

下顎骨再建計画に重要な特徴量の複数医師間の解析

畑山 侑介[†] 永井 一希^{††} 中尾 恵^{††} 松田 哲也^{††}

[†] 京都大学工学部電気電子工学科 〒606-8501 京都市左京区吉田本町

^{††} 京都大学大学院 情報学研究科 〒606-8501 京都市左京区吉田本町

E-mail: hatake@sys.i.kyoto-u.ac.jp

あらまし 医師は医療機関の設備や方針、自らの経験を考慮に入れて医療行為を遂行しており、画一的に最適化された機械学習モデルが受け入れられるとは限らない。同一症例であっても、手術計画は担当する医師によって異なる場合があり、データに内在する意思決定の多様性に柔軟に適応できる予測モデルを構築できるかは機械学習が直面する課題の一つと考えられる。本研究では、複数医師による下顎骨再建計画を対象に、腓骨片数の決定に重要な低次元特徴量の解析を行った。口腔外科医及び歯科技工士3名による合計696の手術計画を対象に、手術計画を再現可能な7次元特徴量を抽出し、それぞれが重視する特徴量の共通点や差異を明らかにしたので報告する。

キーワード Lasso 解列挙, 解釈可能性, 特徴抽出, 下顎骨再建

Analysis of important features in surgical planning for mandibular reconstruction among multiple surgeons

Yusuke HATAKEYAMA[†], Kazuki NAGAI^{††}, Megumi NAKAO^{††}, and Tetsuya MATSUDA^{††}

[†] Undergraduate School of Electrical and Electronic Engineering, Kyoto University

Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501, Japan

^{††} Graduate School of Informatics, Kyoto University Yoshida Honmachi, Sakyo-ku, Kyoto, 606-8501, Japan

E-mail: hatake@sys.i.kyoto-u.ac.jp

Abstract Surgeons perform surgical treatment by considering the facilities and policies of medical institutions and their own experience. This suggests that a uniformly optimized machine learning model is not always accepted. Since different surgeons may have different surgical plans despite the same case, building a predictive model reflecting the diversity of decision-making process is considered to be one of the challenges facing machine learning. The purpose of this study was to analyze the important features in the mandibular reconstruction plans among multiple surgeons. We extracted 7-dimensional important features from total 696 surgical plans of two oral surgeons and one dental technician, and analyzed the universal properties and differences of the feature sets.

Key words Enumeration of Lasso solutions, Interpretability, Feature extraction, Mandibular reconstruction

1. はじめに

医療現場では、医師は知識や経験を駆使して診断や治療を進めており、近年高度化が進む医療技術を取り入れることで更なる治療成績の向上が目指されている。例えば、患者自身の腓骨を用いて再建を行う下顎骨の再建手術において、医師は患者ごとの下顎骨の形状を考慮して、再建に使用する腓骨片の本数と配置を決定する必要がある [1]。三次元 CT 画像に対する CAD (Computer Aided Design) 技術の利用が進んでおり、腓骨の分割・配置を対話的にシミュレートしつつ術前計画の立案、検討することが可能となっている [2][3]。また腓骨片配置の自動計

画 [4][5] も試みられている。しかし、同一症例であっても、手術計画は担当する医師によって異なる場合がある。医師個人の知識や経験、手術を行う医療機関の設備や方針によっても異なる可能性があり、また、各医師それぞれの考えを反映した手術計画決定プロセスは明らかにされていない。そのため、手技の標準化や客観的な手術計画作成が可能となる医療プロセス明確化を複数医師の考え方に基いて行うことが求められている。

近年、機械学習モデルの予測結果に解釈性や説明可能性を求める Explainable AI 技術に関する研究が盛んに行われている [6]。特に、医療現場で使用できる信頼性の高い手術計画を作成するためには、人間による解釈が可能、かつ、一意に算出可能な特

微量である解剖学的特徴量を使用した特徴量抽出が望まれる。Lasso 回帰 [7] はデータの適合と特徴量の抽出を同時に行う学習モデルと位置付けられるが、そのままでは一つのモデルしか得られず、ユーザーの理解が得られない可能性がある。近年異なる特徴量を用いたモデルを複数求める Lasso 解列挙 [8] が提案されている。我々はこれまでに Lasso 解列挙を多クラス分類へ拡張し、一名の手術計画データを対象に下顎骨再建に重要な特徴量を抽出する試み [9] [10] を行った。しかし、再建計画に重要な特徴量は医師個人の知識や経験、そして手術を行う医療機関の設備や方針によっても異なる可能性があり、画一的に最適化された手術計画モデルが必ずしもすべての医療機関に受け入れられるとは限らない。このようにデータに内在する意思決定の多様性に柔軟に適応できる予測モデルを構築できるかは機械学習が直面する課題の一つと考えられる。

