプやスマートポンプ，血液ガス分析装置などと連携され正確なデータをリアルタイムに取ることができる．レコピックのような手術で利用した材料を読み取るセンサーを内包した製品と連携することで取り漏れに関しても防ぐことができるようになっている．現在様々な医療機関のシステム導入に関わっているが，神経ブロックエコーの画像管理に関しては PACS など

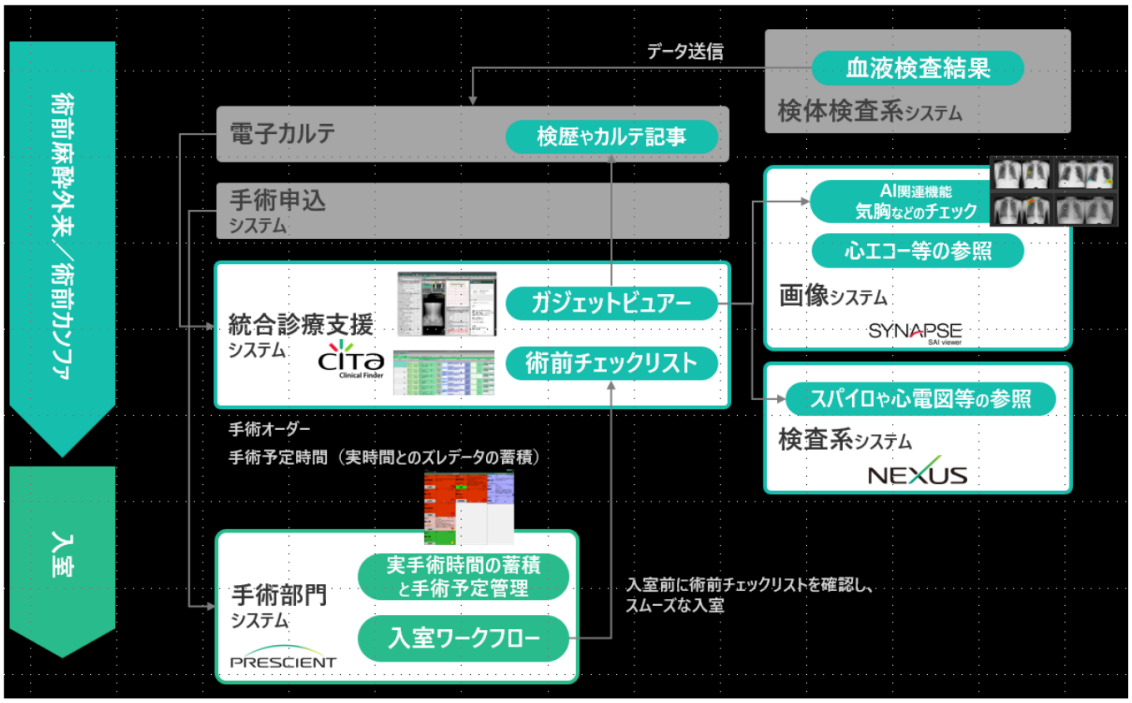

図 5．術前におけるシステムとシステム連携図

に保存されている施設が少ないように感じている．神経ブロックエコーは検査ではないため，電子カルテから検査オーダーをたてて RIS や PACS とデータ連携をするようなスキームにはなっていない．また，用途としても診断ではなく手技の補助であるため PACS に保存したとしても運用性が無いのではないかと思われる．Prescient で昨今，神経ブロック画像を麻酔記録上に残す取り組みをはじめている．麻酔記録上にあることで訴訟対策にも用いることが容易になる．

4 - 2．術中の映像管理

術中における記録はバイタルデータやイベントなどの記録だけではなく手技そのものの術野動画データや手術室内のスタッフの動きなどを記録する術場動画データの保存なども挙げられる．現在では多くの医療機関で術中映像の管理が行われている．その中でも近年課題になるのはデータの保存領域の確保と，撮影漏れの防止ではないかと考える．データ保存領域は近年では「研究・教育用」の高画質データと「医療安全対策用」の圧縮データにわけて管理することが多い．前者は 3 か月程度，後者は 3 年程度の期間保存している施設が多くある．これは診療科別の手術件数などでも異なるため院内で各診療科との調整が必要となる．撮り漏れ防止に関しては，麻酔記録システムと連携することが一般的になっている．麻酔記録上の手術開始をクリックした際に高画質での動画撮影が開始され，手術終了をクリックした際に停止する

といった運用である．麻酔記録の操作は確実に行われるため，個別に映像システムを操作する状況に比べ撮り漏れ防止対策となる．またシステム連携をすることで映像システムにも術式や患者情報を送り，誤った患者の動画データが作成されないような配慮もすることができる．

4 - 3．術中におけるシステム連携案

ここまで述べてきた術前におけるシステム設計を連携図として記載した (図 6)．

術中においては主にエビデンス管理が重要に

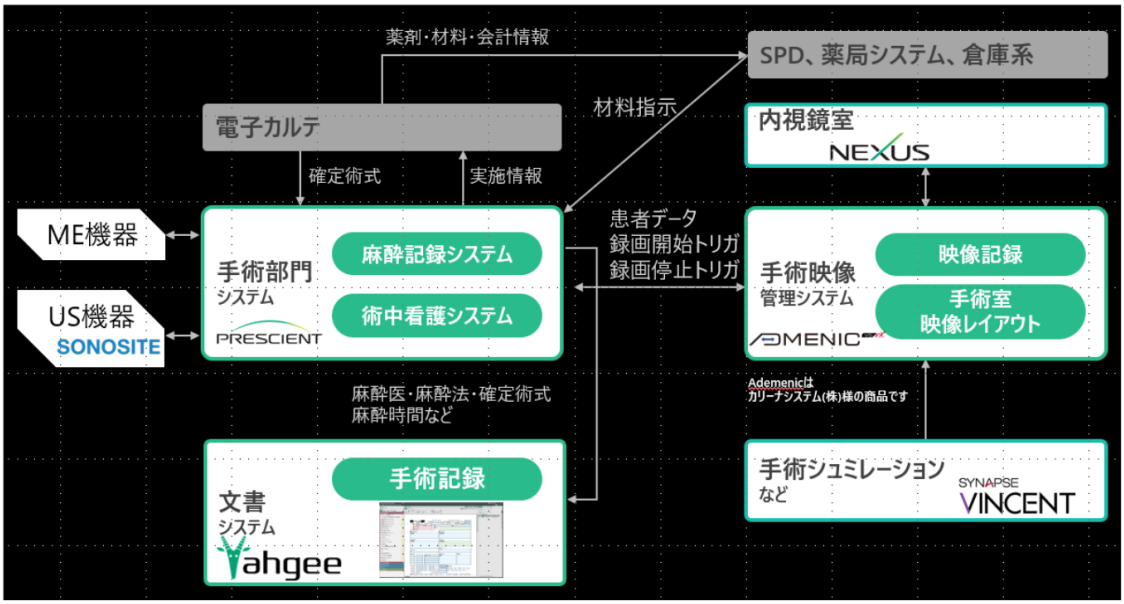

図 6. 術前におけるシステムとシステム連携図

なっている．神経ブロックエコーの麻酔記録への取込や，手術映像システムとの連携などでより確実なエビデンス管理が可能となる．また内視鏡室においても ESD などの手術が行われることが多くなっており，手術室以外で発生する手術の動画記録も統合管理できると良いのではないかと考える．

5. 術　後

5 - 1. 術後から ICU 入室の際のデータ連携

手術終了後に ICU に入室される際，データ連携を望まれることも多い．ICU は電子カルテシステムで管理されている施設も多く，その際は実現が難しいが，ICU 部門システムが導入されている際は，術式・薬剤・術中偶発症・術前の ASAPS といった項目を連携したいという声が大きい．

また，手術オーダー番号が連携されているとどの手術に対しての入床か　といったデータ活用ができるため，必要性について今後検討していきたいと考えている．

5 - 2. 術後疼痛管理チーム加算の取り漏れ防止

2022 年度に新設された術後疼痛管理加算に関して取りづらいといったことを最近では伺うことが多い．全身麻酔後で，硬膜外麻酔や神経ブロックで局所麻酔薬の持続注入または麻薬持続静注 (IV-PCA など) 中の患者という分母に対して，麻酔開始・看護師・薬剤師がチームとして動き，術後疼痛管理指示の策定から 3 日間の評価表の記載を行うことが必要となる．ここでは術前チェックリストとして活躍した CITA のような統合管理システムと文書システム・麻酔記録システムとを連携させることで少しでも業務の改善を支援できないかと考えている．

まずは対象患者を麻酔記録システムと連携したデータをもとに絞り込み一覧リスト化する．右側には術後疼痛管理指示書と評価表を 3 日分並べる．チームメンバーは未入力の書類をクリックすることで文書システムが起動し対象患者の文書を作成することができる．評価表はチームメンバーのサインをもって確定し，入力済か未入力かを簡単に判別することができる (図 7).

図 7 術後疼痛管理チーム加算の管理画面運用事例

5 - 3．術前～術後まで周術期全体でのシステム連携案

各章にわたって述べてきたシステム連携を下図にまとめる．各システムと連携することで術前から術後までを通したシステムの効率化やエビデンスの適切な管理が可能となるのではないかと考える．

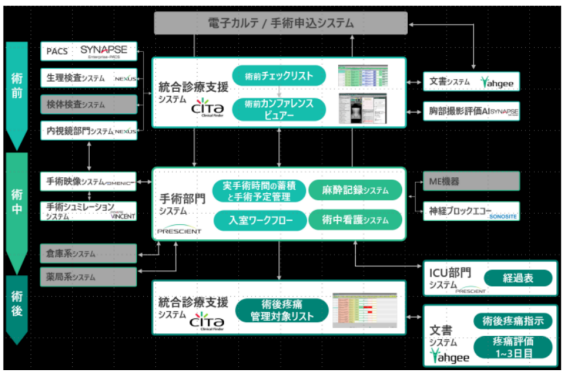

周術期全体のシステム連携図

6．さいごに

手術室 IT に関しては単体でのシステム構築によるエビデンスの適切な管理や運用改善ももちろん可能ではあるが，最終的なイメージを持ち様々な関係システムと連携することでより効率的で，より正確なエビデンス管理が可能になると考える．本敲が IT 化の検討が必要な際，少しでも役立てば幸いである．

参考文献

1. 東京慈恵会医科大学附属第三病院, 麻酔科, ハシチウォヴィッチトマシュ先生 富士フイルムメディカル WEB セミナー 2022 統合診療支援システム CITA を用いて入室時の患者情報確認から周術期の全患者フローに適応できる CITA 基板の情報管理システムへ
2. 国立病院機構呉医療センター 麻酔記録システム Prescient OR リアルタイムスケジュール画面
3. 社会医療法人雪の聖母会 聖マリア病院様 CITA による術後疼痛管理チーム加算取得支援画面

AneXam-GPT 構築：麻酔科専門医認定筆記試験を ChatGPT が解く！

佐和 貞治

はじめに

ChatGPT (Chat Generative Pre-trained Transformer)[1] は，OpenAI 社 [2] が 2022 年 11 月に公開したチャット生成人工知能 (生成 AI) である．2020 年に発表された GPT-3 に続いて，2023 年 3 月には新モデル GTP-4 が公開された．実際に GPT-4 がアメリカの司法試験で上位 10 %に入る成績を叩き出して話題となり，その性能向上が注目されている [3]．今回，麻酔科専門医認定筆記試験 FileMakerPro データベースに，OpenAI-API を利用して Chat-GPT が解説付き解答をする機能を追加した AneXam-GPT を作成し，麻酔科専門医認定筆記試験 (第 61 回 2022 年度) を受験させてみた [4]．

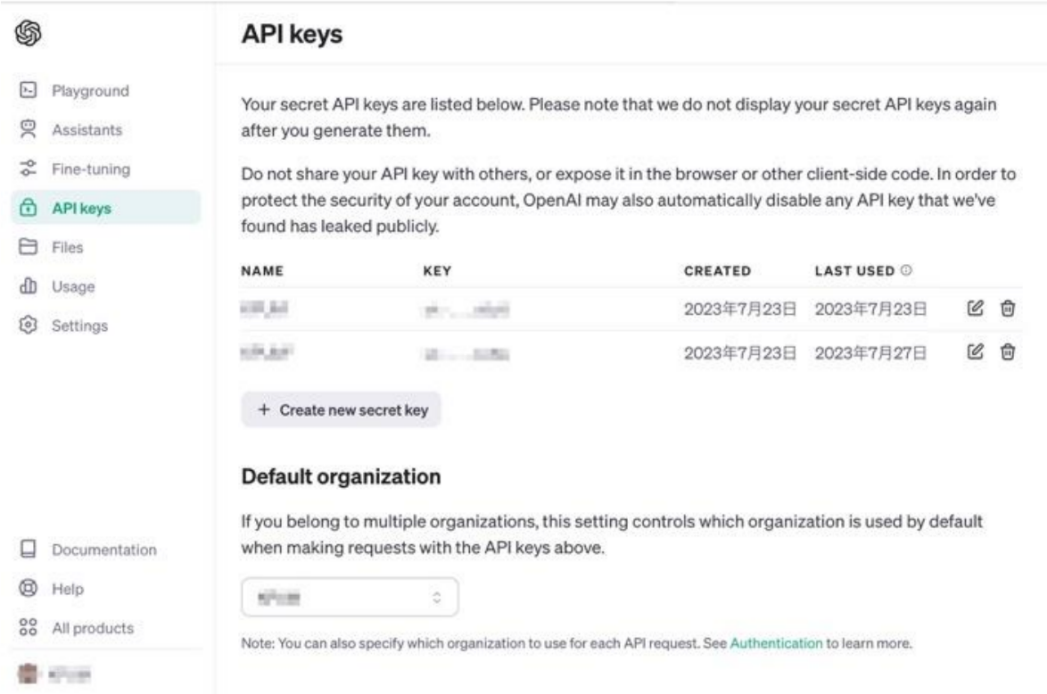

図 1. OpenAI 社ウェブサイトから API Key の取得

1. OpenAI API キー

ChatGPT は，GPT(Generative Pre-trained Transformer) というモデルを基にしており，無料版として GPT-3.5 が利用できる．執筆時点での最新バージョンは GPT-4 で，現在，この GPT-4 を利用する場合は有料サービス (月額$20) の ChatGPT Plus に登録する必要がある．Chat-GPT へのアプリケーションソフトウェアやプログラミングからのアクセスは，OpenAI 社の有料

京都府立医科大学附属病院

図 2．Chat-GPT で解説付き解答をする専門医認定筆記試験データベース AneXam-GPT

サービスである ChatGPT Plus による OpenAI Application Programming Interface (API) 機能の利用を介して行われる [4]．ちなみに API とは，プログラムやアプリケーションが外部のサービスとやり取りするためのインターフェースであり，OpenAI API を利用すれば，テキスト生成や自然言語処理のタスクを行うためのツールセットがユーザに提供される．OpenAI のウェブサイト (https://platform.openai.com) から有料サービスを購入し，API キーを事前に取得する (図 1)[4]．

2．FileMakerPro データベース (AneXam) への ChatGPT 機能の組み込み

過去の筆記試験問題を収めた試験問題 SQL データベースより，データベース管理ソフトウェアである FileMakerPro(Claris International Inc., Santa Clara, CA, USA) にデータ移管させたデータベース AneXam を過去に作成していたが，今回，その機能に ChatGPT に問題を解かせる機能を追加した AneXam-GPT を作成した (図 2)．FileMakerPro では，スクリプト機能を用いて，OpenAI の API を呼び出して，設問フィールドの内容を URL に送り込んで，ChatGPT からの解答を得て，解答フィールドに表示させる (図 3)．

この作業を Chat-GPT ボタンをクリックすれば自動で行うためには，アクセスサイト URL，ChatGPT 使用モデルの指定情報とともに，FileMakerPro で設定入力画面を作成し，変数フィールド api_key, url, model に入力できるようにしておく (図 4)．なお，ChatGPT 設定時点では，有料モデルで 0.5 ドル以上使用しないと API key を通じた GPT-4 の利用はできない．

3．ChatGPT による解答と正解率：GPT モデル毎の比較

OpenAI 社は GPT-3，GPT-3.5 の上位モデル

```
1  # 途中の履歴を保持してChatGPT APIを呼び出す
2
3  # API接続情報
4  変数を設定 [ $api_key ; 値: Setting::api_key ]
5  変数を設定 [ $url ; 値: Setting::url ]
6  変数を設定 [ $model ; 値: Setting::model ]
7
8  If [ IsEmpty ( Moodle2FMP2::chat_text ) ]
9      現在のスクリプト終了 [ テキスト結果: ]
10 End If
11
12 # メッセージ構成
13 変数を設定 [ $messages ;
   値: JSONSetElement ( $messages ; [ "[0].role" ; "user" ; JSONString ]; [ "[0].content" ; Moodle2FMP2::chat_text; JSONString ] ) ]
14 フィールド設定 [Moodle2FMP2::messages ;$messages ]
15
16 # リクエストJSON
17 変数を設定 [ $json ; 値: JSONSetElement ( $json ; [ "model" ; $model ; JSONString ]; [ "messages" ; $messages ; JSONRaw ] ) ]
18
19 # API呼び出し
20 URL から挿入 [ 選択 ; ダイアログあり: オフ ;Moodle2FMP2::result_json ; $url ; cURL オプション:
   "-H \"Content-Type: application/json\" -H \"Authorization: Bearer " & $api_key & "\" -d @$json" ]
21 変数を設定 [ $result ; 値: Moodle2FMP2::result_json ]
22
23 ポータル内の行へ移動 [ 選択: オン ; 最後の ]
24 フィールド設定 [Moodle2FMP2::output_text ;Trim ( JSONGetElement ( $result ; "choices[0].message.content" ) ) ]
25 ブラウズモードに切り替え [ 一時停止: オフ ]
26 現在のスクリプト終了 [ テキスト結果: ]
```

図 3. FileMakerPro での OpenAI API による ChatGPT 自動呼び出しスクリプト

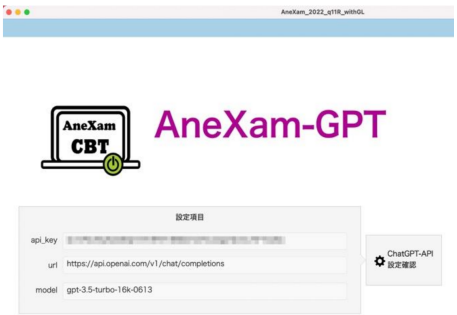

図 4. OpenAI API キーの登録と，ChatGPT URL とモデルの指定

である GPT-4 を 2023 年 3 月 14 日に公開した．GPT-4 は GPT-3.5 よりも遥かに創造的で信頼性が高く，より細かい指示に対応できるとしている．GPT-4 は，GPT-3 や GPT-3.5 に比べて出力精度が高く，誤字脱字が大幅に減ったのはもちろんのこと，複数の指示を含む応用的なプロンプトの意

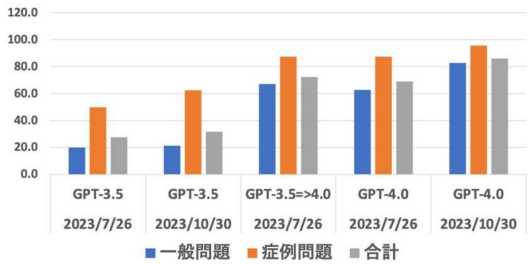

図 5. ChatGPT モデルと正解率

図にも対応できるようになった．当初，GPT-4 は GPT-3.5 同様，学習済みのデータが 2021 年 9 月までのものが使われていたが，2023 年 10 月下旬に GPT-4 がアップデートされ，GPT-4 の学習データが 2022 年 1 月から 2023 年 4 月までに拡張した．2023 年 7 月と，2023 年 10 月の 2 点において，

GPT-3.5 と GPT-4 によって，画像データを除く専門医認定筆記試験 (第 61 回 2022 年度) の設問 (一般 A 問題 80 問中 70 問，症例 B 問題 55 問中 24 問) を解答させた (図 5)．その結果，2023 年 7 月時点で GPT-3.5 の正答率は，一般問題 20%, 症例問題 50.0%で，合計 27.7%で，低いものであった．2023 年 7 月時点では，GPT-4 の正答率は一般問題 62.9%, 症例問題 87.5%で合計 69.1%，更に GPT-3.5 で間違った問題だけを GPT-4 で再度解いてみると，一般問題 67.1%, 症例問題 87.5%で合計 72.3%であった．OpenAI によると，GPT-4 は 2022 年 1 月までの学習データから，2023 年 4 月までの学習データに基づくアップデートが 2023 年 9 月下旬に発表された．そこで，2023 年 10 月に再度，問題を解かすと GPT-3.5 の正答率は，一般問題 21.4%, 症例問題 62.5%で合計 31.9%と同年 7 月とあまり変わらなかったが，GPT-4 の正答率は，一般問題 82.9%, 症例問題 95.8%で，合計 86.2%と素晴らしい正答率となった．

4. ChatGPT によるハルシネーション (幻覚 Hallucination)

人工知能が学習したデータからは正当化できないはずの回答を堂々とする現象については，人工知能が幻覚を見ているかのように誤回答することからハルシネーション (hallucination, 幻覚) と呼ばれる 5)． #61-A-10 問では，プレガバリンの作用について正しい選択肢を選ぶものであったが，「ナトリウムチャネルに作用する」という間違った選択肢に対して，GPT-3.5 では「プレガバリンの作用機序は神経細胞内のカルシウチャネルの流入阻害することで，神経伝達物質の放出を調節します．そのため，ナトリウムチャネルに作用すると言えます.」と，少し頓珍漢な間違った解答をした．一方で，GPT-4 では，「プレガバリンは，主にカルシウムチャネルに結合し，神経細胞におけるカルシウムの流入を減少させることにより作用します．ナトリウムチャネルへの直接的な作用はありません.」と適切な解答を提示した．

5. ChatGPT による問題の検証

#61-A-9 問では，トラマドールについて正しい選択肢を 2 つ選ばせる問題であった．選択肢には血漿半減期や，生体内代謝経路，モルヒネと比較力価，経口投与時の生物学的利用率などの細かい知識を求める設問である．生体内代謝経路で,「N-脱アルキル化によって肝臓で代謝」は，GPT-4 では「トラマドールは主に肝臓で代謝され，その過程で複数の代謝物が生成されます.」とされて正解として選んでいる．設問上では，主たる代謝経路ではないために，この選択肢は不正解ということが期待されているのだろうと思うが，そこで，GPT-4 に改めて,「トラマドールの代謝は，N-脱アルキル化によって肝臓で代謝が主な代謝経路でしょうか?」と問い合わせをした．その結果は,

- トラマドールの代謝経路には複数が存在しますが，N-脱アルキル化はその主要な経路の一つではありません．トラマドールは主に肝臓での代謝を受け，主な代謝経路は以下の二つです：
- デメチル化 - これは CYP2D6 酵素によって行われ，トラマドールから O-デスメトラマドール (M1) へと変換されます．この M1 メタボライトは，親化合物よりも強力なオピオイド受容体アゴニストです.
- N-デメチル化 - これは CYP3A4 酵素による代謝で，N-デスメトラマドール (M2) を形成します.
- これらの代謝物の中で，特に O-デスメトラマドール (M1) はトラマドールの鎮痛活性において重要な役割を果たしていると考えられています．N-脱アルキル化というプロセスは，トラマドールの代謝に関与する主なルートではないか，または誤った表現である可能性があります.

とかなり詳細に解説が戻ってきた.

6. ChatGPT による類似問題作成機能

アセトアミノフェンについて正しいのはどれか? というような問題に対して，GPT-4 に対して「類

似する多肢選択問題を作成せよ.」と問うと，以下のようにイブプロフェンに関する問題を正解に対する解説付きで作成してくれた.

イブプロフェンについて正しいのはどれか．3 つ選べ.

a. アセトアミノフェンより抗炎症作用は強い.
b. アセトアミノフェンと鎮痛解熱作用は同等である.
c. アセトアミノフェンより血小板凝集抑制作用は弱い.
d. 1 日最大使用量は 1,200mg である.
e. シクロオキゲナーゼ 1 と 2 を阻害する.

この問題は，アセトアミノフェンに関する問題と類似しており，別の非ステロイド性抗炎症薬 (NSAIDs) であるイブプロフェンに関する知識を問うものです．選択肢はイブプロフェンの特徴を反映したものになっています．正しい回答は a, b, e です．イブプロフェンは抗炎症作用が強く，シクロオキゲナーゼ 1 と 2 を阻害し，アセトアミノフェンよりも鎮痛解熱作用が同等であると言われています．また，血小板凝集抑制作用もありますが，それはアセトアミノフェンよりも強いです．1 日最大使用量は 1,200mg が一般的です.

まとめ

ChatGPT による正答率向上は素晴らしいものであった．GPT-4 で 61 回専門医試験のうち，画像データを含まない 94 問を解いた場合，81 問で正答を得て，86.2 点となった.

LLM[2]の進化は目覚ましく，我々は今後，試験問題の作成や学習に LLM をどのように利用していくのかを考える AI 新時代に突入した.

引用文献

1. ChatGPT. https://chat.openai.com
   アクセス 2023 年 12 月 19 日.
2. OpenAI. https://openai.com
   アクセス 2023 年 12 月 19 日.
3. GetNaviWeb. 最新 AI チャット技術「GPT-4」発表！ 司法試験で上位 10%の成績を叩き出す. https://getnavi.jp/digital/841268/.
   アクセス 2023 年 12 月 19 日.
4. OpenAI API reference. https://platform.openai.com
   /docs
   /overview
   アクセス 2023 年 12 月 19 日.
5. Wikipedia. ハルシネーション. https://ja.wikipedia.org
   /wiki
   /ハルシネーション_(人工知能)
   アクセス 2023 年 12 月 19 日.

[2]LLM: Large Language Models. 大規模言語モデル

ABSTRACT

AneXam-GPT construction: ChatGPT solves the anesthesiologist certification board written exam!

Teiji Sawa, MD, PhD

ChatGPT is a chat generation artificial intelligence (generation AI) released by OpenAI in November 2022. Following the 2020 GPT-3, the latest 2023 GTP-4 model was released. This time, using OpenAI-API, we created AneXam-GPT, a database for the anesthesiologist certification written exam in which Chat-GPT provides answers with explanations, and Chat-GPT offers answers to the anesthesiologist certification written exam (61st 2022). Out of 135 questions (80 general questions and 55 case questions), 94 questions (70 general questions and 24 case questions) that did not include image data were targeted for the exam. Tests were conducted with both GPT-3.5 and GPT-4.0. By adding the ChatGPT answer function to the written test past question database, it was possible to check and confirm the answer reasons efficiently. As a result, the correct answer rate for GPT-3.5 was 21.4% for general questions and 62.5% for case questions, for a total of 31.9%, while the correct answer rate for GPT-4 was 82.9% for general questions and 95.8% for case questions, for a total of 86.2%. The evolution of generative AI is remarkable, and we have entered a new era of AI in which we are thinking about how to use generative AI in creating test questions and learning.

The University Hospital of Kyoto Prefectural University of Medicine

空液検知機能も兼ねた，重量センサによる輸液速度自動記録装置の開発

西村 一樹，藤田 憲明

目　的

輸液管理は，呼吸管理と並び麻酔上必要不可欠であるが，乳児など精密な輸液管理が必要なケースで輸液ポンプを使用する以外，通常は自然滴下で使用することが多く，滴下速度の把握や空液の検知などは，目視に頼るのが現実である．空液の検知についても，複数のルートを使用する場合や，導入覚醒，出血時など麻酔科医の監視が手薄となる場合，気づかないこともあり，特に TIVA においては薬剤投与に影響が出るため，安全管理上も何らかの方法で検知できることが望まれる．

そこで，シンプルに輸液すると輸液バッグの重量が減ることを利用して，空液検知，輸液投与量・速度の自動記録が可能で，簡便に使用できる装置を作製した．開発は 2 つのコンセプトをもとに行った．1 つめは従来通り点滴棒のフックに輸液をかけるだけで使用できるという簡便性であり，これは既存の医療現場への導入が容易である．2 つ目は自動的に時刻と共に輸液速度と投与量が記録されることであり，輸液データを自動的に収集・蓄積することで，輸液管理を後方視的に利用しやすいと言うメリットがある．投与時刻も正確に記録されることで，教育や研究への応用が期待できる．

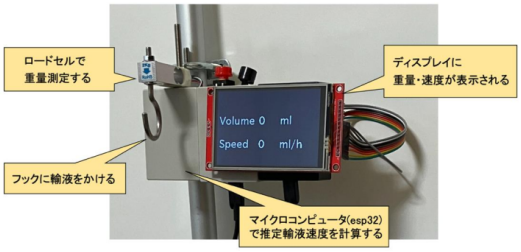

図 1：装置の外観

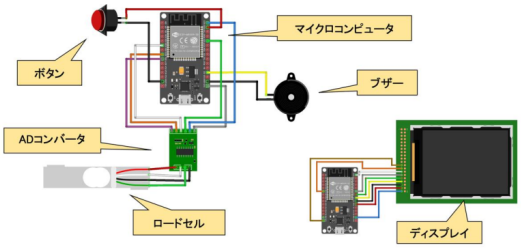

図 2：装置の構成

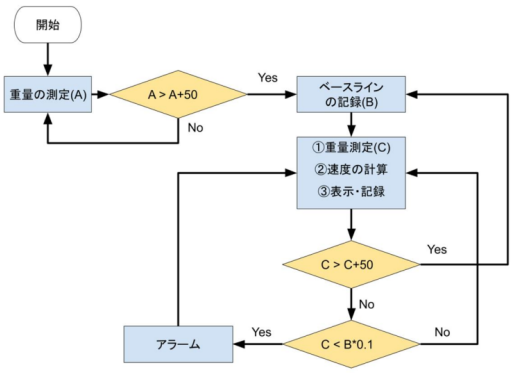

図 3：制御フロー

方　法

装置の外観，構成，制御フローを図示する (図 1,2,3 参照)．輸液バックの重量は，点滴スタンドを模したフックに組み込んだロードセルバーを用いて算出した．サンプリングは毎分 1 回実施し，汎用マイクロコントローラーである esp32 を利用して重量変化を 1 時間相当に換算するため 60 倍することで推定輸液速度 (ml/h) を算出し，結果をディスプレイに表示した．残量検知に機能として，決められた初期の重量から 10%以下となった場合に残量アラームを吹鳴するよう，プログラミングを行った．これらのデータについては esp32 のシリアル通信を用いて，シリアル通信モニタソ

KKR 札幌医療センター 麻酔科

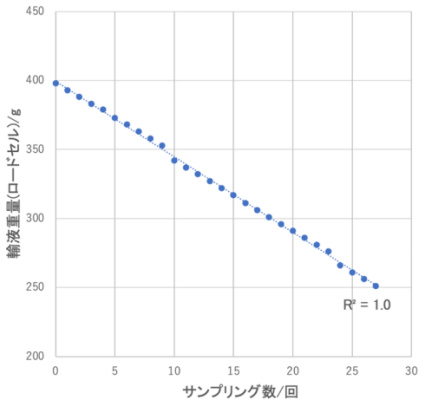

図 4：常用域におけるロードセルの Linearity の検証

フトをインストールした PC と通信を行った．プログラミングには，Arduino IDE を用いて Sketch 言語により行った．

結　果

【重量変化の直線性の検証】

本装置の常用域におけるロードセルの直線性 (Linearity) を検証するため，輸液が 400ml 入ったバッグから 1 回 5ml ずつ抜き取った際の重量変化を計測した．結果を図 4 に示す．近似曲線の決定係数がほぼ 1 となる良好な Linearity を示した．

【推定輸液速度の検証】

本装置に吊るした輸液バッグの下流に，既存のポンプテルフュージョン 28 型を取り付け，10, 50,

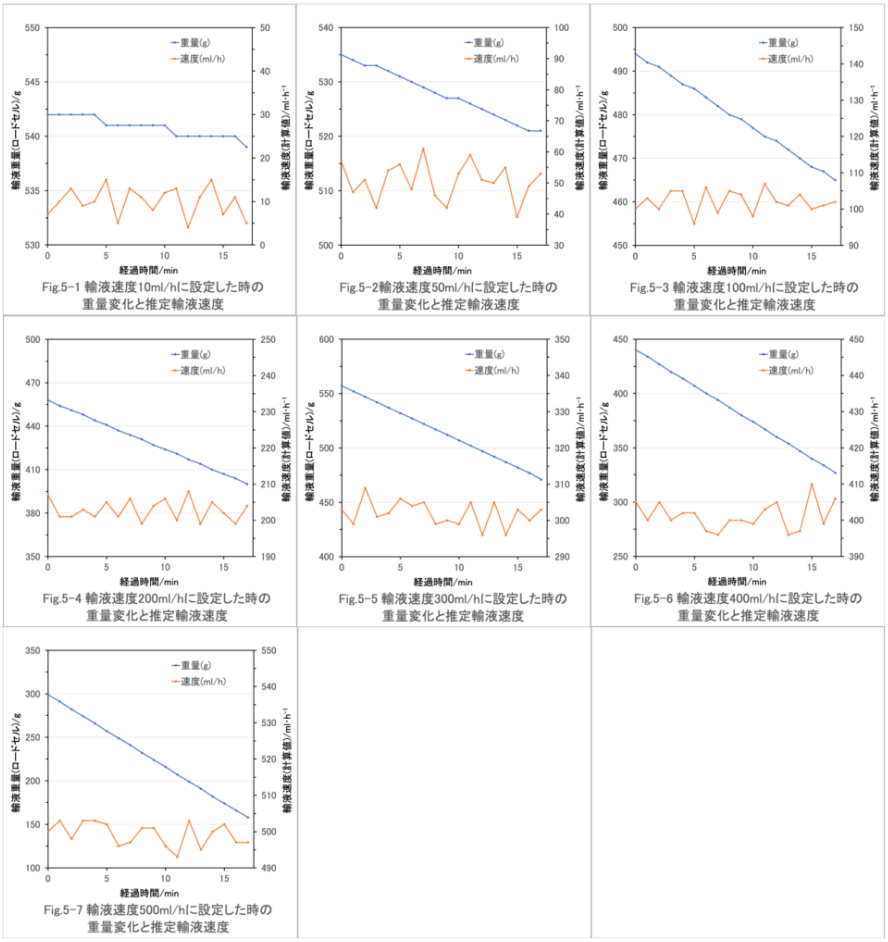

図 5：推定輸液速度の精度検証

100, 200, 300, 400, 500 ml/h の速度でそれぞれ輸液した際，本装置で得られる推定輸液速度と重量変化を計測した (図 5-1~7)．200 ml/h 以上の流量においては，既存の輸液ポンプの輸液速度と ± 3 ml/h の範囲の誤差だった (図 5-4 5-7)．100 ml/h 以下の低流量では，推定輸液速度の誤差の割合は大きくなったものの全ての輸液速度において，誤差の絶対値は± 6 ml/h(± 2SD) だった (図 5-1 5-3)．ロードセルの重量誤差 0.05%であるため，500g のバッグの測定重量は 0.25g の誤差が生じる．推定輸液速は 1 分間の重量変化の 60 倍として算出しているため，生じてしまう誤差と考えられた．また一定閾値以下における残量アラームに関しても，実用上問題のなく機能することを確認した．

考　察

投与速度は輸液ポンプを用いて調整することが一般的であるが，本装置では輸液を点滴スタンドに掛けるという通常の使い方で同様の機能を実現可能であり，要求される精度にはよるが，現在目測で行われている速度調整に比べ，より客観的な輸液管理が可能である．この輸液速度検知の機能を用いることで, 医療安全の観点でも, 予期しない全開投与や，クレンメの開き忘れといったエラーも，ソフトウェアの追加で検知可能と考えられる．また，自動麻酔記録と組み合わせることで，輸液入力の省力化にもつながり，記録精度の向上が期待される．

Limitation として 4 つ挙げる．1 つ目は，バッグが揺れると誤差が発生することである．対策は測定回数を増やしてフィルターをかけることと考える．2 つ目は，輸液回路やチャンバーの重さに対応できないことである．対策はチャンバーホルダーにより，輸液回路の重さをキャンセルする方法が考えられるが，重量変化を測定しているため実際はそれほど影響がないと思われる．3 つ目は，アラームの設定である．今は初期重量の 10%以下で鳴るようになっているが，輸液がなくなる 5 分前に吹鳴するなど実運用に即して改修が可能と考える．4 つ目は，低流量では推定輸液速度の誤差の割合が大きくなることである．低流量では推定輸液速度算出を 5 分間の平均にするなど工夫が必要であろう．

今後の展望として，双方向性 IC タグの使用を考えている，双方向 IC タグを使用することで，例えば 1 分ごとにタグに推定残量を記録することで，輸液製剤の変更を認識できる．輸液中断後に再度元の輸液に戻すときは書き込んだ推定残量を読み込み，輸液重量の把握が可能となる．また，輸液の比重，薬剤名，バッグ重量，ルート情報などの関連情報も登録し，現在の自動麻酔記録プログラムを改修することで，輸液の交換や残量の完全自動記録なども可能となる．

今後は小型化により点滴スタンドと一体化することで，既存の点滴スタンドの置き換えを図り，輸液管理において，安全性の向上や麻酔記録の自動化だけでなく，教育・研究への応用が可能と考える．

Creating a Program for Visibility in Surgical Departments' Operational Efficiency

Shinju Obara*† , Rieko Oishi*† , Shin Kurosawa† and Satoki Inoue†

Introduction

With 778 beds, the Fukushima Medical University Hospital is the only advanced treatment hospital in Fukushima Prefecture (population of approximately 1.77 million as of 2023). The number of operating rooms in the hospital increased from 12 to 14 in October 2017. Since 2020, two rooms for local anesthesia surgeries, operating only twice a week, have begun to be used. In fiscal 2022, 6303 surgeries were performed.

Efficiently managing a surgical department requires a great deal of data to understand existing situations. In particular, understanding the total amount of labor used is important to properly assess work efficiency and personnel deployment in the department. Usually, the number of operations is used for this purpose. However, the number of operations alone is an insufficient metric as time requirements vary substantially among different surgical procedures. Time patients spend in the operating room can be a proxy for time used for actual patient care and is in agreement with intuitive estimates by the site staff. However, if this data is not part of a hospital's healthcare record, it has to be created using raw data downloaded from a data warehouse. Since fiscal 2016, the Fukushima Medical University Hospital has assessed and published this data monthly in the hospital, using a program invented by the author (VIPLESS Software©, programmed by S.O). During the past five years, many efforts have been made to increase the number of operations performed and to improve operational efficiency. This paper describes these efforts and their effects on the data obtained with this program.

1. Methods

Approval of the hospital's ethics committee was not required to prepare this report.

(1) Program Details

To manage surgery-related work, the Fukushima Medical University Hospital uses a "surgical department system" that runs on an electronic medical record system. Data related to the surgery department's operations are recorded along with other types of data that are input from an anesthesia information management system, separate from the surgical department's system. Our surgical department system can output raw data in CSV formats, such as operating room entry/exit times, surgery and anesthesia start and end times, the operating rooms used, whether the case was managed by the anesthesiology department, and whether the surgery was scheduled or an emergency.

