

下顎骨再建に重要な特徴量群抽出に基づく手術計画モデルの生成

永井 一希[†] 中尾 恵[†] 上田 順宏^{††} 今井 裕一郎^{†††} 畠中 利英^{††}
桐田 忠昭^{††} 松田 哲也[†]

[†] 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

^{††} 奈良県立医科大学口腔外科学講座 〒634-8521 奈良県橿原市四条町 840

^{†††} 洛和会音羽病院口腔外科 〒607-8062 京都府京都市山科区音羽珍事町 2

あらまし 医師は医学知識と経験を駆使して医療行為を遂行しており、その判断基準が明確になれば手術手技の体系化に繋がると考えられる。これまでに下顎骨再建計画を対象として、多クラス分類に対応した Lasso 解列挙を提案したが、特徴量組の探索に要する計算量が大きい点が課題であった。本研究では、頻出特徴量を優先的に選出する多クラス分類問題に対応した Lasso 解列挙アルゴリズムを提案し、可読性の高い低次元特徴量群に基づく手術計画モデルの生成を試みた。232 の手術計画例を対象とした実験により、従来の約 76% の計算時間で医師の手術計画を 90% 以上の正解率で再現する 5 次元の特徴量組を抽出したので報告する。

キーワード Lasso 解列挙, 解釈可能性, 特徴抽出, 下顎骨再建

Surgical planning model generation by extracting important feature sets in mandibular reconstruction

Kazuki NAGAI[†], Megumi NAKAO[†], Nobuhiro UEDA^{††}, Yuichiro IMAI^{†††}, Toshihide HATANAKA^{††},
Tadaaki KIRITA^{††}, and Tetsuya MATSUDA[†]

[†] Graduate School of informatics, Kyoto University

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

^{††} Department of Oral and Maxillofacial Surgery, Nara Medical University

Shijocho 840, Kashihara-shi, Nara, 634-8521, Japan

^{†††} Department of Oral and Maxillofacial Surgery, Rakuwakai Otowa Hospital

Otowachinjiicho 2, Yamashina-ku, Kyoto, 607-8062, Japan

Abstract Because implicit medical knowledge and experience are used to perform medical treatment, such decisions must be clarified when systematizing surgical procedures. We proposed the enumeration of Lasso solutions corresponding to multiple classes in mandibular reconstruction, but the calculation amount required to search feature sets was large. In this study, we propose the enumeration of Lasso solutions algorithm for multi-class classification that preferentially selects frequently features. Experiments showed that the 5-dimensional feature set which can correctly estimate more than 90% of surgeons' plans with 76% calculation time compared to the previous methods.

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

1. ま え が き

医療技術の高度化が進む中、医師は医学知識と経験を駆使して、診断や手術などの医療行為を遂行している。例えば、患者自身の腭骨の移植による下顎骨の再建手術 [1] では、再建に用いる腭骨片数と下顎骨切除領域への配置を決定する必要があるが、下顎骨の形状の多様性から様々な再建計画が考えら

れる [2]。現状において再建計画の立案は過去の症例の習熟と参照に頼る部分が大きく計画ポリシーが医師個人の主観や経験に依存するため、品質の維持が難しい。またその決定に至るプロセスは明らかになっていない。近年では、腭骨配置の自動化 [3] [4] が試みられているが、研究者の洞察に基づいて指標を設計する方式は指標探索に時間を要することに加え、客観性に課題が残る。また、アルゴリズム内で自動算出された

特徴量は解剖学的特徴点に基づかず、既存知識との関係性を議論することが困難である。信頼性の高い手術計画を得るためには、人間による解釈が可能、かつ、一意に算出可能な特徴量を使用することが求められる。

一方で情報学の分野では、深層学習が大きな発展を遂げ、様々な分野に応用されているが、モデルがブラックボックスとなる点が問題となる場合がある。そこで近年、機械学習モデルの予測結果や決定に至るプロセスに解釈性や説明可能性を求める Explainable AI(XAI) 技術に関する研究が盛んに行われている。XAI 技術の一つとして、高次元データに普遍的に内在するスパース性を利用することで情報の抽出を目指すスパースモデリングが挙げられる。 L_1 正則化に基づいてデータの適合と特徴量の選択を自動で行える Lasso (Least absolute shrinkage and selection operator) 回帰 [5] が知られており、信号処理や画像処理等の多くの分野で活用されている。スパースモデリングの考え方を手術計画データに導入することによって、計画の立案に重要となる特徴量を客観的に抽出でき、可読性の高い手術計画モデルを生成できる可能性がある。一般に、類似した特徴量が存在する場合、同等の推定性能を持つモデルは複数存在し得るが、Lasso 回帰では一つのモデルしか得られない。そこで、異なる特徴量組を用いたモデルを複数求める Lasso 解列挙が提案されている [6]。我々はこれまでに下顎骨再建計画を対象として、多クラス分類に対応した Lasso 解列挙 [7][8] を提案したが、特徴量組の探索に要する計算量が大きい点が課題であった。