本研究では、複数医師のデータから得られた特徴量組の共通点と相違点を解析することで、下顎骨の再建計画において重要な特徴量を明確化することを目的とする。過去 10 年程度の臨床論文で参照された下顎骨の解剖学的名称を用いて定義された 78 次元の特徴量を対象に、Lasso 解列挙アルゴリズムに基づいて各医師が重要な特徴量組の抽出を行い、その共通点と相違点を調査する。特徴量組の抽出では組み合わせ最適化問題を解く必要があり、従来の Lasso 解列挙では計算コストの高さが課題であった。これに対し、本研究では下顎骨再建計画において腓骨変数の決定に重要な低次元特徴量を抽出する Lasso 解列挙アルゴリズムに改良を行い、高頻度に列挙される特徴量を優先選出することで、推定性能の高い特徴量組をより少ない計算量で得る。

提案手法を利用して、事前に取得した 口腔外科医 2 名 と 歯科技工士 1 名の計 3 名による 232 通りの手術計画データから、下顎骨再建計画に重要な低次元特徴量を抽出する。複数医師共通の特徴量組を得る実験と、各医師個別の特徴量組を得る実験を行う。得られた手術計画モデルの推定性能を比較すると共に、それぞれが重視する特徴量の共通点や差異を調査する。

2. 提案手法

2.1 複数医師による手術計画データ

使用する手術計画データについて説明する。本研究では、過去に下顎骨再建術を受けた患者 29 名の頭部と下肢の三次元 CT 画像を対象に Nagai らによる研究 [9] [10] において作成されたデータを使用する。特徴量を作成する上で使用されている点は、切断点と解剖学的特徴量点である。まず、切断点について説明する。

切除領域による影響を評価するために、医師の指導の下で 6 種類の切断面を定義した。図 1(a) に示した 6 種類の切断面は解剖学的特徴に基づいて決められている。6 種類の切断面はそれぞれ、 C_0 : 下顎枝、 C_1 : 正中と C_0 の中点、 C_2 : C_3 の正中に関する対称点、 C_3 : 正中と C_5 の中点、 C_4 : C_3 と C_5 の中点、 C_5 : オトガイ孔となっている。これらの切断面を用いて、(C_0, C_2), (C_0, C_3), (C_0, C_4), (C_0, C_5), (C_1, C_2), (C_1, C_3), (C_1, C_4), (C_1, C_5) の 8 種類の切除領域が各下顎骨データに対して設定されている。患




図 1 下顎骨再建における切除面と解剖学的特徴量, (a) 切除面の例, (b) 解剖学的特徴点と符号付き距離に基づく特徴量




図 2 同一症例に対して医師間で異なる腓骨片数が選択された例, (a) 2 本の場合, (b) 3 本の場合

表 1 232 例に対して各医師が選択した各クラス（腓骨片数）のデータ数及び平均腓骨片数

	1 本	2 本	3 本	平均腓骨片数 (本)
医師 A	50	138	44	1.974
医師 B	36	113	83	2.203
歯科技工士 C	35	119	78	2.185

者 29 名の下顎骨データに対して各 8 種類の切除領域が設定されているため、計 232 例のデータが設定されたことになる。

対話型下顎骨再建計画システムを用いることで、腓骨片数が 1 本、2 本、3 本の場合のシミュレーションを行い、口腔外科医 2 名と歯科技工士 1 名の計 3 名それぞれから 232 例のデータそれぞれに対する最適な腓骨変数の数とその配置について回答を得ることで 3 名それぞれの正解データが定められている。