*Surgical Operation Department, Fukushima Medical University Hospital
†Department of Anesthesiology, Fukushima Medical University School of Medicine
Corresponding author: Surgical Operation Department, Fukushima Medical University Hospital, 1 Hikarigaoka, Fukushima, Fukushima, JAPAN 960-1295
E-mail: obashin99@gmail.com, FAX: +81-24-548-0828, TEL: +81-24-547-1342

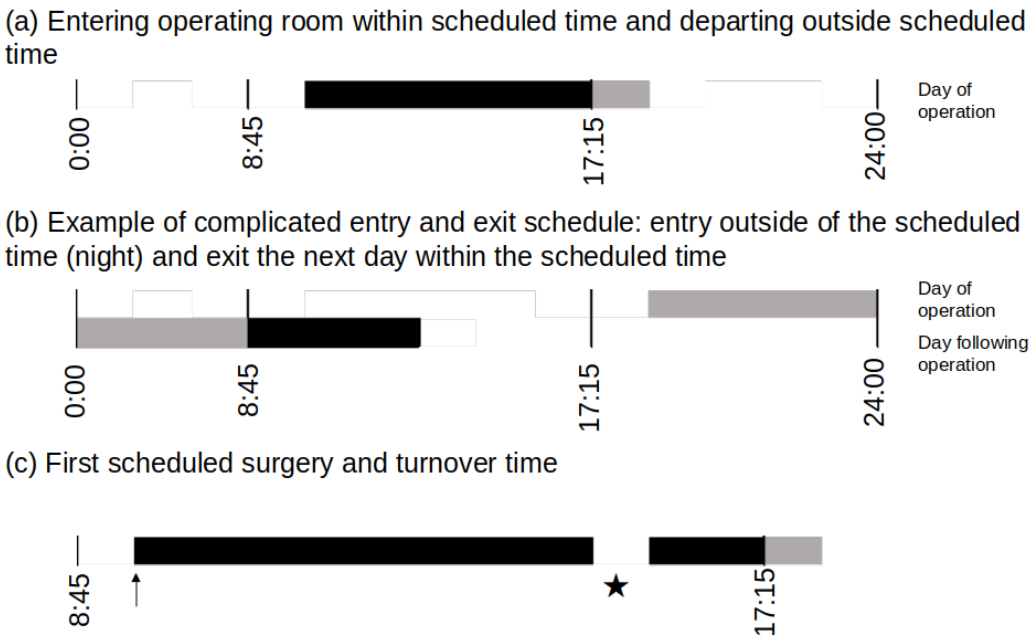

Figure 1. Time Spent in Operating Rooms as Calculated by the Program.
The program calculates the time spent within the scheduled time for operations (black), as well as the time spent outside the scheduled time (gray), based on records of the time spent in the operating room in the surgical department's system. (a). For an example case that entered the operating room at 10:00 and left at 19:00, the scheduled time spent in the operating room is 435 minutes (10:00-17:15), and the unscheduled time spent in the operating room is 105 minutes (17:15-19:00). (b) Combinations of scheduled and unscheduled times are varied and complex, and the program recognizes and categorizes each case when calculating the time spent inside and outside scheduled times. (c) Time for the first scheduled surgery (arrow) and turnover time (★). If the operating room entry time for a first surgery is not delayed and the turnover is quick, it is possible to shorten the amount of time spent in the operating room outside the schedule. In this analysis, the scheduled time period was set from 8:45 to 17:15, though it can easily be reset.

Visual Basic Editor, part of Microsoft Excel®, was used to create a program for calculation of various operational metrics. The program's basic function is to calculate the time patients spend in operating rooms for all surgery cases (from entry/exit time records, separated by scheduled times versus non-scheduled times (Figures 1a and 1b)). Based on this data, the clinical metrics discussed below can be calculated.

The aforementioned CSV file is downloaded once a month and pasted as a spreadsheet into an .xlsm file that includes the program. A calendar for the corresponding month is created in a set spreadsheet format in the same Excel file. The calendar displays the number of operating blocks for each day. For example, a weekday has 12 blocks, whereas non-weekdays have none (Operating blocks will be discussed in more detail later). When the program is run, a report is created that details the surgical department's monthly operational status. The following information is calculated.

A) Data for all days

a. Sum (in minutes) of scheduled surgeries involving an anesthesiologist, within set times

b. Sum (in minutes) of scheduled surgeries involving an anesthesiologist, outside of set times

c. Sum (in minutes) of unscheduled surgeries involving an anesthesiologist, within set times

d. Sum (in minutes) of unscheduled surgeries involving an anesthesiologist, outside of set times

e. Sum (in minutes) of scheduled surgeries not involving an anesthesiologist, within set times

f. Sum (in minutes) of scheduled surgeries not involving an anesthesiologist, outside of set times

g. Sum (in minutes) of unscheduled surgeries not involving an anesthesiologist, within set times

h. Sum (in minutes) of unscheduled surgeries not involving an anesthesiologist, outside of set times

The sum of the above (a-h) is the total time spent in the operating room. a+c+e+g is the length of time spent in the operating room within the set time, and b+d+f+h is the length of time spent in the operating room outside of set time.

B) Data for workdays (regular weekdays only)

i. Sum (in minutes) of scheduled surgeries involving an anesthesiologist, within set times

j. Sum (in minutes) of unscheduled surgeries involving an anesthesiologist, within set times

k. Sum (in minutes) of scheduled surgeries not involving an anesthesiologist, within set times

l. Sum (in minutes) of unscheduled surgeries not involving an anesthesiologist, within set times

m. Sum of "operating block" times (in minutes); sum of (number o blocks × set operating room operating time[1]) on workdays

n. Sum of "operating room" times (in minutes); sum of (number of operating rooms × set operating room operating time[1]) on workdays

Operating blocks are times when rooms and personnel (nursing staff and anesthesiologists) able to participate in a surgery are assigned by the surgical department to various other departments during scheduling. This information includes days of the week, number of rooms, and times (A.M. and/or P.M. within set time). Prior to September 2017, there were 12 operating rooms and 9 or 10 operating blocks. In 2023, there are 16 operating rooms (two for local anesthesia surgery, which are only used twice a week) and 12 or 13 blocks. Operating block utilization, which has been examined in many studies, effectively measures how efficiently operating rooms and human resources are being used for scheduled surgeries[1)].

Operating room utilization also measures how well operating rooms are used within set times. This metric can be improved by reducing open time prior to the start of a surgery, shortening time to patient entry from exit of the previous patient (patient turnover time) (Figure 1c), and revising schedules on an ongoing basis based on the overall progress of surgeries.

C) Time (in minutes) spent in the operating room by department and its percentage of overall time (%)

This shows the percentage of time-based occupancy by each department to overall surgical department time.

D) Median time of operating room entry

[1]Operating room times are 8:45 A.M. to 5:15 P.M.(8.5 hours).
Operating block utilization =(i+j+k+l)/m (%)
Operating room utilization =(i+j+k+l)/n (%)

for the first-scheduled surgery (Figure 1c)

Operating room entry time is when operating room entry information is input into the electronic anesthesia record.

E) Median patient turnover time (Figure 1c)

The time between the exit of one patient and the entry of the next into the operating room where two operations are scheduled to be performed in a row in the same operating room.

The aforementioned report was released, along with the number of operations by each department, in a monthly surgery department liaison meeting and used in various discussions.

This study shows changes over an nine-year period of time spent in the operating room (in total, within scheduled time, and outside of scheduled time), the number of operations, rates of utilization of operating blocks and operating room, operating room entry times for first-scheduled surgeries, and lengths of patient turnover time.

(2) Changes in surgery department circumstances during this period and changes made to improve work

A) Increasing the number of operating rooms and operating blocks

In October 2017, the number of operating rooms was increased from 12 to 14 (one operating room with MRI capability and another hybrid operating room). One year earlier, the surgery department consulted multiple times with other departments and increased the number of operating blocks substantially as described earlier. Anticipating the additional labor needed, the hospital hired more nurses and radiological technologists. Since 2020, two rooms for local anesthesia surgeries, operating only twice a week, have begun to be used.

B) Early identification of unused operating blocks

Regular scheduling is done as follows. Every Thursday, each department requests the operating blocks they need for surgeries, and the head nurse or the assistant head nurse allocates operating rooms. Afterward, cases needing anesthesiology management are allocated to the anesthesiologist in charge, and on Friday, the schedule is finalized and published, after which unused operating blocks are reserved for any department's unscheduled or emergency surgeries. The starting dates and times for these additional surgeries are determined based on available operating rooms, nursing staff, and anesthesiologists.

Starting in 2016, an "open operating block calendar," updated daily, was created, with open blocks accessible at any time from electronic healthcare records. When departments come to know that they do not need future operating blocks, they contact the surgery department, and the information is shared using the calendar. Departments looking for operating rooms then secure open blocks on a first-come, first-served basis. Since April 2023, the rule that such reporting should be done three weeks prior has been strictly enforced.

C) Directly preventing longer patient turnover time

a. Cleaning between surgeries: Since 2015, cleaning done by a contractor between surgeries has been simplified than end-of-the-day cleaning, while maintaining a required level of cleanliness.

b. Alleviation of hindrances at operating room entrances: Entrances to operating rooms allow up to two patient stretchers to pass simultaneously. To prevent patient mix-ups, patient

confirmations were done at entrances and exits. However, because these confirmations delayed entry and exit times, their management was changed as follows.

i. Single set of footwear: In the past, shoe racks were always placed at the entrance to the surgery department, for changing into sandals exclusively for the operating room. This rule was changed in 2017. Those already wearing hospital footwear could enter the operating room without having to change their shoes, and individuals not wearing hospital footwear could use disposable shoe covers. This is expected to quicken the flow of patients.

ii. Relaxation of regulations for changing clothes: Previously, all medical staff entering the operating room had to change into surgical scrubs. This rule was also changed. As long as individuals do not go into the operating arena, the supply hall, or other areas requiring antisepsis preparation, they are allowed to enter the surgery department wearing their hospital uniform, a cap, and a mask.

iii. Patient handoffs in operating room: In 2018, the place where the ward nursing staff handed off patients to the operating room nursing staff was changed from the surgery department entrance to inside the operating room. This provided the surgical nursing staff additional time to prepare the operating room for surgery.

c. Surgical equipment packaging: In 2018, the hospital started using a specialized company to provide packaged surgical equipment for most typical and common surgical procedures. Hence, the surgery staff no longer had to pick up surgical equipment in the surgery department in selected surgical procedures. As of November 2023, this service is available for 45 different surgical procedures.

2. Results

(1) Total daily work

Figure 2 shows the total amount of work and the number of surgeries each day. Total time spent in the operating room was 1,226,216 minutes with 6,225 surgeries in fiscal 2015, 1,242,851 minutes with 6,280 surgeries in fiscal 2016, 1,282,270 minutes with 6,677 surgeries in 2017, and 1,379,742 minutes with 6,950 surgeries in 2018, showing an increasing trend. These growths were assisted by the two operating rooms added in October 2017 and the resulting rise in operating blocks (see arrows in Figure 2). Due to the COVID-19 pandemic, the total time spent in the operating room peaked at 1,455,822 minutes with 7,094 surgeries in the fiscal 2019 and subsequently experienced a decline, with a recovery beginning in early 2023. Total time spent in operating rooms changed over time in a similar manner to time spent in the operating room within the set time.

(2) Operating block and operating room utilization on workdays

Figure 3 shows the utilization of operating blocks and operating rooms on weekdays (i.e., days that the hospital regularly schedules surgeries). No months stand out as having either extremely high or low utilization. After the increase in operating rooms and operating blocks in October 2017, operating block utilization dropped and did not increase again until May 2018. Although operating block and operating room utilization peaked at 87.2% and 75.4%, respectively, in February 2020, these indices declined due to the COVID-19 pandemic, with recovery beginning in early 2023.

(3) Operating room entry time for the first-scheduled surgeries

In fiscal 2014, the median operating room entry was often later than 8:50 (8:50-8:53), but

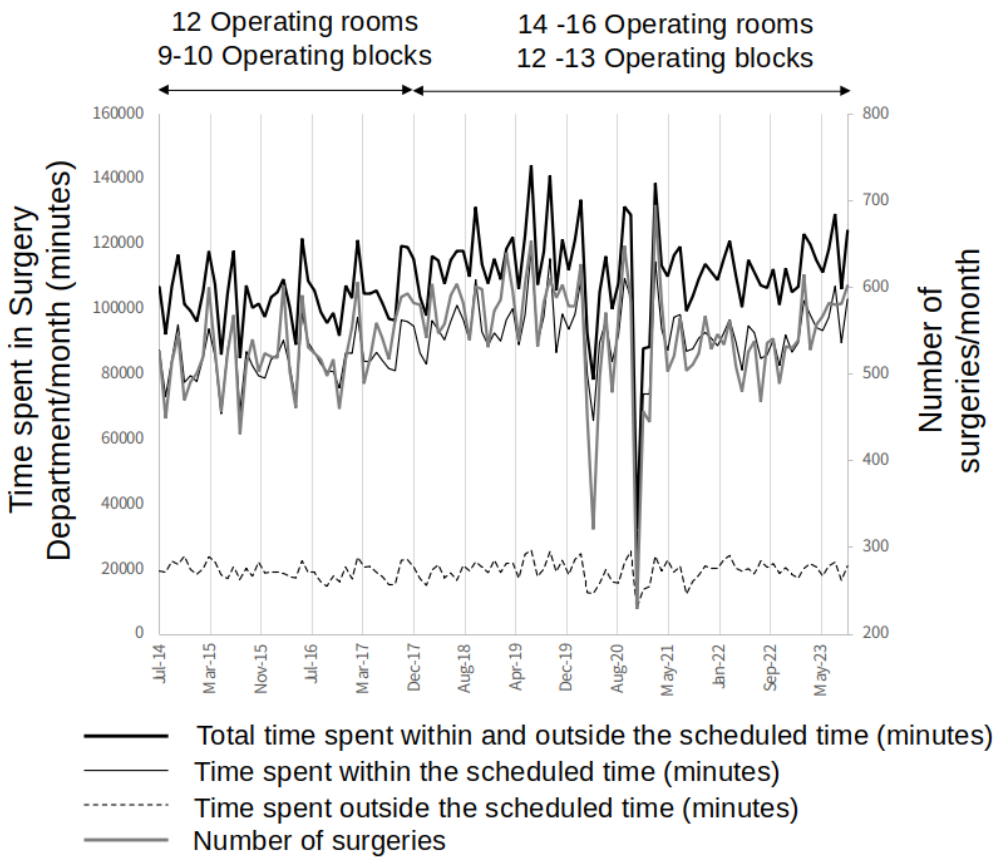

Figure 2. Time spent in the surgical department and the number of operations.

from fiscal 2020, it remained stable at 8:46.

(4) Patient turnover time

Figure 4 shows median lengths of patient turnover time, which were between 25 and 33 minutes in fiscal 2014 (when they were first tracked), started lengthening in October 2017, and then shortened at the start of 2019 to about 33 minutes. During the COVID-19 outbreak, it was extended to 30-37 minutes.

3. Discussion

Operating room efficiency continues to be a high priority for hospitals[2]. The improved efficiency requires proper assessment of existing situations, for which the number of operations performed has been used traditionally. However, as operating blocks are continuous time periods, examining their use requires consideration in "time" units, rather than the number of operations. Time spent by patients in a surgery department also can be viewed as the amount of care given to a patient; it is an easily measurable index of the amount of work they do, although a surgical staff generally does a lot of work unrelated to surgery. Accordingly, total time spent in the operating room can serve as a proxy for the amount of work done in relation to the proper deployment of personnel and the existing situations of facilities.

Using a program created by hospital staff with extensive experience in the surgery department, the Fukushima Medical University Hospital periodically assesses and publishes surgery department workflow metrics as shown in the Results

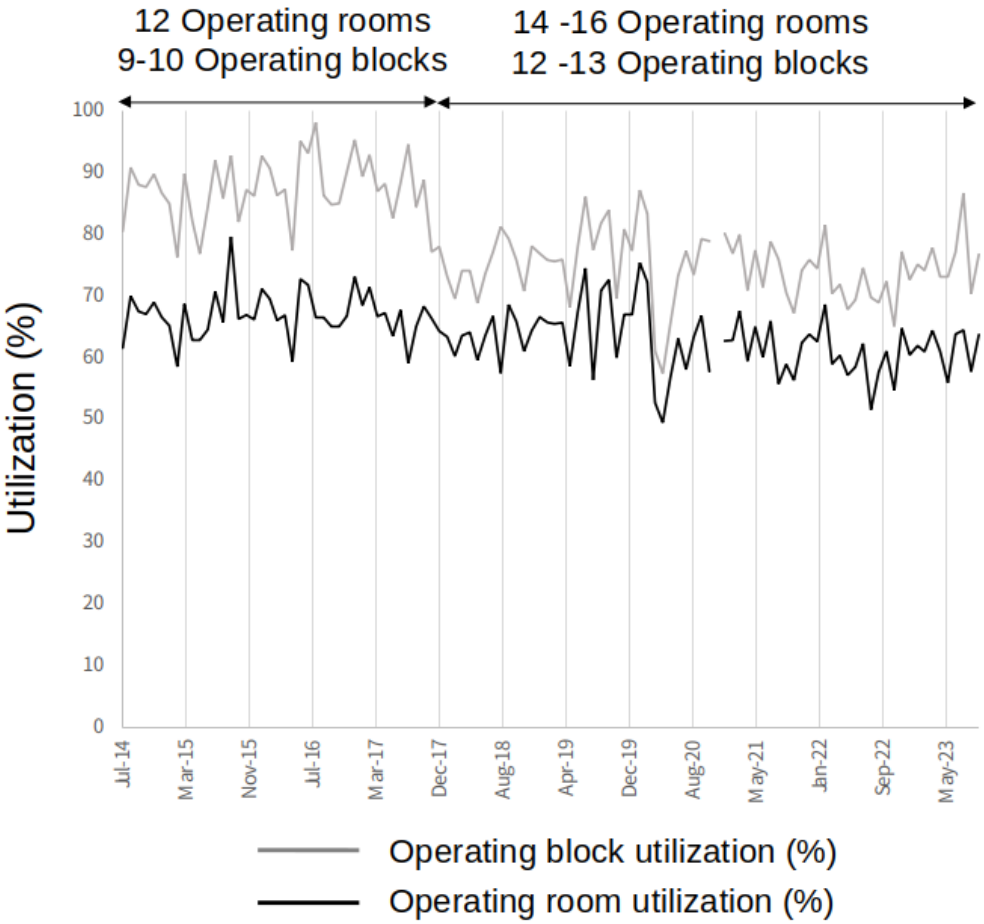

Figure 3. Utilization of surgical blocks and operating rooms.

section. This method has several benefits. First, it is free, and glitches can be fixed immediately. Further, input errors and abnormal data resulting from integrating the anesthesiology record system and the surgery department system can be found in calculated data and program irregularities. Meanwhile, outsourcing data for analysis reduces the opportunity to have the raw data checked by healthcare professionals, or detect and correct data abnormalities.

Several problems arise when assessing the status quo using the number of operations as the sole metric for amount of work done. For example, nurses and anesthesiologists working in the operating room recognize that there is not a proportional relationship between the number of surgeries and the amount of labor that goes into them. For example, it is difficult to intuitively accept as similar aggregate assessments of an ophthalmological case that requires only 15 minutes and a cardiovascular surgery that requires much more time and more staff involvement. Because these two cases do not legitimately assess the amount of labor involved, treating them as equal could lead to faulty administrative decisions.

Since October 2017, the greater number of operating rooms and operating blocks has led to a

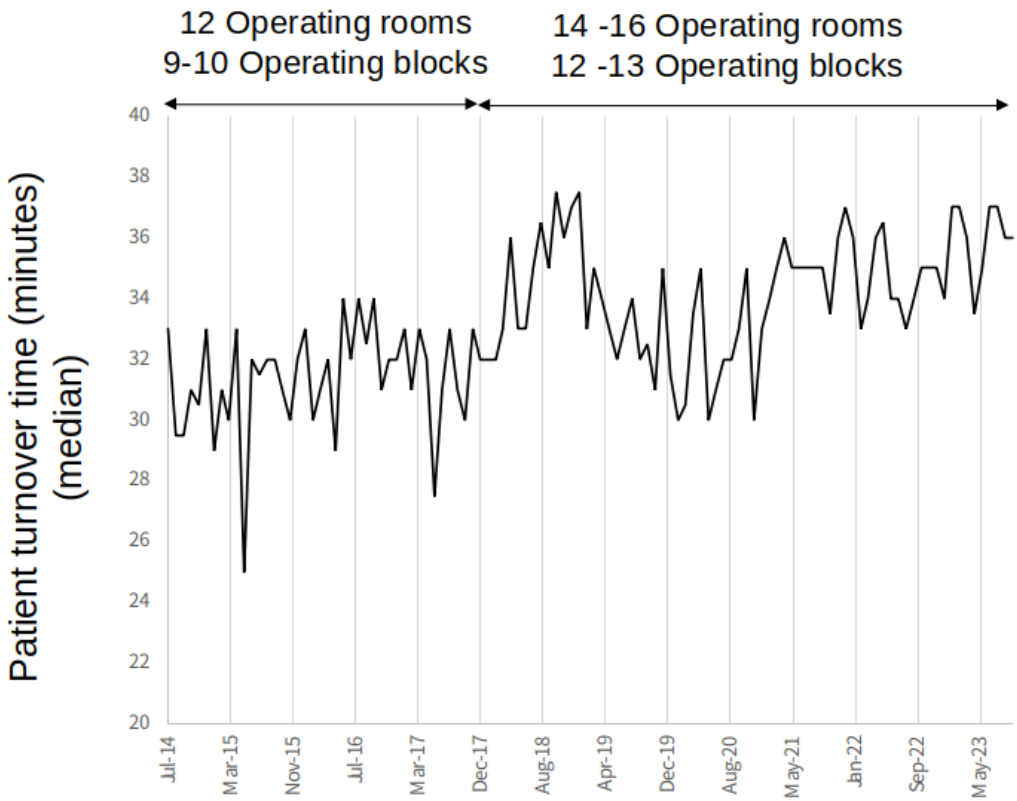

Figure 4. Patient turnover times

For two consecutive scheduled surgeries in the same operating room, the time in minutes from when the previous patient left to when the next patient entered the operating room. Data shown are median values.

higher number of operations. This is presumably why the total length of time spent in the operating room increased. Although the number of operations and total time spent in the operating room showed similar patterns of change, the latter appeared to be more easily acceptable as a measure of the amount of work rather than the number of operations alone.

From 2014 through the first half of 2017, rates of utilization of operating blocks in most months exceeded 80%. This percentage decreased after October 2017, when the number of operating rooms and operating blocks rose. Utilization decreased because (a) surgeries were constantly scheduled more than available operating blocks prior to the 2017 increase in operating rooms and thus the apparent utilization rate was high, and (b) the total number of operating blocks was increased in 2017 according to requests from departments, but increased operating blocks were not used fully because some departments did not have sufficient manpower. Schedule updates and reallocation of operating blocks to departments with excess manpower and many patients requiring surgery appear to be effective, as suggested by an increase in overall utilization of operating

blocks.

Operating room utilization was below 70% for all months in 2014, increasing because of improvements to 75% in July 2019. It has been reported that more operating rooms can decrease utilization, even when the number of operations performed increases[3]. The same mechanism presumably underlies the observation at our hospital that utilization decreased somewhat after the operator room increase in October 2017, but then rose over time.

Too high an operating room utilization rate may indicate that the availability for emergency surgeries is limited in some time zones. Fukushima Medical University Hospital performs many emergency cesarean section births and other emergency surgeries that cannot be handled by other hospitals in the region. Thus, having open operating rooms for emergency use is a major benefit. Operating rooms in Japan with capacity utilization above 75% are rated top-class[3]. At Fukushima Medical University Hospital, the 75% utilization rate is near its maximum, and it seems that little additional utilization improvements are realistically achievable.

Prior to 2018, as noted in the Methods section, the hospital verified and handed off patients at operating room entrances. This caused congestion for the first surgeries of the day (entry starting at 8:45 A.M.) at the surgery department entrance. Fortunately, this congestion dissipated after the handoff procedure changed. The data reflected the more efficient entry of patients into the operating room.

Patient turnover time has been used in many studies as a parameter reflecting hospitals' efficiency, and many hospitals work to decrease i[4]. Patient turnover also is important to build teamwork and encourage the institution's focus on achieving maximum throughput in operating rooms[5]. As described in the Methods section, Fukushima Medical University Hospital made efforts for efficiency improvement and predicted that turnover times would go down. However, no major reduction was seen initially. In fact, patient turnover times increased for certain time periods, possibly caused by: (1) locating new operating rooms in a separate building adjoining the surgery department via a corridor, which lengthened the distance between operating rooms and wards and (2) entering patient information after operating room handoffs or patient confirmations, and (3) Increase in procedures necessary for infection prevention due to the COVID-19 pandemic. Additionally, the hospital had limited manpower for patient transportation and surgery operations; this might have caused unavoidable delays. Turnover times in May 2015 and June 2017 were shorter than other months, because many brief ophthalmological surgeries (with local anesthesia) were performed during these months (averaging 106 per month in 2015, with 113 performed in May 2015, and averaging 121 in 2017, with 135 performed in June 2017). A review of multiple university hospitals noted that patient turnover times ranged from 34 to 66 minutes[6]. This wide range suggests that the length of patient turnover time varies depending on institutions and surgical procedures; therefore, significance of reducing a particular measure is unclear and excessive focus on turnover time may be counterproductive[5]. The Fukushima Medical University Hospital, in contrast, simply observes changes in turnover times and makes no extreme efforts to reduce them.

4. Conclusion

A program was created to quantitatively analyze the management of the surgery department, and the actual data focused on changes in the hospital over a nine-year period were analyzed. In summary, until just before the COVID-19 pandemic, both the number of surgeries performed and the total time spent in operating rooms were trending upward. However, the percentages of utilization of operating blocks and operating rooms initially declined in 2017, following an increase in the number of operating rooms, and were further impacted by the COVID-19 pandemic.

References

1. Dexter F, Macario A, Traub RD, et al.: Operating room utilization alone is not an accurate metric for the allocation of operating room block time to individual surgeons with low caseloads, Anesthesiology 98:1243-1249, 2003
2. Pedron S, Winter V, Oppel EM, et al.: Operating Room Efficiency before and after Entrance in a Benchmarking Program for Surgical Process Data, Journal of medical systems 41:151, 2017
3. Koh M, Yoko H, Kayoko N: Not only case volume, but also operating room utilization and total case minutes may be evaluated as an indicator of activity of operating suite (Japanese literature with English abstract), The Journal of Osaka Rosai Hospital 40:8-12, 2017
4. Bhatt AS, Carlson GW, Deckers PJ: Improving operating room turnover time: a systems based approach, Journal of medical systems 38:148, 2014
5. Kindscher JD. Operaing Room Management. In: MILLER RD, COHEN NH, ERIKSSON LI, FLEISHER LA, WIENER-KRONISH JP, YOUNG WL, editors. Miller's Anesthesia: ELSEVIER; 2015. p. 56-72.
6. Dexter F, Abouleish AE, Epstein RH, et al.: Use of operating room information system data to predict the impact of reducing turnover times on staffing costs, Anesth Analg 97:1119-1126, 2003

ABSTRACT

Efficiently managing a surgical department requires the visibility of a great deal of data to understand existing situations. Metrics calculated from time spent by a patient in an operating room represent a promising way to show the total amount of labor in a surgical division. Percentages of utilization of operating blocks and operating rooms in set weekday time periods can be calculated and used as metrics of operational efficiency.

Calculating these metrics is not a function of the healthcare information system in our hospital. Since fiscal 2016, the hospital has used a program that the author created with Visual Basic Editor to assess and publish monthly data in the hospital. Data accumulated between 2014 and 2023 were used to examine the impact of a change in the number of operations and the many efforts to improve operational efficiency in the surgical department.

The number of operations and total time spent in the operating room were increasing in particular since the inclusion of two operating rooms in October 2017. The percentages of utilization of operating blocks and operating rooms decreased somewhat with this increase in room number but later returned to previous levels in a year. The number of operations and total time spent in the operating room reached a record high in the fiscal year 2019 but declined due to COVID-19; the pandemic of Coronavirus disease 2019; it has been recovering since early 2023.

By having data about how much time patients spend in operating rooms through this homebuilt program, one can quantitatively assess effects of various efforts that are unclear from the number of operations alone.

Key words: Operating room, operating block, efficiency, time spent, patient turn over time

Acknowledgments:

The author expresses deep appreciation to Ms. Hiromi Shishido, M.S., who aggregated the information of surgeries performed and largely contributed to debugging the program.

舌下神経刺激装置植込術における術中神経モニタリングの報告

Case report on Intraoperative Nerve Monitoring
in hypoglossal nerve stimulator Implantation

高谷恒範[*,‡]，山内基雄[†]，上村裕和[§]，
林浩伸[‡]，曽碩真弘[¶]，川口昌彦[‡]

背　景

舌下神経刺激装置植込術 (HNS: hypoglossal nerve stimulator Implantation) は，最近，CPAP の代替治療として健康保険適用を得た閉塞性睡眠時無呼吸 (OSA) に対する新規治療法である．我々は，これまで 3 例の HNS 症例を経験しており，そのうち 1 例において刺激強度タイトレーションを終えている．舌下神経電気刺激装置植込み術に際し，当院で工夫した術中神経モニタリング (IONM: Intra-operative neuromonitoring) を行っているので症例提示しながら紹介する．

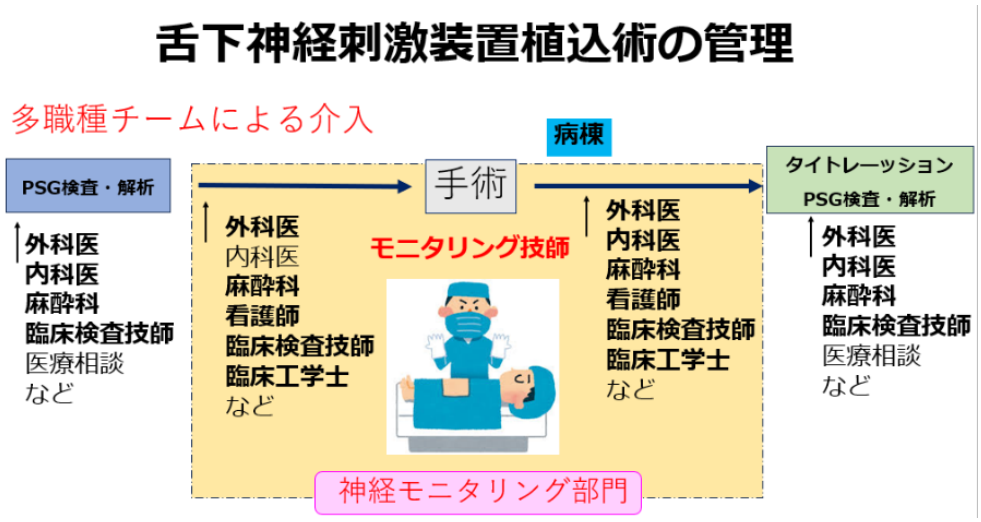

図 1．舌下神経刺激装置植込術の流れ

1. Patient Selection　(PSG 検査にて)
2. DISE：薬物睡眠下内視鏡検査　(AP collapse pattern)
3. 舌下神経刺激装置植込術
4. アクティベーション - 植込み後，約 1 ヶ月に実施
5. タイトレーション PSG　Fine tune タイトレーション
6. アクティベーションから約 3 ヶ月前後に実施
7. フォローアップ Fine Tune PSG 後 1 ヶ月以内に来院
8. 長期管理 6-12 カ月ごとに定期外来

*奈良県立医科大学附属病院 中央手術部
†同 呼吸器・アレルギー内科
§同 耳鼻咽喉・頭頸部外科
‡同 麻酔科
¶同 医療技術センター

現在当院では，舌下神経刺激装置植込術の管理は，多職種が連携を取りながら行っている．臨床検査技師は，PSG 検査時から術中神経モニタリング刺激タイトレーッションの微調整まで携わっている．タスクシフト・タスクシェアの関係で検査技師に委ねられているのが現状である．

症　例

70 歳代 男性．身長：171.0 cm，体重：75.0 kg，BMI：25.6 で現病歴は，前医にて睡眠時無呼吸症候群と高血圧症，2 型糖尿病にて通院中．舌下神経刺激療法に興味を持たれ，当院での精査・加療を希望され紹介受診となった．本人曰く，『もう十分 CPAP 行った．これ以上の装着は無理である』また，『当直 (15 日/月) 時に CPAP を接続しながら行うのは困難である』と訴えがあった．CPAP アドヒアランス[1]良好であるが，CPAP 使用が容易ではないことから，舌下神経刺激療法への転向希望である．ということで 舌下神経刺激療法の実施となった．

診断 PSG 検査結果

AHI 30.5 (OSA 61/night 7.0/hr, hypo 204/night 23.4/hr), ODI3 24.1, Arousal Index 31/hr, AHI-NREM 30.2, AHI-REM 31.3, Stage R duration 142min (27.2%), mean SpO_2 awake 95%, NREM 94%, REM 94% 覚醒時呼吸　RR 18/min, SpO_2 96%, $TcpCO_2$ 44mmHg 入眠時呼吸　RR 16/min, SpO_2 95%, $TcpCO_2$ 44mmHg

技師コメント：すべて仰臥位睡眠のため体位依存は不明．呼吸障害イベントに伴う SpO_2 低下は，多くは 80%まで低下していた．長いイベントでは，最低 69%まで低下．NREM では，閉塞性低呼吸と無呼吸の混在．REM では無呼吸がほぼ占める．睡眠安定すると呼吸イベントが消失する時間も認める．ループゲインが高いことを思わせる呼吸波形はなく，また覚醒閾値が低いような印象もない．

手　術

術前 DISE：プロポフォールを使用した鎮静下で内視鏡検査を施行して，軟口蓋虚脱を評価する．75 %以上であれば，適応候補者除外 (全周性逸脱)75 %以下であれば，Inspire の治療適応候補となる．AP collapse pattern　または，部分的な全周性逸脱があれば適応となる．(図 2-1，2-2)

[1]adherence: 医学界では，患者が治療方針の決定に賛同し積極的に治療を受けることを意味する．

図 2．軟口蓋逸脱について

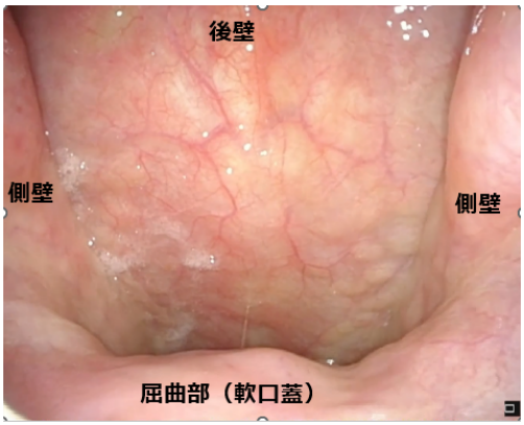

図 2-1．拡張期

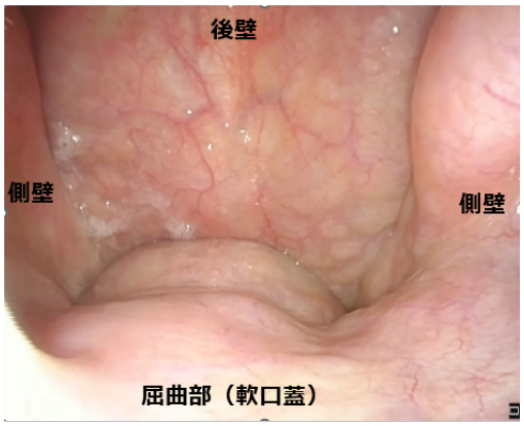

図 2-2．収縮時

麻酔は全静脈麻酔で行い，導入時は，プロポフォール TCI (Target-controlled infusion)3.0μg/ml, レミフェンタニル 0.5μg/kg/min , ロクロニウム 0.6mg/kg

維持：プロポフォール TCI 2.6n, フェンタニル適宜, ロクロニウムの追加投与は行わなかった.

術中神経モニタリング

IONM は直接刺激 (NIM:nerve integrity monitoring) と経頭蓋運動野刺激 (Tc-MEP) を組み合わせ, 舌を前方移動させるオトガイ舌筋 (GG：Genioglossus) とオトガイ舌骨筋 (GH：Ge niohyoid) 後方移動させる茎突舌筋 (SG：Styloglossus) と舌骨舌筋 (HG：Hyoglossus) の筋電図を記録測定した．(図 3-1，3-2，3-3)

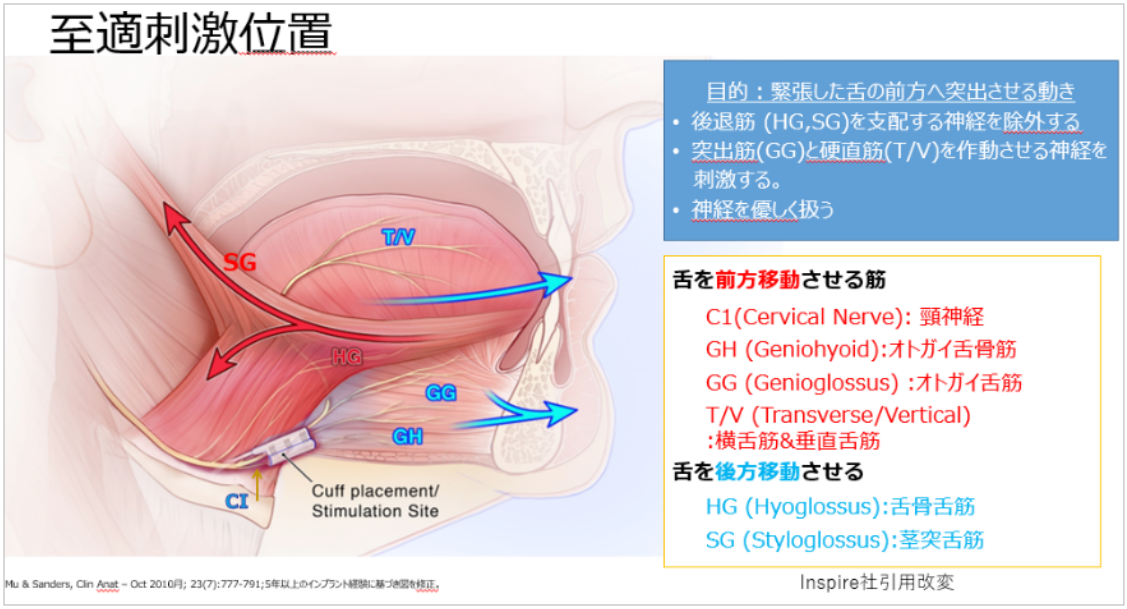

図 3．至適刺激位置について

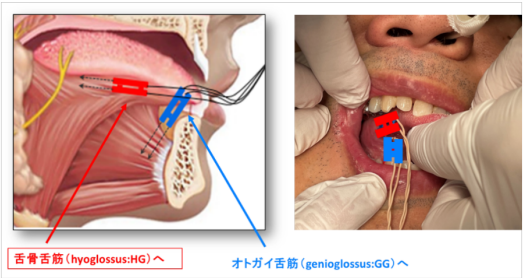

図 3-2．設置場所

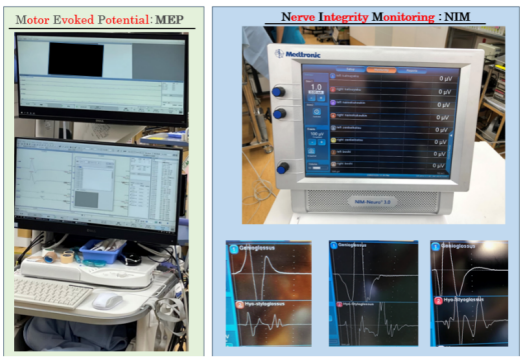

図 3-3．術中神経モニタリング機器

直接刺激で SG,HG,GG の筋電位を確認し，SG,HG への分枝と GG への分枝を同定分離後，HG の遠位側で舌下神経舌筋枝にカフ刺激電極を留置した．植込み術終了前には Tc-MEP によって全筋 (SG,HG,GG,GH) の筋電図を記録し中枢側での神経損傷がないことを確認した．　頸部切開を行い，舌下神経を露出後，術野の直接刺激で筋電位を確認する．舌下神経本幹から，茎突舌筋 (SG)，舌骨舌筋 (HG) への分枝確認し，刺激を行う．オトガイ舌筋 (GG) への分枝確認後，SG,HG と GG とを分離再度刺激を行い，GG が動く (舌が前方に動く) 舌舌神経にカフを設置する．(図 4)

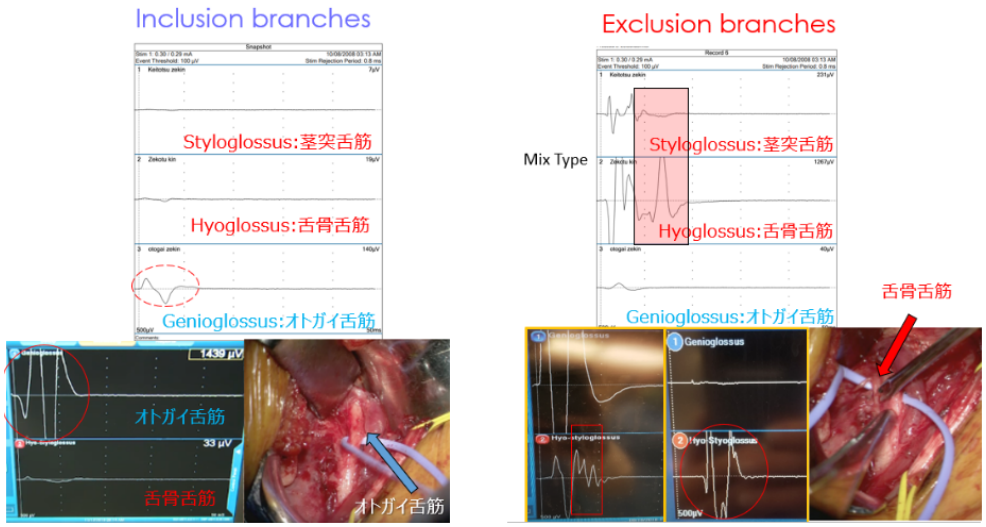

図 4．神経支配筋マッピング

神経剥離操作終了後，運動野への経頭蓋電気刺激で全筋の筋電位を記録する．(図 5)

図 5．経頭蓋刺激筋記録において術野より中枢側 (舌下神経) での圧迫・牽引などによる神経損傷が無いことを確認して縫合に入る．

経　過

ONM は直接刺激 (NIM:nerve integrity monitoring) と経頭蓋運動野刺激 (Tc-MEP) を組み合わせ, 舌を前方移動させるオトガイ舌筋 (GG：Genioglossus) とオトガイ舌骨筋 (GH：Geniohyoid) 後方移動させる茎突舌筋 (SG：Styloglossus) と舌骨舌筋 (HG：Hyoglossus) の筋電図を記録測定する．直接刺激で SG,HG,GG の筋電位を確認し，SG,HG への分枝と GG への分枝を同定分離後，HG の遠位側で舌下神経舌筋枝にカフ刺激電極を留置した．植込み術終了前には Tc-MEP によって全筋 (SG,HG,GG,GH) の筋電図を記録し中枢側での神経損傷がないことを確認した．HNS 装置植込み術後約 4 か月目に刺激強度タイトレーション PSG を施行し，効果的に刺激強度を設定することができた．

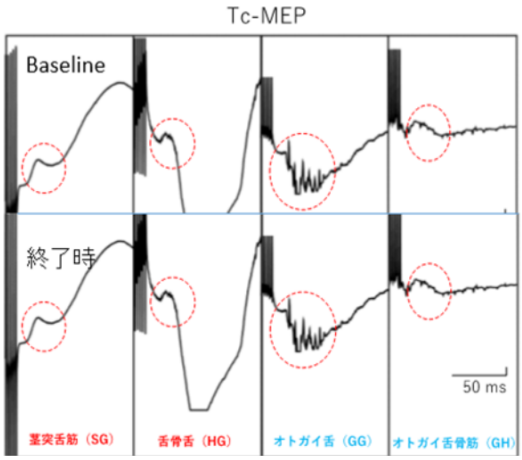

図 5．舌下神経刺激装置植込術の流れ

結　語

当院で工夫した直接刺激と経頭蓋運動野刺激を組み合わせた IONM を行い，安全かつ精度の高い手術を施行することができた．

手術顕微鏡の機能を利用した術中神経モニタリングシステムの使用経験

曽碩真弘*，高谷恒範†，林浩伸†，
松田良介‡，小西康司*，川口昌彦†

はじめに

脳神経外科手術において，術後，患者の神経機能を温存するために，ナビゲーションシステム，術中神経モニタリング，術中脳波測定など様々な医療機器が用いられている．

当院手術室ではナビゲーションシステムの操作は外科医が手術中に行い，顕微鏡画面にナビゲーションの各種情報を拡張現実により投影させて手術することが可能となっている．一方で，術中神経モニタリングに関しては，医師の指導及び指示のもと，モニタリングを行っている技師が手術操作を確認しながら必要に応じて電気刺激を加えて波形確認を行っている．しかし，一般的には技師が確認している波形情報は口頭で術者に報告され，術者は報告された内容を聞き，手術を行っている．

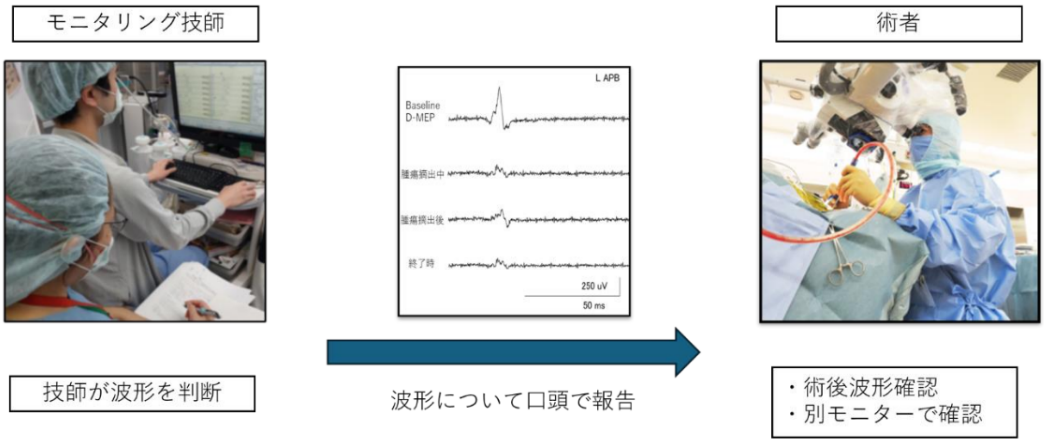

図 1 実際のモニタリングの様子

現状の課題

術中神経モニタリングについて，頭蓋底手術のようにモニタリング項目が多い手術や脊椎手術のように記録筋が多い手術の場合，どこの部位の波形がどのように変化したか口頭では伝わりにくく，報告をうけた術者は波形変化の結果において混乱することがあった．また，術者自身がモニタリングの波形を確認したいが術野から大きく目を外したくない状況があり，モニタリング技師も波形の情報を口頭で説明するのが難しい場面もあった．術者と実際の波形画面を共有し，波形の変化について説明するべき場面が度々あった．

*奈良県立医科大学附属病院 医療技術センター
†奈良県立医科大学 麻酔科学教室
‡奈良県立医科大学 脳神経外科学教室

解決策：手術顕微鏡の機能を用いた方法による波形描画法 (Super-impose system)

この状況を解決するために，手術顕微鏡 (ZWISS 社製 KINEVO, PENTERO) のナビゲーションインターフェイスを用いて術中神経モニタリングの波形を顕微鏡画面に描出できるシステムを持った術中神経機能検査装置 (inomed 社製, ISIS Expert) の導入を行った．

実際の運用では手術顕微鏡と術中神経機能検査装置を専用ケーブルで接続して，モニタリング波形を手術顕微鏡に出力している．

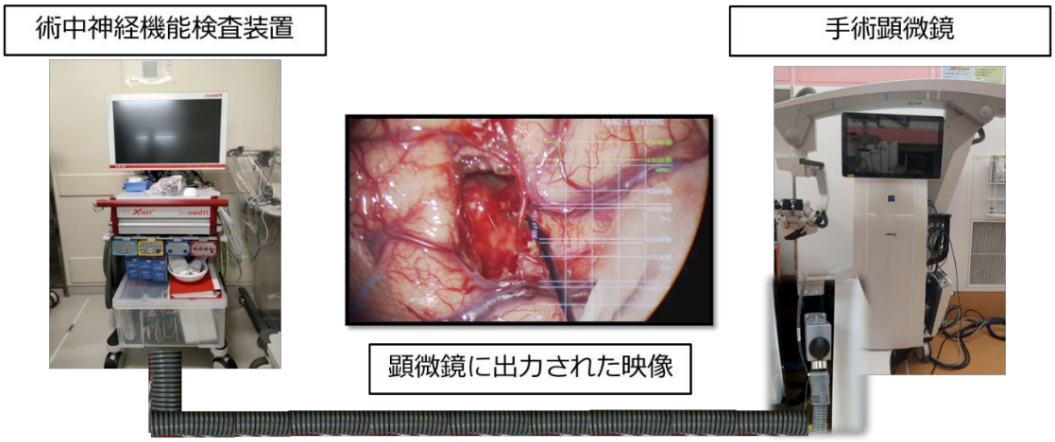

図 2 術中神経機能検査装置と手術顕微鏡の接続

Super-impose system の原理

Super-impose system の仕組みは手術顕微鏡の対物レンズと接眼レンズの間に透明の液晶パネルが内蔵されており，その液晶パネルに術中神経機能検査装置から出力された映像を映し出すことで，術野映像に神経モニタリングの波形を描画することを可能としている．

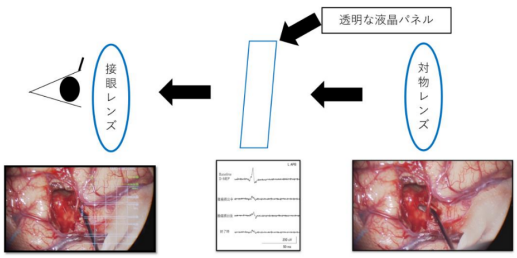

図 3 Super-impose system の原理について

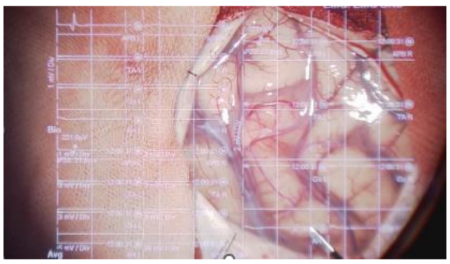

図 4 Super-impose system を用いた皮質直接刺激による MEP 描出波形を顕微鏡下に描画

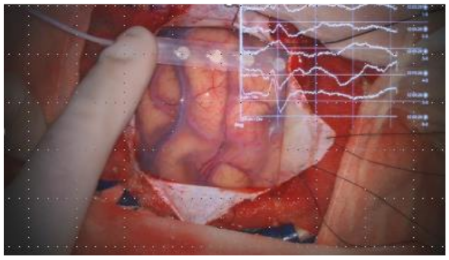

図 5 Super-impose system を用いて中心溝同定描出波形を顕微鏡下に描画

導入することにより得られたもの

このシステムを導入することは術者, 技師各々にとってメリットがあった．一方で, 課題もあった.

① 技師からの口頭報告とともに，術者は実際の波形を術野から目をそらすことなく確認することが可能となった.

② リアルタイムで手術操作を行いながら波形の変化を確認できるため，術者自身が波形を確認しながら最適な位置に脳表電極を留置することや，波形の変化を見ながら手術を行うことができた.

③ 助手の医師は指導医の手術操作と波形変化を同時に確認, 共有することで, 教育的な効果をより高めることができた．加えて術後の振り返りや共有をする際には，モニタリング波形変化と手術操作が同画面で録画された映像を視聴することが可能となり，変化の様子が医療スタッフにとって理解しやすいものとなった.

④ モニタリング技師にとっては，口頭説明に加え，視覚的に波形情報を術者に提示できることで負担の軽減になった.

⑤ 表示できるレイアウトに制限があるため，多くの波形情報を術野に描写すると術野映像全面に情報が表示されるので，術野が煩雑になってしまうことがあった.

⑥ 接続しても表示されない，接続しても直ちに切断されてしまうなどの接続トラブルも発生した.

考　察

術者は従来と異なり，手術操作を行いながらモニタリング技師とともに同時に波形確認をすることが可能となった．また，Stoecklein VM らも inomed 社製の術中神経機能検査装置 (ISIS IOM Neuromonitoring System) を Super-imposed system によって顕微鏡画面に波形情報を投影することがモニタリング師と術者間の波形情報の伝達遅延と伝達エラーを回避するのに効果的であると報告している [1]．一方で表示レイアウトが限られるため手術開始前に術者と共有したい波形を最適化すると同時に，メーカーにも表示させたいレイアウトの要望をあげて改善を図っていく必要を感じた.

参考文献

1. Stoecklein VM, Faber F, Koch M, Mattm?ller R, Schaper A, Rudolph F, Tonn JC, Schichor C. Optional real-time display of intraoperative neurophysiological monitoring in the microscopic field of view: avoiding communication failures in the operating room. Acta Neurochir (Wien). 2015 Nov;157(11):1843-7.

周術期管理センターにおける麻酔説明端末の設置から考える業務の DX 化

河田 大輝，川西 秀明，川口 晶彦

背 景

当院の周術期管理センターでは業務効率の改善を図るべく，DX 化への取り組みを進めている．過去に取り組みの一環として案内ロボット (pepper) の運用試験を実施した際には「ロボットの動きが説明動画の理解の妨げになる」といった端末仕様について改善が必要とするフィードバックが得られた [1]．その他，端末のリース料等を含めたランニングコストの高さが課題となった．今回我々は案内ロボット導入事例を踏まえて新たな端末を自作し，運用に必要となる要件や周術期管理センターの業務の将来像について検討した．

方 法

設計にあたっての要件は着座姿勢でタッチ操作が可能な大画面を備えた可搬式の端末に任意の情報にアクセスが可能な UI を搭載するものとし，端末の完成後は実際に周術期管理センターに設置して使用者から意見聴取を行った．

結 果

端末は 21.5 インチモバイルモニター，Raspberry Pi 4 Model B/8GB，キャスター付きモニタースタンドを用いて構築した (図)．操作方式は画面タッチとした．案内コンテンツは Canva®(Canva inc. オーストラリア) を用いて web ページとして作成した．端末の電源を入れるとコンテンツを web ブラウザで自動表示し，選択した麻酔法について動画が流れる形式としている．術前診察を待つ患者が自ら端末を操作し，麻酔情報にアクセスする運用を想定し，周術期管理センターの待合スペースに設置した．端末の設置後に使用者数名から意見聴取を行ったところ，術前外来での説明で分かりにくかった内容についての復習に活用できたという意見やタッチ操作に馴染みのない使用者から使用法がわからないといった意見が寄せられた．

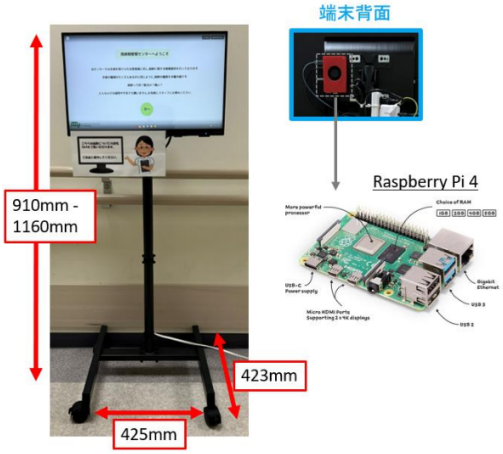

図 1．端末構成

考 察

今回作製した端末は市販品を用いて構築したことで価格が抑えられた．また UI に Canva を採用したことによりノンプログラミングで任意のデバイスからコンテンツの編集が可能となった．運用面においては画面デザインの意図が伝わらないケースが見られたほか，特定箇所のタッチで意図しない挙動をする誤作動といった UI デザイン面で課題を残す結果となった．デザインや機能については患者満足度や理解度を評価しつつ今後改善を進めていく必要がある．

ベルランド総合病院 麻酔科

結　語

市販品を用いて汎用的な説明端末を作製することができた．業務 DX 化にあたっては患者満足度や理解度を評価しつつ進めていく必要がある．

引用文献

1. Kawanishi H, Ida M, et al : A Questionnaire Survey on Anesthesia Explanations Provided by a Robot before Anesthesiology Consultations. J Clin Anesth vol.42 : 232-237 2022

手術時間管理システム (いいね・わるいね) の開発

讃岐 美智義，高橋 直之*，足立 雄平*

はじめに

効率的な手術室運営の基本は定時内に手術を収めることである．手術予定時間と実施時間の差異が大きいことは定時内の手術終了の目途の把握を困難にする．

そこで今回，術者が宣告する手術予定時間と手術実施時間が手術室全体でリアルタイムに把握できるシステムが必要と考え，富士フィルムメディカル IT ソリューションズ社と共に手術時間の乖離をステータスモニターに表示するシステムを開発し，2022 年 1 月から運用を開始した．

本システム導入前と導入後の手術予定時間と手術実施時間について検討したのでシステムの概要とあわせて報告する．

方　法

術者が執刀直前に申告した手術予定時間 (予定時間) を看護師が PC に入力し，麻酔科医が麻酔記録に記録する入室から退室までのイベント時刻入力をステータスモニターに反映 (図 1) した．ステータスは手術室内の廊下のモニターおよび電子カルテに公開しリアルタイムに全手術室の利用状況が表示される (図 2) 仕様とした．

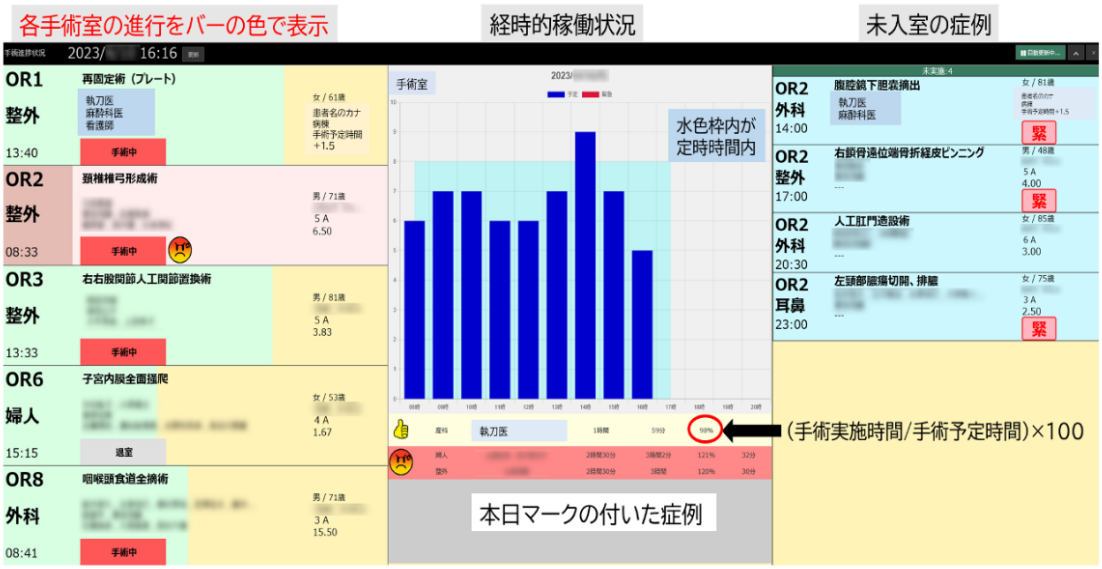

図 1．手術室ステータスモニター (平日・日勤中)

また，手術終了時に予定時間の 90~100%であった場合を理想の時間として，いいねマーク (図 3) が表示され，手術実施時間 (実時間) が予定時間の 120%を超えた場合と 200%を超えた場合には，怒りマークと激怒マーク (図 3) がそれぞれ表示される仕様とした．データは自動集計され，独自のポイント計算 (図 4) を行うことで主治医別や診療科別にリスト表示することも可能とした．本システム導入前の 2021 年と導入後の 2022 年のタイムアウト時に宣言した予定時間と実時間の差異およ

NHO 呉医療センター 麻酔科
*富士フィルムメディカル IT ソリューションズ

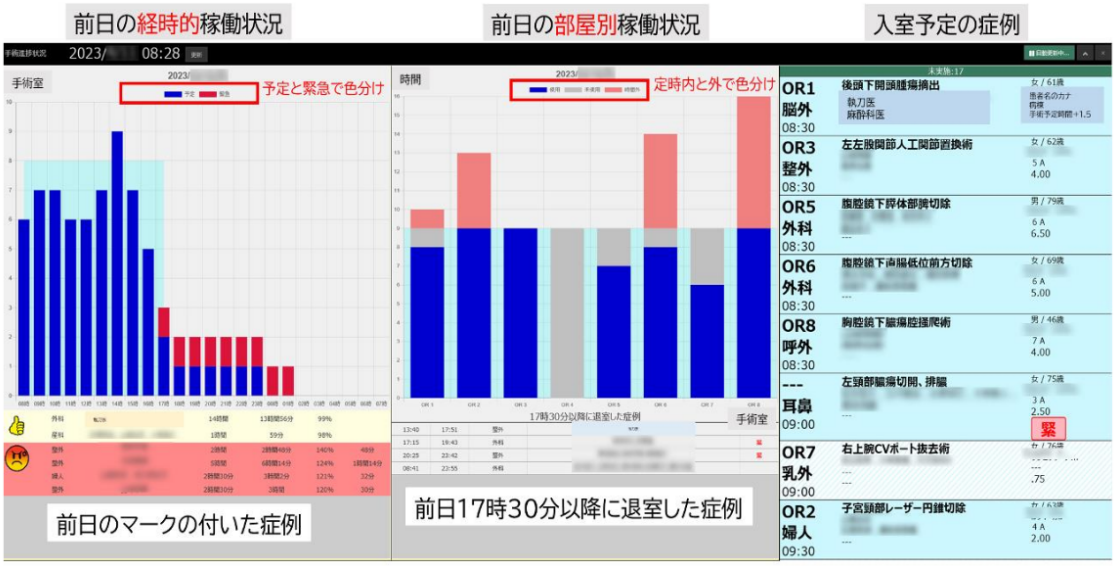

図 2. 手術室ステータスモニター (翌朝・手術室患者入室前)

び，導入後の 2022 年と 2023 年を比較し予定時間の超過割合，科別の予定時間と実時間の差異を検討した．

結　果

実時間/予定時間は，2021 年が 87.4 ± 37.5%であったのに対して，2022 年は 91.1 ± 33.7%と実時間に近づき，ばらつきも減少した (表)．導入後の予定時間の超過割合は，2022 年が，34.4 %であったのに対して 2023 年は 40.3 %と増加したが，手術件数の多い上位 3 診療科 (整形外科，外科，耳鼻咽喉科) では，いずれの診療科も予定時間と実時間の差異はそれぞれ，-8.1 分，-6.9 分，-4.5 分と減少した．

考　察

導入初年度は，新しい手術時間管理システムにより予定時間と実施時間の差が小さくなっただけでなく，ばらつきも減少した．これは，システム導入により手術時間宣言の正確性に対する術者の意識づけができたと考えられる．導入 2 年目は，1 年目と同じ術者であった診療科はさらに差分が

図 3. いいね、怒り、激怒マーク

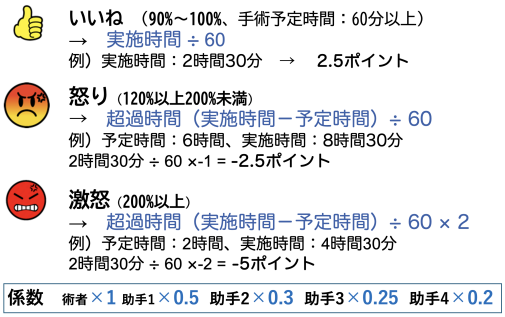

図 4. ポイントの集計方法

表 . 診療科別タイムアウト時間推移

	2021	2022	
手術件数	2400	2482	
予定時間 (min)	163.7±108.0	158.1±102.9	n.s
実施時間 (min)	149.1±124.9	148.4±115.1	n.s
実施時間/予定時間 (%)	87.4±37.5	91.1±33.7	p<0.00001

予定時間、実施時間、実施時間/予定時間はmean±SD

少なくなったが，術者の入れ替わりがあった診療科は差分が増大した．術者の入れ替わりにより，手術時間を正確に宣言する意識付けのない術者で

は，システムの効果が享受できないことを示している．手術時間宣言の正確性に対する術者の意識づけを行うためには，システムの意図を新たな術者に説明する機会が必要と考えられた．

結　論

新しい手術時間管理システムを開発した．本システム導入により，手術時間宣言の正確性に対する術者の意識づけに貢献できる．

ABSTRACT

Development of surgical time management system (good or bad)

*Michiyoshi Sanuki,†Naoyuki Takahashi, †Yuhei Adachi

The basis of efficient operating room operations is to complete surgeries on time. The large discrepancy between the scheduled operation time and the actual operation time makes it difficult to grasp the prospect of completing the operation on time.

Therefore, we developed a system in cooperation with Fujifilm Medical IT Solutions Co., Ltd. to display the discrepancy between the scheduled operation time and the operation time on a status monitor in real time in the operating room, and started its operation in January 2022.

In the first year of implementation, the new surgical time management system not only reduced the difference between the scheduled time and the actual time, but also decreased the variation.

This system contributes to the awareness of surgeons regarding the accuracy of surgical time declarations.

**Department of anesthesiology, Critical Care and Pain Medicine, NHO Kure Medical Center and Chugoku Cancer Center*
†FUJIFILM Medical IT Solutions Co., Ltd.

連絡先：
讃岐美智義
737-0023 広島県呉市青山町 3 番 1 号
NHO 呉医療センター麻酔科
Phone: 0823-22-3111
FAX: 0823-21-0478
e-mail: msanuki@msanuki.com

全身麻酔維持中の患者状態の数値化の試み

讃岐美智義，高橋直之*，足立雄平*

はじめに

全身麻酔中の患者状態のモニター異常値の検出は，現状では麻酔チャートを開いて全体を概観するしか方法はない．そこで，全身麻酔中のモニター数値を逐次評価して総合得点としてスコア化することで，モニター値の異常が継続した症例を発見できる可能性を探る．

麻酔維持 (手術開始-手術終了) のフェーズについて全身麻酔状態を数値化して表現し，一定範囲を長時間逸脱した状態にある症例の検出を試みた．

方法と結果

循環，呼吸，体温，麻酔深度，筋弛緩の 5 項目につき，一定範囲を逸脱が 3 分以上継続した時間を累積し，減点法で評価し，各項目の合計の平均を算出 (図 1，表) した．

BIS	乖離度の例	減点方法
減点方法	BIS=39以下61以上が3分未満	減点なし
	BIS=35～39/61～65が3分以上	－２０点×（継続時間／手術時間）
	BIS=30～34/66～70が3分以上	－５０点×（継続時間／手術時間）
	BIS＝29以下71以上が3分以上	－１００点×（継続時間／手術時間）

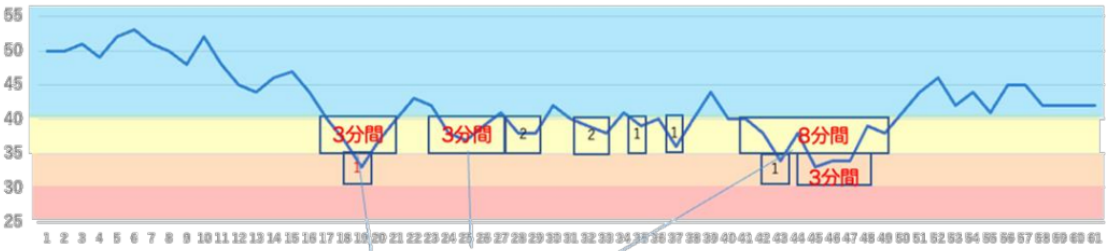

乖離度小の継続時間＝3分間＋３分間＋（８分間－３分間）＝１１分間
乖離度中の継続時間＝3分間
スコア＝100点－20点×(11分／60分)－50点×(3分／60分) ＝100-3.7-2.5 = 93.8点

図 1．手術中の患者状態スコア算出方法 (BIS) の概要

手術中のモニター数値が最初から最後まで正常範囲内であった症例を 100 点満点とし，正常範囲から乖離していた時間の長さと乖離の大きさに従い減点方式でスコアを算出し，偏差値に変換した．偏差値の低い症例は，手術終了後に表示されるリスト上で目立つ様に色分けして表示 (図 2) した．

サマリ画面として，それぞれの項目の術中経過のグラフと点数，最大値，最小値等を表示できるようにし，術中の変化もグラフ化表示 (図 3) した．得られた数値が低いものに関して，グラフ化表示を確認し，原因別に分類した．

考　察

麻酔のエンドポイントについて，過去には体動の抑制および血圧や脈拍のおおよそのコントロールであった．これが現在では周術期アウトカムの

NHO 呉医療センター麻酔科
*富士フィルムメディカル IT ソリューションズ

表. 正常範囲と減点対象範囲 (正常範囲は変更可能)

分類	項目	正常範囲	乖離度小 -20 点	乖離度中 -50 点	乖離度大 -100 点
循環	HR	40≦n≦120	35≦n＜40 120＜n≦130	30≦n＜35 130＜n≦140	n＜30 140＜n
	ART(M)	65≦n	60≦n＜65	55≦n＜60	50≦n＜55
	NIBP(M)	65≦n	60≦n＜65	55≦n＜60	50≦n＜55
呼吸	EtCO2	30≦n≦40	25≦n＜30 40＜n≦45	20≦n＜25 45＜n≦50	n＜20 50＜n
	SpO2	90≦n≦100	85≦n＜90	80≦n＜85	n＜85
体温	T1/T2	36.0≦n≦39.0	35.5≦n＜36.0 39.0＜n≦39.5	35.0≦n＜35.5 39.5＜n≦40.0	n＜35.0 40.0＜n
麻酔深度	BIS	40≦n≦60	35≦n＜40 60＜n≦65	30≦n＜35 65＜n≦70	n＜30 70＜n
	PSI	25≦n≦50	20≦n＜25 50＜n≦55	15≦n＜20 55＜n≦60	n＜15 60＜n
	SR	0≦n≦1	1＜n≦2	2＜n≦3	3＜n
筋弛緩	TOF(Count)	0≦n≦2	2＜n≦3	3＜n≦4	4＜n
	T1%	0≦n≦30	30＜n≦35	35＜n≦40	40＜n

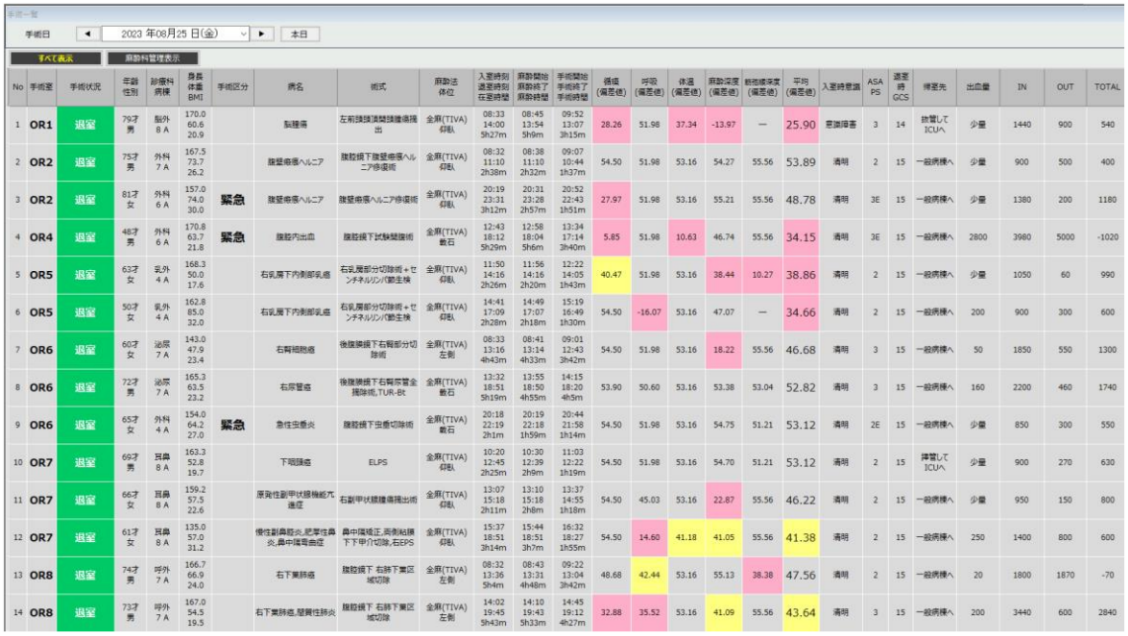

手術日 ◀ 2023 年08月25 日(金) ▶ 本日

すべて表示 麻酔科管理表示

No	手術室	手術状況	年齢 性別	診療科 病棟	身長 体重 BMI	手術区分	病名	術式	麻酔法 体位	入室時刻 退室時刻 在室時間	麻酔開始 麻酔終了 麻酔時間	手術開始 手術終了 手術時間	循環 (偏差値)	呼吸 (偏差値)	体温 (偏差値)	麻酔深度 (偏差値)	筋弛緩率度 (偏差値)	平均 (偏差値)	入室時意識	ASA PS	退室時 GCS	帰室先	出血量	IN	OUT	TOTAL
1	OR1	退室	79才 男	脳外 8 A	170.0 60.6 20.9		脳腫瘍	左前頭頭頂葉頭蓋骨摘出	全麻(TIVA) 仰臥	08:33 14:00 5h27m	08:45 13:54 5h9m	09:52 13:07 3h15m	28.26	51.98	37.34	-13.97	—	25.90	意識障害	3	14	挿管して ICUへ	少量	1440	900	540
2	OR2	退室	75才 男	外科 7 A	167.5 73.7 26.2		腹壁瘢痕ヘルニア	腹壁瘢痕ヘルニア修復術	全麻(TIVA) 仰臥	08:32 11:10 2h38m	08:38 11:10 2h32m	09:07 10:44 1h37m	54.50	51.98	53.16	54.27	55.56	53.89	清明	2	15	一般病棟へ	少量	900	500	400
3	OR2	退室	81才 女	外科 6 A	157.0 74.0 30.0	緊急	腹壁瘢痕ヘルニア	腹壁瘢痕ヘルニア修復術	全麻(TIVA) 仰臥	20:19 23:31 3h12m	20:31 23:28 2h57m	20:52 22:43 1h51m	27.97	51.98	53.16	55.21	55.56	48.78	清明	3E	15	一般病棟へ	少量	1380	200	1180
4	OR4	退室	48才 男	外科 6 A	170.8 63.7 21.8	緊急	腹腔内出血	腹腔鏡下試験開腹術	全麻(TIVA) 砕石	12:43 18:12 5h29m	12:58 18:04 5h6m	13:34 17:14 3h40m	5.85	51.98	10.63	46.74	55.56	34.15	清明	3E	15	一般病棟へ	2800	3980	5000	-1020
5	OR5	退室	63才 女	乳外 4 A	168.3 50.0 17.6		右乳房下内側部乳癌	右乳房部分切除術＋センチネルリンパ節生検	全麻(TIVA) 仰臥	11:50 14:16 2h26m	11:56 14:16 2h20m	12:22 14:05 1h43m	40.47	51.98	53.16	38.44	10.27	38.86	清明	2	15	一般病棟へ	少量	1050	60	990
6	OR5	退室	50才 女	乳外 4 A	162.8 85.0 32.0		右乳房下内側部乳癌	右乳房部分切除術＋センチネルリンパ節生検	全麻(TIVA) 仰臥	14:41 17:09 2h28m	14:49 17:07 2h18m	15:19 16:49 1h30m	54.50	-16.07	53.16	47.07	—	34.66	清明	2	15	一般病棟へ	200	900	300	600
7	OR6	退室	60才 女	泌尿 7 A	143.0 47.9 23.4		右腎結石症	後腹膜鏡下右腎部分切除術	全麻(TIVA) 左側	08:33 13:16 4h43m	08:41 13:14 4h33m	09:01 12:43 3h42m	54.50	51.98	53.16	18.22	55.56	46.68	清明	3	15	一般病棟へ	50	1850	550	1300
8	OR6	退室	72才 男	泌尿 7 A	165.3 63.5 23.2		右尿管癌	後腹膜鏡下右腎尿管全摘除術, TUR-Bt	全麻(TIVA) 砕石	13:32 18:51 5h19m	13:55 18:50 4h55m	14:15 18:20 4h5m	53.90	50.60	53.16	53.38	53.04	52.82	清明	3	15	一般病棟へ	160	2200	460	1740
9	OR6	退室	65才 女	外科 4 A	154.0 64.2 27.0	緊急	急性虫垂炎	腹腔鏡下虫垂切除術	全麻(TIVA) 砕石	20:18 22:19 2h1m	20:19 22:18 1h59m	20:44 21:58 1h14m	54.50	51.98	53.16	54.75	51.21	53.12	清明	2E	15	一般病棟へ	少量	850	300	550
10	OR7	退室	69才 男	耳鼻 8 A	163.3 52.8 19.7		下咽頭癌	ELPS	全麻(TIVA) 仰臥	10:20 12:45 2h25m	10:30 12:39 2h9m	11:03 12:22 1h19m	54.50	51.98	53.16	54.70	51.21	53.12	清明	2	15	挿管して ICUへ	少量	900	270	630
11	OR7	退室	66才 女	耳鼻 8 A	159.2 57.5 22.6		原発性副甲状腺機能亢進症	右副甲状腺腫瘍摘出術	全麻(TIVA) 仰臥	13:07 15:18 2h11m	13:10 15:18 2h8m	13:37 14:55 1h18m	54.50	45.03	53.16	22.87	55.56	46.22	清明	2	15	一般病棟へ	少量	950	150	800
12	OR7	退室	61才 女	耳鼻 8 A	135.0 57.0 31.2		慢性副鼻腔炎,肥厚性鼻炎,鼻中隔弯曲症	鼻中隔矯正,両側粘膜下下甲介切除,ESPS	全麻(TIVA) 仰臥	15:37 18:51 3h14m	15:44 18:51 3h7m	16:32 18:27 1h55m	54.50	14.60	41.18	41.05	55.56	41.38	清明	2	15	一般病棟へ	250	1400	800	600
13	OR8	退室	74才 男	呼外 7 A	166.7 66.9 24.0		右下葉肺癌	腹腔鏡下 右肺下葉区域切除	全麻(TIVA) 左側	08:32 13:36 5h4m	08:43 13:31 4h48m	09:22 13:04 3h42m	48.68	42.44	53.16	55.13	38.38	47.56	清明	2	15	一般病棟へ	20	1800	1870	-70
14	OR8	退室	73才 男	呼外 7 A	167.0 54.5 19.5		右下葉肺癌,壁胸性肺炎	腹腔鏡下 右肺下葉区域切除	全麻(TIVA) 左側	14:02 19:45 5h43m	14:10 19:43 5h33m	14:45 19:12 4h27m	32.88	35.52	53.16	41.09	55.56	43.64	清明	3	15	一般病棟へ	200	3440	600	2840

図 2. 症例の一覧表示（点数の悪い項目を赤、黄色で表示

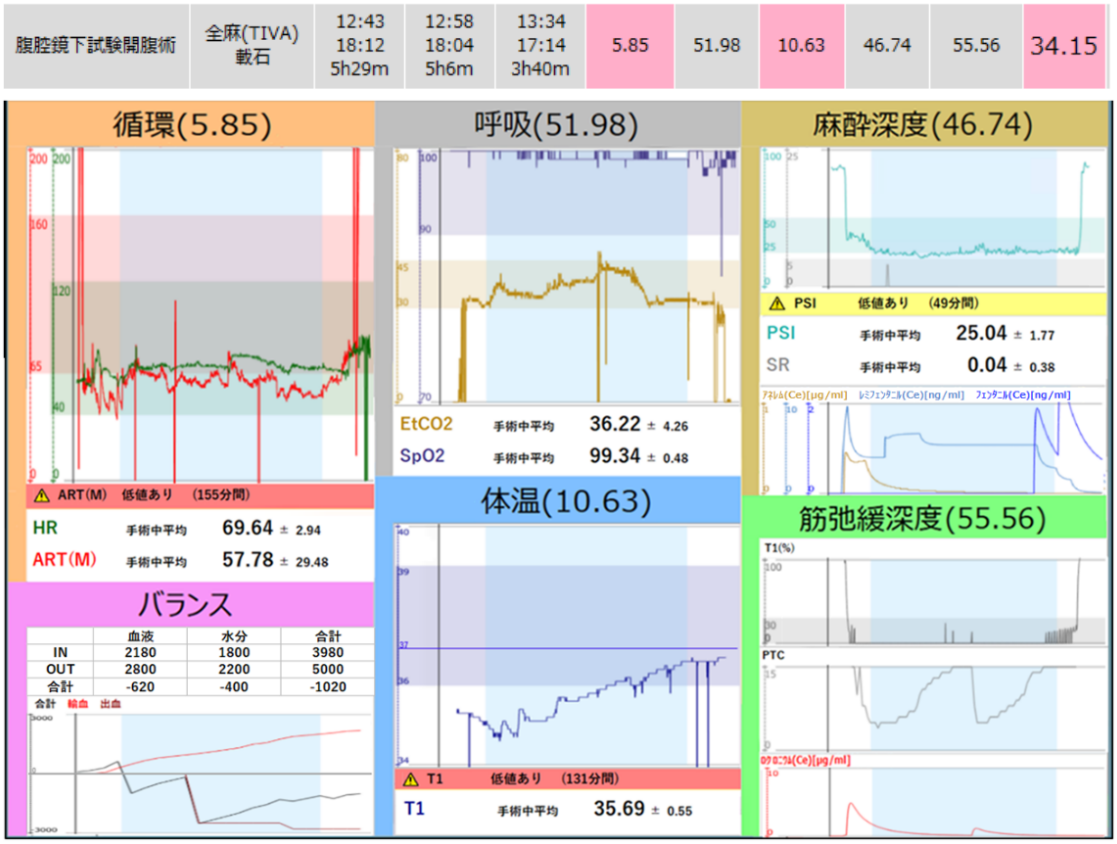

図 3. 術中サマリー画面（術中出血量が 2800mL）

向上と地球環境への配慮へと変化してきた．具体的には，適切な麻酔深度を維持し，早期の術後回復 (PONV や術後疼痛管理，術後せん妄の予防，早期離床)，十分な鎮痛，鎮静によるストレス反応の抑制 (麻酔による厳密な生体コントロール)，適正輸液，体温管理，平均血圧の維持 (体内環境の適正化・厳格化) などである．すなわち，現代では全身麻酔管理中に求められるものが多岐にわたるだけでなく，厳格化してきたことを示している．これを麻酔の質と表現するなら，術中の全身状態を数値化が必要とされることは明らかである．患者状態の数値化は，全状状態をよい状態に保ちつつ，患者によい手術環境を提供することにつながると考えた．

今回，その試みとして循環，呼吸，体温，麻酔深度，筋弛緩の 5 項目につき，一定範囲を逸脱が 3 分以上継続した時間を累積し，減点法で評価した．素点でのみ評価すると点数のみの比較となるため，過去症例と比較する偏差値を採用した．95 %タイル以上の乖離は偏差値が 40 未満となり 99 %タイル以上の乖離が 30 未満となるため偏差値の低い症例を抽出しやすくなると考えた．実際，手術終了後に表示されるリスト上で目立つ様に色分けして表示することで，リスト上でどの項目に異常値が継続しているのかを一目で見つけることが可能であった．

結　語

全身麻酔中の患者状態をスコア化することで，麻酔維持中に異常値が継続した症例をリスト表示から見分けることが容易でなった．また，手術終

了時に表示される術中サマリ画面により，循環，呼吸，体温，麻酔深度，筋弛緩の項目ごとに術中経過をわかりやすく表示できた．

ABSTRACT

Attempt to automatically convert and display numerical values of patient status during maintenance of general anesthesia at the end of surgery

*Michiyoshi Sanuki,†Naoyuki Takahashi, †Yuhei Adachi

Currently, the only way to detect abnormalities in monitored patient status during general anesthesia is to open the anesthesia chart and look through the entire anesthesia record. Therefore, we attempted to detect cases with ongoing abnormal monitor values by sequentially evaluating monitor values during general anesthesia and scoring them as an overall score at the end of surgery.