表 1 に、各医師と歯科技工士における、使用する腓骨片数ごとの手術計画データ数を示す。同一症例にもかかわらず、医療機関の設備や方針、医師の知識や経験によって、異なる腓骨片数が選択される場合があるため、平均使用腓骨片数も異なっている。同一症例でも医師で異なる腓骨片数を選択している例として、(C_1, C_5) の切除領域が設定された Case3 の計画例を図 2.1 に示す。(a) が腓骨片を 2 本用いた場合の計画例、(b) が腓骨片を 3 本用いた時の計画例である。医師 A が 2 本、医師 B と歯科技工士 C が 3 本を選択していた。同一症例にもかかわらず、医療機関の設備や方針、医師の知識や経験によって、異なる腓骨片数が選択される場合がある。

次に、特徴量作成の上で使用されている解剖学的特徴量点について説明する。本実験で使用されている解剖学的特徴量点は、3 次元 CT 画像上で解剖学的特徴点と切断点を目視で確認し、その 3 次元座標を手動プロットによって取得されている。

図 1(b) に示すように、各 10 年程度の臨床論文で解剖学的名称や医学用語として定義された指標から選定されたものを基にして、正中、左右の中間点、左右の下顎頭、左右の下顎角、左右のオトガイ孔、左右のオトガイ結節の 11 点が設定されている。正中については、左右のオトガイ結節を結ぶ線分に対し、距離が最大となる下縁ライン上の点として定義されている。なお、左右の中間点は、オトガイ結節と下顎角を結ぶ線分に対する距離が最大となる下縁ライン上の点として定義されている。

設定された解剖学的特徴量点を用いて、78 の距離を定義し、特徴量としている。なお、座標値そのものではなく距離を用いているのは、座標系への依存を排除するためである。各特徴量は、 $F1, F2, \dots, F78$ と表すこととする。

- 解剖学的特徴点間の距離：55 次元
- 左右の切断点と解剖学的特徴点間の距離：22 次元
- 左切断点と右切断点の距離：1 次元

図 1(a) に示すように症例ごとに切断点が定義されているが、切断点が各解剖学的特徴点に対して左右どちら側に定義されているかは症例によって異なる。各解剖学的特徴点と切断点の左右の位置関係を表現するために、図 1(b) に示すように、切除領域に含まれる解剖学的特徴点と切断点を結ぶ距離は正の距離、切除領域に含まれない解剖学的特徴点と切断点を結ぶ距離は負の距離としている。なお、距離として表現される全 78 通りの特徴量について、下顎頭間の距離を 1 とすることによって正規化を行っている。

2.2 問題設定

本研究では、口腔外科医 2 名と歯科技工士 1 名の計 3 名が下顎骨再建術において重要視する特徴量を解析することを目指している。特に、下顎骨再建計画において複数医師共通で重要な特徴量や各医師個別で重要な特徴量があるという仮説から、口腔外科医及び歯科技工士の各データそれぞれ 232 例ずつから得られた特徴量組の共通点と相違点を解析することで、下顎骨の再建計画において重要な特徴量を明確化することを目的としている。本目的に対し、Lasso 解列挙 [8] の考え方を下顎骨再建計画に応用し、腓骨片数との決定に重要な低次元特徴量を複数組列挙するアルゴリズムにより下顎骨の再建計画において重要な特徴量のうち推定性能の最も高い特徴量を得る。

特徴量組の抽出では組み合わせ最適化問題を解く必要があり、従来の Lasso 解列挙では計算コストの高さが課題であった。これに対し、本研究では下顎骨再建計画において腓骨変数の決定に重要な低次元特徴量を抽出する Lasso 解列挙アルゴリズムに改良を行い、高頻度に列挙される特徴量を選出することで、推定性能の高い特徴量組をより少ない計算量で得る。計算コストを抑えたアルゴリズムについては 2.3 節で述べる。

再建計画に重要な特徴量は医師個人の知識や経験、そして手術を行う医療機関の設備や方針によっても異なる可能性がある。本研究では、図 3(a) に示すように、3 名の医師の計 696 例のデータをそのまま学習させて得られる画一的な予測モデルでは、各医師の意思決定の多様性が踏まえられたモデルであるとは限らないという点に着目している。同一症例でも、医師によって腓骨片数は異なる場合があり、複数医師のデータに内在




図 3 予測モデルの概念比較 (a) 画一的な予測モデル, (b) 各医師に個別化された予測モデル

する各医師の意思決定の多様性を踏まえた予測モデルを構築する必要がある。そのため本研究では、図 3(b) のように、各医師のデータを個別に学習させ、各医師の意思決定の多様性を踏まえた予測モデルを構築する。複数医師のデータを混ぜて画一的に得られた予測モデルとの推定性能を比較する。