For the five items of circulation, respiration, temperature, anesthesia depth, and muscle relaxation as the general anesthesia state during the anesthesia maintenance period from the start of surgery to the end of surgery, the time when the anesthesia state deviated from a certain range for more than 3 minutes was accumulated and evaluated using the point reduction method. Since evaluation using only the prime scores would result in a point-only comparison, deviation values were employed for comparison with past cases.

As a result, by sequentially scoring patient conditions during general anesthesia, it became easier to find cases with continued abnormal values during anesthesia maintenance. The intraoperative summary screen displayed at the end of the surgery was able to clearly display intraoperative progress for each of the following items: circulation, respiration, body temperature, anesthesia depth, and muscle relaxation monitoring.

**Department of anesthesiology, Critical Care and Pain Medicine, NHO Kure Medical Center and Chugoku Cancer Center*
†FUJIFILM Medical IT Solutions Co., Ltd.

連絡先：
讃岐美智義 737-0023 広島県呉市青山町 3 番 1 号
NHO 呉医療センター麻酔科

心臓植込み型電気デバイス一括管理ソフト ORFICE の導入と展望

三浦晃裕，黒川宗雄，前川敦史，楠井敏之，
松本佳子，小西康司，畠中利英，川口昌彦†

緒　言

全国の植込み型ペースメーカ等の心臓植込み型電気デバイス (Cardiac implantable electric device: CIEDs) の植込み患者数は年々増加しており，それに伴い当院ても管理するべき CIEDs 植込み患者数も増加の一途を辿っている．また平成 30 年度の診療報酬改定により CIEDs の遠隔モニタリンク (Remote Monitoring System: RMS) 加算か算定可能となり，CIEDs 植込み患者に対する RMS による遠隔の情報管理も必須となっている．これら CIEDs 植込み患者の管理と RMS による遠隔の情報管理は各医療機関において重要てあるが施設により管理方法は様々で，自作の filemaker や Excel 等てデータベースを作成し管理している施設が比較的多く見受けられる．

現在の運用

当院では平成 24 年に臨床工学技士が CIEDs 関連業務に従事してからデータベースを使用した患者管理は行なっておらず，CIEDs の定期的なデバイスチェック等の情報は電子カルテに都度記載している．また RMS による遠隔の情報は印刷し画像情報として取り込む事で電子カルテに載せているのが現状てある．電子カルテへの都度記載は他の診療情報と情報が混在してしまい，CIEDs 植込み患者管理の点では問題があり，データベースとしての機能を有していない．また RMS による遠隔の情報を印刷してから画像として取り込む方法は電子テータを印刷し再度電子テータとして電子カルテに取込む非効率な時間と用紙，毎月の印刷用紙枚数が 3,000 枚程となっておりコストの点に問題がある．

奈良県立医科大学附属病院 医療技術センター
†奈良県立医科大学附属病院 麻酔科学教室

システム導入

今回当院ては「株式会社 NEXIS 社製ペースメーカ遠隔モニタリンク一元管理システム ORFICE(以下 ORFICE)」を 2023 年 9 月より導入しデータベース兼 RMS 管理システムとして運用を開始した．

ORFICE の特徴

本システムにより可能となる事は ① RMS データの自動収集とデータベース化がある．ペースメーカ各社様のサーバに蓄積された RMS データおよび PDF レポートを自動収集しデータベースに登録する．遠隔モニタリング業務で最も負担の大きい”各メーカー専用サイトの個別訪問”，”遠隔モニタリングレポートの紙管理” が不要とする事が出来る． ② 必要事項を電子カルテにワンクリック転送が可能になる．RMS 指導管理の実績としてカルテ記載が必要とされているが，記載に必要な要素を電文およびファイル形式で電子カルテに転送可能である．所見コメントの定型文入力機能と合わせて，カルテ記入の負担を低減する事が出来る． ③ 入力支援機能の充実がある．これは RMS データへの所見コメントを定型文登録して簡単に入力することが可能となる．またこれは臨床工学技士のコメント，医師のコメントを別個に登録可能となっている．その他にも電子カルテ連携により患者基本情報取得，バーコードによるデバイス・リード情報入力，デバイス設定のテンプレート入力など，各種支援機能を搭載している． ④ 大量のデータ管理やチームでの分担管理の円滑化の機能を有している．これはレコード検索機能に加え，規定条件に該当するレコードのハイライ

ト機能や ME チェック→医師チェックのようなチームでの分担管理機能を実装している．RMS 件数が大量な場合でも，チームで効率的な RMS のワークフローを実現できる．⑤手術情報・外来チェックデータも一元管理となる．RMS データだけでなく，手術情報，デバイス・リード情報(スペック，設定など)，プログラマーから出力される外来チェックレポートなど，ペースメーカ管理に必要なあらゆる情報をワンストップ管理出来る．要件ごとに複数の帳簿を使い分ける手間を回避することが可能となる．⑥RMS 加算請求内容を自動算定出来る．RMS 加算の請求内容は，カルテで過去の指導管理実績を 1 件ずつ確認し手計算するのが一般的であるが，これは手間がかかる作業となる．「ORFICE」を活用する事ができれば請求内容は患者ごとに自動算定され一覧表示される．これにより医事課スタッフは手間なく確実に請求を行うことが出来る．

ORFICE データフロー概要

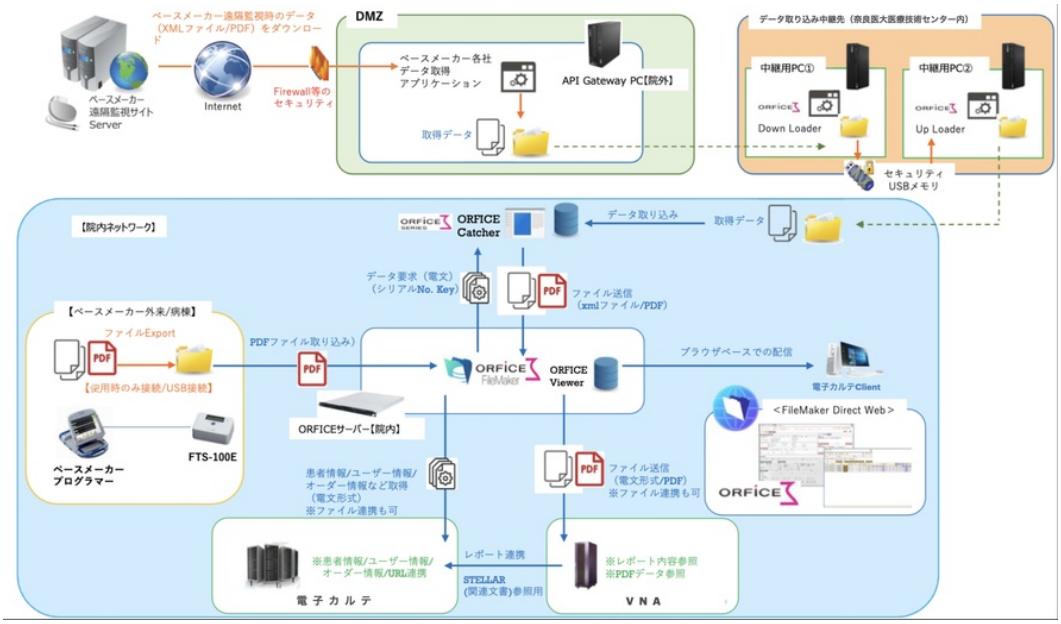

図．ORFICE データフロー概要

セキュリティ

院外ネットワークと院内電子カルテ系に情報を持ち込むため，情報セキュリティ対策は必須となる．ORFICE では以下 3 点で情報セキュリティの対策を取っている．①外部インターネット上にある「PM 各社の遠隔サイト」と「ORFICE 院外用サーバ」との間には VPN ルータを設置し，通信制限を行っている．②「ORFICE 院外用サーバ」と院内電子カルテ系ネットワーク環境に参加している「ORFICE 院内用サーバ」とは，物理的に切り離し，データの受け渡しは院内のセキュリティーポリシーに準拠したセキュリティ USB にて人的作業で行っている．③一貫してデータの流れは「外部」→「ORFICE 院外用サーバ」「ORFICE 院外用サーバ」→「ORFICE 院内用サーバ」と一方通行である．

ORFICE の特徴に対する当院の現状

①RMS データの自動収集とデータベース化に関しては，現在 RMS データの自動収集とデータ

ベース化は完了している．②必要事項を電子カルテにワンクリック転送が可能な点に関しては，RMS 指導管理の実績としてカルテ記載が必要とされているが，所見コメントの定型分登録が打ち合わせ中のため，コメントは必要に応じた電子カルテへの都度記載が続いている現状である．③入力支援機能の充実の点に関しては，電子カルテ連携・バーコードによるデバイス・リード情報入力の運用が開始出来ている．しかし入力支援機能のうち定型分登録やデバイス設定のテンプレート入力等の定型分内容が打ち合わせ中のため運用保留中となっている．④大量のデータ管理やチームでの分担管理の円滑化の機能は，レコード検索機能や規定条件に該当するレコードのハイライト機能の活用は行えているが，ME チェック→医師チェックのようなチームでの分担管理機能は現在運用開始段階であり，円滑なチームでの分担管理機能は活用できていない段階にある．ワークフローが課題となっている．⑤手術情報・外来チェックデータも一元管理可能な点に関しては，ORFICE は RMS データだけでなく，手術情報，デバイス・リード情報 (スペック，設定など)，プログラマーから出力される外来チェックレポートなども一元管理する事が可能であるが現在は外来での運用が開始出来ていないため，外来で運用を開始し全ての情報を一元管理する事が課題となっている．⑥RMS 加算請求内容を自動算定可能となる機能に関しては，「ORFICE」を活用する事ができれば請求内容は患者ごとに自動算定され一覧表示され確実に請求を行うことが出来るが，現在はデバイス外来での運用が開始出来ていないため，RMS 加算請求の自動化が課題となっている．

ORFICE に対する当院の課題

現在データベース化は完了しているがデバイス外来での運用が出来ていない．そのためデバイス外来で必要となる RMS 加算請求の自動算定化の機能も活用できていない状態にある．また定型分登録やデバイス設定のテンプレート入力等の定型分内容が打ち合わせ中のため運用保留中となっている．デバイス外来での ORFICE 運用開始の課題の具体的な点は，循環器内科外来に対する LAN ポートの開設工事やネットワーク設定等のハード面の理由が大きい．これら課題に対応し ORFICE の機能を十分に活用した患者管理を行える体制を築く必要がある．

結　語

ORFICE の運用開始後の当院での現状と課題を報告した．今後 ORFICE の機能を十分に活用し，増加する CIEDs 植込み患者管理に繋けていきたい．

汎用シミュレーションソフトを利用した輸液調節アルゴリズムの評価法の開発

森主 絵美*，畔柳 綾†，長田 理‡

はじめに

輸液投与を合理的に調整するには，客観的指標と指標に基づいた輸液速度調節アルゴリズムの検証が必要である．輸液速度の調節には，GDFT などの指標を用いた輸液速度調節が報告されているが，現段階で確立された指標は存在せず，経験的判断による輸液速度の調節が行われることが多い．今回，臨床前検証を目的として，指標に基づいた輸液速度調節アルゴリズムを用いて，アルゴリズムの臨床的妥当性を評価する方法を開発した．評価方法の開発を目的とするため，評価に用いる輸液速度調節アルゴリズムはシンプルなアルゴリズムとした．

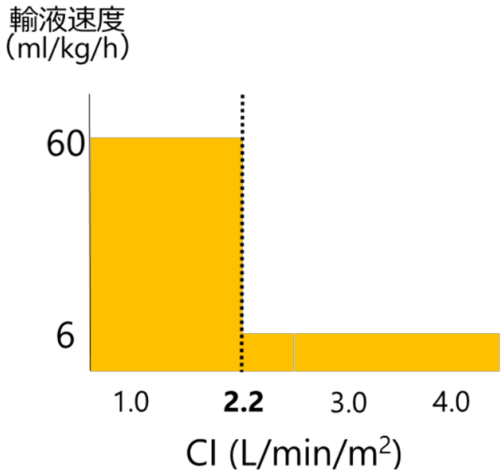

図 1．輸液投与速度の説明（50kg の例）

方　法

Windows11 環境下で動作する ExtendSim CP (extendsim®)v10.1.0 (Imaging That Inc., USA) を使用して，以下に示す 2 つのシミュレーションモデルを作成した．

1. 輸液制御モデル：CI≧2.2 (L/min/m^2) を維持する輸液投与調節アルゴリズム．
2. 輸液に反応するモデル：輸液速度の変化に応じて CI が変化するモデル．

基本データには，1 分毎の MAP, HR, CI(計 100 分間) を用いて，1 分毎の MAP, 輸液速度, CI(計 100 分間) を出力した．CI には，正規分布に従う 10%の誤差変動を加えて 10 回のシミュレーションを実施し，輸液速度と CI の平均値及び標準偏差を記録した．

輸液制御モデルの作成

CI≧2.2(L/min/m^2) を維持する様に輸液速度を調整する輸液投与調節アルゴリズムを，GDFT 文献 [1] のアルゴリズムをシンプルな方法に改変して作成した．アルゴリズムを以下に示す．

* 基本の輸液速度を 250(ml/h) とする
* CI<2.2(L/min/m^2) の時点で，10 分間 3000 (ml/h) の輸液負荷を行なう．
* 10 分後に CI を再評価して 15%改善したら輸液速度を 250(ml/h) に戻す．改善がなければ 10 分間 3000(ml/h) の輸液負荷を継続する．

この輸液制御モデルを ExtendSim で記述した．

輸液反応モデルの作成

*東京大学医学部附属病院 麻酔科・痛みセンター
†埼玉協同病院 麻酔科
‡東都春日部病院 麻酔科

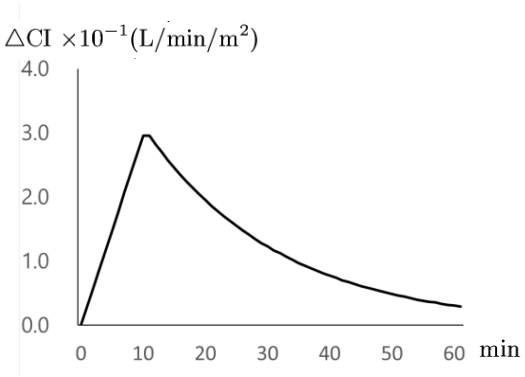

図 2. △CI の推移
(HR=60, 半減期 15 分,
輸液速度 3000ml/h あたり)

輸液速度の変化に応じて CI が変動する輸液反応モデルを作成した．輸液速度 3000ml/h (50ml/min) の輸液負荷を行うと，1 回拍出量 SV は 1 分間に Δ SV=50/HR, 1 分間に 1 回拍出係数 SVI は Δ SVI=50/HR/BSA 線形増加すると仮定した．1 分間に上昇する心係数 CI は，Δ SVI の変化量に応じて増加すると仮定した．

* 1 分間に △SV =50/HR, △SVI=50/HR/BSA 線形増加する
* 輸液負荷 1 分後の △CI=輸液負荷前の CI×(輸液負荷前の SVI+△SVI)/輸液負荷前の SVI
* 輸液負荷 10 分後の △CI=輸液負荷前の CI×(輸液負荷前の SVI+10×△SVI)/輸液負荷前の SVI

輸液負荷を中止すると，以下の式に従って指数関数的に Δ CI は漸減すると仮定した．輸液負荷中止後 t 分後の Δ CI は

* △CI = (輸液負荷終了時点の △CI $\times e^{(-kT)}$

* -kT= (10-t)× log2 ÷ T1/2 (”半減期” = T1/2)

このように輸液速度によって △CI が変化するモデルを作成した．輸液負荷開始前の CI は推定循環血液量である体重 (kg) /13 を用いて，CI= 循環血液量/BSA と仮定し，輸液負荷前の SVI= CI/HR/1000 と仮定した．

臨床データを用いた基本データの作成

基本データに用いる CI を，臨床データに基づいて作成した．

臨床データから得られる CI は輸液速度の影響を受けているため，臨床データの輸液速度情報を収集することで，基本データに用いる CI を前述した輸液反応モデルを用いて以下の式で示した．

* 基本データの CI = (臨床データの CI)-(輸液反応モデルから得られる △CI)

なお，今回の検討では CI のみを対象とし，HR,MAP は解析モデルに含めなかった．HR,MAP は臨床データを表示しやすい形に修正した．

結　果
シミュレーションから得られた輸液速度と CI の推移

輸液反応モデル，輸液制御モデル下で実行したシミュレーションの結果，後述する ①～③ の場合に得られた輸液速度と CI(Modified CI) の平均値と標準偏差を示す．推移については，1 回のシミュレーションのグラフを示し，赤が輸液投与速度，緑が基本データの CI，青が CI(Modified CI) を示す．

① 輸液投与調節アルゴリズムに従った場合 (図 3)

CI(Modified CI)2.49±0.31(L/min/m^2)，輸液速度 1875±163(ml/h) だった．輸液の急速投与により CI が上昇し，その後輸液速度は基本速度に復帰するのを繰り返す状況が確認できる．

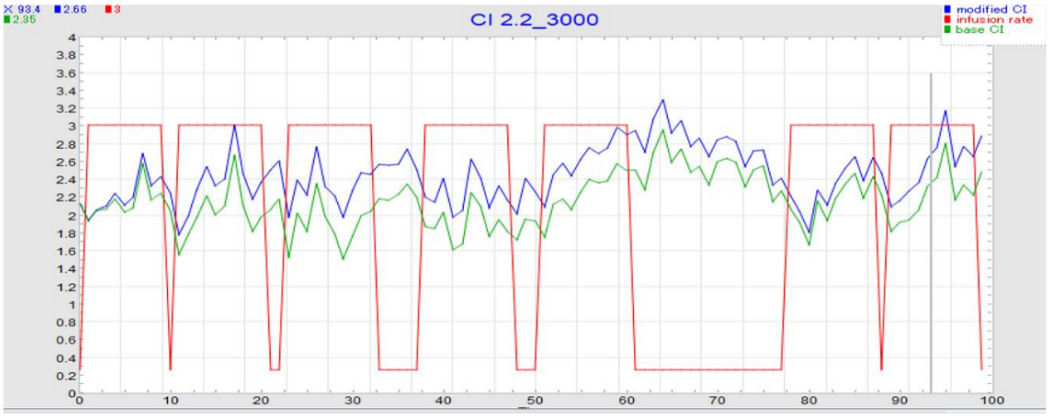

図 3. CI 閾値 2.2(L/min/m^2)，最高輸液速度 3000(ml/h) の場合

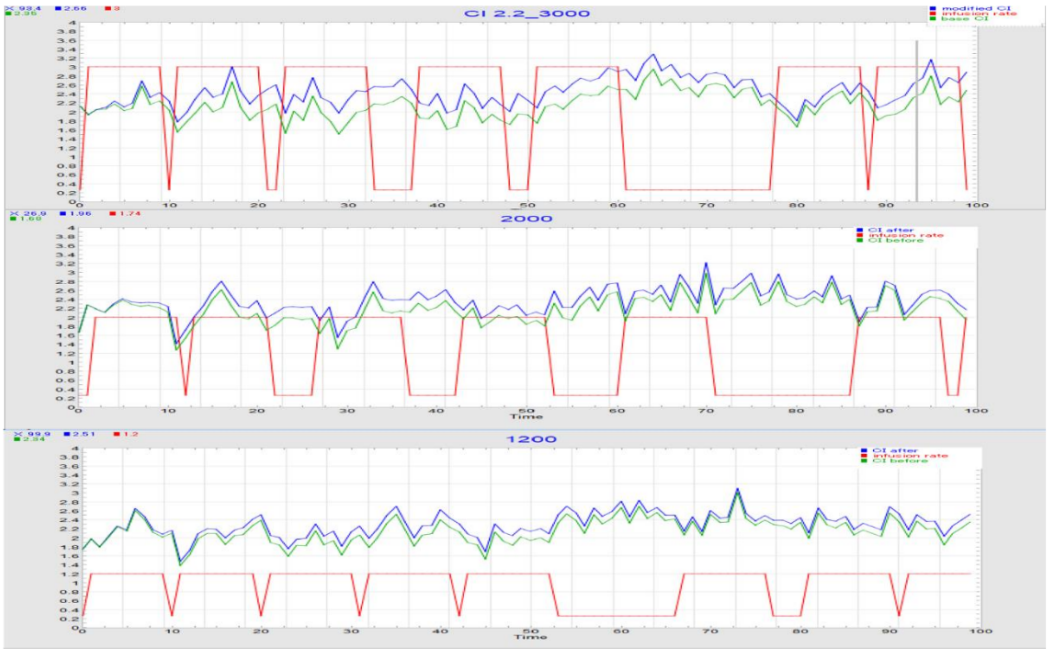

図 4. CI 閾値 2.2(L/min/m^2)，最高輸液速度 3000, 2000, 1200(ml/h) の場合

② 輸液投与調節アルゴリズムの最高速度 3000ml/h を変化させた場合 (図 4)

最高速度 2000 (ml/h) の場合, Modified CI 2.36 ±0.31 (L/min/m^2)，輸液速度 1361 ±843(ml/h) だった．最高速度 1200(ml/h) の場合，Modified CI 2.29 ±0.31 (L/min/m^2)，輸液速度 934 ±427(ml/h) だった．輸液急速投与の最高速度を減じると，CI の上昇が緩やかとなり，なかなか基本速度に復帰しない事がグラフより確認できる．

③ 急速輸液を行う CI の閾値を下げた場合の輸液速度と CI の推移 (図 5)

CI の閾値を 2.0(L/min/m^2) にした場合，Modified CI 2.39 ±0.30 (L/min/m^2)，輸液速度 1600 ±1375(ml/h) だった．CI の閾値を下げると，急速投与のタイミングが遅くなり，CI の上昇を得

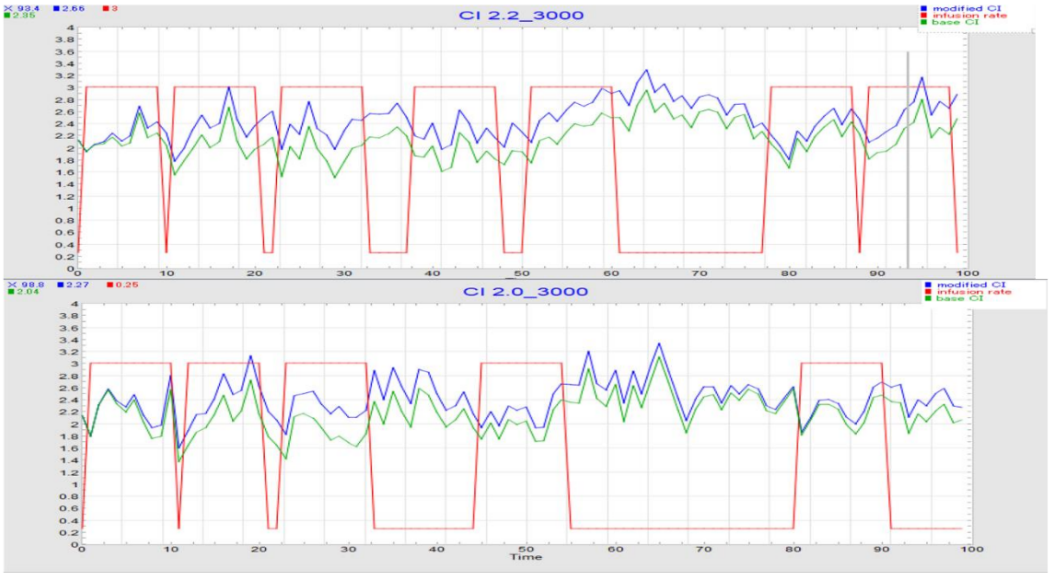

図 5. 最高輸液速度 3000(ml/h) で CI 閾値が 2.2, 2.0(L/min/m^2) の場合

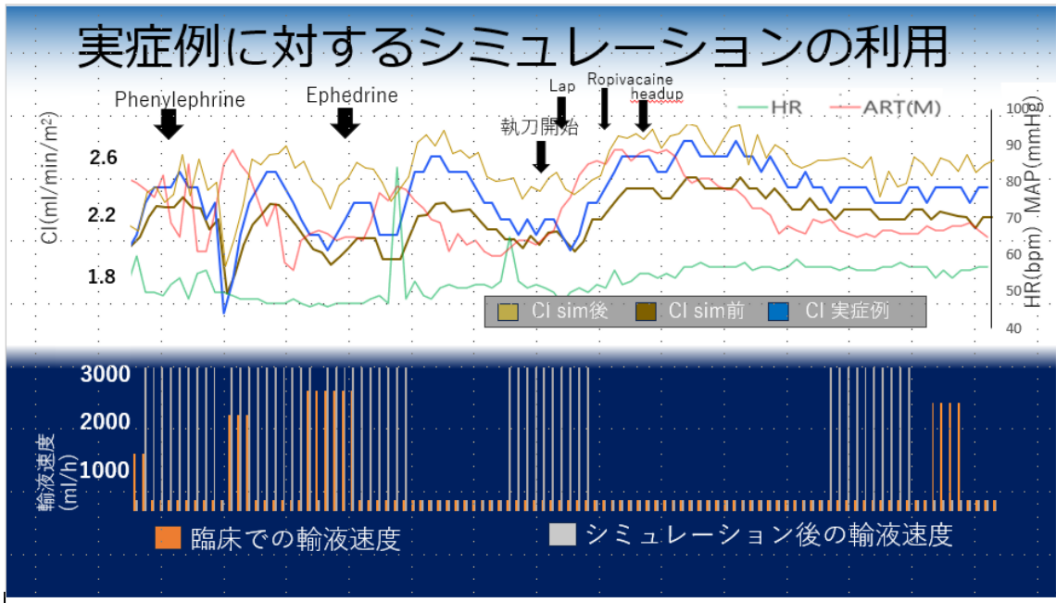

図 6.
【上部のグラフ】青：実症例の CI，茶：シミュレーションに用いた CI 基本データ，
薄茶：シミュレーションから得られた CI，赤：MAP，緑：HR
【下部のグラフ】橙：臨床での輸液速度，灰：シミュレーションから得られた輸液速度，
縦棒グラフ 1 本が 1 分間を示す

にくい事がグラフより確認できる．

実症例に対するシミュレーションの適応

輸液投与調節アルゴリズムに従った場合 (最高速度 3000(ml/h)，CI 閾値 2.2(L/min/m^2) の輸液速度と，臨床症例での輸液速度実績を比較し

た (図 6). 臨床症例では CI≧2.2(L/min/m^2) を維持する様に，輸液負荷と昇圧剤を併用して管理するものとして, 輸液負荷速度および昇圧剤の種類・および使用量は麻酔科医の判断で調節した.

症例記録を元にシミュレーションを行ったところ，実症例での CI が 2.25±0.20 (L/min/m^2) であったのに対し計算された Modified CI は 2.42±0.20 (L/min/m^2) となった．また輸液速度は，実症例で 537±705(ml/h) に対してシミュレーションでは 1598±1382(ml/h) だった．シミュレーションによる自動調節モデルでは CI の低下に対して輸液速度を増加させるが，麻酔科医が管理する臨床症例では CI が低下した場合であっても経験的判断に基づいて輸液負荷を行う状況が観察された.

考　察

今回の検討では，汎用シミュレーションソフトを用いて **1)** 輸液速度に応じて目標値 (CI) が変化するモデルを作成し，**2)** 事前に作成した輸液制御アルゴリズムに従って輸液速度を変更する際の CI の変化をシミュレーションで検討した．更に，実際に経験した臨床症例における CI の変化を本モデルに組み込み，作成した輸液制御アルゴリズムを適応した場合の輸液投与速度を実際の記録と比較することで，輸液制御アルゴリズムの妥当性について評価した.

輸液投与の合理的調節方法については，GDFT を始め様々な方法が試みられているものの，簡便な調節指標はいまだ普及しておらず，また初心者による機械的な調節が実現できるアルゴリズムも開発されていない．一方，仮に調節性の良い制御指標・アルゴリズムが考案されたとしても，いきなり臨床現場でその輸液速度調節アルゴリズムを使用するのは安全性の面から拙速であると言わざるを得ない．そこで，制御指標を元に恣意的ではない輸液速度調節アルゴリズムを開発するにあたり，輸液速度調節アルゴリズムの臨床的妥当性を評価するために汎用シミュレーションソフトを利用したシミュレーション環境を作成し，アルゴリズムを適応した場合の輸液速度の状況を検討することとした.

今回作成した輸液速度を変更した場合の CI 変動モデルは，過去の経験を汎用シミュレーションモデルで記述したものである．このモデルと共に, 過去の経験からしばしば観察される CI 変動を元にした疑似データを利用して，輸液速度調節アルゴリズムに基づく機械的な輸液速度調節を行った場合の輸液速度調節と CI の変動をシミュレーションにより解析した．今回検討した輸液速度調節アルゴリズムはほぼオン／オフ制御ではあったが，臨床的に妥当な輸液速度に変更しながらおおよそ CI を目標とする値に維持することができた.

シミュレーションを利用した検討では，事前に様々な仮定に基づく輸液速度調節アルゴリズムや輸液反応性の異なるモデル，実臨床を想定した基本データを作成するなど，麻酔中の予期せぬ状況 (例えば大出血，体位変換，生体情報が一時的に取得できない，など) においても輸液投与制御状況と (結果として得られる)CI を求めることができる．今回の検討では，実際に経験した麻酔症例から得られた輸液速度と CI のデータから，機械的な輸液投与速度調節アルゴリズムを適応した場合の輸液速度と CI の推移は，麻酔科医による輸液速度調節による CI と同様に増減していたものの，より目標値に近い値を示した．目標とする状況を維持するという意味においては，機械的な輸液投与速度調節アルゴリズムは妥当性があると言えるであろう.

本研究の制約としては，**1)** 輸液速度に応じて目標値 (CI) が変化する輸液反応モデルは極めて単純化されており，生体反応を完全に再現するものではない，**2)** 事前に作成した輸液制御アルゴリズムは単純であり，改善の余地がある，**3)** 今回設定した制御変数 (CI) が輸液投与調節における最善の目標状態を反映しているわけではない，というものである．そこで，輸液によって反応する生体情報を更に正確に説明する輸液反応モデルが得ら

れれば，輸液による生体反応を予測する精度が向上する．また，臨床経験の中から輸液投与調節のための良い指標を探し求めると共に，その指標を活用して輸液速度を調節するための効果的なアルゴリズムを開発することで，目標とする状態が得られるよう輸液速度を調節する精度が向上すると期待される．

結　語

輸液投与と調節指標の関係をモデルに記述し，制御アルゴリズムに基づく機械的な輸液制御を組み込んだシミュレーションを実施する事で，機械的な輸液制御の実用性を検討できる．

本報告に関し利益相反はない．また症例データについては患者本人から書面での同意を得た．

引用文献

1. Nicklas JY et al: Personalised haemodynamic management targeting baseline cardiac index in high-risk patients undergoing major abdominal surgery: a randomised single-centre clinical trial. Br J Anaesth. 2020 Aug;125(2):122-132.

Original article

Postoperative complications after gastrointestinal surgery under general anesthesia and their association with nociceptive response index and mean blood pressure during surgery

Kenta Takeda[1*] ,Sachiko Oshita[1*], Akane Kido[1*], Yuka Matsuki[2] , Munetaka Hirose[1]

Introduction

Intraoperative hypotension is reportedly associated with increased postoperative morbidities and mortality in patients undergoing non-cardiac surgery[1,2]. Lowest mean blood pressure (MBP) during surgery < 55 mmHg was significantly associated with the development of postoperative complications after non-cardiac surgery[2]. On the other hand, a recent study using meta-analysis reported that intraoperative hypotension showed no association with postoperative mortality, and inversely reduced the length of hospital stay after surgery[3].

Higher surgical invasiveness also facilitates the development of postoperative complications. Although moderate surgical stress responses facilitate and support postoperative recovery, excessive surgical stress responses caused by higher surgical invasiveness increases the incidence of postoperative complications[4−6]. The nociceptive response (NR) index, as one of the nociception monitors used during general anesthesia, is a dimensionless number between 0 and 1, with higher values reflecting increased surgical stress during surgery under general anesthesia[6]. The averaged values of nociceptive response index (mean NR) from the start of surgery to the end of surgery ≥ 0.85 was reportedly associated with an increased rate of postoperative complications in patients undergoing elective laparoscopic gastrointestinal surgery[7].

To evaluate associations between postoperative complications, lowest MBP, during surgery and mean NR index during surgery, we performed a retrospective observational study in adult patients undergoing gastrointestinal surgery in the present study.

Method

This multi-institutional, observational study was approved by the Ethics Committee at Hyogo

Patients

Participants comprised consecutive patients who underwent gastrointestinal surgery under general anesthesia from March 2019 to July 2020 at the surgical centres in Hyogo Medical University and in University of Fukui. Exclusion criteria were age < years, American Society of Anesthesiologists − physical status (ASA-PS) > V, and no perioperative data of serum concentrations of C-reactive protein (CRP), MBP, and NR.

Data collection

To assess the primary outcome of this study,

[1]Department of Anesthesiology, Hyogo Medical University Faculty of Medicine
*Equally contributed.
[2]Department of Anesthesiology & Reanimatology, Faculty of Medicine Sciences, University of Fukui

as the association between the incidence of postoperative complications, lowest MBP during surgery < 55 mmHg, and mean NR index during surgery ≥ 0.85, we obtained perioperative data of age, sex, body mass index, ASA-PS, emergency status, surgical procedure, anesthetic management, serum concentrations of CRP before surgery and at postoperative day (POD) 1, and complications occurring within 30 days after surgery from our institutional medical records. We retrospectively reviewed these data, which were obtained from medical records in two institutions.

Data collection

Postoperative complications were graded according to the extended Clavien-Dindo classification, which includes seven grades: grade I, any deviation from the normal postoperative course; grade II, normal course altered; grade IIIa, complications that require interventions performed under local anesthesia; grade IIIb, complications that require interventions performed under general or epidural anesthesia; grade IVa, life-threatening complications with single organ dysfunction; grade IVb, life-threatening complications with multi-organ dysfunction; and grade V, death [8]. Postoperative complications were defined as Clavien-Dindo grade II or greater in the present study.

The NR index is calculated using the three variables of heart rate (HR), systolic blood pressure (SBP) and perfusion index (PI),

$$NR = \frac{2}{1 + e^{-(0.01HR + 0.02SBP - 0.17PI)}} - 1,$$

representing intraoperative nociception [9]. It is presented as a dimensionless number between 0 and 1, with ‘ 1 ’ representing greater nociception. This equation for NR index was installed on the anesthesia information managing system (ORSYS; Philips Japan, Tokyo, Japan) in all the operation rooms at our institution, and the NR value has been calculated and stored every 1 min during surgery in all patients since May 2018. BP was measured either every 1 min using direct measurement, or every 5 min using indirect measurement during surgery. In the latter cases, the latest value of SBP was used to calculate NR values. Thereafter, both lowest MBP and mean NR index during surgery were obtained for each patient, using Vi-Pros data-search software (Dowell, Sapporo, Japan).

Anesthetic management during surgery

No patients received premedication. General anesthesia was induced with propofol, in addition to fentanyl and rocuronium, followed by insertion of a tracheal tube or supraglotic airway. Anesthesia was maintained with sevoflurane, desflurane or propofol, in addition with fentanyl, rocuronium and continuous infusion of remifentanil. Doses of remifentanil and fentanyl were adjusted to maintain mean blood pressure within the range of $\pm$ 20% of the pre-anesthesia level. Additional requirements for regional anesthesia were determined by the anesthesiologists in charge. Bispectral index was maintained between 40 and 60 by adjusting the concentration of sevoflurane, desflurane or propofol. Rocuronium bromide was used for muscle relaxation during surgery, as needed.

Statistics

All statistical testing was performed using JMS Pro version 14.2.0 (SAS Institute Inc. Cary, NC, United States). Multivariate logistic regression analysis was used to determine the correlation between postoperative complications, lowest MBP, and highest NR index. To

exclude confounding the effects, we selected preoperative variables of age, sex, BMI, ASA-PS and preoperative CRP levels, as candidate variables for multivariable logistic regression analysis.

Table 1. Patients ’ characteristics and perioperative variables

Preoperative variables	
Age (SD) in years	61 (17)
Sex, n (%)	
Male	684 (62.5)
Female	411 (37.5)
MI (SD) in kg· m^{-2}	21.6 (4.0)
ASA-PS, n (%)	
<III	285 (26.0)
≥III	810 (74.0)
Emergency surgery, n (%)	159 (14.5)
Preoperative CRP level (SD) in mg· dL^{-1}	1.91 (5.16)
Intraoperative variables	
Gastrointestinal surgeries, n	1095
Gastric surgery, n (%)	200 (18.3)
Small bowel surgery, n (%)	64 (5.8)
Large bowel surgery, n (%)	690 (63.0)
Others, n (%)	141 (12.9)
Lowest MBP (SD) mmHg	58.8 (10.8)
Mean NR index (SD)	0.819 (0.056)
Duration of surgery (SD) in min	210 (152)
Duration of anesthesia (SD) in min	284 (162)
Blood loss (SD) in mL.	171 (336)
Urine volume (SD) in mL.	271 (277)
Postoperative variables	
Clavien-Dindo grade, n (%)	
<II	706 (64.5)
≥II	389 (35.5)

Data are expressed as numbers (Anesthesiologists – Physical Status, BMI: body mass index, CRP: C-reactive protein, MBP: mean blood pressure, NR: nociceptive response, RBC: red blood cells, SD: standard deviation.

Subgroup analysis

We divided the patients into two groups, including patients with and without postoperative complications. Comparisons of lowest MBP during surgery and mean NR index during surgery were performed using the unpaired t-test. Normality of data was assessed using the normal quantile plot, and values of $P < 0.05$ were considered to indicate statistical significance.

Results

In the present study, 1,095 patients were enrolled (Table 1). Postoperative complications, defined as Clavien-Dindo grade ≥ II, occurred in 389 patents (35.5%).

We performed multivariable logistic regression analyses to determine the association between postoperative complications, lowest MBP < 55 mmHg, and mean NR index ≥ 0.85. Eight preoperative and intraoperative variables of age ≥ 70 years, male sex, BMI ≥ 25 kg·m^{-2}, ASA- PS ≥ III, emergency surgery, preoperative CRP levels ≥ 1.00 mg·dL^{-1} were selected as candidate variables[10]. Multivariable logistic regression revealed that both emergency surgery, preoperative CRP levels ≥ 1.00 mg·dL^{-1}, and mean NR index ≥ 0.85 were independent risk factors for the development of postoperative complications within 30 days after surgery (Table 2).

Table 2. Multivariable logistic regression analysis of perioperative variables related topostoperative complications (Clavien-Dindo grade ≥ II)

Pre- and intraoperative variables		Odds ratio [95%CI]	*P*
Age, years	<75	Ref	
	≥75	0.98[0.73−1.31]	0.871
Male sex		0.89 [0.68−1.76]	0.871
BMI, kg·m^{-2}	<25	Ref	
	≥25	1.24 [0.88−1.76]	0.214
ASA-PS	<III	Ref	
	≥III	1.21 [0.89−1.65]	0.225
Emergency surgery		2.46 [0.27−0.61]	<0.001**
Preoperative CRP level, mg·dL^{-1}	<1.00	Ref	
	≥1.00	2.23 [1.61−3.68]	<0.001**
Lowest MBP, mmHg	<55	Ref	
	≥55	1.00 [0.75−1.32]	0.981
Mean NR index	<0.85	Ref	
	≥0.85	1.68 [1.26−2.25]	<0.001**

ASA-PS: American Society of Anesthesiologists–Physical Status, BMI: body mass index, CI: confidence interval, CRP: C-reactive protein, MBP: mean blood pressure, NR: Nociceptive esponse. Statistical significance was defined at **P<0.01.

In the subgroup analysis, we divided all patients into two groups with (n=386) and without postoperative complications (n=706). Although there was no significant difference in lowest MBP during surgery between two groups, mean NR index in patients with postoperative complications was significantly higher than that in those without postoperative complications (Table 3).

Table 3. Comparisons of lowest MBP and mean NR during surgery between patients with and without postoperative complications

	Clavien-Dindo grade <II n = 706	Clavien-Dindo grade ≥II n = 389	*P*
Lowest MBP (SD) mmHg	59.0 (10.7)	58.5 (10.8)	0.391
Mean NR index (SD)	0.810 (0.057)	0.833 (0.052)	0.001**

MBP: mean blood pressure, NR: Nociceptive Response, SD: standard deviation. Statistical significance was defined at $^{**}P<0.01$.

Discussion

The present results are comparable to our previous studies showing a significant correlation between the development of postoperative complications and intraoperative mean NR index in patients undergoing gastrointestinal surgery under general anesthesia[7,11]. Lowest MBP during surgery < 55mmHg, however, showed no association with postoperative complications, and there was no significant difference in lowest MBP during surgery between patients with and without postoperative complications in the present study. Due to the wide range of surgical procedures performed in this study (heterogeneity in surgical invasiveness), the resulting variations in surgical stress responses might mask the impact of intraoperative hypotension on postoperative complications.

This study has limitations. First, it was a retrospective observational study, which inherently weakens the ability to establish cause-and-effect relationships. Second, data on the duration of hypotension, another factor known to influence postoperative complications, was not collected. Future prospective studies are needed to definitively assess the impact of both NR- and MBP-guided general anesthesia on postoperative complications.

In summary, the development of postoperative complications is likely associated with mean NR index during surgery, although it showed no association with lowest MBP during surgery in patients undergoing gastrointestinal surgery under general anesthesia.

Declaration of interest:
The authors have no conflict of interest.
Conflicts of Interest:
Munetaka Hirose is an inventor on a patent application for the equation of the nociceptive response (NR) index, which was registered on August 25, 2021 (Japanese Patent No. 6934251). Philips Japan Co. Ltd. (Tokyo, Japan) installed the equation on the ORSYS anesthesia information management system, but as of yet no commercial activity has occurred. This was included in the disclosure of conflict of interests to patients.
Ethical approval:
This single-institutional observational study was approved by the Ethics Committee of Hyogo Medical University (Ethical Committee number 3138) on March 4, 2019.

References

1. Monk TG, Bronsert MR, Henderson WG, Mangione MP, Sum-Ping ST, Bentt DR, Nguyen JD, Richman JS, Meguid RA, Hammermeister KE. Association between Intraoperative Hypotension and Hypertension and 30-day Postoperative Mortality in Noncardiac Surgery. Anesthesiology 2015; 123: 307-19
2. Gregory A, Stapelfeldt WH, Khanna AK, Smischney NJ, Boero IJ, Chen Q, Stevens M, Shaw AD. Intraoperative Hypotension Is Associated With Adverse Clinical Outcomes After Noncardiac Surgery. Anesth Analg 2021; 132: 1654-65
3. D'Amico F, Fominskiy EV, Turi S, Pruna A, Fresilli S, Triulzi M, Zangrillo A, Landoni G. Intraoperative hypotension and postoperative outcomes: a meta-analysis of randomised trials. Br J Anaesth 2023; 131: 823-31.
4. Dobson GP. Addressing the global burden of trauma in major surgery. Front Surg. 2015; 2:

43
5. Cusack B, Buggy DJ. Anaesthesia, analgesia, and the surgical stress response. BJA Educ 2020; 20: 321-8
6. Hirose M, Okutani H, Hashimoto K, Ueki R, Shimode N, Kariya N, Takao Y, Tatara T. Intraoperative Assessment of Surgical Stress Response Using Nociception Monitor under General Anesthesia and Postoperative Complications: A Narrative Review. J Clin Med 2022; 11: 6080.
7. Ogata H, Nakamoto S, Miyawaki H, Ueki R, Kariya N, Tatara T, Hirose M. Association between intraoperative nociception and postoperative complications in patients undergoing laparoscopic gastrointestinal surgery. J Clin Monit Comput 2020; 34: 575-81
8. Dindo D, Demartines N, Clavien PA. Classification of surgical complications: a new proposal with evaluation in a cohort of 6336 patients and results of a survey. Ann Surg 2004; 240: 205-13.
9. Ooba S, Ueki R, Kariya N, et al. Mathematical evaluation of responses to surgical stimuli under general anesthesia. Sci Rep 2020; 10: 15300.
10. Onoe K, Ogata H, Okamoto T, Okutani H, Ueki R, Kariya N, Tatara T, Hashimoto M, Hasegawa S, Matsuki Y, Hirose M. Association between thoracic epidural block and major complications after pleurectomy/decortication for malignant pleural mesothelioma under general anesthesia. Reg Anesth Pain Med 2022; 47: 494-9.
11. Ogata H, Matsuki Y, Okamoto T, Ueki R, Kariya N, Tatara T, Shigemi K, Hirose M. Intraoperative nociceptive responses and postoperative major complications after gastrointestinal surgery under general anaesthesia: A prospective cohort study. Eur J Anaesthesiol. 2021; 38: 1215-22.

Abstract

Postoperative complications after gastrointestinal surgery under general anesthesia and their association with nociceptive response index and mean blood pressure during surgery

Kenta Takeda, Sachiko Oshita, Akane Kido, Yuka Matsuki., Munetaka Hirose

Although intraoperative hypotension has been known to associate with the development of postoperative complications, opposite results were also reported. On the other hand, higher surgical stress responses also facilitate the development of postoperative complications. To evaluate associations between postoperative complications within 30 days after surgery, intraoperative hypotension, and surgical stress responses, We performed a multi-institutional retrospective observational study in patients undergoing gastrointestinal surgery under general anesthesia. Multivariable logistic regression analysis was performed to evaluate the association in consecutive adult patients, enrolled from March 2019 to July 2020. The lowest mean blood pressure (MBP) during surgery was collected as an indicator of intraoperative hypotension, and the averaged value of nociceptive response (mean NR) index during surgery was also obtained as an indicator of surgical stress responses with other perioperative variables from our institutional data records. The multivariable analysis revealed that both mean NR index $\geq$ 0.85, emergency surgery, and preoperative C-reactive protein levels $\geq$ 1.00 mg·dL^{-1} were independent risk factors for the development of postoperative complications. Lowest MBP $<$ 55 mmHg, however, showed no significant correlation with postoperative complications. These results suggested that the development of postoperative complications is likely associated with higher levels of mean NR index during gastrointestinal surgery under general anesthesia.

Key words: hypotension, nociception, surgical invasiveness, postoperative morbidity.

Corresponding author:
Muneteka Hirose, Department of Anesthesiology, Hyogo Medical University Faculty of Medicine, 1-1 Mukogawa-cho, Nishinomiya, Hyogo 663-8501, Japan
TEL: +81-798-45-6392
E-mail: mhirose@hyo-med.ac.jp

Support: Supported by grant No. 22K09059 from the Grant-in-Aid for Scientific Research KAKENHI (Tokyo, Japan; to Dr. Hirose).

要旨

消化管手術における術後合併症の発症と術中の Nociceptive Response (NR) index と平均動脈圧の関係

術中低血圧は術後合併症の発症と関連することが知られているが，逆の結果も報告されている．一方，手術ストレス反応が高いと，術後合併症の発症も促進される．術後 30 日以内の術後合併症，術中低血圧，手術ストレス反応との関連を評価するため，全身麻酔下で消化器外科手術を受けた患者を対象に，多施設共同による後方視的観察研究を行った．2019 年 3 月から 2020 年 7 月に手術を受けた成人患者を対象に多変量ロジス

ティック回帰分析を行い，この関連を評価した．術中低血圧の指標として手術中の平均血圧 (MBP) の最低値を収集し，手術ストレス反応の指標として手術中の侵害受容反応 (術中平均 NR 値) の平均値も，施設のデータ記録から他の周術期変数とともに取得した．多変量解析の結果，術中平均 NR 値 ≧0.85，緊急手術，術前 C 反応性蛋白値 ≧1.00mg-dL^{-1} が術後合併症発症の独立した危険因子であった．しかし術中最低 MBP<55mmHg は術後合併症と有意な相関を示さなかった．以上の結果から術後合併症の発症は術中平均 NR 値の高値と関連している可能性が高いことが示唆された．

連絡先：廣瀬宗孝
〒 663-8501 兵庫県西宮市武庫川町 1 － 1
兵庫医科大学麻酔科学講座
mhirose@hyo-med.ac.jp

電極電気から解析した電気軸の解釈

田中 義文

はじめに

アイントホーフェンの提唱した標準四肢誘導は今日でも通用する技術であるが，一般の成書では検電計を心筋を貫く電流計のように説明しているように見受けられる．実際は心筋間の電位差を示しているにすぎない，筆者は第 II 誘導について，右肩電位を心内膜側細胞外電位，左脚電位を心尖部細胞外電位を反映すると解釈して図 1 に示す各誘導を提唱した．

2. 侵害受容 (Nociception) とは?

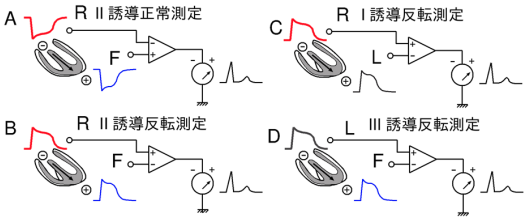

図 1. 心電図の測定原理 (田中モデル)

京都府立医科大学 麻酔科学教室

すべての物質は非線形波動である

横山 博俊

光は不思議な物理的対象である．なぜなら，粒子と波動の 2 つの性質を併せ持つからである．量子力学の世界では，物理的対象が粒子と波動の性質を併せ持つことを古典力学の範囲では説明できないと考えられている．このため，光の 2 重性を説明する関係で，量子力学の世界では物理的対象の幾何学的描像を描くことができず，物理学の本質は確率的であるとされている．つまり，物理学における本質ともいうべき原因から結果が導かれるという因果律が，量子力学において成立しないのである．粒子と波動の性質をもつものは古典力学では存在しないと量子力学の教科書に記載されているが，本当にそうだろうか．非線形波動は 1965 年に Physical Review Letters に数値計算による計算結果として報告され，その 2 年後には解析的な研究結果も報告された．非線形波動は粒子的性質をもつ波動である．古典力学の範囲内に粒子的性質と波動的性質を同時にもつ物理的対象が出現したのだから，非線形波動によって量子力学を再検討しなければならなかったはずだが，現実にはそうならなかった．これは量子力学がコペンハーゲン学派による解釈に支配されており，この学派に対し異を唱えることができなかったからではないだろうか．

光はニュートンによって粒子と考えられたが，その後ホイヘンスによって波動であるとされた．20 世紀になってアインシュタインによる光電効果の発見によって光は再び粒子的性質を持つことが明らかになった．このため，光には粒子的性質と波動的性質が同時に存在していることになるが，この同時性は当時の古典物理学の範囲内では説明することができなかった．20 世紀にコペンハーゲン学派による量子力学が誕生したが，その量子力学の中でも光が粒子的性質と波動的性質を同時にもつことは非常に不思議な記載になっており，物理学的にきちんと説明をすることは今日でもできていないと考えることが妥当である．多くの教科書ではこの同時性に対しては，確率的説明による記載がされている．つまり，時に応じて粒子になり，時に応じて波動になる不思議な「量子過程」をもつものであるとされる．1965 年に非線形波動が発見されてから 50 年以上経つのだから，多少違った意見がでてもよさそうだが，コペンハーゲン学派の権威のため，異論が出なかったのだと思われる．

多くの教科書では，量子力学は実験結果と完全に符合しているのだから，完全な理論であると書かれているが，本当にそうだろうか．確かに水素のスペクトル計算では実験結果と同じ値を出すとされるが，水素は原子核に陽子が 1 個だけ存在する単純な物理的対象である．もっと複雑な化学反応に量子力学が有効であればよいが，基本的に確率値しか出さないので，化学反応の計算に有効であるとは思えない．まして，物理的対象に幾何学的描像を与えないので，いったい何を言っているのかを理解することが常に非常に困難である．ここではこの不思議な正統派量子力学，相対論的量子力学および場の量子論については忘れて，非線形波動という概念を持ち込んで物理学を再構築できないかを考えたい．

物理的宇宙は非常に不思議な存在だが，人間が作ったものではなく，自然現象によって作り出されたものである．したがって，物質の起源は空間から生み出される機序を持っていなければならない．何もないと考えられる空間からどのようにして物質やエネルギーが発生したのだろうか．宇宙に始まりがあるとすれば，そこには凝縮された空間があっただけで，他には何もなかっただろう．

国立病院機構 金沢医療センター 麻酔科

空間には最小単位が存在し，これ以上は小さくはならないものであったと考えられる．空間の最小単位の内部に光が伝搬するとすれば，この空間における光の伝搬時間が時間の最小単位にならなければならない．数学的世界には無限小と無限大の概念が存在するが，物理的世界には無限小も無限大も存在せず，どのようなものでも大きさを持つ対象には最小値と有限な最大値があると考える方が妥当である．

最小単位の空間からなる原子宇宙には時間も運動もなかったとしても，少なくともある時点からは時間と運動が発生したと考えなければならない．最小空間単位には空間の中心ともいうべき核が存在すると，非常に都合がよい．なぜなら単純な概念で電子や陽子の内部構造を作り出せるからである．核は最小空間単位の壁と非線形弾性でつながっている．最小空間単位の核は運動せず，静止していたが，あるときに外からエネルギーが進入し，運動を開始したと考えられる．このとき時間が始まったと考えることができる．核は空間の中心を回転し始めただろう．外からエネルギーが進入すれば，核の運動はますます盛んになり，最小空間単位に大きな変動を起こす．核は２つに分裂し，円環体の陽子と球状の電子に分かれたのではないだろうか．したがって，最小空間単位１個から１個の陽子と１個の電子が発生したと考えられる．陽子と電子は最小空間単位から発生した物質である．陽子と電子のみが長い寿命を持っている．また，陽子と電子の数は宇宙全体で同一のため，宇宙は電気的に中和されていると考えなければならない．陽子と電子は内部に空間を持っている物質である．物質であるということは，質量を持っていることを意味する．質量は空間から発生される重力波によって生み出される．つまり，陽子と電子はそれぞれ，重力波を発生させていると考えなければならない．重力波は空間をほんの僅かだけ収縮させる非線形波動である．重力波を発生させる空間単位 (陽子・電子) は，互いに引き合う性質を持っている．このため，重力波を発生させる空間は質量を持つことになる．重力波は光の速度で伝搬するが，重力波自身は内部に空間を持っていないので，重力波には質量は存在しない．重力波は空間をわずかに収縮させるので，非常に小さなエネルギーを持っている．

光も重力波と同様に空間を伝搬する非線形波動である．空間にはエーテルのような媒質は含まれていない．光は空間のどのような性質を媒質にしていると考えなければならないのか．光は横波であり，その進行速度は文字通り光速である．１個の光子は非常に小さな幅を持っていると考えなければならない．したがって，光の横波は空間をほんの少しだけ伸展させる非線形波動である．空間自体が光の媒質でなければならないからである．重力波と同様に，内部に空間を持っていないため質量は存在しない．しかし，空間を少しだけ伸展させる微小なエネルギーを持っている．光も重力波も空間自体を媒質にする非線形波動だが，光 (電磁波) は空間を拡張させ，重力波は空間を収縮させる．どちらも質量は持たないが，非常に小さなエネルギーを持っている．

宇宙はどのように始まったのか?

最初にたった１個の最小空間単位が爆発し，周りに光によるエネルギー伝搬が生じたことが宇宙の始まりだと思われる．この過程で最小空間単位のうち，陽子と電子に分かれるものとエネルギーを放出し，大きな空間を作り上げたものに分かれたと思われる．ある一定量のエネルギーの供給を受けると最小空間単位の内部構造で受け取れる上限を超えた場合，爆発して空間を作ったものと思われる．内部構造の上限以内のエネルギーを受け取った最小空間単位では内部の核点が活発に運動を開始し，陽子と電子に分かれたのであろう．恐らく，空間を形成したものの割合の方が高かったと思われる．なぜなら，宇宙は非常に大きな空間を有するのだから．光 (電磁波) は内部に空間を持たない非線形波動であるため，質量は存在しない．空間を少しだけ大きくするというと不思議な

感じかも知れないが，基本的に宇宙には空間しか存在しないのだから，すべての事象は空間のみから説明できなければならないからである．

最小空間単位から発生した陽子と電子はスピンをもっている．スピンは回転運動であるため，最初，電子は自転していると考えられた．しかし，電子のスピンは 2 分の 1 である．すなわち，電子のスピンとは 2 周して元の位置に戻ることを意味している．電子は物理学的にほぼ完全な真球である．このため，1 回転すれば元の位置に戻るはずだから，スピンは自転運動と考えることはできない．電子のスピンとは内部構造における回転運動と考えなければならない．陽子も同様にスピンは 2 分の 1 である．陽子におけるスピンも自転運動ではなく，内部構造における回転運動と考えなければならない．

アインシュタインは質量とエネルギーの間に有名な式

$E = m\,\mathrm{c}^2$ が存在する．アインシュタインはこの方程式を非常に巧妙な方法で導き出した．質量に光速の二乗をかけたエネルギーが存在するということは非常に驚くべきことかも知れない．質量は結局，重力波を発生させる空間を意味しているのだから，この空間の内部に上記の関係を導く内部構造が存在しなければならない．電子にも陽子にも同様な内部構造によって，エネルギーを内在させる構造が推定される．エネルギーは結局，空間を押し広げる作用だから，この結果，空間には内在的にエネルギーが存在していると考えなければならない．重力波を発生させることによって，空間自体に質量を誕生させることが可能になる．

電子の内部に核点があり，周囲の壁と非線形弾性関係でつながっていると考えると，物質における質量とエネルギーの関係を内部構造から説明することができる．電子は既に真球であることが実験的に明らかにされている．電子の周囲を構成する壁と中心にある核点との間に非線形関係 $F = kr^2$ なる関係が存在すれば，電子の持つ内部エネルギー

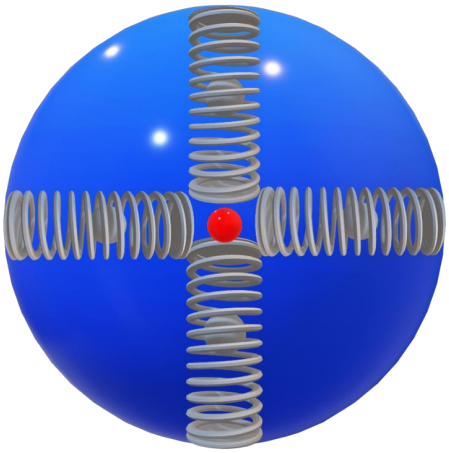

図 1　最小空間単位

前後・左右のない対称的構造
中心点は核点であり，壁との間に非線形弾性の関係を持っている．中心点が静止しているときは，最小空間単位は振動も波動も生じない．外からエネルギーが加えられて中心点が運動し始めたと推定される．

の合計を以下のように算出することができる．ただし，この場合核点はまだ運動をしておらず，電子の中心，つまり真球の中心に存在するときの内部エネルギーである．

電子に更にエネルギーを与えれば，核点は真球の中心から離れ，回転運動を行うことになる．この場合，核点は電子内の小さな円環上の表面を運動する．この時の内部エネルギーは核点が中心にあった時よりも大きくなる．電子は内部構造によってエネルギー量を増減させることが可能である．核点が真球の中心を離れ，核点が表面を運動する円環体が真球の中心から離れ，その径を大きくするにつれて内部エネルギーは大きくなる．電子の持つ内部エネルギーは 1 個 1 個の電子ごとに異なると考えなければならない．

- $E = 4\pi r^2 \times \int kr^2 dx = 4\pi r^2 \times \frac{1}{3}kr^3$
  $= \frac{4}{3}\pi r^3 \times kr^2 = mc^2 \quad (1)$
- $r = \frac{1}{2}ct \quad c$: 光の速度　t : 最小時間
- $k = \frac{4}{t^2}k'$ とすれば $kr^2 = \frac{4}{t^2}k'\frac{c^2t^2}{4} = k'c^2$
- $\frac{4}{3}\pi r^3 k'$　は質量 m とみなせる

上記の如く電子の体積を質量に相当すると考えれば，電子は内部エネルギーを $E = mc^2$ と算出することができる．物質は核点を中心とする壁との非線形弾性関係によって大きなエネルギーを持つと考えることができるのである．このような内部構造を持つがゆえに電子は内臓するエネルギーを高くしたり，低くしたりできるのである．

電子が真球であるのに対し，陽子は円環体であると考えなければならない．最小空間単位から陽子と電子が作られた過程は恐らく全宇宙で均一であり，非常に単純な物理的経過でなされたはずである．最小空間単位にエネルギーが持ち込まれたときに, 内部の核点に回転運動が発生し, 最小空間の極に向かって回転しながら，そこで反転し内部に向かって螺旋状に進行していったと思われる．この時，極からの内部にむかって核点が回転しながら進行し，電子と陽子を切り分けて，二つの物質が誕生したと考えられる．その後，電子の核点が壁に近い部分で回転する方向と，電子の円環体において核点が壁に近いところで回転する方向が逆向きになっている．核点の回転によって電子の表面, および陽子の表面には電磁波が発生するが, 電子の進行方向 (電磁波の強い方向に進行する) と陽子によって作られる電磁波の回転は逆方向となる．電子，陽子の発生する電磁波が磁力の原因である．したがって，電子が陽子の周りを回転するとすれば，陽子の長径の軌道軸上に電子は運動する．陽子も電子も内部構造によって，内部に有するエネルギー量は異なってくる．それによって，発生する電磁波の強さも変化すると考えなければならない．

量子力学における初期的な問題で，陽子と陽子の周りを周回する電子の問題が存在する．古典力学的には，電子が電磁波を発しながら陽子の周りを周回するならば, いずれ電子はエネルギーを失って陽子のところまで墜落するというものがあった．現実には電子は陽子のところまで墜落することはなく，原子は安定な状態を保っている．ある一定の軌道では電子内部の核点の回転運動と電子の周回運動の周期は一致していれば，地球と月の関係のように月が地球に対していつも同じ面を見せているように, 電子も同じ面を見せているため, 電磁波が発生することなく，陽子の周りを周回しているものと思われる．電子の内部にエネルギーを与えるのは光量子であり，一定のエネルギーによって電子の周回軌道と内部の核点の回転運動がうまく同期するする部分が安定した軌道だといえるのではないだろうか．したがって，電子は内部構造によってそれに応じた軌道を安定して周回運動をするのであると考えられる．もし，電子に光エネルギーを与えれば, 徐々に外側の軌道へと移動し, 最終的には原子内部から飛び出すと思われる．

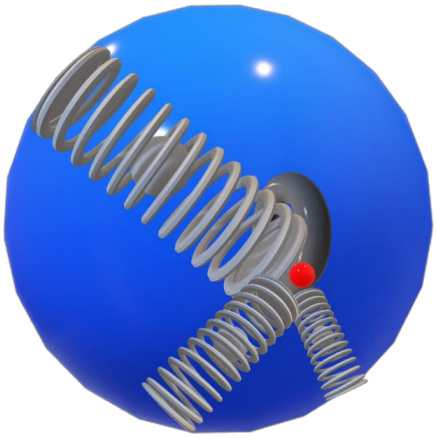

図 2 電子の内部構造

灰色のリングは電子を構成する非線形波動の中心点の軌道．電子は進行方向と回転方向に非対称性を持つ．陽電子は非線形波動の中心点の回転方向が真逆だろう．

陽子においても，アインシュタインの質量とエネルギーの関係が成立する．陽子は円環体であり，その大きさは大半径 R と小半径 r によって決定することができる．ただし，陽子の内部の穴は非常に小さく，電子がすっぽりとはまる大きさでなければならない．このため，大半径Rと小半径 r の差は電子の半径に等しいと考えなければならない．電子と異なり，陽子の核点は円状になっており，陽子の内部に存在する核点の集合である円が

回転する小さな円環体の表面を運動する．電子も陽子もスピンは 1/2 であり，これは核点の運動に由来する．電子の核点は電子内部の円環体を 2 周して元の位置に戻るため，スピンは 1/2 である．電子の核点は壁に微妙な運動を発生させ，歳差運動と考えられるものの原因である．陽子の内部の核点の集合である円も内部の円環体の表面を 2 周して元の位置に戻るためにスピン 1/2 である．

陽子の場合も電子と同様に内部構造から，陽子内部のエネルギーを算出することが可能である．

- $E = 4\pi^2 rR \times \int kr^2 dx = 2\pi^2 r^2 R \times \frac{2}{3}kr^3$
  $= 2\pi^2 r^2 R \times \frac{2}{3}kr^2 = mc^2$
- $r = \frac{1}{2}ct$　　c : 光の速度　t : 最小時間
- $k = \frac{4}{t^2}k'$ とすれば　$kr^2 = \frac{4}{t^2}k'\frac{c^2t^2}{4}$
  $= k'c^2$ とおける
- $2\pi^2 r^2 R \times \frac{2}{3}k'$ は質量 m とみなせる

陽子の場合，表面積と内部の核点はそれぞれ円環を構成する円によって内部エネルギーを持っており，電子の場合と同様に内部エネルギーを $E = mc^2$ と置くことができる．陽子と電子は半永久的寿命をもつ物質であり，それぞれ内部構造によって大きなエネルギーを内在する理由を説明することができる．

宇宙の始まりには凝縮された空間しか存在せず，しかもその空間には莫大なエネルギーが存在するのだから，これはなぜかという疑問は残る．空間が広がり始めるまで，運動も時間も存在しなかったのだから，この始まりの状態の説明は非常に困難である．それ以前の時間が全く存在しないのだとすれば，この問題は解決することはできないように思われる．つまり，非常に凝縮された空間がどのように誕生したのかの説明はできないことになってしまう．この問題は空間と時間についての更に深い洞察が必要だろう．宇宙には解明できないことはないと考えることが私の信念なので，なぜ空間と時間が始まったのか，という問題は現在のところ未解決だが，いずれ何らかの説明をすることはできるはずだと思う．

図 3　陽子は円環体 (トーラス) 構造を持つ

陽子は内部に円状になった核を持つ．トーラスの中心の穴は小さく，電子がちょうど嵌まり込む大きさだろう．

物質のなかで長い寿命を持つものは陽子と電子のみである．中性子は陽子と電子が結合して作られたものだから，中性子が陽子と電子に分かれる現象は既に認められている．原子核の内部で陽子と中性子が入れ替わるという現象も認められているという．中性子と電子を結びつける力は物理学的には「弱い力」とされており，これは物理学的に 4 つに分かれるとされる力の中で重力の次に弱い力である．私の考えるモデルでは，陽子は円環体であり，電子は真球である．陽子はドーナツの形をした円環体ではあるが，内部の穴は非常に小さいと考えなければならない．なぜなら，陽子と電子は 1 個の最小空間単位から発生しており，陽子の円環体の穴は電子が抜け落ちた穴だからである．したがって，中性子は陽子の円環体の中心の穴に電子が嵌まり込んだものであろう．螺旋状回旋の電磁波はこのために中和され，中性子は電気的に中性となる．中性子は電気的に中性だから，原子核に入りやすくまた出やすいともいえる．電子が中性子の中心の穴にとどまる力は「弱い力」なので，時々電子は転がり落ちて，原子核内部では隣の陽子の穴に嵌まり込んでしまうのではないだろうか．「量子力学」: 岩波講座現代物理学の基礎 10 によれば，「中性子の方は，中心に近い方に負の電荷，外側に正の電荷が広がっているようである..」とある．中性子の中心に電子が嵌まり込

み負電荷を発生していると考えることは，決して無理な考え方ではない．全体として中性子は電荷をもっていないことになっているだけである．

陽子と電子はそれぞれ内部に回転運動が存在するが，その回転運動は螺旋状の運動であり，陽子と電子では向きの異なる螺旋状回旋を呈する．陽子と電子の螺旋状回転によって，陽子と電子にはそれぞれ電磁波が螺旋状に放出されるが，その向きが異なっている．この放出される螺旋状電磁波が電磁力の起源となる．陽子は円環体，電子は真球とすれば，どちらにも上下左右は存在しないことになってしまう．しかし，陽子と電子の内部に存在する回転運動の位置と回転方向によって，それぞれに上下左右をつけることが可能である．もちろん，陽子にも電子にも上下を区別することはできないが，座標を割り付けることができるという意味である．これによって電子には進行方向を内部の回転運動と関連して決定することができると考えられる．

最小空間単位は 1 個の陽子と 1 個の電子を生み出した．しかし，すべての最小単位が陽子と電子になったのではなく，多くの最小空間単位は内部のエネルギーを光に変換し，空間を押し広げたものと思われる．宇宙空間には多くの銀河が存在し，最新の宇宙望遠鏡による報告では，銀河の数はますます増加するばかりである．一体，宇宙にはどれだけの銀河が存在するのだろうか．最小空間単位が非常に大きくなっても，時間の進行速度が速くなるため，最小空間単位の大きさをはかることは困難である．これでは最小空間単位の大きさを測定することができないように思われるが，これは重力によって知ることができる．非常に拡大した空間では重力値が非常に小さくなるからである．このため，宇宙全体で万有引力係数は一定ではないと推定される．宇宙にはニュートンの万有引力の法則では説明することができない渦巻き状銀河などが存在する．これは普通，暗黒物質の影響とされている．しかし，実際には暗黒物質は発見されていない．宇宙全体で万有引力係数が大きく異なれば，渦巻き銀河の問題は解決するのではないだろうか．つまり，物質の放出する重力波は一定だが，それによって収縮する空間の程度は宇宙の場所によって異なると考えなければならない．空間の広がりの程度は宇宙全体で均一では無く，非常に押し広がった空間とそうでもない空間が緩やかに結合していると考えなければならない．

物質は結局，基本的に陽子と電子のみから構成されると考えてよい．陽子の内部には円環上の核が運動する経路があり，壁との間に非線形関係で結びついている．電子も中心近くに円環上の核の移動経路が存在し，核は壁と非線形関係で結びついている．このため，陽子も電子も非線形格子による運動状態，つまり非線形波動から構成されるといってもよい．光 (電磁波) も重力波も非線形波動である．したがって，「非線形波動」は物理学における核心的概念であるということが私の意見である．

宇宙が陽子と電子を生み出した直後は，高いエネルギーのために高温状態であったと推定される．すなわち，物質が大きな運動エネルギーを持って激しく動き回る状態である．このため，最初は陽子と電子がバラバラな状態，すなわちプラズマ状態であったと推定される．この後，宇宙空間は更に広がり，温度も低下して，陽子と電子の運動が緩やかになると，それぞれの内部エネルギーが低下し，陽子の電磁力が電子をひきつけ次第に水素などの原子を作り始めただろう．

現実には物理学の教科書を探索しても「非線形波動」という言葉を見つけ出すことは難しい．波動について論じてある教科書を調べても，「非線形波動」について記載されていることはまれである．これはいったいなぜなのだろうか．1965 年に報告されてから 50 年以上経過しているのに，なぜこのような状態なのであろうか．一つには非線形波動は数学的には数値解析の方法を用いなければ，様々の一般的状態を扱うことができないことにある．確かに解析的な例も見出されているが，解析的手法によって応用を自在に行うことは難し

い．しかも，近年，佐藤幹夫によって非線形波動の代数的性質が解明されてしまった．つまり，非線形波動における重要な数学的問題が解かれてしまったので，多くの数学者が非線形波動の研究から離れていったとされている．したがって，非線形波動の研究に従事している数学者や物理学者はそれほど多くはないのではないだろうか．ある程度の期間で学術論文が書けないような分野は研究対象として注目されることは難しいと考えて差し支えないようだ．

波動に関する物理学の教科書においても，書かれているのは線形波動のみである．現実世界の物理的対象でどれほど，線形波動が存在するのだろうか．光 (電磁波) も重力波も非線形波動である．音波すらも非線形波動である．数学的に取り扱うことが難しいためだろうか．

私は 1985 年に医学部を卒業してから，ずっと動脈系の研究を行ってきた．研究といっても数値解析や数学的研究のみではあるが．動脈圧波動が非線形波動であるとすぐに考えたため，非線形波動の研究は 40 年近くに及ぶ．今回，量子力学を取り上げたのは，物質の本質が非線形波動であることに気が付いたため，非線形波動を物理学や数学の檜舞台に立たせたいと考えたからである．しかし，コペンハーゲン解釈に対して異を唱えるなど，日本では正気の沙汰ではないらしい．コペンハーゲン解釈に対して何の疑問も存在しない 21 世紀の現状では非常に困難だが，コペンハーゲン解釈はいずれ忘れなければならないと私は考えている．これによって，物理学は因果律を取り戻さなければならないと思う．化学反応を量子力学で計算できると多くの教科書に書いてあるが，量子力学の計算はそもそも確率的で，幾何学的描像を全く与えないため，あまり役に立つものとは言えない．幾何学的イメージを得ないで，物理学を理解することができるのだろうか．ディラックの「現代物理学講義」では「量子力学の現在の形式は最終的な形式ではないはずだから，終局的にはアインシュタインが正しいと証明されるときが来るように思えます．現在の量子力学には，大きな困難があります.」とある．現在の量子力学は 21 世紀内に書き換えなければならない．アインシュタインは，量子力学が物理学から因果律を消滅させたことに大きな危惧を抱いていた．なんとかしなければならないのではないだろうか．

すべての物理現象は幾何学的対象による幾何学的関係によって説明されなければならないということが私の考えの根本である．物質は陽子と電子から構成されており，それぞれは非線形波動から構成されると考えることができる．したがって，すべての物質は非線形波動から構成されるといえる．光 (電磁波) も重力波も非線形波動なのだから，非線形波動は数学者と物理学者に強い関心を持たれなければならない．現状では目立たない存在である非線形波動は実は物理学における重要な核心的概念である．非線形波動はもっと知られなければならないし，もっと研究しなければならない．

以上は私の「空想」から誕生した「自由な統一場理論」について解説したものであるので，大変恐縮だが，権威あるコペンハーゲン解釈に対し，あろうことか異を唱えたものである．

参考文献

1. メシア量子力学 I・II・III 小出昭一郎，田村二郎訳 1971 東京 東京図書株式会社
2. 朝永振一郎：量子力学 I・II 1952 東京 みすず書房
3. ジョン・W・モファット 水谷淳訳：重力の再発見 2009 東京 早川書房
4. ディラック 有馬朗人，松瀬文浩訳：現代物理学講義 1985 東京 培風館
5. Saif Anwaruddin etc: Cardiovascular Hemodynamics : 2013, New York , Springer
6. ガイトン，ホール：オックスフォード生理学：2021 ELSEVIER
7. Robert C. Little : Physiology of the Heart & Circulation 3rd 1985 Chicago Year Book Medical Publishers
8. Benson R. Wilcox, Andrew C. Cook , Robert H. Anderson : Surgical Anatomy of the Heart 2004 Cambridge University Press

9. Cha Hasdemir etc: Demonstration of Ventricular Myocardial Extensions into the Pulmonary Artery and Aorta Byond the Ventriculo-Arterial junction volume 30 Issue 4 P534-539 2007 Pacing and clinical Electrophysiology
10. 渡辺慎介：ソリトン物理入門 1985，東京，培風館
11. ランダウ，リフシッツ：理論物理学教程 力学 (増訂第 3 版) 1974，東京，東京図書
12. ランダウ，リフシッツ：物理学小教程 力学・場の理論 2008，東京，筑摩書房
13. V.I. アーノルド：古典力学の数学的方法 1980，東京，岩波書店
14. ファインマン，レイトン，サンズ：ファインマン物理学　電磁気学 1969，東京，岩波書店
15. ゴールドスタイン，ポール，サーフコ：古典力学 (上・下)2006，東京，吉岡書店
16. 山本義隆，中村孔一：解析力学 I，II 1998，東京，朝倉書
17. V.P. ナイア 現代的視点からの場の量子論 基礎編 発展編 阿部泰祐，磯暁訳 2009 シュプリンガージャパン 東京
18. 量子力学 I・II・III 岩波講座 現代物理学の基礎 3・4・5 湯川秀樹，井上健，豊田利幸 1972 東京，岩波書店
19. フランコ・セレリ 量子力学論争 櫻山義夫訳 1986．東京，共立出版
20. 小出昭一郎：量子論 1968，東京，裳華房
21. H.F. ハメカ：量子論入門 黒田晴雄訳 1971，東京，共立出版
22. 小出昭一郎：量子力学 I・II 1969，東京，裳華房
23. 野村昭一郎：量子力学入門 1963，東京，コロナ社
24. J.M. カースルズ：基礎量子力学 鈴木皇訳 1962，東京，培風館
25. 小出昭一郎，水野幸夫：量子力学演習 1978，東京，裳華房
26. 山崎郭滋：偏微分方程式の数値解法入門 1993，東京，森北出版
27. 戸田盛和，渡辺慎介：非線形力学 1984，東京，共立出版株式会社
28. 戸田盛和：非線形波動とソリトン (新版)2000，東京，日本評論社
29. 田中光宏：非線形波動の物理 2017，東京，森北出版株式会社
30. 谷内俊弥，西原功修：非線形波動 1977，東京，岩波書店
31. 和達三樹：非線形波動 (岩波講座 現代の物理学)1992，東京，岩波書店
32. 大宮眞弓：非線形波動の古典解析-ソリトン，それに続く非線形の世界- 2008，東京，森北出版株式会社
33. P.G.Drazin, R.S.Johnson : Solitons :an introduction 1989 Cambridge University Press
34. 戸田盛和：非線形格子力学 増補版 1987，東京，岩波書店
35. 山内恭彦：量子力学 1968，東京，培風館
36. 田中広城：発展方程式 1975，東京，岩波書店
37. 井ノ口順一：曲線とソリトン 2010，東京，朝倉書店
38. アブロビッツ，シーガー：薩摩順吉，及川正行訳：ソリトンと逆散乱変換 1991，東京，日本評論社
39. 三輪哲二，神保道夫，伊達悦朗：ソリトンの数理 2007，東京，岩波書店
40. 佐藤幹夫著述 野海正俊記録：ソリトン方程式と普遍グラスマン多様体 1984 上智大学数学講究録 No.18
41. Charles W.Misner, Kip S. Thorne, John Archibald Wheeler: 若野省己訳 ：重力理論 Gravitation ?古典力学から相対性理論まで，時空の幾何学から宇宙の構造へ 2011，東京，丸善出版
42. 原子核論：岩波講座 現代物理学の基礎 湯川秀樹，高木修二，丸森寿夫 1973，東京，岩波書店
43. M.S. スワンソン 経路積分法 -量子力学から場の理論へ- 青山秀明，川村浩之，和田信也訳 1996，東京，吉岡書店
44. 楠瀬博明：スピンと軌道の電子論 2019，東京，サイエンティフィック
45. T. バスティン：量子力学は超えられるか 柳瀬睦男，村上陽一郎，黒崎宏，丹治信春訳 1973，東京，東京図書
46. J.V. ノイマン：量子力学の数学的基礎 井上健，広重徹，恒藤敏彦訳 1957，東京，みすず書房
47. F. マンドル：場の量子論入門 村田良夫訳 1971，東京，東京図書
48. ミグダル，クライノフ：量子力学の近似的方法 岩崎与世夫訳 1973，東京，総合図書
49. 横山寛一：量子電磁力学 ーゲージ構造を中心として- 1978，東京，岩波書店
50. 加藤敏夫：量子力学の数学理論 摂動論と原子等のハミルトニアン 2017 東京，近代科学社
51. 武谷三男：量子力学の形成と論理　原子模型の形成 1972 東京，頸草書房

ABSTRACT

All matter is nonlinear waves

Hirotoshi Yokoyama

Light is a mysterious physical object. This is because it has both particle and wave properties. In the world of quantum mechanics, the fact that a physical object has both particle and wave properties is considered unexplainable within the scope of classical mechanics. For this reason, in relation to explaining the dual nature of light, quantum mechanics cannot paint a geometric picture of a physical object, and the essence of physics is considered to be probabilistic. The law of causality, which is the essence of physics, cannot be established in quantum mechanics. It is stated in quantum mechanics textbooks that nothing with the properties of a particle and a wave exists in classical mechanics, but is this really true? Nonlinear waves were reported numerically in Physical Review Letters in 1965, and analytical results were reported two years later. Nonlinear waves are waves with particle-like properties. The emergence of a physical object with both particle and wave properties within the scope of classical mechanics should have prompted a reexamination of quantum mechanics in terms of nonlinear waves, but in reality this did not happen. This may be because quantum mechanics is dominated by the Copenhagen school of interpretation, which could not be challenged.