本研究では腓骨片数が 1 本、2 本、3 本の 3 クラス分類問題を対象としているが、表 1 に示すように、クラスごとのサイズに偏りのあるクラス不均衡データとなっている。このため、得られたデータをそのまま用いて学習を行い、推定性能を算出する方法では、クラス不均衡により結果に偏りが生じる恐れがある。これに対し本研究では、クラス不均衡データによる偏りを軽減する手法の一つである SMOTE 法 [11] を用いてオーバーサンプリングを行い、クラス不均衡データによる分類への影響を低減することを試みる。クラス間のデータ数を統一したうえで、特徴量抽出と推定性能の算出を行う。

2.3 特徴量の出現頻度に基づく Lasso 解探索

下顎骨再建に重要となる特徴量の算出には Nagai らによって提案されている多クラス分類に対応した Lasso 解列挙アルゴリズム [9] [10] を拡張して用いる。本法では、one-versus-rest 法 [12] に基づいて、腓骨片数が 1, 2, 3 本の 3 クラスからなる手術計画データに対し、3 次元ベクトルのバイナリラベルを用いてラベリングを行う。次に、Lasso 回帰により各クラスに対してスパースな重みベクトル β を得る。このとき、それぞれの特徴量の多クラス分類へ影響度合いを評価するための評価値 E を導入し、特徴量抽出の際の指針として用いている。Lasso 解の算出と、指定された次元数分の評価値上位の特徴量群を得る処理を繰り返すことで、手術計画を再現する低次元特徴量組を複数列挙する枠組みを与えている。

一方、本法では Lasso 解の算出時に得られる評価値のみに基づいて特徴量組を探索する方式であるため、高次元特徴量を対象とする場合に計算コストが高くなっていた。一方、これまでの Nagai らの試みから、推定性能の高い特徴量組に共通して含まれる特徴量が存在することが分かっている [9] [10]。そこで本研究では、高頻度に列挙される頻出特徴量を選出することで、推定性能の高い特徴量組をより少ない計算量で得る頻出特徴量に基づく Lasso 解列挙へと拡張を試みた。本方法では、Lasso 解の列挙が一定回数成された際に、高頻度に抽出される特徴量を頻出特徴量と定義し、頻出特徴量を優先選出することで解の探索範囲を限定し、探索効率を高めることを試みる。改良アル

ゴリズムは以下の通りとなる。

頻出特徴量に基づく Lasso 解列挙アルゴリズム

STEP 1 k 回の列挙を行い全ての特徴量について抽出された確率を求める

STEP 2 抽出確率が $p\%$ 以上の場合、対応する特徴量を頻出特徴量としてリストに追加する

STEP 3 リストにある特徴量を全て含んだ k 回の列挙を行い、リストに含まれない特徴量について抽出確率を新たに求める

STEP 4 $p\%$ を新たに上回る特徴量が存在しなくなるまで STEP2 と STEP3 を繰り返す

STEP 5 頻出特徴量を優先選出した Lasso 解列挙を行う

ここで k は頻出特徴量の一つ決定する際に行う重複を許さない Lasso 解列挙の試行回数であり、 p は頻出特徴量を決定する際の閾値である。頻出特徴量を決定し、頻出特徴量を全て優先選出した列挙を行うことで、高推定率を実現できる可能性が高い探索範囲を集中して探索する枠組みが与えられる。頻出特徴量の選出と最終的に得られる特徴量組の推定性能は (k, p) の組み合わせに依存する。本研究では、これらの関係を実験によって明らかにし、本問題に適したパラメータの組み合わせを決定する。


3. 実験

3.1 探索パラメータと特徴量探索の関係

本実験では、頻出特徴量組を取得する上で必要な探索パラメータと特徴量探索の関係について調査し、提案手法で使用するパラメータの検討を行う。検討するパラメータは、頻出特徴量の一つ決定する際に行う Lasso 解列挙の試行回数 k と、頻出特徴量を決定する際の選出の閾値 p である。

まず初めに、試行回数 k と選出の閾値 p について検討する。高い推定性能を持ち最高正解率が高く、かつ、安定して頻出特徴量組が選出されるパラメータを検討する。試行回数 k はできるだけ早く頻出特徴量組を見つけるため、安定して頻出特徴量組を選出している下限となる値がよりふさわしい。このとき、78 次元の特徴量から抽出する次元数は例として、6 次元とする。複数医師から得られたすべての手術計画データを対象として、78 次元の特徴量のうち評価値 E が大きい上位 6 次元の特徴量を使用し、上位 6 個以外の特徴量の重みをゼロにすることで推定を行う。探索範囲を狭める際の列挙回数も含め、重複を許して 10000 回の解列挙が行われた時点で列挙終了とする。試行回数 k は 5, 10, 15, $\dots$, 100 とし、選出の閾値 p は 0.5, 0.55, 0.6, $\dots$, 1.0 を使用し、試行回数 k と選出の閾値 p のパラメータの総当たりで実験を行う。

頻出特徴量組として選出された特徴量を図 4 に示す。図 4 の (a) の各パラメータ条件における色は、図 4 の (b) における選出された頻出特徴量組ごとの最高正解率の平均値に対応しており、各色が異なる頻出特徴量組を表している。なお、図 4 の (a) において白色となっている部分は頻出特徴量が選出されなかったことを示す。



(a) 選出された頻出特徴量組

頻出特徴量組	最高正解率の平均値
F72	91.250
F67 F68 F72	90.556
F72 F78	89.992
F67 F72 F78	89.722
F68 F71 F72 F78	89.583
F71 F72 F78	89.507
F78	89.444
F66 F68 F72 F78	88.889
F66 F72 F78	88.889
F67 F71 F72 F78	88.556
F66 F71 F72 F78	88.333
F66 F68 F71 F72 F78	87.222
F63 F71 F72 F78	87.222
F67 F68 F71 F72 F78	86.667
F66 F67 F71 F72 F78	85.000

(b) 頻出特徴量組ごとの最高正解率の平均値

図 4 異なるパラメータセットに対する頻出特徴量の選出結果, (a) 試行回数, 選出の閾値と正解率の関係, (b) 頻出特徴量組ごとの最高正解率の平均値

まず、試行回数 k に着目する。試行回数 k が 45 回以下の場合と 50 回以上の場合の結果を比較すると、45 回以下の場合には頻出特徴量組のばらつきが大きく、選出が不安定になっていることが確認された。一方、試行回数 k が 50 回以上になると、F72, F78 の頻出特徴量組や F71, F72, F78 の頻出特徴量組のどちらかが選出されるようになり、頻出特徴量組が安定して選出されていることが確認された。

次に、選出の閾値 p について着目する。選出の閾値 p が高いと選出される特徴量数は少なくなり、選出の閾値 p が低いとより多くの特徴量が選出されていることが確認された。試行回数 k が 50 回以上で、安定して頻出特徴量組が選出されている部分を見ると、選出の閾値 p が 0.9 では F72, F78 が安定して選出され、選出の閾値 p が 0.6 では F71, F72, F78 が安定して選出されていることが確認された。選出の閾値 p が 0.6 と 0.9 の間では、F72, F78 と F71, F72, F78 のいずれかが選出されており、0.9 に近いほど F72, F78 が、また、0.6 に近いほど F71, F72, F78 が選出されやすくなっていた。

頻出特徴量組ごとの最高正解率の平均値を図 4 の (b) に示す。最高正解率の平均値が高い順に見ると、F72 のみの頻出特徴量組、F67, F68, F72 の頻出特徴量組、F72, F78 の頻出特徴量組と続いた。試行回数が 50 回以上の部分において安定して選出されている頻出特徴量組である、F72, F78 と F71, F72, F78 について比べてみると、F72, F78 のほうが高い正解率を示していた。

本研究での試行回数 k は、安定して頻出特徴量組を選出している下限となる数値である 50 に設定する。また、選出の閾値 p は安定して正解率が高い F72, F78 の頻出特徴量組を選出して




図5 抽出次元数に対する最高正解率

表2 各医師個別の特徴量と正解率の関係

	正解率	頻出特徴量	頻出特徴量以外の特徴量
医師 A	93.33%	F68, F71, F78	F66, F70, F13, F77
医師 B	90.56%	F72, F78	F71, F14, F13, F68, F48
歯科技工士 C	93.33%	F71, F78	F72, F67, F38, F37, F7
歯科技工士 C	93.33%	F71, F78	F67, F69, F17, F35, F7