If we consider that the electron has a nuclear point inside and is connected to the surrounding wall by a nonlinear elastic relationship, the relationship between mass and energy in matter can be explained in terms of its internal structure. It has already been experimentally shown that the electron is spherical. Here, we will assume that the electron is a sphere. If there exists a nonlinear relationship between the walls that make up the electron's periphery and the nuclear point at its center $F = kr^2$.

If the relationship between the electron's wall and the nucleus exists, the total internal energy of the electron can be calculated as follows. However, in this case, the nuclear point is not yet in motion and is the internal energy when it exists at the center of the electron, i.e., at the center of the true sphere.

Matter is composed of protons and electrons, each of which can be considered to be composed of nonlinear waves. Therefore, we can say that all matter is composed of nonlinear waves. Since light (electromagnetic waves) and gravitational waves are both nonlinear waves, nonlinear waves must be of strong interest to mathematicians and physicists. Nonlinear waves, which are currently unnoticed, are in fact an important core concept in physics. Nonlinear waves must be better known and studied. This is because it is believed that all matter must be considered to be composed of nonlinear waves.

Keywords： nonlinear waves , quantum physics , proton , electron ,quantum mechanics

Department of Anesthesiology, National Hospital Organization Kanazawa Medical Center

心臓は機械的ポンプとして血液を大動脈へ押し出すことはできない

横山 博俊

心臓は左心室から大動脈へ血液を駆出する．「心臓が機械的ポンプであるということをわれわれが知っているのは，Harvey やその先人のおかげである」(オピーの心臓生理学　細胞から循環まで) このように，ほとんどすべての循環生理学の教科書に，心臓が左心室から大動脈へ拍出する仕組みは，心臓の力強い機械的ポンプ作用であると書かれている．解剖学的にみる限り，左心室と大動脈の間には大動脈弁が存在し，機械的ポンプであることは明らかであるとされる．機械的ポンプでないとしたら，他にどんな駆出方法があるというのか，ということが一般的な認識であろう．しかし，本当にそうだろうか?心臓は 200g〜300g 程度の小さな臓器なのである．1 日中力強く収縮することなどできるのだろうか? 非線形波動を長い期間研究してきた私はどのような角度から考えて，心臓が機械的ポンプ作用を果たすことは不可能であることを今から説明していこうと思う．そしてそれに代わるエネルギー効率がもっとよい方法が存在することを示したいと考える．

麻酔科医は手術の麻酔を行うが，急速に大量出血が生じた場合，血液を大量にポンピングと言われる方法で輸血する．血液は水の粘性の 3 倍もあるため，血液をポンピングすることは大層，骨の折れる作業である．心臓は 1 日に約 10 万回も拍動し，毎分約 5 リットルの血液を体へ送り出す．末梢静脈は太くても 14 ゲージ程度であるから，大量の輸血をすることが非常に大変な作業であることは，麻酔科医ならだれでも知っている．心臓は筋肉量としてせいぜい 200g〜300g 程度の臓器なのに大量の血液を送り出すことなど到底無理ではないだろうか．ところがほとんどすべての教科書に心臓は機械的ポンプであると書かれているし，実際に血液を送り出している．物理学の本を隅から隅まで読んでも機械的ポンプ以外の方法を多少でも示唆することが書かれているわけではない．このため，ほとんどすべての人が心臓は機械的ポンプとして信じて疑わないのである．

心臓の仕事量を正確に計算することは難しい．しかし，循環生理学の教科書には以下のような式が書かれている．

$$\text{心臓仕事量} = \text{平均動脈圧} \times 1\text{ 回拍出量}$$

これではあまりにも漠然としていて，心臓がどれだけの仕事をしたのか，計算することは難しい．物理学的には仕事とは力 × 移動した距離である．

$$\text{仕事} = \text{力} \times \text{移動距離}$$

心臓をピストンだと考えれば，もう少し具体的な式を提示することが可能である．

$$\text{仕事} = \text{圧力} \times \text{断面積} \times \text{移動距離}$$

ここでは具体的な数値を出すために，非常に簡単な左心室モデルを設定してみよう．1 辺が 5cm の立方体であるので，ポンプ全体の体積は 125cm^3 である．ピストンは 3cm だけ押し込むとすると，拍出される血液は 75cm^3 となる．したがって，駆出率は 60%に設定されることになる．毎分 60 回の心拍数とすれば，1 回の心拍は 1 秒間以内に行われる．最初の 0.3 秒で血液が駆出されるとする．直径 2cm の大動脈がスムースに接続されているとすれば，23.87cm の円柱状に血液が大動脈に駆出されるから，平均 12cm と置くことができる．

心臓がどれくらいの仕事をこなしているか，心臓をピストンとして考えた場合について考察する．左心室の圧力変動が 60mmHg〜120mmHg だとすると，平均的に 80mmHg 程度の圧力がシリンダーにかかっていると考えることができる．断面積は 25cm^2 である．ピストンと考えた場合の仕事量は圧力×断面積×移動した距離である．ピストン

国立病院機構 金沢医療センター 麻酔科

3cm 押し込まれるわけなので，移動距離は 3cm となる．80mmHg は 108.7kgf/cm^2 なので，仕事量は

$$W = PAL = 108.7 \times 25 \times 3 = 8152.5\text{kgcm} = 81.525\text{kgm}$$

となる．

心拍数 60 ならば，上記仕事量は 1 秒間の仕事量になる．仕事量 8152.5kgcm は 1 秒間の仕事量．1 kgcm は 2.34 キロカロリー (kcal) である．

ピストンによる仕事量　W = PAL
P 左心室内圧 120mmHg〜60mmHg
平均圧を 80mmHg とする
A 断面積は 5cm × 5cm = 25cm^2
L ピストンが移動した距離 3cm
80mmHg は 108.7 kgf/cm^2
W = PAL = 108.7 × 25 × 3 = 8152.5 kgcm
= 81.525 kgm
心拍数 60 なら 1 秒間の仕事率 799.48 ワット
799.487 ワット 0.19095 kcal/1 秒
0.19 × 60 × 6 × 24 = 16416 kcal/日

心臓が行う仕事量をカロリーに換算していくと，非常に膨大なエネルギーが必要であることが明らかである．人間は心臓から血液を拍出することだけにエネルギーを消費するわけではないから，必要不可欠な作業であっても，心臓が必要とされるカロリーはもっと少なくなければならない．したがって，ピストンとして考えると，心臓が血液拍出に必要とされるエネルギーは予想されるものよりもかなり大きく，賄いきれないように思われる．しかも血液の粘性は水の 3 倍だから，左心室壁と血液，大動脈壁と血液の間に拍出の間大きな粘性抵抗が発生する．したがって必要とされるエネルギーはもっと大きなものになると考えられる．これでは心臓を機械的ポンプと考えることは非常に難しい．

しかし，では心臓が機械的ポンプでないとしたら，どうやって血液を大動脈へ移動させているのだろうか．物理学の教科書を眺めても解答になるものを発見することはできない．心臓を解剖学の教科書から判断すれば，機械的ポンプ作用しか考えられないとういことも納得できる．しかし，物理的に考えれば，小さな心臓に機械的ポンプの作用を期待することは物理的に不可能である．答えは非線形波動にある．

非線形波動は 1965 年に physical review letters に報告された数学的概念で，媒質の振幅と弾性の間に非線形関係がある場合に発生する波動である．1965 年に発表されたときは数値解析によるものだったが，その 2 年後には解析的な結果が報告され，数理物理学的対象として認められ今日に至っている．非線形波動は 1965 年に発見されたのだから，すでに 50 年以上たっているのだから，非常に認知度が上がっていそうだが，なぜかそうなってはいない．非線形波動は方程式が非線形偏微分方程式になるため，解析的に解ける例が非常に少ないこと，多くの場合，数値解析の方法を用いなければならないことが挙げられる．数学的な論文の場合，数値解析は数学的論文とは認められない．したがって，非線形波動は数学者にとって扱いにくい研究課題となっているのかも知れない．また，佐藤幹夫によって非線形波動の解に代数的性質があることが証明された．つまり非線形波動における重要問題が既に解かれてしまったわけである．このことは非線形波動が数学者の研究対象になりにくいことを意味している．

非線形波動による物質の移動は戸田盛和著「非線形波動とソリトン」の P108 において「ふつうの波でも 2 次の効果として物質の 移動はあるが，非線形波のソリトンでは 1 次の効果として物質の移動がある，といった方が正しいと思われる．」と非線形波動における物質の移動がほのめかされているが，具体的な説明はない．したがって，この説明は非線形波動における物質の移動に関して最も接近した内容になっているが，この説明だけで非線形波動による物質の移動を理解することは実際には困難である．つまり非線形波動に関する物

質の移動に関して正確に知ることは教科書からでは困難であると言わざるを得ない．

非線形波動における物質の移動とは，波動伝搬の際に, 非線形弾性を有する媒質自体の運動によって，物質の移動が発生することを意味している．動脈系の場合，非線形弾性を有するのは血管壁であるが，血管壁は運動するが，血管壁は移動することはなく，血管壁の内部に存在する媒質を補助する物質，すなわち血液が波動伝搬による血管腔の幾何学的変形によって，内部の血液を少しずつ前方へ移動させていることである．動脈系における血液の移動は血管系の中で動脈圧波動が伝搬している部分，つまり圧力波動が伝搬している幾何学的膨大部でのみ血液は移動しており，その他の部分では血液は静止している．このため，動脈系の血液の運動は間欠的に行われるものであり，故に拍動流なのである．非線形波動は心臓血管系で考えるならば，心臓に機械的ポンプ作用を要求せず，左心室において圧力波動を発生させることだけを必要としている．このため，心臓の仕事量は非常に少なく，1 日に 10 万回の拍動も可能にしていると思われる．ただし，非線形波動による物質の移動については教科書に具体的記載はないので，直接知ることはできない．

私の場合，非線形波動に関する数値シミュレーションのプログラムを自作し，検討していく過程で気が付いたことなので，非常にわかり易い説明文を紹介することができない．もちろん，過去論文を徹底的に調べたわけではないので，どこかに記載があるかも知れない．非線形波動に関する一般的な教科書はほとんど調べたが，物質の移動に関する説明は戸田盛和先生の著書以外に見つけていない．どこかの教科書に書かれているかも知れない．非線形波動における物質の移動を挙げるならば，深海を伝搬する津波による海水の移動や，非線形波動である重力波によって物質と物質が接近することによる物質の移動が挙げられる．重力波は波動発生源に近づくように物質が移動する．上記は私の見解であり，津波も重力波も非線形波動と認識されているわけではないようなので，これらに関する記述は見つけることはできない．現在のところ，プラズマ以外に非線形波動に関する具体的な物理的対象を挙げることが難しい状況である．

1) 左心室内圧が大動脈圧よりも高いのは収縮期の前半 1/3 程度
2) 左心室内圧が大動脈圧より高くなった直後に大動脈弁が開放せず，時間差がある．
3) 左心室圧が大動脈圧より低くなった直後に大動脈弁が閉鎖せず，時間差がある．
4) 時間差は圧力波動がバルサルバ洞を通過するために要する時間

（入内島十郎編集「臨床医のための循環生理」）

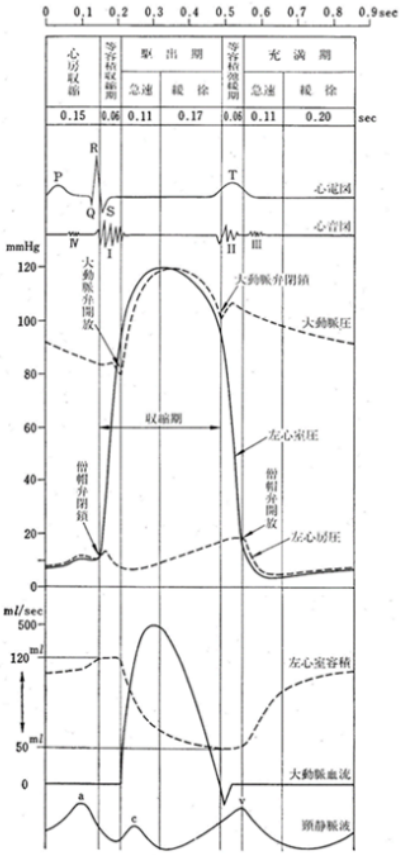

図 1 心臓周期図 入内島十郎：臨床医のための循環生理

上記に示したのは，血行動態学的に考えても，心臓を機械的ポンプとみなすことが難しいことを示すためである．もし，心臓が機械的ポンプであるならば，左心室圧は駆出の間，大動脈圧よりも高くなければならない．しかし，実際には左心室圧が大動脈圧よりも高いのは収縮期の 1/3 程度である．この事実は心臓機械ポンプ説で説明することは困難だが，非線形波動による物質の波動では説明では容易である．波動の伝搬に従って血液が付いてきているのだから，当然収縮期の途中では大動脈圧が左心室圧よりも高くなければならないのである．

心臓が機械的ポンプであるならば，左心室圧が大動脈圧よりも高くなった瞬間に大動脈弁が開放しなければならない．実際にはそうなっていない．これは圧力波動の先端が大動脈弁起始部を通過し，バルサルバ洞先端に伝播し，バルサルバ洞を拡張させることによって，受動的に大動脈弁を開放させているからである．つまり，圧力波動がバルサルバ洞を通過するのに要する時間差だけ大動脈弁が開放するのに時間を要しているのである．

また，収縮期が終了し，左心室圧が大動脈圧よりも低くなってもすぐに大動脈弁は閉鎖せず，小さな時間差を要している．左心室から発生した収縮期圧波形の終端が大動脈弁起始部を通過し，バルサルバ洞先端に達してから大動脈弁が閉鎖しているためである．ここにおける小さな時間差も，バルサルバ洞を圧波形が通過するために発生していると考えられる．

物理的応用はどうなのだろうか．基本的方程式から数値解析等で性質が明らかになった後も，当初物理的な応用が積極的に試みられたかどうかといえば，あまり多くの例を挙げることができない．最初のころはプラズマ中を伝搬する波動が非線形波動として研究されたが，そもそもプラズマは核融合研究でもしなければ特に出現してこない物理的対象だから，一般的な注目を引いてこなかったと思われる．現実に物理学の教科書を調べたが，波動の章を調べても，非線形波動について詳しく書かれているものは全く存在しない．物理的対象には非線形波動がほとんど存在しないのであろうか．物理学の中で，非線形波動は人気がなく，新しく出版される教科書も少ない．このような現状は非常に悲しむべき状況のように思える．私の考えでは，非線形波動は物理学における核心的概念である．また，波動の章の中でもほとんど扱われていない．現実に存在する波動はほとんど非線形波動であると私は考えている．

心臓が血液を大動脈に拍出する仕組みは，機械的ポンプ作用ではなく，非線形波動による物質の移動であると考えなければならない．ただし，非線形波動に関する記述も，非線形波動による物質の移動もほとんど見当たらないといってもよい．

人間の心臓がおこなう心臓の駆出作業は非常に少ない仕事量によって効率よく行わなければならないことは明らかである．血液の拍出に際し，心臓はほとんど仕事をしていないからである．したがって，非線形波動による物質の移動に関する教科書における記載がほとんど見当たらない現状では，心臓の真の拍出機構に到達することは非常に困難であると言わざるを得ない．この点は非常に残念な現状だが，非線形波動による物質の移動という概念を何とか一般的な常識の位置にまで押し上げることによって，心臓の真実の機能についての理解に到達できるようにしなければならない．

参考文献

1. N.J.Zabusky，M.D.Kruskal: Interaction of Solitons in a collisonless plasma and the recurrenc of initial state Volume15, Number6 1965 Physical review letters
2. 入内島十郎：「臨床医のための循環生理」1976 東京，真興交易医書出版部
3. Spencer , Greiss：Circulation Research 10：274, 1962
4. 沖野 遥, 菅原基晃, 松尾裕英：心臓血管系の力学と基礎計測：1980,, 東京，講談社サイエンティフィック
5. Saif Anwaruddin etc: Cardiovascular Hemodynamics : 2013, New York , Springer
6. ガイトン，ホール：オックスフォード生理学：2021 ELSEVIER
7. Robert C. Little : Physiology of the Heart &

Circulation 3rd 1985 Chicago Year Book Medical Publishers
8. Benson R. Wilcox, Andrew C. Cook , Robert H. Anderson : Surgical Anatomy of the Heart 2004 Cambridge University Press
9. Cha Hasdemir etc: Demonstration of Ventricular Myocardial Extensions into thePulmonary Artery and Aorta Byond the Ventriculo-Arterial junction volume 30 Issue 4 P534-539 2007 Pacing and clinical Electrophysiology
10. 渡辺慎介：ソリトン物理入門 1985，東京，培風館
11. ランダウ，リフシッツ：理論物理学教程 力学 (増訂第 3 版) 1974，東京，東京図書
12. ランダウ，リフシッツ：物理学小教程 力学・場の理論 2008，東京，筑摩書房
13. V.I. アーノルド：古典力学の数学的方法 1980，東京，岩波書店
14. ファインマン，レイトン，サンズ：ファインマン物理学　電磁気学 1969，東京，岩波書店
15. ゴールドスタイン，ポール，サーフコ：古典力学 (上・下)2006，東京，吉岡書店
16. 山本義隆，中村孔一：解析力学 I，II 1998，東京，朝倉書店
17. 横山博俊：左心室-大動脈血流モデル 日本麻酔・集中治療とテクノロジー 2011 96-104，2012
18. 横山博俊：心第血管系の数値流体力学の問題点 日本麻酔・集中治療とテクノロジー 2012 56-67，2013
19. 横山博俊：非標準的圧縮性流体解析による心第血管系の数値流体力学 日本麻酔・集中治療とテクノロジー 2013 18-26 2015
20. 横山博俊：ラグランジュ力学 (解析力学) の動脈系への適用，及び微分可能多様体の，動脈壁と動脈内腔への対応 日本麻酔・集中治療とテクノロジー 2014 53-62 2016
21. 横山博俊：トーラスで計算する弾性管内拍動流 ?空間変動によって受動的に運動する流体粒子- 日本麻酔・集中治療とテクノロジー 2015 55-64 2016
22. 横山博俊：トポロジーによる動脈内流体粒子の軌跡の算出 日本麻酔・集中治療とテクノロジー 2016 30-34 2017
23. 横山博俊：ハミルトンの最小作用の原理による動脈の血行動態 日本麻麻酔・集中治療とテクノロジー 2017 40-47 2018
24. 横山博俊：人体の血管内血流は螺旋状に回転して流れる 日本麻酔・集中治療とテクノロジー 2019 62-68 2020
25. 高橋亮一，棚町芳弘：差分法 1991，東京，培風館
26. 山崎郭滋：偏微分方程式の数値解法入門 1993，東京，森北出版
27. 戸田盛和，渡辺慎介：非線形力学 1984，東京，共立出版株式会社
28. 戸田盛和：非線形波動とソリトン (新版)2000，東京，日本評論社
29. 田中光宏：非線形波動の物理 2017，東京，森北出版株式会社
30. 谷内俊弥，西原功修：非線形波動 1977，東京，岩波書店
31. 和達三樹：非線形波動 (岩波講座　現代の物理学)1992，東京，岩波書店
32. 大宮眞弓：非線形波動の古典解析-ソリトン，それに続く非線形の世界- 2008，東京，森北出版株式会社
33. P.G.Drazin, R.S.Johnson : Solitons :an introduction 1989 Cambridge University Press
34. 戸田盛和：非線形格子力学 増補版 1987，東京，岩波書店
35. 矢嶋信男，野木達夫：発展方程式の数値解析 1977，東京，岩波書店
36. 田中広城：発展方程式 1975，東京，岩波書店
37. 井ノ口順一：曲線とソリトン 2010，東京，朝倉書店
38. アブロビッツ，シーガー：薩摩順吉，及川正行訳：ソリトンと逆散乱変換 1991，東京，日本評論社
39. 三輪哲二，神保道夫，伊達悦朗：ソリトンの数理 2007，東京，岩波書店
40. 佐藤幹夫著述 野海正俊記録：ソリトン方程式と普遍グラスマン多様体 1984 上智大学数学講究録 No.18

ABSTRACT

The heart cannot push blood out into the aorta as a mechanical pump.

Hirotoshi Yokoyama

The heart pumps blood from the left ventricle to the aorheartta. Thus, almost all textbooks on cardiac physiology describe the heart's powerful mechanical pumping action as the mechanism by which the heart beats from the left ventricle to the aorta. The heart's powerful mechanical pumping action is the mechanism by which it beats from the left ventricle to the aorta. Anatomically speaking, the presence of an aortic valve between the left ventricle and the aorta makes it clear that it is a mechanical pump. If it is not a mechanical pump, what other method of ejection is there? But is this really the case? The heart is a small organ, weighing only 200 to 300 grams, and can it contract vigorously throughout the day? Having studied nonlinear waves for a long time, I will now try to explain from what angle it is impossible for the heart to perform a mechanical pumping action. I will also try to show that there are more energy-efficient alternatives.

The mechanism by which the heart beats blood into the aorta must be considered to be the movement of matter by nonlinear waves, not mechanical pumping action. However, there are almost no

descriptions of nonlinear wave action, nor of non-linear wave-induced mass transfer. However, it is clear that the cardiac pumping action of the human heart must be performed efficiently with a very small workload. This is because the heart does very little work in beating blood. Therefore, it is very difficult to reach the true beating mechanism of the heart, since there are almost no textbooks on nonlinear wave transfer of materials. This is a very unfortunate situation, but we must somehow push the concept of non-linear wave transfer to the position of common knowledge, so that we can reach an understanding of the true function of the heart.

Keywords： heart pomp function , nonlinear waves , mechanical pumping action

Department of Anesthesiology, National Hospital Organization Kanazawa Medical Center

特別寄稿：

臨床診断と機械学習二値分類モデル：COVID-19 急性低酸素性呼吸不全のデータセットを用いた Python プログラミング

佐和貞治[1,3]，須藤和樹[2,3]，木下真央[3]，井上敬太[2]，
串本洸輔[3]，吉井龍吾[2]，小尾口邦彦[2]

1. はじめに

臨床診断や治療方針決定に関わる人工知能 (AI) 支援では, 集積されたデータを機械学習させ, データの背景にある規則やパターンを見出してモデルを作成し，その学習成果に基づいて判断・予測をする．臨床診断や治療方針に至るエキスパート臨床医の思考回路についても，決定結果を目的変数と捉えて，決定に関わったと推定される因子を説明変数として因果解析を行い，分類モデルや多重回帰モデルを構築することで，その意思決定に至る主要な因子を抽出し，より高い精度の診断や治療方針の AI 支援に繋げていくことが期待される．著者らは，最近 COVID-19 重症呼吸不全患者の呼吸療法選択に関する主治医の意思決定についての解析を報告した [1,2]．この臨床研究では，コンピュータ言語 Python や R 言語を用いた重症患者の治療対応に関する 2 値分類解析に取り組んだ．今回は，この論文で報告した COVID-19 重症呼吸不全患者のデータセットを用いて，Python 機械学習プログラミングによる 2 値分類モデル作成と作図機能について本稿にまとめ，今後の臨床研究活用への一助としたい．

2. 高流量鼻カニューレ酸素療法 (HFNC) と ROX index

高流量鼻カニューレ酸素療法 (HFNC) は，30 − 60L/min の高流量の加温加湿ガスを鼻カニューレを使用して送気する画期的な技術革新である [3−6]．HFNC は非侵襲的換気 (NIV) よりも使用や適用が容易であるため，急性低酸素性呼吸不全 (AHRF) の有望な代替治療法として登場してきた．新型コロナウイルス感染症 (COVID-19) の AHRF への HFNC の適応は，パンデミック当初はエアロゾルの発生が懸念されて，その使用が控えられた時期があった．その後に, 接触, 飛沫, 空気を媒介とした医療従事者の感染リスクを高めることには否定的な研究報告も行われて，中等症の COVID-19 AHRF 患者を対象に HFNC を適応する治療法の選択が普及した [7]．COVID-19 AHRF に対する HFNC 療法は，従来の低流量での酸素療法と比較して，気管挿管や臨床的改善までの日数を減らしたという報告がある一方で， HFNC の適応に頼って人工呼吸療法 (MV) の導入タイミングを遅らせないことが重症化を防ぐ上で重要であることも指摘されてきた [8]．そのような背景の中で，HFNC 治療の成否を予測する有用な指標として ROX index が報告された [9]．ROX index とは [SpO_2/FiO_2]/呼吸回数 [/分] であり，初期の研究では HFNC の成否 (MV 移行の基準) を判定するカットオフ値は，HFNC 導入後 6∼12 時間では 4.88(95 % CI は 4.2∼5.4) 程度と報告された [9,10]．AHRF を患う新型コロナウイルス感染症患者のメタ分析でも，ROX index が HFNC 不全を予測するための優れた指標であることが示唆されたが，そのカットオフ値は 2.7 から 5.99 まで変動した [11−16]．

[1]京都府立医科大学附属病院
[2]京都府立医科大学附属病院集中治療部
[3]同大学院医学研究科麻酔科学教室

3. ROX index と肺浸潤度 (Lung Infiltration Index，LIV)：Data Set 適応

我々の施設においても COVID-19 で AHRF に至り，HFNC 管理を行った 59 名の患者を対象に，MV への移行と ROX index 等の臨床指標の関係を後方視野的に解析して論文報告を行った [1]．この患者群 59 名のデータセットは公開している (doi: 10.7717/peerj.15174/supp-15, raw_data_f16.xlsx)． 対象となった全体 59 名の重症 AHRF 患者のうち，選択された呼吸療法の内訳と予後に関しては，HFNC で管理できた患者が 35 名 (全員救命)，MV 管理を行った患者が 24 名 (4 名が死亡) であった．主治医の治療選択の判断を目的変数として，それに影響を及ぼしたであろう各種臨床指標について，多変量ロジスティック解析を行って有意な説明変数を求めたところ，ROX index と胸部 CT 画像からコンピュータ算定した肺浸潤度 (Lung Infiltration Index，LIV，単位は%) が有意となった．

4. 治療選択に関する機械学習による 2 値分類

今回，上述のデータセットを用いて，呼吸療法選択 (HFNC か，MV かの 2 値分類) を目的変数，ROX index と LIV の 2 つを説明変数として，Python を用いた機械学習による分類モデルの構築と Python のグラフ描画ライブラリ Matplotlib を用いたグラフ図の作成を試みる．注意点として，この患者群では，HFNC 適応が開始された患者でも，状態が悪化すれば気管挿管されて MV に移行するため，HFNC 群には死亡患者はいない．一方では，もしかすると気管挿管して MV する必要が無かった患者も管理群には含まれている可能性がある．一方で，MV 群で救命できなかった 4 名の患者については，機械学習で分類した場合においても，できれば MV 群に分類されるべきであろう．教師あり機械学習では，データセットを訓練データ (training set) とテストデータ (test set) に分けて，分類モデルを構築して検証を加える．今回は，症例数が 59 件と少ないので，すべてのデータを訓練データに投入して分類モデルを構築してそのモデルを評価する．

		予測値	
		HFNC 陰性 /Negative/0	MV 陽性 /Positive/1
実際	HFNC 陰性 /Negative/0	TN 真陰性	FP 偽陽性
	MV 陽性 /Positive/1	FN 偽陰性	TP 真陽性

図 1. 高流量鼻カニューラ療法 (HFNC) と人工呼吸療法 (MV) の分類

1) Python プログラミング 1: データ読み込みと準備

機械学習としては，実際の HFNC 適応を陰性 negative, MV 適応を陽性 positive として捉えた場合，実際に MV を行った患者が MV に予測されることは真陽性 true positive (TP)，実際に HFNC を行った患者が HFNC に予測されることは真陰性 true nagative (TN)，MV を行った患者が HFNC に予測されることは偽陰性 false negative (FN), 逆に実際に HFNC を行った患者が MV に予測されることは偽陽性 false positive(FP) となる (図 1).

以下，Python プログラミングコードは，Appendix (Supplementary Python program code) として，著者のブログ (https://anesth-kpum.org/blog_ts/?p=4063) 上に添付する．プログラム実行による作図を含む結果 (Output) のみを本稿に挿入する．Python のコードは，Jupyter Notebook で実行し，解析・作図が可能である [17]．Python プログラミングでは，まず始めに Python の科学計算ライブラリ (NumPy)[18]，グラフ描画ライブラリ Matplotlib[19]，データ解析ライブラリ Pandas[20]，データ可視化ライブラリ Seaborn[21]，IPhython の Display モジュール [22]，そして機械学習 scikit-learn ライブラリ [23] の訓練用テスト用

データ分割モジュール sklearn.model_selection，モデル評価モジュール sklearn.metrics，前処理ライブラリ sklearn.preprocessing を導入した (加えて，エクセルファイル (.xlsx) を Pandas の DataFrame に読み込めるようにモジュール openpyxl を組み込んだ)[*PythonCode#1*]．

続いて 59 名の患者データ (Therapy，ROX index，LIV，Morality) のエクセルファイル raw_data_f16.xlsx を Pandas のデータフレーム df に読み込み，16 種類のデータコラムから，今回の解析に必要な“ResipratoryTherapy ”，“ROX index ”，”LIV (%) ”，“Mortality ”のみを抽出し，それぞれ ”Therapy, “ROX ”，”LIV ”，“Mortality ” と単純なコラム名に変換し，かつ ” Therapy ” については ” HFNC ” か ” MV ” と，データの記述を単純化した (同時にオリジナルデータのミススペル (Mortality: ”survivied ” = ”survived ”) も修正した [*PythonCode#2*]．

```
[Python Code #1 OUT]
[Python Code #2 OUT]
Index(['ResipratoryTherapy', 'ROX index', 'LIV (\%)', 'Gender', 'Age', 'BMI',
       'WBC (μ/L)', 'Cr (mg/dL)', 'CRP (mg//dL)', 'LDH (U/L)',
       'd-dimer (μ/L)', 'PSI', 'CCI', 'Days to Hostital (days)',
       'Days to HFNC (days)', 'Mortality'],
      dtype='object')

Index(['Therapy', 'ROX', 'LIV', 'Gender', 'Age', 'BMI', 'WBC', 'Cr', 'CRP',
       'LDH', 'd-dimer', 'PSI', 'CCI', 'DtoH', 'DaystoHFNC', 'Mortality'],
      dtype='object')
…<途中省略>…
   Therapy  ROX   LIV  Mortality
56      MV  3.0  36.1  survived
57      MV  8.1  32.8  survived
58      MV  4.5  33.7  survived
```

そして，ROX index と LIV の分布頻度について，ペアプロット機能で HFNC 群と MV 群それぞれについて描いて観察してみた [PythonCode#3]．

このペアプロットでは，赤色分布が MV 群，緑色分布が HFNC 群であり，ROX も LIV も重なる部分があるものの，明らかに違った分布を示していることがわかる．

次に，データフレーム data に読み込んだデータについて，カテゴリデータ (Therapy と，Mortality) を 2 値で数値化 ([Therapy : ’HFNC’:0, ’MV’:1] [Mortality : ’survived’:0, ’died’:1]) した [PythonCode#4]．

[Python Code #3 OUT]

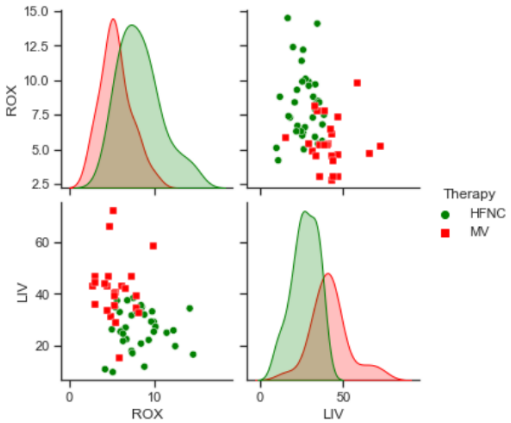

[Python Code #4 OUT]

	Therapy	ROX	LIV	Mortality
0	0	9.9	29.2	0
1	0	11.4	25.0	0
2	0	9.3	22.2	0

便宜上，必要なフィールドの組み合わせで，細分化したデータセットを用意し，NumPy の配列 data_0, data_1, data_2, data_3, Mortality, Therapy にデータコピーした [PythonCode#5]．

[Python Code #5 OUT]

	ROX	LIV
0	9.9	29.2
1	11.4	25.0
2	9.3	22.2

	ROX
0	9.9
1	11.4
2	9.3

	LIV
0	29.2
1	25.0
2	22.2

	Mortality
0	0
1	0
2	0

	Therapy
0	0
1	0
2	0

2) Python プログラミング 2: ロジスティック回帰による 2 値分類

まず，59 名の患者のデータを X 軸に ROX index, Y 軸に LIV(%) として, HFNC 患者と, MV 患者でラベルしてプロットしてみた [PythonCode#6]．ここでは，MV 患者の 4 名が救命できなかった患者 (■) も示している．

[Python Code #6 OUT]

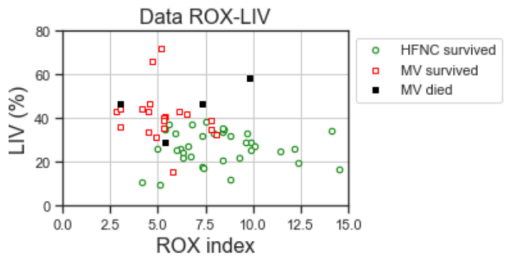

① ROX index 単独での 2 値ロジスティック解析による分類

この図をもとに，ROX index 単独で HFNC 群と MV 群の選択を分類するカットオフをロジスティック解析で予測した [PythonCode#7]，

[Python Code #7 OUT]

MAE = 0.237, RMSE = 0.487
score = 0.763
Coef = [-0.66758559]
Intercept = [4.04631497]

[PythonCode#8]．

[Python Code #8 OUT]

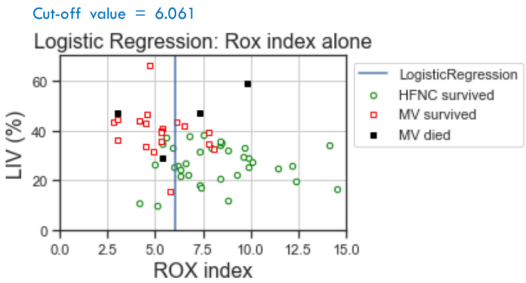

その結果，ROX index 単独のカットオフ値は 6.06 となった．この ROX index 単独でのカットオフによる HFNC 群と MV 群の選択分類では，正解率 (accuracy) 0.763，精度 (precision) 0.708，検出率 (recall) 0.708，F 値は 0.708 となった [PythonCode#9]．

[Python Code #9 OUT]

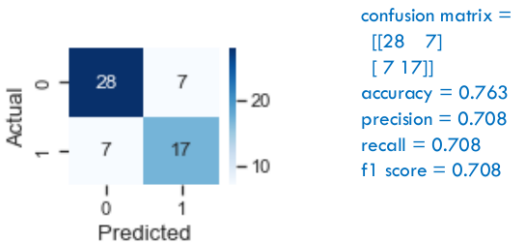

そして，ROX index 単独での ROC の AUC は 0.834 であった [PythonCode#10]．

[Python Code #10 OUT]

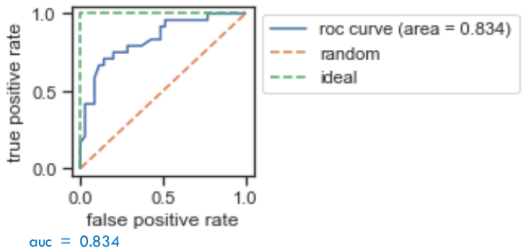

② LIV 単独での 2 値ロジスティック解析による分類

次に LIV を単独でカットオフとして用いた場合の HFNC 群と MV 群を分類するロジスティック解析についても確認した [PythonCode#11],[PythonCode#12]．その結果，LIV 単独でのカットオフ値は 35.5% となった．

[Python Code #11 OUT]

```
MAE = 0.169,  RMSE = 0.412
score = 0.831
Coef = [0.22727056]
Intercept = [-8.06167609]
Threshold of LIV = 35.472
```

[Python Code #12 OUT]

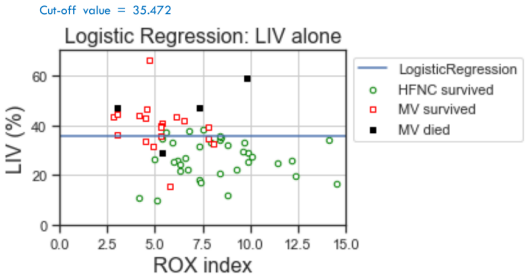

LIV 単独でのカットオフによる HFNC 群と MV 群の分類では，正解率 (accuracy) 0.831，精度 (precision) 0.818，検出率 (recall) 0.750，F 値は 0.783 となり，ROX index 単独のカットオフ値よりも，分類評価のパラメータは改善していた [PythonCode#13]．

[Python Code #13 OUT]

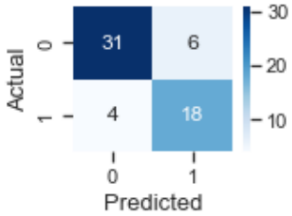


```
confusion matrix =
 [[31  4]
 [ 6 18]]
accuracy = 0.831
precision = 0.818
recall = 0.750
f1 score = 0.783
```

LIV 単独での分類の ROC の AUC は 0.892 であった [PythonCode#14]．

[Python Code #14 OUT]