いた 0.9 に設定する。

3.2 特徴量次元と正解率の関係

本実験は複数医師共通の特徴量を見つける目的で行う。複数医師から得られたすべての手術計画データを対象として特徴量抽出を行うことで、画一的な機械学習モデルが得られる。正解率が高くなる抽出次元数の下限を得ることで、解釈しやすく、かつ、推定性能の高い特徴量組を得ることを目的とする。抽出次元数は 1 から 15 までとする。抽出次元数に対する最高正解率を表すグラフを図 5 に示す。抽出次元数が 3 以上になると 85% を超える正解率となり、抽出次元数が 7 次元以上では正解率が 90% を超えていた。抽出次元数が 9 次元のとき、93.33% の正解率を示し、抽出次元数 1 から 15 の間では最も高い正解率を示した。

90% を超える高い正解率を安定して得ることができる抽出次元数のうち最小の抽出次元数として、最高正解率 90.56% となった 7 次元特徴量組を各医師データに適用して推定性能を確認した結果を表 3 に示す。各医師ともに推定性能は 85% 程度にとどまっていた。


90% を超える高い正解率を安定して得ることができる抽出次元数のうち最小の抽出次元数として、7 次元を以降の実験で利用するものとする。

3.3 各医師に個別化された特徴量

本実験は、各医師に個別化された特徴量を明らかにする目的で行う。複数の医師のデータについてそれぞれ個別に実験を行う。各医師のデータに対してオーバーサンプリングを行い、特徴量抽出と推定性能の算出を行う。最高正解率となる特徴量組が複数あった場合、5 回算出した正解率で標準偏差が小さい、すなわち、正解率が安定している特徴量組を選ぶものとする。各医師で最高正解率となった特徴量組を表 2 に示す。歯科技工士 C では、最高正解率と最高正解率の標準偏差が全く等しい特徴量組が 2 つ得られたため両方示している。F78 は各医師個別


表3 複数医師共通の特徴量と各医師個別の特徴量の推定性能比較 (%)

	複数医師共通の特徴量	各医師個別の特徴量
医師 A	85.00	93.33
医師 B	83.33	90.56
歯科技工士 C	85.00	93.33



複数医師共通の特徴量組	特徴量番号	特徴量名称
頻出特徴量	F72	右オトガイ孔と右切断点の距離
	F78	左切断点と右切断点の距離
頻出特徴量以外の特徴量	F21	左下顎角と左オトガイ孔の距離
	F61	右オトガイ孔と左切断点の距離
	F63	右オトガイ結節と左切断点の距離
	F66	正中と左切断点の距離
	F77	正中と右切断点の距離

図6 複数医師共通の 7 次元特徴量組



医師Aの特徴量組	特徴量番号	特徴量名称
頻出特徴量	F68	右下顎頭と右切断点の距離
	F71	左オトガイ孔と右切断点の距離
	F78	左切断点と右切断点の距離
頻出特徴量以外の特徴量	F13	右下顎頭と左オトガイ孔の距離
	F66	正中と左切断点の距離
	F70	右下顎角と右切断点の距離
	F77	正中と右切断点の距離

図7 医師 A の 7 次元特徴量組

の特徴量組において、3 名共通して頻出特徴量として選ばれていた。

各医師個別特徴量組による推定性能は、表 3 に示すように、3 名ともに 90% を超えた。また、3 名全てにおいて、各医師個別の特徴量組の推定性能が複数医師共通の特徴組を上回っていた。

複数医師共通の特徴量と医師 A 個別の特徴量について、特徴量番号と特徴量名称の対応関係および下顎骨における特徴量の該当部分を図 6 と図 7 に示す。複数医師共通の特徴量組は医師

A 個別の特徴量組と比べ、下顎頭や下顎角についての特徴量が含まれておらず、顎の先端付近の特徴量点である正中やオトガイ結節、オトガイ孔に対する左右の切断点からの距離が抽出されていた。F78 は複数医師共通の特徴量と各医師個別の特徴量組において共通して頻出特徴量として選ばれていた。

4. おわりに

本研究では口腔外科医 2 名と歯科技工士 1 名の再建計画例を用いて、下顎骨再建術に重要な特徴量の複数医師間の解析を行った。頻出特徴量の優先選出に基づく特徴量抽出法を提案し、特徴量抽出の高速化を試みた。