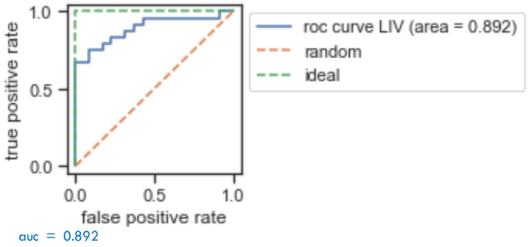

③ ROX index と LIV の両方を用いた 2 値ロジスティック解析による分類

次に，ROX index と LIV の両方を用いた場合の HFNC 群と MV 群の分類についてロジスティック解析を行った．その結果，ロジット関数

$$\log(p/(1-p)) = \beta_0 + \beta_1 x_1 + \beta_2 x_2$$
$$SCORE = coef_1[0] \times [ROXindex + coef_1[1] \times [LIV] + intercept_1$$

は，$SCORE = -0.742 * [ROXindex] + 0.190 * [LIV] - 1.81$ となった．分類の境界線は $p = 0.5$ の場合であるので，$-0.742 * [ROXindex] + 0.190 * [LIV] - 1.81 = 0$ となり，$LIV = 3.89 * ROX + 9.53$ となった [PythonCode#15], [PythonCode#16]．

[Python Code #15 OUT]

```
MAE = 0.153,  RMSE = 0.391
score = 0.847
Coef =  [-0.74187745  0.1902778 ]
Intercept =  [-1.80717029]
```

[Python Code #16 OUT]

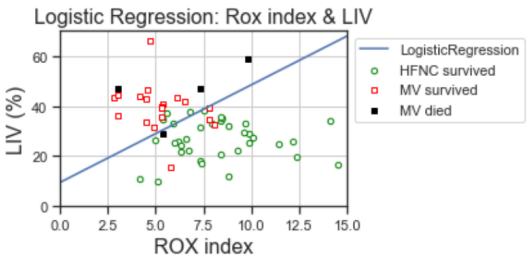

ROX index と LIV の両方を用いた場合の HFNC 群と MV 群選択の分類では，正解率 (accuracy) 0.847，精度 (precision) 0.826，検出率 (re-

call) 0.792，F 値は 0.809 となり，それぞれ単独の場合よりも改善を示した [PythonCode#17]．

[Python Code #17 OUT]

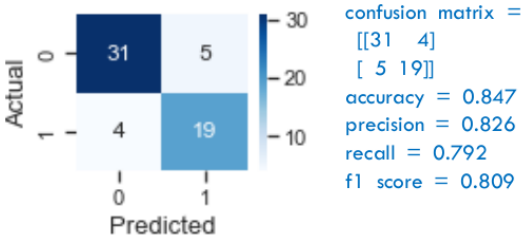

ROX index と LIV の両方を用いた HFNC 群と MV 群の分類では，ROC の AUC は 0.937 であった [PythonCode#18]．

[Python Code #18 OUT]

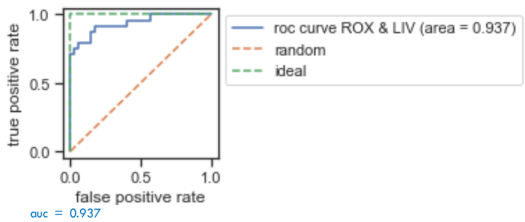

上記 3 つのロジスティック解析による分類モデルによる ROC 曲線を，一つのグラフにまとめて描いて比較してみた [PythonCode#19]．

[Python Code #19 OUT]

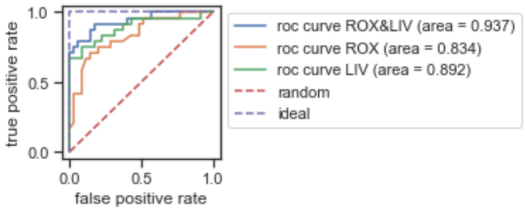

3) Python プログラミング 3: サポートベクトルマシンによる 2 値分類

次に，サポートベクターマシン (SVM) を用いた 2 値分類を HFNC 群と MV 群の選択分類に適応してみた．サポートベクトル (Support Vector) とは，データを分割する直線に最も近いデータのことであるが，サポートベクトルと対象データの距離を最大化し，分類推定の精度を高めるアルゴリズムを用いて 2 値分類に取り組む方法である [24, 25]．直線的な境界線を引く線形サポートベクトルと，曲線の境界で分類線を引く非線形サポートベクトルとに分かられるが，線形分離可能なデータを前提としたハードマージン，線形分離不可能なデータを前提として誤分類をある程度許容するソフトマージンがある．

① ソフトマージン線形サポートベクトルマシンによる 2 値分類

まずは，ソフトマージン線形サポートベクトルマシンによる分類を試みた [PythonCode#20] [25]．

[Python Code #20 OUT]

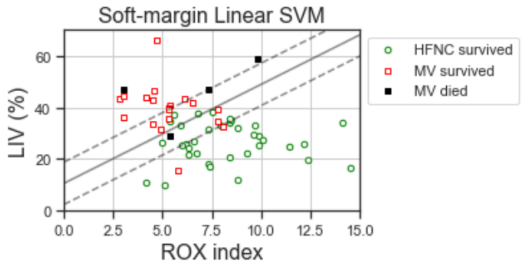

ソフトマージン線形サポートベクトルマシンを用いた場合，HFNC 群と MV 群選択の分類に対して，正解率 (accuracy) 0.864，精度 (precision) 0.864，検出率 (recall) 0.792，F 値は 0.826 となり，前述のロジスティック回帰による分類よりも更に改善した [PythonCode#21]．

[Python Code #21 OUT]

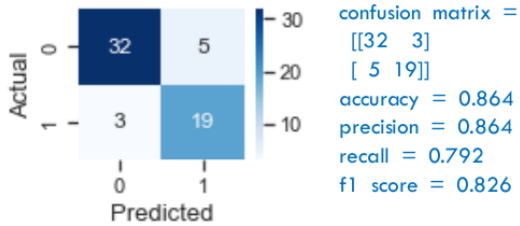

次にサポートベクターマシンにカーネル法を適用することにより，曲線的な分離線で HFNC 群と MV 群選択の分類を行える非線形に拡張した非線形サポートベクトルマシンを試した [25]．はじめに，sklearn.Preprocessing のデータ

標準化モジュール StandardScaler() を用いて，データセットの標準化を行った．標準化を行うことによって，特徴量の比率を揃えることができる [PythonCode#22]，[PythonCode#23]．標準化されたデータに対して，sklearn.svm の SVC を用いてモデル化を行った．

[Python Code #22 OUT]
[Python Code #23 OUT]

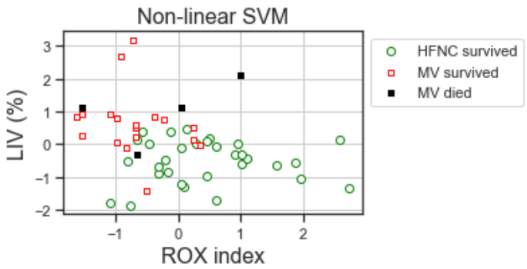

② 非線形サポートベクトルマシン (多項式カーネル) による 2 値分類

まず始めにカーネル法による非線形サポートベクトルマシンカーネル関数には，多項式カーネル (poly) を選択した [PythonCode#24]，[PythonCode#25]．

[Python Code #24 OUT]
[Python Code #25 OUT]

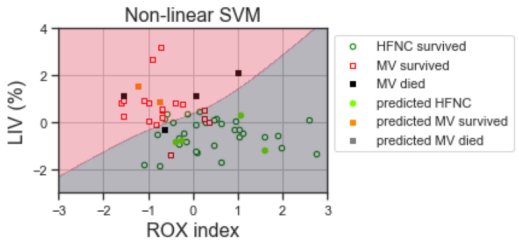

非線形サポートベクトルマシンを用いた場合，HFNC 群と MV 群選択の分類に対して正解率 (accuracy) 0.864，精度 (precision) 0.864，検出率 (recall) 0.792，F 値は 0.826 となった．ほぼ．ソフトマージン SVC と同等の値となった [PythonCode#26]．

[Python Code #26 OUT]

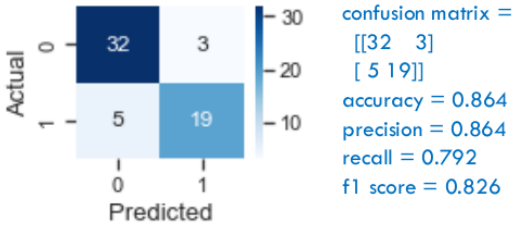

③ 非線形サポートベクトルマシン (ガウスカーネル) による 2 値分類

次に非線形サポートベクトルマシンのカーネル関数にガウスカーネル (RBF：Radial Basis Function) を選択した [PythonCode#27]，[PythonCode#28]．

[Python Code #27 OUT]
[Python Code #28 OUT]

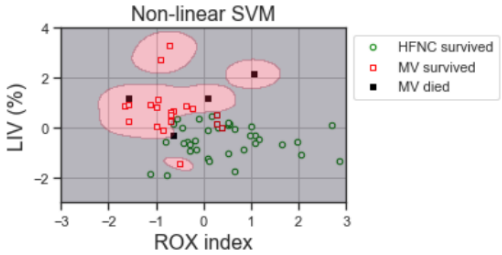

非線形サポートベクトルマシンでガウスカーネルを選択した結果，HFNC 群と MV 群選択の分類に対して，正解率 (accuracy) 0.932，精度 (precision) 1.00，検出率 (recall) 0.833，F 値は 0.909 と最高となった [PythonCode#29]．

[Python Code #29 OUT]

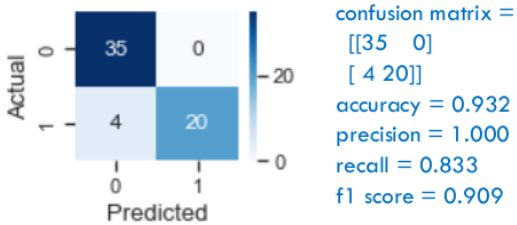

しかしながら，一方で，グラフをみて分かる通り，明らかに島状にエリア分類された MV 群は，いわゆる過学習状態であることがわかる．

4) Python プログラミング 4: ナイーブベイズフィルタによる 2 値分類

最後にベイズ理論を利用したガウシアンナイーブベイズによる単純ベイズ分類器（ナイーブベイズフィルタ）を用いた[PythonCode#30], [PythonCode#31], [PythonCode#32][26]．ラベルに対する特徴量の尤度がガウス分布であると仮定したベイズフィルタであり，同じラベルに属しているデータのガウス分布を求め，新しいデータに対してどちらの分布に近いかを判別していく方法である．

[Python Code #30 OUT]
score = 0.831
[Python Code #31 OUT]
[Python Code #32 OUT]

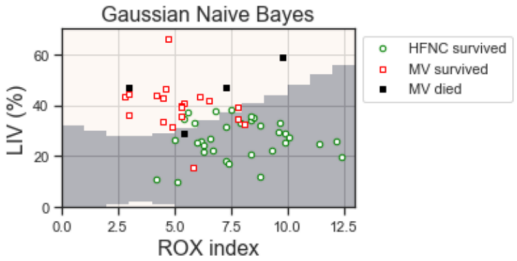

ソフトマージンサポートベクトルマシンを用いた場合，HFNC 群と MV 群選択の分類に対して正解率 (accuracy) 0.831，精度 (precision) 0.792，検出率 (recall) 0.792，F 値は 0.792 となった．ソフトマージンサポートベクトルマシンより分類の成績は少し下がった [PythonCode#33]．

[Python Code #33 OUT]

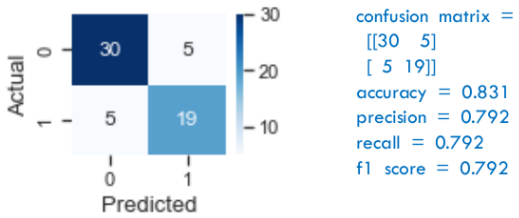

5. 治療選択判断に関する機械学習分類モデルの比較

今回，試した 7 つの分類モデルによる成績を表に比較してみる (表 1)．非線形 SVM(kernel = RBF) が最も良い値をもたらしたが，前述の通りその結果は明らかに過学習であった．臨床的な判断の基準となる分類の精度としてはソフトマージン線形 SVM か，非線形 SVM(kernel = poly) あたりが最良であった．

表1. 7 つの分類モデルによる成績比較

methods	accuracy	precision	recall	f1 score
Logistic Regression ROX	0.763	0.708	0.708	0.708
Logistic Regression LIV	0.831	0.818	0.750	0.783
Logistic Regression ROX & LIV	0.847	0.826	0.792	0.809
Soft Margin Linear SVM	0.864	0.864	0.792	0.826
Non-Linear SVM kernel=poly	0.864	0.864	0.792	0.826
Non-Linear SVM kernel=rbf	0.932	1.000	0.833	0.909
Gaussian Naive Bayes	0.831	0.792	0.792	0.792

6. まとめ

以上，COVID-19 重症呼吸不全患者のデータセットを用いて，コンピュータ言語 Python による 2 値分類 (HFNC か MV か) の機械学習プログラミングと作図機能について，7 つのモデルを示した．短いプログラムコードによって，機械学習による分類モデル化の実践を示せたものと考える．本稿での図 1 を除くグラフ図は，すべて添付

の Python のプログラムコードから Python Matplotlib のグラフ機能を用い，イラストレータなどの絵かきソフトでの加工は一切行っていない．直接論文投稿に耐えうる美しいグラフ作成が可能であることを付記しておきたい [19]．

参考文献

1. Sudo K, Sawa T, Kushimoto K, Yoshii R, Yuasa K, Inoue K, Kinoshita M, Yamasaki M, Kooguchi K. Choice ofrespiratory therapy for COVID-19 patients with acute hypoxic respiratory failure: a retrospective case series studies. PeerJ 11:e15174, 2023. doi:10.7717/peerj.15174.
2. 須藤和樹, 吉井龍吾, 井上敬太, 山崎正記, 小尾口邦彦, 佐和貞治. ベイジアンネットワーク解析; COVID-19 重症呼吸不全の呼吸管理法がかかわる統計因果推論. 麻酔・集中治療とテクノロジー 2022 (第 40 回日本麻酔・集中治療テクノロジー学会論文集). https://jsta.net/pdf/2023.pdf (アクセス 2023 年 6 月 10 日).
3. Matthay MA, Thompson, BTWare LB. The Berlin definition of acute respiratory distress syndrome: should patients receiving high-flow nasal oxygen be included? Lancet 9: 933-936, 2021.doi:10.1016/S2213-2600(21)00105-3.
4. Duan J, Chen B, Liu X, Shu W, Zhao W, Li J, Li Y, Hong Y, Pan L, Wang K. Use of high-flow nasal cannula and noninvasive ventilation in patients with COVID-19: A multicenter observational study. Am J Emerg Med 46:276-281. 2020.?doi: 10.1016/j.ajem.2020.07.071.
5. Guy T, Cr?ac ’ hcadec A, Ricordel C, Sal? A, Arnouat B, Bizec J-L, Langelot M, Lineau C, Marquette D, Martin F, Lederlin M, Jouneau S. High-flow nasal oxygen: a safe, efficient treatment for COVID-19 patients not in an ICU. Eur Respir J 56:2001154. 2020.?doi: 10.1183/13993003.01154-2020
6. Patel M, Gangemi A, Marron R, Chowdhury J, Yousef I, Zheng M, Mills N, Tragesser L, Giurintano J, Gupta R, Gordon M, Rali P, D’Alonso G, Fleece D, Zhao H, Patlakh N, Criner G. Retrospective analysis of high flow nasal therapy in COVID-19-related moderate-to-severe hypoxaemic respiratory failure. BMJ Open Respir Res 7:e000650, 2020.?doi: 10.1136/bmjresp-2020-000650.
7. Westafer L, Soares W, Salvador D, Medarametla V, Schoenfeld EM. No evidence of increasing COVID-19 in health care workers after implementation of high flow nasal cannula: A safety evaluation. Am J Emerg Med 39:158-161, 2021.?doi: 10.1016/j.ajem.2020.09.086.?
8. Kang BJ, Koh Y, Lim CM, Huh JW, Baek S, Han M, Seo HS, Suh HJ, Seo GJ, Kim EY, Hong SB. Failure of high-flow nasal cannula therapy may delay intubation and increase mortality. Intensive Care Med 41:623-632, 2015. doi:10.1007/s00134-015-3693-5.
9. Roca O, Messika J, Caralt B, Garcia-de-Acilu M, Sztrymf B, Ricard JD, Masclans JR. Predicting success of high-flow nasal cannula in pneumonia patients with hypoxemic respiratory failure: The utility of the ROX index. J Crit Care 35:200-205, 2016. doi:10.1016/j.jcrc.2016.05.022.
10. Roca O, Messika J, Samper M, Sztrymf B, Hern?ndez G, Garc?a-de-Acilu M, Frat J-P, Masclans JR, Ricard J-D. An index combining respiratory rate and oxygenation to predict outcome of nasal high flow therapy. Am J Respir Crit Care Med 199:1368-1376, 2019. doi: 10.1164/rccm.201803-0589OC.
11. Prakash J, Bhattacharya PK, Yadav AK, Kumar A, Tudu LC, Prasad K. ROX index as a good predictor of high flow nasal cannula failure in COVID-19 patients with acute hypoxemic respiratory failure: A systematic review and meta-analysis. J Crit Care 66:102-108, 2021. doi: 10.1016/j.jcrc.2021.08.012.
12. Zhou X, Liu J, Pan J, Xu Z, Xu J. The ROX index as a predictor of high-flow nasal cannula outcome in pneumonia patients with acute hypoxemic respiratory failure: A systematic review and meta-analysis. BMC Pulm Med 22:121, 2022. doi:10.1186/s12890-022-01914-2.
13. Ferrer S, Sancho J, Bocigas I, Bures E, Mora H, Monclou E, Mulet A, Quezada A, Royo P, Signes-Costa J. ROX index as predictor of high flow nasal cannula therapy success in acute respiratory failure due to SARS-CoV-2. Respir Med 189:106638, 2021. doi:10.1016/j.rmed.2021.106638.
14. Hu M, Zhou Q, Zheng R, Li X, Ling J, Chen Y, Jia J, Xie C. Application of high-flow nasal cannula in hypoxemic patients with COVID-19: A retrospective cohort study. BMC Pulm Med 20:324, 2020. doi:10.1186/s12890-020-01354-w.
15. Vega ML, Dongilli R, Olaizola G, Colaianni N, Sayat MC, Pisani L, Romagnoli M, Spoladore G, Prediletto I, Montiel G, Nava S. COVID-19 pneumonia and ROX index: Time to set a new threshold for patients admitted outside the ICU. Pulmonology 28:13-17, 2022. doi: 10.1016/j.pulmoe.2021.04.003.

16. Junhai Z, Jing Y, Beibei C, Li L. The value of ROX index in predicting the outcome of high flow nasal cannula: A systematic review and meta-analysis. Respir Res 23:33, 2022. doi:10.1186/s12931-022-01951-9.
17. Jupyter Notebook. https://jupyter.org (access on June 10, 2023).
18. NumPy. The package for scientific computing with Python. https://numpy.org (access on June 10, 2023).
19. Matplotlob. Visualization with Python. https://matplotlib.org (access on June 10, 2023).
20. Pandas. Python Data Analysis Library. https://pandas.pydata.org (access on June 10, 2023).
21. Seaborn. statistical data visualization https://seaborn.pydata.org (access on June 10, 2023).
22. Module: display. IPython https://ipython.readthedocs.io/en/stable/api/generated/IPython.display.html (access on June 10, 2023).
23. Scikit-learn. Machine learning in Python. https://scikit-learn.org (access on June 10, 2023).
24. 田村孝廣. 非線形サポートベクトルマシン. やさしく学べる数学の基礎と Python による実践. オーム社. 2022. 東京. pp.133-173. ISBN: 978-4274229671.
25. 植村誠. 判別モデル: サポートベクトルマシーン. 物理のためのデータサイエンス入門 (KS 物理専門書)?. 講談社, 2023, 東京. pp.154-158. ISBN: 978-4065309933.
26. ガウシアンナイーブベイズ. https://taketake2.com/N60.html (access on June 7, 2023).


```
Appendix: Supplementary Python (ver 3.8) program code
(https://anesth-kpum.org/blog_ts/?p=4063)
#-[Python Code #1]-----------------------------------------------
import numpy as np
import matplotlib.pyplot as plt
import pandas as pd
import seaborn as sns
import IPython.core.display as display
import IPython.display
%matplotlib inline

from sklearn.model_selection import train_test_split
from sklearn.metrics import mean_squared_error
from sklearn.metrics import mean_absolute_error
from sklearn.metrics import confusion_matrix
from sklearn.metrics import accuracy_score
from sklearn.metrics import precision_score
from sklearn.metrics import recall_score
from sklearn.metrics import classification_report
from sklearn.preprocessing import StandardScaler

# pip install openpyxl
# you may need to restart the kernel to use updated packages.
#-[END]-----------------------------------------------------------
#-[Python Code #2]-----------------------------------------------
# Read Excel Database raw_data_f16.xlsx, and preprocessing
df = pd.read_excel('raw_data_f16.xlsx')
print(df.columns)

df_copy = df.copy()
df_copy.rename(columns = {'ResipratoryTherapy': 'Therapy', \
'ROX index': "ROX", \
'LIV (%)': "LIV", \
'Gender': "Gender", \
       'Age': "Age", \
'BMI': "BMI", \
'WBC (μ/L)': "WBC", \
'Cr (mg/dL)': "Cr", \
       'CRP (mg//dL)': "CRP", \
'LDH (U/L)': "LDH", \
'd-dimer (μ/L)': "d-dimer", \
'PSI': "PSI", \
'CCI': "CCI", \
       'Days to Hostital (days)': "DtoH", \
'Days to HFNC (days)': "DaystoHFNC", \
'Mortality': "Mortality" }, inplace=True)
print("")
print(df_copy.columns)

data = df_copy[["Therapy", "ROX", "LIV", "Mortality"]]

print("")
print(data.head(3))
print("")
print(data.tail(3))

# Therapy data: simplify to ['HFNC', 'MV']
def therapy_convert(x):
    if x == 'High-flow Nasal Cannulation':
        return 'HFNC'
    elif x == 'Mechanical Ventilation':
        return 'MV'

# Mortality: fix misspell ['survivied'] to ['survived']
def mortality_convert(x):
    if x == 'survivied':
        return 'survived'

# Therapy: simplify the data description
data["Therapy"] = data["Therapy"].apply(therapy_convert)

# Fix misspell in Mortality
data["Mortality"] = data["Mortality"].apply(mortality_convert)

print("")
print(data.head(3))
print("")
print(data.tail(3))
#-[END]-----------------------------------------------------------
#-[Python Code #3]-----------------------------------------------
# Pair Plot
sns.set(style="ticks")
sns.pairplot(data, hue='Therapy', markers=['o', ','], \
palette={'HFNC': 'green', 'MV': 'red'})
plt.show()
#-[END]-----------------------------------------------------------
#-[Python Code #4]-----------------------------------------------
#Numericalization of categorical data
data_0 = data
class_mapping1  \
= {'HFNC':0, 'MV':1}
data_0['Therapy'] \
= data['Therapy'].map(class_mapping1)
class_mapping2  \
= {'survived':0, 'died':1}
data_0['Mortality'] \
= data['Mortality'].map(class_mapping2)
data_0.head(3)
#-[END]-----------------------------------------------------------
#-[Python Code #5]-----------------------------------------------
data_1 = data_0.iloc[:,1:3]
data_2 = data_0.iloc[:,1:2]
data_3 = data_0.iloc[:,2:3]
Mortality = data_0.iloc[:,3:4]
Therapy = data_0.iloc[:,0:1]

IPython.display.display(data_1.head(3))
IPython.display.display(data_2.head(3))
IPython.display.display(data_3.head(3))
IPython.display.display(Mortality.head(3))
IPython.display.display(Therapy.head(3))
#-[END]-----------------------------------------------------------
#-[Python Code #6]-----------------------------------------------
# Classifying patients to 3 subgroups
df_group_1 = data_0[(data_0['Therapy'] == 0) \
& (data_0['Mortality'] == 0)]
df_group_2 = data_0[(data_0['Therapy'] == 1) \
& (data_0['Mortality'] == 0)]
df_group_3 = data_0[(data_0['Therapy'] == 1) \
& (data_0['Mortality'] == 1)]
# Plot data
plt.figure(figsize = (4,2.5))
plt.scatter(df_group_1['ROX'], df_group_1['LIV'], \
 label="HFNC survived", \
            color='white', s=20, marker="o", \
 edgecolor='green')
plt.scatter(df_group_2['ROX'], df_group_2['LIV'], \
label="MV survived", \
            color='white', s=20, marker=",", \
edgecolor='red')
plt.scatter(df_group_3['ROX'], df_group_3['LIV'], \
 label="MV died", \
```

```
color='black', s=20, marker=",", \
edgecolor='black')
plt.title("Data set")
plt.xlim(0,15)
plt.ylim(0,80)
plt.title("Data ROX-LIV", fontsize=16)
plt.xlabel("ROX index", fontsize=16)
plt.ylabel("LIV (%)", fontsize=16)
plt.grid()
plt.legend(loc='upper left', bbox_to_anchor=(1,1))
#~[END]-------------------------------------------------------
#~[Python Code #7]---------------------------------------------
###########################
# Logistic Regression ROX
###########################
from sklearn.linear_model import LogisticRegression

# Split the data to training and test data sets
# X_train, X_test, Y_train, Y_test
# = train_test_split(data2, Therapy, test_size = 0.2, random_state=0)
X_train = data_2
Y_train = Therapy
X_test = data_2
Y_test = Therapy

# Evaluation
Logreg_2 = LogisticRegression()
Logreg_2.fit(X_train, Y_train)

# Logistic Regression
Y_pred_2 = logreg_2.predict(X_test)

# Evaluation
# mean absolute error(MAE)
mae_2 = mean_absolute_error(Y_test, Y_pred_2)
# root mean squared error(RMSE)
rmse_2 = np.sqrt(mean_squared_error(Y_test, Y_pred_2))
# Score
score_2 = logreg_2.score(X_test, Y_test)

coef_2 = logreg_2.coef_[0]
intercept_2 = logreg_2.intercept_

print("MAE = %.3f, RMSE = %.3f" % (mae_2, rmse_2))
print("score = %.3f" % (score_2))
print("Coef = ", coef_2)
print("Intercept = ", intercept_2)
#~[END]-------------------------------------------------------
#~[Python Code #8]---------------------------------------------
# Plot Logistic Regression
plt.figure(figsize = (4,2.5))
plt.scatter(df_group_1['ROX'], df_group_1['LIV'], \
label="HFNC survived", color='white', \
s=20, marker="o", edgecolor='green')
plt.scatter(df_group_2['ROX'], df_group_2['LIV'], \
label="MV survived", color='white', \
            s=20, marker=",", edgecolor='red')
plt.scatter(df_group_3['ROX'], df_group_3['LIV'], \
 label="MV died", color='black', \
s=20, marker=",", edgecolor='black')

line = np.linspace(0, 70)
plt.plot((line * 0 - intercept_2 / coef_2), line, c='b', \
label="LogisticRegression")
print("Cut-off value = %.3f" % (- intercept_2 / coef_2))
plt.ylim(0, 70)
plt.xlim(0, 15)
plt.title("Logistic Regression: Rox index alone", fontsize=16)
plt.xlabel("ROX index", fontsize=16)
plt.ylabel("LIV (%)", fontsize=16)
plt.grid()
plt.legend(loc='upper left', bbox_to_anchor=(1, 1))
#~[END]-------------------------------------------------------
#~[Python Code #9]---------------------------------------------
# Making Heat Map
cm = confusion_matrix(Y_pred_2, Therapy)
plt.figure(figsize = (2,1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()

from sklearn.metrics import confusion_matrix, accuracy_score, \
precision_score, recall_score, f1_score
print("confusion matrix = \n", \
confusion_matrix(y_true=Therapy, y_pred=Y_pred_2))
print("accuracy = %.3f" \
% (accuracy_score(y_true=Therapy, y_pred=Y_pred_2)))
print("precision = %.3f" \
% (precision_score(y_true=Therapy, y_pred=Y_pred_2)))
print("recall = %.3f" \
% (recall_score(y_true=Therapy, y_pred=Y_pred_2)))
print("f1 score = %.3f" \
% (f1_score(y_true=Therapy, y_pred=Y_pred_2)))

from sklearn.metrics import roc_auc_score
print("auc = %.3f" \
% (roc_auc_score(y_true=Therapy, y_score=Y_score_2)))
#~[END]-------------------------------------------------------
#~[Python Code #10]--------------------------------------------
from sklearn.metrics import roc_curve, auc
Y_score_2 = logreg_2.predict_proba(data_2)[:, 1]
fpr_2, tpr_2, thresholds_2 \
= roc_curve(y_true=Therapy, y_score=Y_score_2)

plt.figure(figsize=(2,2))
plt.plot(fpr_2, tpr_2, label \
='roc curve (area = %0.3f)' % auc(fpr_2, tpr_2))
plt.plot([0, 1], [0, 1], linestyle='--', label='random')
plt.plot([0, 0, 1], [0, 1, 1], linestyle='--', label='ideal')
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
plt.xlabel('false positive rate')
plt.ylabel('true positive rate')
plt.show()

from sklearn.metrics import roc_auc_score
print("auc = %.3f"  \
% (roc_auc_score(y_true=Therapy, y_score=Y_score_2)))

#~[END]-------------------------------------------------------
#~[Python Code #11]--------------------------------------------
###########################
# Logistic Regression LIV
###########################
X_train = data_3
Y_train = Therapy

# LogisticRegression
logreg_3 = LogisticRegression()

logreg_3.fit(X_train, Y_train)

# Prediction
Y_pred_3 = logreg_3.predict(X_test)

# Evaluation
# mean absolute error(MAE)
mae_3 = mean_absolute_error(Y_test, Y_pred_3)
# root mean squared error(RMSE)
rmse_3 = np.sqrt(mean_squared_error(Y_test, Y_pred_3))
# Score
score_3 = logreg_3.score(X_test, Y_test)
coef_3 = logreg_3.coef_[0]
intercept_3 = logreg_3.intercept_

print("MAE = %.3f, RMSE = %.3f" % (mae_3, rmse_3))
print("score = %.3f" % (score_3))
print("Coef =", coef_3)
print("Intercept =", intercept_3)
print("Threshold of LIV = %.3f" % (-intercept_3/coef_3))
#~[END]-------------------------------------------------------
#~[Python Code #12]--------------------------------------------
# Plot Logistic Regression
plt.figure(figsize= (4, 2.5))
plt.scatter(df_group_1['ROX'], df_group_1['LIV'], label="HFNC survived", \
            color='white', s=20, marker="o", edgecolor='green')
plt.scatter(df_group_2['ROX'], df_group_2['LIV'], label="MV survived", \
            color='white', s=20, marker=",", edgecolor='red')
plt.scatter(df_group_3['ROX'], df_group_3['LIV'], label="MV died", \
            color='black', s=20, marker=",", edgecolor='black')

line = np.linspace(0, 15)
plt.plot(line, line * 0 - intercept_3/coef_3, c \
='b', label="LogisticRegression")
print("Cut-off value = %.3f" % (- intercept_3/coef_3))
plt.ylim(0, 70)
plt.xlim(0, 15)
plt.title("Logistic Regression: LIV alone", fontsize=16)
plt.xlabel("ROX index", fontsize=16)
plt.ylabel("LIV (%)", fontsize=16)
plt.grid()
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
#~[END]-------------------------------------------------------
#~[Python Code #13]--------------------------------------------
# Making Heat Map
cm = confusion_matrix(Y_pred_3, Therapy)
plt.figure(figsize = (2, 1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()

print("confusion matrix = \n", \
confusion_matrix(y_true=Therapy, y_pred=Y_pred_3))
print("accuracy = %.3f" \
% (accuracy_score(y_true=Therapy, y_pred=Y_pred_3)))
print("precision = %.3f" \
% (precision_score(y_true=Therapy, y_pred=Y_pred_3)))
print("recall = %.3f" \
% (recall_score(y_true=Therapy, y_pred=Y_pred_3)))
print("f1 score = %.3f" \
% (f1_score(y_true=Therapy, y_pred=Y_pred_3)))
#~[END]-------------------------------------------------------
#~[Python Code #14]--------------------------------------------
```

```
Y_score_3 = logreg_3.predict_proba(data_3)[:, 1]
fpr_3, tpr_3, thresholds_3 \
= roc_curve(y_true=Therapy, y_score=Y_score_3)

plt.figure(figsize= (2, 2))
plt.plot(fpr_3, tpr_3, label \
='roc curve LIV (area = %0.3f)' % auc(fpr_3, tpr_3))
plt.plot([0, 1], [0, 1], linestyle='--', label='random')
plt.plot([0, 0, 1], [0, 1, 1], linestyle='--', label='ideal')
plt.legend(loc='upper left', bbox_to_anchor=(1, 1))
plt.xlabel('false positive rate')
plt.ylabel('true positive rate')
plt.show()

print("auc = %.3f" \
% (roc_auc_score(y_true=Therapy, y_score=Y_score_3)))
#-[END]-----------------------------------------------------------
#-[Python Code #15]------------------------------------------------
################################
# Logistic Regression   ROX & LIV
\
################################
from sklearn.linear_model import LogisticRegression

# Split the data to training and test data sets
# X_train, X_test, Y_train, Y_test = train_test_split(data1,
# Therapy, test_size = 0.2, random_state=0)
X_train = data_1
Y_train = Therapy
X_test = data_1
Y_test = Therapy

# LogisticRegression
# logreg = LogisticRegression(penalty='l2', solver="sag")
logreg_1 = LogisticRegression()
logreg_1.fit(X_train, Y_train)

# Prediction
Y_pred_1 = logreg_1.predict(X_test)

# Evaluation
# mean absolute error(MAE)
mae_1 = mean_absolute_error(Y_test, Y_pred_1)
# root mean squared error(RMSE)
rmse_1 = np.sqrt(mean_squared_error(Y_test, Y_pred_1))
# Score
score_1 = logreg_1.score(X_test, Y_test)

coef_1 = logreg_1.coef_[0]
intercept_1 = logreg_1.intercept_

print("MAE = %.3f, RMSE = %.3f" % (mae_1, rmse_1))
print("score = %.3f" % (score_1))
print("Coef = ", coef_1)
print("Intercept = ", intercept_1)
#-[END]-----------------------------------------------------------
#-[Python Code #16]------------------------------------------------
# Plot Logistic Regression
line = np.linspace(0, 15)

plt.figure(figsize=(4, 2.5))
plt.scatter(df_group_1['ROX'], \
df_group_1['LIV'], label= "HFNC survived", \
            color='white', s=20, marker="o", edgecolor='green')
plt.scatter(df_group_2['ROX'], \
df_group_2['LIV'], label="MV survived", \
            color='white', s=20, marker=",", edgecolor='red')
plt.scatter(df_group_3['ROX'], \
df_group_3['LIV'], label="MV died", \
            color='black', s=20, marker=",", edgecolor='black')

plt.plot(line, -(line * coef_1[0] + intercept_1) / coef_1[1], \
c='b', label="LogisticRegression")
plt.ylim(0, 70)
plt.xlim(0, 15)
plt.title("Logistic Regression: Rox index & LIV", fontsize=16)
plt.xlabel("ROX index", fontsize=16)
plt.ylabel("LIV (%)", fontsize=16)
plt.grid()
plt.legend(loc='upper left', bbox_to_anchor=(1, 1))
#-[END]-----------------------------------------------------------
#-[Python Code #17]------------------------------------------------
# Making Heat Map
cm = confusion_matrix(Y_pred_1, Therapy)
plt.figure(figsize = (2, 1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()

print("confusion matrix = \n", \
confusion_matrix(y_true=Therapy, y_pred=Y_pred_1))
print("accuracy = %.3f" \
% (accuracy_score(y_true=Therapy, y_pred=Y_pred_1)))
print("precision = %.3f" \
% (precision_score(y_true=Therapy, y_pred=Y_pred_1)))
print("recall = %.3f" \
% (recall_score(y_true=Therapy, y_pred=Y_pred_1)))
print("f1 score = %.3f" \
% (f1_score(y_true=Therapy, y_pred=Y_pred_1)))
#-[END]-----------------------------------------------------------
#-[Python Code #18]------------------------------------------------
Y_score_1 = logreg_1.predict_proba(data_1)[:, 1]
fpr_1, tpr_1, thresholds_1 \
= roc_curve(y_true=Therapy, y_score=Y_score_1)

plt.figure(figsize= (2, 2))
plt.plot(fpr_1, tpr_1, label \
='roc curve LIV (area = %0.3f)' % auc(fpr_1, tpr_1))
plt.plot([0, 1], [0, 1], linestyle='--', label='random')
plt.plot([0, 0, 1], [0, 1, 1], linestyle='--', label='ideal')
plt.legend(loc='upper left', bbox_to_anchor=(1, 1))
plt.xlabel('false positive rate')
plt.ylabel('true positive rate')
plt.show()

print("auc = %.3f" \
% (roc_auc_score(y_true=Therapy, y_score=Y_score_1)))
#-[END]-----------------------------------------------------------
#-[Python Code #19]------------------------------------------------
plt.figure(figsize=(2, 2))
plt.plot(fpr_1, tpr_1, label \
='roc curve ROX&LIV (area = %0.3f)' % auc(fpr_1, tpr_1))
plt.plot(fpr_2, tpr_2, label \
='roc curve ROX (area = %0.3f)' % auc(fpr_2, tpr_2))
plt.plot(fpr_3, tpr_3, label \
='roc curve LIV (area = %0.3f)' % auc(fpr_3, tpr_3))
plt.plot([0, 1], [0, 1], linestyle='--', label='random')
plt.plot([0, 0, 1], [0, 1, 1], linestyle='--', label='ideal')
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
plt.xlabel('false positive rate')
plt.ylabel('true positive rate')
plt.show()
#-[END]-----------------------------------------------------------
#-[Python Code #20]------------------------------------------------
#######################
# Soft Margin Linear SVM
#######################

# Split the data to training and test data sets
# X_train, X_test, Y_train, Y_test = train_test_split(data1,
# Therapy, test_size = 0.2, random_state=0)
X_train = data_1
Y_train = Therapy
X_test = data_1
Y_test = Therapy

soft_linear_svc = SVC(C=0.1, kernel='linear')
soft_linear_svc.fit(X_train, Y_train)

y_test_pred = soft_linear_svc.decision_function(X_test)
y_test_len = len(y_test_pred)
Y_pred_S = soft_linear_svc.predict(X_test)

plt.figure(figsize= (4, 2.5))
plt.scatter(df_group_1['ROX'], \
df_group_1['LIV'], label="HFNC survived", \
            color='white', s=20, marker="o", edgecolor='green')
plt.scatter(df_group_2['ROX'], \
df_group_2['LIV'], label="MV survived", \
            color='white', s=20, marker=",", edgecolor='red')
plt.scatter(df_group_3['ROX'], \
df_group_3['LIV'], label="MV died", \
            color='black', s=20, marker=",", edgecolor='black')

plt.ylim(0, 70)
plt.xlim(0, 15)
xlim = plt.xlim()
ylim = plt.ylim()

xx = np.linspace(xlim[0], xlim[1], 30)
yy = np.linspace(ylim[0], ylim[1], 30)
XX, YY = np.meshgrid(xx, yy)
xy = np.vstack([XX.ravel(), YY.ravel()]).T
Z = soft_linear_svc.decision_function(xy).reshape(XX.shape)
plt.contour(XX, YY, Z, colors='k', \
 levels= [-1, 0, 1], alpha=0.5, linestyles= ['--', '-', '--'])

plt.title("Soft-margin Linear SVM", fontsize=16)
plt.xlabel("ROX index", fontsize=16)
plt.ylabel("LIV (%)", fontsize=16)
plt.grid()
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
#-[END]-----------------------------------------------------------
#-[Python Code #21]------------------------------------------------
# Making Heat Map
cm = confusion_matrix(Y_pred_S, Therapy)
plt.figure(figsize = (2, 1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()

print("confusion matrix = \n", \\
```

```
confusion_matrix(y_true=Therapy, y_pred=Y_pred_S))
print("accuracy = %.3f" \\
% (accuracy_score(y_true=Therapy, y_pred=Y_pred_S)))
print("precision = %.3f" \\
% (precision_score(y_true=Therapy, y_pred=Y_pred_S)))
print("recall = %.3f" \\
% (recall_score(y_true=Therapy, y_pred=Y_pred_S)))
print("f1 score = %.3f" \\
% (f1_score(y_true=Therapy, y_pred=Y_pred_S)))
#-[END]-----------------------------------------------------------
#-[Python Code #22]-----------------------------------------------
#######################
# Non-Linear SVM
#######################
import sklearn.model_selection
from sklearn.svm import SVC

def pt_plot(x1_x2, label):
    plt.figure(figsize=(4, 2.5))
    plt.grid(True)
    #plt.ylim(0, 70)
    #plt.xlim(0, 13)
    plt.title("Non-linear SVM", fontsize=16)
    plt.xlabel("ROX index", fontsize=16)
    plt.ylabel("LIV (%)", fontsize=16)

    datalen = len(x1_x2)
    for cnt in range(datalen):
        if label[cnt] == 0:
            plt.scatter(x1_x2[:, 0][cnt], x1_x2[:, 1][cnt], \
label="HFNC", \
            color='white', s=20, marker="o", edgecolor='green')
        elif label[cnt] == 1:
            plt.scatter(x1_x2[:, 0][cnt], x1_x2[:, 1][cnt], \
label="MV survived", \
            color='white', s=20, marker=",", edgecolor='red')

def pt_plot_mortality(x1_x2, label, mortality):
    plt.figure(figsize= (4, 2.5))
    plt.grid(True)
    plt.title("Non-linear SVM", fontsize=16)
    plt.xlabel("ROX index", fontsize=16)
    plt.ylabel("LIV (%)", fontsize=16)

    x1_x2_1 = np.empty(2)
    x1_x2_2 = np.empty(2)
    x1_x2_3 = np.empty(2)
    group_1_cnt = 0
    group_2_cnt = 0
    group_3_cnt = 0

    datalen = len(x1_x2)
    for cnt in range(datalen):
        if label[cnt, 0] == 0:
            x1_x2_1 = np.append(x1_x2_1, x1_x2[cnt], axis=0)
            group_1_cnt += 1
        if label[cnt, 0] == 1:
            x1_x2_2 = np.append(x1_x2_2, x1_x2[cnt], axis=0)
            group_2_cnt += 1
        if mortality[cnt, 0] == 1:
            x1_x2_3 = np.append(x1_x2_3, x1_x2[cnt], axis=0)
            group_3_cnt += 1

    x1_x2_1 = x1_x2_1.reshape(group_1_cnt+1, 2)
    x1_x2_2 = x1_x2_2.reshape(group_2_cnt+1, 2)
    x1_x2_3 = x1_x2_3.reshape(group_3_cnt+1, 2)

    x1_x2_1 = np.delete(x1_x2_1, 0, 0)
    x1_x2_2 = np.delete(x1_x2_2, 0, 0)
    x1_x2_3 = np.delete(x1_x2_3, 0, 0)

    plt.scatter(x1_x2_1[:, 0], x1_x2_1[:, 1], label="HFNC survived", \
                color='white', s=20, marker="o", edgecolor='green')
    plt.scatter(x1_x2_2[:, 0], x1_x2_2[:, 1], label="MV survived", \
                color='white', s=20, marker=",", edgecolor='red')
    plt.scatter(x1_x2_3[:, 0], x1_x2_3[:, 1], label="MV died", \
                color='black', s=20, marker=",", edgecolor='black')

def false_positive_rate(y_true, y_pred):
    tn, fp, fn, tp = confusion_matrix(y_true, y_pred).flatten()
    return fp / (tn + fp)
#-[END]-----------------------------------------------------------
#-[Python Code #23]-----------------------------------------------
X_train = data_0
Y_train = Therapy

# Classifying patinets to 3 subgroups
X_train_1 = X_train [(X_train['Therapy'] == 0) \
& (X_train['Mortality'] == 0)]
X_train_2 = X_train [(X_train['Therapy'] == 1) \
& (X_train['Mortality'] == 0)]
X_train_3 = X_train [(X_train['Therapy'] == 1) \
& (X_train['Mortality'] == 1)]

scaler = StandardScaler()
scaled_features = scaler.fit_transform(X_train.values[:, 1:3])
scaled_features_train = np.hstack((scaled_features, \
X_train['Therapy'].values.reshape(-1, 1), \
X_train['Mortality'].values.reshape(-1, 1)))
pt_plot_mortality(scaled_features, \
X_train.values, scaled_features_train[:, 3:4])
plt.legend(loc='upper left', bbox_to_anchor=(1, 1))
plt.show()
#-[END]-----------------------------------------------------------
#-[Python Code #24]-----------------------------------------------
# Step 2. Training the model
# kernel = Guass
knl = 'sigmoid'
# kernel options
# knl = 'poly'
# knl = 'sigmoid'

gma = 5
dgr = 2
# cost parameter C
c_values = [0.01, 0.1, 1.0, 10, 100]

# Step 2: Split the training data
k = 5
skf = sklearn.model_selection.StratifiedKFold(n_splits=k, \
random_state=0, shuffle=True)

# Step 2: Cross validation
# List of evaluation index
scoring = ['f1_macro', 'precision_macro', 'recall_macro']
scores = None
for c in c_values:
    if knl == 'rbf':
        clf = SVC(kernel=knl, C=c, gamma=gma)
    elif knl == 'poly':
        clf = SVC(kernel=knl, C=c, gamma=gma, degree=dgr)
    else:
        clf = SVC(kernel=knl, C=c)

    score = sklearn.model_selection.cross_validate(clf, \
scaled_features, Y_train,
 scoring=scoring, cv=skf, )
    x = pd.concat([pd.Series(np.full(k, c), name='C'), \
pd.DataFrame(score)], axis=1)
    scores = pd.concat([scores, x])
print(scores)

# Step 2: Training using training data sete
best_c = scores.loc[scores.loc[:, 'test_f1_macro'] \
== max(scores.loc[:, 'test_f1_macro']), 'C'].values[0]

if knl == 'rbf':
    clf = SVC(kernel=knl, C=best_c, gamma=gma)
    print('kernel=', knl)
    print('bestC=', best_c)
    print('gamma=', gma)
elif knl == 'poly':
    clf = SVC(kernel=knl, C=best_c, degree=dgr)
    print('kernel=', knl)
    print('bestC=', best_c)
    print('degree=', dgr)
    print('gamma=', gma)
elif knl == 'sigmoid':
    clf = SVC(kernel=knl, C=best_c)
    print('kernel=', knl)
    print('bestC=', best_c)

clf.fit(scaled_features, Y_train)
#-[END]-----------------------------------------------------------
#-[Python Code #25]-----------------------------------------------
# Prediction of train data
Y_pred_SM2 = clf.predict(scaled_features)

# Display the Boundary
plt.figure(figsize=(4, 2.5))
_x0 = np.linspace(-3, 3, 600)
_x1 = np.linspace(-3, 4, 700)
x0, x1 = np.meshgrid(_x0, _x1)
X = np.hstack((x0.ravel().reshape(-1, 1), x1.ravel().reshape(-1, 1)))
y_decision = clf.predict(X).reshape(x0.shape)

# Plot test data
pt_plot_mortality(scaled_features, \
Y_train.values, scaled_features_train[:, 3:4])
plt.contourf(x0, x1, y_decision, levels= [y_decision.min(), \
 0.1, y_decision.max()], alpha=0.3)
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
plt.show()
#-[END]-----------------------------------------------------------
-[Python Code #26]-----------------------------------------------
# Making Heat Map
cm = confusion_matrix(Y_train, Y_pred_SM2)
plt.figure(figsize = (2, 1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()
```

```
print("confusion matrix = \n", \
confusion_matrix(y_true=Y_train, y_pred=Y_pred_SM2))
print("accuracy = %.3f" \
% (accuracy_score(y_true=Y_train, y_pred=Y_pred_ SM2)))
print("precision = %.3f" \
% (precision_score(y_true=Y_train, y_pred=Y_pred_ SM2)))
print("recall = %.3f" \
% (recall_score(y_true=Y_train, y_pred=Y_pred_ SM2)))
print("f1 score = %.3f" \
% (f1_score(y_true=Y_train, y_pred=Y_pred_ SM2)))
#-[END]-------------------------------------------------------
#-[Python Code #27]--------------------------------------------
# Step 2. Training the model
# kernel = Guass
knl = 'rbf'
# kernel options
# knl = 'poly'
# knl = 'sigmoid'

gma = 5
dgr = 2
# cost parameter C
c_values = [0.01, 0.1, 1.0, 10, 100]

# Step 2: Split the training data
k = 5
skf = sklearn.model_selection.StratifiedKFold(n_splits=k, \
 random_state=0, shuffle=True)

# Step 2: Cross validation
# List of evaluation index
scoring = ['f1_macro', 'precision_macro', 'recall_macro']
scores = None
#
for c in c_values:
    if knl == 'rbf':
        clf = SVC(kernel=knl, C=c, gamma=gma)
    elif knl == 'poly':
        clf = SVC(kernel=knl, C=c, gamma=gma, degree=dgr)
    else:
        clf = SVC(kernel=knl, C=c)

    score = sklearn.model_selection.cross_validate(clf, \
 scaled_features, Y_train, scoring=scoring, cv=skf)
    x = pd.concat([pd.Series(np.full(k, c), name='C'), \
pd.DataFrame(score)], axis=1)
    scores = pd.concat([scores, x])
print(scores)

# Step 2: Training using training data sete
best_c = scores.loc[scores.loc[:, 'test_f1_macro'] \
== max(scores.loc[:, 'test_f1_macro']), 'C'].values[0]

if knl == 'rbf':
    clf = SVC(kernel=knl, C=best_c, gamma=gma)
    print('kernel=', knl)
    print('bestC=', best_c)
    print('gamma=', gma)
elif knl == 'poly':
    clf = SVC(kernel=knl, C=best_c, degree=dgr)
    print('kernel=', knl)
    print('bestC=', best_c)
    print('degree=', dgr)
    print('gamma=', gma)
elif knl == 'sigmoid':
    clf = SVC(kernel=knl, C=best_c)
    print('kernel=', knl)
    print('bestC=', best_c)
#-[END]-------------------------------------------------------
#-[Python Code #28]--------------------------------------------
# Prediction of train data
Y_pred_SM1 = clf.predict(scaled_features)

# Display the Boundary
plt.figure(figsize= (4, 2.5))
_x0 = np.linspace(-3, 3, 600)
_x1 = np.linspace(-3, 4, 700)
x0, x1 = np.meshgrid(_x0, _x1)
X = np.hstack((x0.ravel().reshape(-1, 1), \
               x1.ravel().reshape(-1, 1)))
y_decision = clf.predict(X).reshape(x0.shape)

# Plot test data
pt_plot_mortality(scaled_features, \
              Y_train.values, \
              scaled_features_train[:, 3:4])
plt.contourf(x0, x1, y_decision, \
              levels= [y_decision.min(), 0.1, \
                     y_decision.max()], alpha=0.3)
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
plt.show()
#-[END]-------------------------------------------------------
#-[Python Code #29]--------------------------------------------
# Making Heat Map
cm = confusion_matrix(Y_train, Y_pred_SM1)
plt.figure(figsize = (2, 1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()

#from sklearn.metrics
# import confusion_matrix,
# accuracy_score, precision_score, recall_score, f1_score

print("confusion matrix = \n", \
      confusion_matrix(y_true=Y_train, y_pred=Y_pred_SM1))
print("accuracy = %.3f" \
      % (accuracy_score(y_true=Y_train, y_pred=Y_pred_SM1)))
print("precision = %.3f" \
      % (precision_score(y_true=Y_train, y_pred=Y_pred_SM1)))
print("recall = %.3f" \
      % (recall_score(y_true=Y_train, y_pred=Y_pred_SM1)))
print("f1 score = %.3f" \
      % (f1_score(y_true=Y_train, y_pred=Y_pred_SM1)))
clf.fit(scaled_features, Y_train)
#-[END]-------------------------------------------------------
#-[Python Code #30]--------------------------------------------
########################
# Gaussian Naive Bayes
########################
from sklearn.naive_bayes import GaussianNB

# Split the data to training and test data sets
# X_train, X_test, Y_train, Y_test = train_test_split(data1,
# Therapy, test_size = 0.2, random_state=0)
X_train = data_1
Y_train = Therapy
X_test = data_1
Y_test = Therapy

# Classification test
clf = GaussianNB()
clf.fit(X_train, Y_train)

# Prediction
Y_pred_G1 = clf.predict(X_test)

# Evaluation
score_G = clf.score(X_test, Y_test)

print("score = %.3f" % (score_G))
#-[END]-------------------------------------------------------
#-[Python Code #31]--------------------------------------------
# data, initial value set, preprocessing
# X, Y values
XY = data_1
# label value
L = Therapy.astype(np.int)
# Maximum value of X
A = int(max(data_1['ROX']))
# Maximum value of Y
B = int(max(data_1['LIV']))
C, D = np.meshgrid(np.arange(A), np.arange(B))
# Combination of X and Y
E = np.hstack((C.reshape(A*B, 1), D.reshape(A*B, 1)))
# Classification
clf = GaussianNB()
clf.fit(XY, L)
Y_pred_G2 = clf.predict(E)
#-[END]-------------------------------------------------------
#-[Python Code #32]--------------------------------------------
# Plot Gaussian Naive Bayes
plt.figure(figsize= (4, 2.5))
# Plot boundaries
plt.pcolormesh(C, D, Y_pred_G2.reshape(C.shape), alpha=0.3)
plt.scatter(df_group_1['ROX'], \
df_group_1['LIV'], label="HFNC survived", \
            color='white', s=20, marker="o", edgecolor='green')
plt.scatter(df_group_2['ROX'], \
df_group_2['LIV'], label="MV survived", \
            color='white', s=20, marker=",", edgecolor='red')
plt.scatter(df_group_3['ROX'], \
df_group_3['LIV'], label="MV died", \
            color='black', s=20, marker=",", edgecolor='black')
plt.grid(True)
plt.ylim(0, 70)
plt.xlim(0, 13)
plt.legend(loc='upper left', bbox_to_anchor= (1, 1))
plt.title("Gaussian Naive Bayes", fontsize=16)
plt.xlabel("ROX index", fontsize=16)
plt.ylabel("LIV (%)", fontsize=16)
plt.show()
#-[END]-------------------------------------------------------
#-[Python Code #33]--------------------------------------------
# Making Heat Map
cm = confusion_matrix(Therapy, Y_pred_G1)
plt.figure(figsize = (2, 1.5))
sns.heatmap(cm, annot=True, cmap='Blues')
plt.xlabel("Predicted", fontsize=13, rotation=0)
plt.ylabel("Actual", fontsize=13)
plt.show()

print("confusion matrix = \n", \
```

```
confusion_matrix(y_true=Therapy, y_pred=Y_pred_G1))
print("accuracy = %.3f" \
% (accuracy_score(y_true=Therapy, y_pred=Y_pred_G1)))
print("precision = %.3f" \
% (precision_score(y_true=Therapy, y_pred=Y_pred_G1)))
print("recall = %.3f" \
% (recall_score(y_true=Therapy, y_pred=Y_pred_G1)))
print("f1 score = %.3f" \
% (f1_score(y_true=Therapy, y_pred=Y_pred_G1)))
#- END ------------------------------------------------------------
```

ABSTRACT

Clinical diagnosis and machine learning binary classification models: Python programming with a dataset of COVID-19 acute hypoxemic respiratory failure

In computer-assisted diagnosis and treatment policy decisions, a computer learns accumulated data (supervised machine learning), finds rules and patterns behind the data, creates a model, and makes predictions based on learning outcomes. In the cause analysis studies, we consider the decision results as objective variables and related factors involved in the decision as explanatory variables and apply classification models or regression models to the thinking patterns of clinicians regarding diagnoses and treatment strategies. By constructing this system, the background of decision-making is expected to be explored, leading to more accurate computer diagnosis and treatment policy decisions. The authors recently reported on the decision-making of attending physicians regarding selecting respiratory therapy for patients with acute hypoxemic respiratory failure (AHRF) due to COVID-19. This time, using this dataset of COVID-19, in this report, binary classification programming and plotting functions were performed using the computer language Python.

Keywords: acute hypoxemic respiratory failure, COVID-19, machine learning, multiple logistic regression, ROX index, support vector machine.

佐和貞治 [1.3]，木下真央 [2,3]，井上敬太 [2]，串本洸輔 [3]，吉井龍吾 [2]，小尾口邦彦 [2]

Teiji Sawa[1.3], Kazuki Sudo[2.3], Mao Kinoshita[3], Kohsuke Kushimoto[3], Ryogo Yoshii[2], Kunihiko Kooguchi[2] 1) University Hospital, Kyoto Prefectural University of Medicine

2)Devision of Intensive Care Unit, University Hospital, Kyoto Prefectural University of Medicine

3) Department of Anesthesiology, Graduate School of Medicine, Kyoto Prefectural University of Medicine.

< 著者連絡先 >

佐和　貞治

京都府立医科大学附属病院

〒 602-8566 京都市上京区河原町通り広小路上る梶井町 465

TEL: 075-251-5230, FAX: 075-4251-5749

E-mail: anesth@koto.kpu-m.ac.jp

特別寄稿:

二酸化炭素中毒事故を酸欠事故とするのは誤り

佐藤　暢

旧労働省が 1980 年に制定した「**労働安全衛生法施行令**」の**別表第 6 「酸素欠乏危険場所**」から「**10** ドライアイスを使用し-一.」を全文削除し，また「**11** ヘリウム，アルゴン，窒素，フロン，炭酸ガス その他不活性の気体を入れてあり–」から 炭酸ガス を削除すべきとする私の論説に対しての厚労省の担当官からの回答を論破した経緯と結末を簡単に纏めて御報告致します.

この問題を解決すべく，石破茂議員の東京事務所へ最初にメールでお願いしたのは，2024 年 2 月 14 日でした．そして秘書の計らいで厚労省に届き，石破事務所を通じて担当官からの応酬が約 30 回もメールで行われました．始めは厚労省労働基準局安全衛生部労働衛生課安全作業班指導係からでしたが，最後には労働基準局安全衛生部安全衛生課衛生専門管から直接私に次のような回答がありました.「厚労省としては，高濃度の二酸化炭素の有害性は充分に認識しており，酸欠則以外の法令で二酸化炭素による労働災害防止のための取り組みを推進しているところ，今回のご指摘をふまえ，これからの現場の実態等について現場や専門家の意見を聞いて行きたいと思います.

一方，酸欠則等の労働安全労働安全衛生法令において，不活性ガスとして二酸化炭素を取り扱っているのは，あくまでも工業現場等において，酸素や空気と置換するために使用する化学的に不活性なガスという趣旨で使われているものであり，生物学的特性に着目したものではありません.」

これに対しての私の返答を簡単に纏めますと，まず 炭酸ガス は常に活性であり，それを不活性ガスとするのは虚偽の記載です．また，貴殿が「生物学的特性に着目しているものではありません」と書かれたのは，貴殿の間違いです．何故ならば，当法令の対象は，生物であるヒトであるからです．労働安全衛生上の問題です.

具体的に説明をすると，炭酸ガス中毒を酸欠事故だとするので，酸素濃度をモニターして警報を発するが，炭酸ガス濃度をモニターしないから，事故の原因となっています．事故を防止するには，炭酸ガス濃度を現場でモニターして，1.5 %以上 (働安全衛生規則：事業者は，坑内の炭酸ガス濃度を 1.5 %以下にしなければならない) で警報を鳴らし退避を促す必要があります．このような対処に至る妨げになっているのが，当該法令・省令です.

以上が，2024 年 5 月 23 日での結論ですが，その後反論が途絶えてしまったので，当担管に 2024 年 6 月 14 日になっても反論がないので漸く解って頂けたものと感謝の意を示し，「Email は書簡に替わるものですから公式な文書として公表してよいと理解します．もし，御異論があれば，至急にご連絡下さい」と念を押してあるが，未だに異論は届いていないので，結末として寄稿することにしました.

この 30 回以上に渉ったメールでは，関連論文多数を送ったが，特に下記の 4 論文は直接関係するものとして挙げておく.

1. 佐藤暢，飯野守男：厚労省も陥ったか，ヒューマンエラーと二酸化炭素中毒に纏わる謎．麻酔・集中治療とテクノロジー 2016 p87-96, 日本麻酔・集中治療テクノロジー学会 2017.

2. 佐藤暢，飯野守男：厚労省も陥ったか，ヒューマンエラーと二酸化炭素中毒に纏わる謎 (続)．麻酔・集中治療とテクノロジー 2017 p118-125, 日

鳥取大學 名誉教授
掲載許可日 2024 年 6 月 23 日

本麻酔・集中治療テクノロジー学会 2018.

3. 佐藤暢，飯野守男：二酸化炭素中毒について．麻酔・集中治療とテクノロジー 2022 p96-103, 日本麻酔・集中治療テクノロジー学会 2023,

4. 佐藤暢，飯野守男：二酸化炭素中毒について (続) 麻酔・集中治療とテクノロジー—2023 p65-72, 日本麻酔・集中治療テクノロジー学会　2024.

以上の中で，3. で述べた論説を活用して，2024 年 4 月 21 日に厚労省の担当官に次のようなメールを送りました．

ここで大切なのは，炭酸ガスが 10 %もあれば 1 分間の吸入で致死的になりますが，室内容積 100 %の中で室内の炭酸ガスが 10 %で, 残りは 90 %ですから 1 割減る空気の中の酸素を 1 割の炭酸ガスが置換・希釈すると，もとは 21 %あった空気中の酸素が 9 割の 18.9 %まで希釈されます．これは，酸素欠乏は無くても炭酸ガス中毒で致死的となることをハッキリ示しています．室内の炭酸ガスが 20 %でも酸素濃度は 17 % (0.8 X 21 %) でほぼ同様です．室内の炭酸ガス濃度が 50 %にあがると酸素濃度は 10.5 % (0.5 X 21 %) で, 始めて酸欠症状も伴い，より重症化します．

つまり，炭酸ガス中毒が**最初からの主体であり，酸欠が起こるのは，後で従続的なもの**だと云うことです．

以上のように不活性ガスが室内の空気中の酸素を物理的に希釈して行く工程は計算できるので，**酸素欠乏になる前に二酸化炭素 (10 %以上) の活性・毒性で意識を失い倒れたまま全例が二酸化炭素による中毒死**にいたることになります．

以上御報告致します．

第 41 回日本麻酔・集中治療テクノロジー学会
会長： 川口 昌彦（奈良県立医科大学 麻酔科学教室 教授）
会期： 2023 年 11 月 24,25 日（金・土）
会場： ホテル 日航奈良

プログラム
特別講演１
11 月 25 日（土） 11：00〜11：50
座長: 佐和 貞治（京都府立医科大学附属病院）
「医療 DX：医療テキストの臨床応用の可能性」
荒牧 英治（奈良先端科学技術大学院大学）

特別講演２
11 月 25 日（土） 13：10〜14：00
座長: 吉谷 健司（国立循環器病研究センター 輸血管理部）
「AI・機械学習を活用する疾患の発症予測と予後予測 - 利点と困難点 -」
尾形 宗士郎（国立循環器病研究センター 予防医学・疫学情報部）

共催シンポジウム１
11 月 25 日（土） 14：50〜15：30
座長: 土井 松幸（浜松医療センター 集中治療科）
「新時代の呼吸モニタリングを提供する EIT」
岡原 修司（岡山大学病院 集中治療部）

「スマートグラスを活用した次世代見守り（ナースコール）システムについて」
花谷 行雄（株式会社スマートゲート）

共催シンポジウム２
11 月 25 日（土） 15：40〜16：20
座長: 讃岐 美智義（呉医療センター 麻酔科）
「携帯端末を使った自動麻酔記録装置への入力」
上山 博史（独立行政法人労働者健康安全機構関西ろうさい病院 麻酔科）

「進化するストレスモニタリング：High Frequency Variability Index
が可視化する新しい麻酔の世界」
田中 暢洋（奈良県立医科大学 麻酔科学教室）

イブニングセミナー
11 月 24 日（金） 18：00〜19：00
座長: 川口 昌彦（奈良県立医科大学 麻酔科学教室）
「医療機器開発哀歌」
萩野 芳弘（日本光電工業株式会社 生体モニタ技術開発部）

モーニングセミナー
11 月 25 日（土） 9：00〜9：45
座長: 萩平 哲（関西医科大学 麻酔科学講座）
「新時代を支えるテクノロジーと術中神経モニタリング」
林 浩伸（奈良県立医科大学 麻酔科学教室）

ランチョンセミナー
11 月 25 日（土） 12：00〜12：50
座長: 廣瀬 宗孝（兵庫医科大学 麻酔科学・疼痛制御科学講座）
「術中低血圧と予後 〜テクノロジーの活用方法〜」

内藤 祐介（奈良県立医科大学 麻酔科学教室）

アフタヌーンセミナー
11 月 25 日（土）　16：30〜17：15
座長: 川口 昌彦（奈良県立医科大学 麻酔科学教室）
「周術期における運用の現状課題と IT ソリューションの現状」
米澤 亮（富士フイルムメディカル IT ソリューションズ株式会社）

テクノロジーラウンド
11 月 25 日（土） 14:10〜14:40
座 長： 長田 理（東都春日部病院 麻酔科）

優秀演題セッション
11 月 25 日（土） 9:50〜10:50
座長: 内田 整（関西医科大学附属病院 麻酔科）
コメンテーター：増井 健一（横浜市立大学大学院医学研究科 麻酔科学）
1 AneXam-GPT 構築：麻酔科専門医認定筆記試験（第 61 回 2022 年度）を ChatGPT が解く！
佐和 貞治（京都府立医科大学 附属病院）
2 空液検知機能も兼ねた，重量センサによる輸液速度自動記録装置の開発
西村 一樹（KKR 札幌医療センター 麻酔科）
3 Excel Visual Basic Editor で作成したプログラムによる手術室運用状況の可視化
小原 伸樹（福島県立医科大学 医学部麻酔科学講座）
4 全静脈麻酔支援ロボット麻酔システムの初航海船出の様子
重見 研司（福井大学附属病院 麻酔科）
5 高齢者の麻酔科術前診察におけるロボット問診システム
眞一 弘士（戸塚共立第 2 病院 麻酔科）

一般演題 1
11 月 25 日（土） 9:50〜10:50
「臨床・症例」
座長: 稲垣 喜三（国際医療福祉大学成田病院 麻酔・集中治療科）
コメンテーター：天谷 文昌（京都府立医科大学 疼痛・緩和医療学教室）
1 血小板無力症を合併した挿管困難を伴う Madelung 病患者の頚部手術の麻酔経験
浜野 憲典（東京医科大学病院 麻酔科）
2 腹腔鏡下褐色細胞腫摘出術における血圧上昇速度と上昇値との関連性
稲畑 啓一郎（大垣市民病院 麻酔科）
3 舌下神経刺激装置植込術における術中神経モニタリングの報告
高谷 恒範（奈良県立医科大学附属病院 麻酔科 / 中央手術部）
4 周麻酔期看護師が実施した全身麻酔時の循環管理に対する安全性の検討
TANG DI（横浜市立大学 大学院医学研究科看護学専攻周麻酔期看護学分野 博士前期課程）
5 顕微鏡の機能を利用した術中神経モニタリングシステムの使用経験
曽碩 真弘（奈良県立医科大学附属病院 医療技術センター）
6 周術期管理センターにおける麻酔説明端末の設置から考える業務の DX 化
河田 大輝（ベルランド総合病院 麻酔科）

一般演題 2
11 月 25 日（土） 14:10〜15:10
「ソフト・機器」
座長: 中尾 正和（曙会シムラ病院 麻酔科）
コメンテーター：片山 勝之（手稲渓仁会病院 麻酔科）
1 手術時間管理システム（いいね・わるいね）の開発
讃岐 美智義（呉医療センター 麻酔科）

2 全身麻酔維持中の患者状態の数値化の試み
讃岐 美智義（呉医療センター 麻酔科）
3 心臓植込み型電気デバイス一括管理ソフト ORFICE の導入と展望
三浦 晃裕（奈良県立医科大学附属病院 医療技術センター）
4 帯型ディスポーザブル注入ポンプの投与精度に関する検討
- 機械式ポンプとバルーン式ポンプの比較
関口 諒（徳島大学病院 麻酔科）
5 汎用シミュレーションソフトを利用した輸液調節アルゴリズム評価法の開発
森主 絵美（東京大学医学部附属病院 麻酔科・痛みセンター）
6 麻酔中の生体情報に対するデータ処理アプリケーションの作成
森松 尭（岡山ろうさい病院 麻酔科）

一般演題３
11 月 25 日（土） 15:20〜16:10
「循環・生理」
座長: 惠川 淳二（奈良県立医科大学 麻酔科学教室）
コメンテーター：白神 豪太郎（京都市立病院 麻酔科）
1 術中最低 MBP と術後合併症の関係について：NR 値を含めた検討
廣瀬 宗孝（兵庫医科大学 麻酔科学・疼痛制御科学講座）
2 電極電位から解析した電気軸の解釈
田中 義文（京都府立医科大学 麻酔科学教室）
3 すべての物質は非線形波動である
横山 博俊（金沢医療センター 麻酔科）
4 心臓は機械的ポンプとして血液を大動脈へ押し出すことはできない
横山 博俊（金沢医療センター 麻酔科）
5 麻酔中の左心室内圧容量関係（LVPVR）を示すモニタの試作
重見 研司（福井大学 器官制御医学講座麻酔・蘇生学分野）

抄録抜粋

イブニングセミナー 医療機器開発哀歌

荻野 芳弘 (日本光電工業株式会社)

いささか私事で恐縮だが日本光電という会社で医療機器の開発に携わり 35 年の歳月が流れていった．過ぎ来し方を懐かしみ未来に託す行く末に思いを馳せるにつけ，医療機器開発という天命の尊さと己の無力さをただただ口惜しく思い嘆く次第である．

私の開発歴の最初の約 25 年間は，一貫して電子自動麻酔器録システムをはじめとする重症系 IT システム製品の開発に従事してきた．しかしながら四半世紀以上にわたるその道のりは，先人たちの残した道標もない前人未踏のもので，想像を絶する苦難に満ちていた．常にシステム製品は社内においては収益性の問題を抱え大きな赤字を作り続け，また，ユーザ先では絶え間なく繰り返される開発（納期）遅延や品質問題に直面してきた．巷からは「『ロク』でもないモノばっかり作って！」「『ロク』でなし！」とボロクソに言われる日々が続いた．

そしてついにある日辞令を手渡され,「マスイキロク」から「ロク」がとれ,「マスイキ」の開発を命じられることとあいなった．そこでかつて「手書き麻酔記録」から「電子自動麻酔器録」をひねり出してきたように,「手動設定麻酔器」から「自動麻酔器」へと発展させていくことは可能だろうか？という課題に目覚めた．残念ながらこの麻酔器開発は種々の大人の事情により日の目を見ることはなくなってしまい,「お前，開発もうまくいかなかったくせに何気取ってんだ！」ということでとうとう「マスイキ」から「キ」もとられてしまい「マスイ」そのものの開発を行うこととなり今日に至る．

本学会でも何度も申し上げて来たことではあるが，医療機器の開発者はどんなに心血を注いで製品開発を行ってきたとしても，決して自分自身がその製品のユーザとなることができない．その一点にかけて，エアコンやクルマの開発よりも医療機器の開発ははるかに失敗のリスクが大きい．私の先輩社員であり，パルスオキシメータのクリエイタでもある青柳卓雄博士はその著書の中で「E（医療機器メーカー）の中から出て来た有望な seeds を見抜いて，それを育ててくれる M（医療従事者）の方の存在が，大変価値の高いものであることと，E の側でも，その seeds の将来性に確かな展望を持ってそれを宣伝し，M の方の共感を得て，技術を育ててゆくための可能性を作り出していくべきであった」と慙愧の念を述べている．今回で第 41 回を迎える本学会（私の初参加は第 8 回）がますます「M と E」,「伊賀忍者と甲賀忍者」の架け橋となり発展していかれることを祈りつつ，医療機器開発に潜む深い闇とそのどん底でもがき続けて来たエンジニアの哀歌をお聞きいただきたい．

高齢者の麻酔科術前診察におけるロボット問診システム

眞一 弘士 [1]，佐藤 美紀 [2]，小野塚 良輔 [3]，増井 健一 [4]
1) 戸塚共立第 2 病院 麻酔科， 2) 戸塚共立第 2 病院， 3) 神奈川県立がんセンター，
4) 横浜市立大学医学部麻酔科学教室

【はじめに】

術前診察において聞くべき項目は多岐に渡っており，特に高齢患者では問診に非常に時間がかかる傾向にある．近年，問診業務の効率化のため，電子デバイスを用いて術前問診票の入力をしてもらう動きが出てきている．我々は，問診業務を効率化するための電子デバイスの開発に取り組み，ロボット「タピア」を用いた問診システムを開発した．本研究では高齢患者において問診ロボットが紙の問診票と比較して， 問診時間を短縮するか， 未記入箇所を減らせるか， 病歴を正確に聴取できるか，を評価し．

【方法】

倫理委員会の承認の元，整形外科または一般外科の予定手術を受ける 70 歳以上の ASA1-4 の患者 39 名を対象とした．ロボット群と問診票群にランダムに割付け， 問診開始から終了までの時間（問診完了時間），紙の問診の記入率，および 問診結果の正確さ，を評価し群間で比較した．また，各問診方法に対する患者評価および患者満足度についてのアンケートを行った．なお，ロボットと問診票による問診のどちらが好ましいかの評価のため，群名の問診方法による問診後に他方の問診も行った．

【結果】

ロボット群 (19 名) でのロボット問診時間は問診票群 (20 名) での問診表による問診時間と同程度だった（492 ± 134 秒 vs518 ± 270 秒:P=0.444）．ロボット問診では記入漏れが許容されないため記入率 100%，紙の問診票の記入率 96%± 6%（P=0.033）であった．問診の正答率は 95%± 5%vs97%± 4%（P=0.588）で同程度であった．アンケート（回答数：ロボット群 19 名，問診票群 20 名）では，ロボット問診について「ロボットの問診が良かった」との回答がそれぞれ 53%，70%,「タッチするだけでいい」が 79%，75%であった．一方,「どこを押していいかわからない」が 37%，20%,「画面が小さくて見にくい」が 21%，30%あった．また，問診票について「後から見返すことができる点が良い」が 47%，30%あった．

【考察と結語】

ロボット問診の方が良いという患者が多かった．一方，ロボット群で紙の問診表は「後から見返すことができる点が良い」という意見が半数近くを占め，これは前の質問に戻れないシステムとしたことが原因と考えられた.「どこを押していいかわからない」という意見がロボット問診の悪い点として最も多かった．高齢患者を対象としたロボット問診システムの構築には，高齢者に分かりやすい画面構成・操作方法，高齢者の認知能力を考慮したものにする必要があると考えられた．

周麻酔期看護師が実施した全身麻酔時の循環管理に対する安全性の検討

TANG DI[1]，他谷 真遵[2]，新井 悠介[2]，後藤 隆久[2]，赤瀬 智子[3]
1) 横浜市立大学 大学院医学研究科看護学専攻周麻酔期看護学分野 博士前期課程，
2) 横浜市立大学附属病院麻酔科，3) 横浜市立大学大学院 医学研究科看護学専攻周麻酔期看護学分野

【背景】

近年の麻酔領域の業務拡大に対し，大学院で麻酔のトレーニングを受け，麻酔科医の直接指示の下で術中麻酔管理を行う周麻酔期看護師が育成され，医療現場で活躍している．しかし周麻酔期看護師が管理に携わった全身麻酔の安全性に関する研究はほとんどない．術中低血圧は，全身麻酔における非常に一般的な副作用である．低血圧が発生した症例や低血圧の累積時間が長い症例は術後有害転帰の発生率が高くなることが先行研究で示されている．

【目的】

周麻酔期看護師が携わる麻酔の安全性を検討するため，全身麻酔中の低血圧の累積時間と発生率を，周麻酔期看護師が携わった症例と麻酔科専攻医が管理した症例で比較する．

【方法】

A 大学附属病院において 2017～2023 年に周麻酔期看護師が麻酔科専門医の直接指示のもと実施した，侵襲的血圧測定を行った全身麻酔症例において，低血圧の累積時間と発生率を，麻酔科専攻医が麻酔科専門医の監督のもとに行った症例と，後ろ向きに比較した．低血圧は平均動脈圧 55mmHg 未満と定義した．平均動脈圧 55mmHg 未満の累積時間の 2 群間比較は， Wilcoxon 検定で行った．

【結果】

背景情報として，周麻酔期看護師群（n=814）では ASA-PSI と　の割合は，86 (10.6 %)/728(89.4 %)，高血圧ありは 319 症例（39.2 %），麻酔時間の中央値は 338 分，血行動態が変動しやすい術式は 99 例（12.2 %）であった．専攻医群（n=1796）では ASA-PSI と　の割合は，143(8.0 %)/1653(92.0 %)，高血圧ありは 795 症例（44.3 %），麻酔時間の中央値は 390 分，血行動態が変動しやすい術式は 513 例（28.6 %）であった．また，周麻酔期看護師群は，主要評価項目である MAP55mmHg 未満の累積時間の中央値は 4 分，四分範囲は［1.00,16.75］，麻酔科専攻医群は，累積時間の中央値は 7 分，四分範囲は［1.00,24.00］であり，2 群間に有意差があった（$p < 0.001$）．なお，周麻酔期看護師群の低血圧の発生率は 79.2 %，専攻医群の低血圧の発生率は 82.9 %であった．

【考察】

MAP55mmHg 未満の累積時間の 2 群間の差は，背景情報の差によると考える．術中低血圧発生に影響する交絡因子があるため，PS マッチングで 2 群間の背景情報を調整して比較していく必要がある．その結果は現在検討中である．

【結語】

周麻酔期看護師は，麻酔科医の指示の下で安全に循環管理を行っている可能性が高いことが示唆された．

帯型ディスポーザブル注入ポンプの投与精度に関する検討
- 機械式ポンプとバルーン式ポンプの比較

関口 諒，鈴木 奈央，木下 倫子，田中 克哉（徳島大学病院 麻酔科）

【背景】

携帯型ディスポーザブル注入ポンプの精度は、温度や抵抗、駆動方式に依存することが報告されている。我々は、日本麻酔科学会第 70 回学術集会で、マイクロポンプ方式の機械式ポンプはバルーン式ポンプと比較して投与速度が安定していることを報告した。今回は、フィンガ方式の機械式ポンプも調査対象に加え、投与条件の違いが投与速度とボーラス投与量に与える影響を調査した。

【方法】

クーデックエイミー PCA（A：機械式 [マイクロポンプ]、大研医器株式会社）、CADD-Solis（CA：機械式 [フィンガ]、スミスメディカルジャパン）、クーデックバルーンジェクター（CB：バルーン式、大研医器株式会社）、楽々フューザー（R：バルーン式、スミスメディカルジャパン）の 4 種類のポンプを評価した。生理食塩水を充填した後、4ml/時の設定で投与を開始し、電子てんびん上のボトルで回収した液体の重量データか

ら、投与速度を算出した。実験は 25 ℃の室温で実施し、以下の 4 条件で投与速度を測定した：　無条件（コントロール）、　硬膜外カテーテルを介した抵抗、　振盪器を用いた振動、　32 ℃の加温。さらに同条件でボーラス投与量も測定した。実測の投与速度（量）と設定速度（量）の比率を計算し、結果は平均 (標準偏差) で示した。比較には、一元配置分散分析と Tukey 法による事後検定を行い、p¡0.05 を有意とした。

【結果】

機械式 A の平均速度は、各条件で有意な影響は認めなかった。機械式 CA の平均速度は、抵抗および振動でコントロールと比べ有意差はあったが、差は小さかった。観測時間内に投与速度が設定の 100 ± 15 %内であった割合は、機械式 A と CA は両方とも各条件で有意差なく安定していた。バルーン式の CB と R では、加温で平均速度が有意に上昇し、観測時間内に投与速度が設定の 100 ± 15 %内であった割合も、条件によって有意に異なっていた。ボーラス投与量は、機械式 CA が抵抗によって統計的に有意に減少したものの、差は小さかった。機械式の A およびバルーン式の CB と R は、投与条件によってボーラス投与量に有意な影響は認めなかった。

【結論】

機械式ポンプは方式を問わず、投与条件による影響が少なく、投与速度も 100 ± 15 %で安定していた。バルーン式ポンプは温度上昇で投与速度が上昇するが、ボーラス投与量は安定していた。携帯型ディスポーザブル注入ポンプを使用する際はそれぞれの特徴に留意し使用する必要がある。