複数医師共通の特徴量組に基づくモデルと、各医師個別の特徴量組に基づくモデルによる推定性能を比較したところ、各医師個別の推定性能のほうが 8% 程度高くなっており、各医師個別の特徴量組に基づくモデルの有効性を確認した。各医師個別の特徴量組における推定性能は、医師 A で 93.33%、医師 B で 90.56%、歯科技工士 C で 93.33% となっており、3 名ともに 90% を超える 7 次元特徴量が抽出に成功した。また、各医師個別の特徴量組について、下顎骨再建術に重要な特徴量の医師ごとの違いや共通点を評価した。医師ごとの共通点として F78 と F71 の 2 つの特徴量を得ることに成功した。

今後の課題としては、各医師により受け入れられやすい機械学習モデルを提供することを目指として、各医師に合わせてカスタマイズできる機械学習モデルの検討を行うことが挙げられる。

謝辞 本研究は日本学術振興会 科学研究費補助金 基盤研究 (B) (課題番号：19H04484) の助成による。医用画像の提供、及び、手術計画データ作成に多大なご協力を頂いた洛和会音羽病院口腔外科、今井裕一郎氏、奈良県立医科大学口腔外科、上田順宏氏、畠中利英氏に御礼申し上げます。

文 献

- [1] J. S. Brown, C. Barry, M. Ho, and R. Shaw, A New Classification for Mandibular Defects after Oncological Resection, The Lancet Oncology, Vol. 17, No. 1, pp. e23-e30, 2016.
- [2] M. Nakao, M. Hosokawa, Y. Imai, N. Ueda, T. Hatanaka, T. Kirita, and T. Matsuda, Volumetric Fibular Transfer Planning with Shape-based Indicators in Mandibular Reconstruction, IEEE Journal of Biomedical and Informatics, Vol. 19, No. 2, pp. 581-589, 2015.
- [3] A. K. Antony, W. F. Chen, A. Kolokythas, K. A. Weimer, and M. N. Cohen, Use of Virtual Surgery and Stereolithography-guided Osteotomy for Mandibular Reconstruction with the Free Fibula, Plastic and Reconstructive Surgery, Vol. 128, No. 5, pp. 1080-1084, 2011.
- [4] M. Nakao, S. Aso, Y. Imai, N. Ueda, T. Hatanaka, M. Shiba, T. Kirita, and T. Matsuda, Automated Planning with Multivariate Shape Descriptors for Fibular Transfer in Mandibular Reconstruction, IEEE Transactions on Biomedical Engineering, Vol. 64, No. 8, pp. 1772-1785, 2017.
- [5] R. Kawasaki, M. Nakao, Y. Imai, N. Ueda, T. Hatanaka, M. Shiba, T. Kirita, and T. Matsuda, Sparse Shape Model for Fibular Transfer Planning in Mandibular Reconstruction, 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 2508-2511, 2016.
- [6] De Fauw, J. et al. Clinically applicable deep learning for diagnosis and referral in retinal disease, Nature medicine, Vol. 24, No. 9, pp. 1342-1350, 2018.
- [7] R. Tibshirani, Regression Shrinkage and Selection via the Lasso,

Journal of the Royal Statistical Society : Series B (Statistical Methodology), Vol. 58, No. 1, pp. 267-288, 1996.

- [8] S. Hara and T. Maehara, Enumerate Lasso Solutions for Feature Selection, In Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence, 2017.
- [9] K. Nagai, M. Nakao, N. Ueda, Y. Imai, T. Kirita, and T. Matsuda, Enumerated sparse extraction of important surgical planning features for mandibular reconstruction, Proc. 42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 5519-5522, 2020.
- [10] 永井一希, 中尾恵, 上田順宏, 今井裕一郎, 桐田忠昭, 松田哲也, 下顎骨再建術を対象とした手術計画に重要な特徴量抽出手法の提案, 電子情報通信学会技術報告 (MI), 119(399), pp. 23-28, 2020.
- [11] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, SMOTE: Synthetic Minority Over-sampling Technique, Journal Of Artificial Intelligence Research, Vol. 16, pp. 321-357, 2002.
- [12] U. Kressel, Pairwise Classification and Support Vector Machines, Advances in kernel methods: support vector learning, The MIT Press, pp. 255-268, 1999.