これにより Lasso 回帰では得られなかった特徴量を用いたモデルが得られ、ユーザーによる理解も得られやすい。しかし、当該手法は多クラス分類に対応していないことに加え、特徴量組の抽出に要する計算量が多い点が課題として残っている。

本論文では、下顎骨再建術を対象とした解釈可能な手術計画モデル生成方法を提案する。特に腓骨片数に関する意思決定は下顎骨の形態に関する幾らかの特徴に基づいてなされると仮定し、腓骨片数の決定問題で高い推定性能を持つ、解釈性の高い n 次元特徴量を提示することを目指す。医師によって対話的に設計された 232 通りの手術計画データを取得し、過去 10 年間程度の臨床論文に用いられている解剖学的名称や医学用語を用いて定義された特徴量を用いることで、従来から参照されてきた医学知識と手術計画の関係の明確化を試みる。これに対し、我々はこれまでに異なる特徴量組を用いた手術計画モデルを生成することを目的に、Lasso 解列挙を多クラス分類に拡張した特徴量の抽出アルゴリズムを構築し、推定性能の高い特徴量組に共通の特徴量が存在することを確認した [7]。そのような推定に貢献度の高い特徴量を特定し、優先的に選出することによって、特徴量組の探索を限定し、短い時間で推定性能が高い特徴量組の抽出を可能とするアルゴリズムへの改良を試みたので報告する。

2. 提案手法

2.1 手術計画データ

まず、本研究で使用する手術計画データについて説明する。




図1 異なる症例、同一切除領域に対して用いられた腓骨片の本数の違い、(a)case2 および (b)case3 の切除領域 (C_0 , C_3) に対する計画




図2 下顎骨における解剖学的特徴点

最初に、過去に下顎骨再建術を受けた患者 29 名の頭部および下肢の三次元 CT 画像 (case1, 2, ..., 29) に対して手動で関心領域を設定し、下顎骨領域および腓骨領域を抽出した。次に下顎骨再建において想定される切除領域のパリエーションを表現し、異なる切除領域に対する手術計画例を多数得るために、医師の指導の下で 6 種類の切断面を定義した。各切断面は下顎骨の解剖学的特徴に基づいており、 C_0 を下顎枝前縁、 C_5 をオトガイ孔と設定した後、 C_1 を正中と C_0 の中点、 C_3 を正中と C_5 の中点と設定し、最後に C_2 を C_3 の正中に関する対称点、 C_4 を C_3 と C_5 の中点と設定した。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 種類の切除領域を各症例に対して設定した。以上のようにして作成した計 232 例のデータに対し、1 名の 26 年の経験を持つ口腔外科医 (日本口腔外科学会専門医) の専門的見地より最適な腓骨片数と配置について手術計画データを得た。具体的には、下顎骨再建システム [9] から生成される下顎骨の 3 次元画像を参照しつつ、腓骨片数について 1, 2, 3 本のいずれかの回答を得、その後に腓骨片の接続位置を 3 次元的に指定することによって腓骨片の配置を得た。図 1(a)(b) のように解剖学的には同等の切除領域であっても、下顎骨の形状によって異なる腓骨片数が選択されていた。

次に、本研究において設計した特徴量について説明する。過去 10 年間程度の臨床論文より解剖学的名称や医学用語を選定し、それらに関連する下顎骨の解剖学的特徴点の三次元座標を抽出する。特徴量の座標系への依存を排除するため座標値そのものは用いず、全て解剖学的特徴点間の距離として用いることとした。

具体的には、解剖学的名称に関連した左右の下顎頭、下顎角、オトガイ孔、オトガイ結節、オトガイ結節と下顎角の中間点および正中の計 11 点を抽出対象とする解剖学的特徴点とし




図3 改良手法における処理の流れ

た．図2に各解剖学的特徴点を示す．11点の解剖学的特徴点と左右2点の切断点を用いて特徴量を設計する．まず，患者の下顎形態に関する情報をより多く特徴量として組み込むために，解剖学的特徴点の全ての組み合わせ (${}_{11}C_2 = 55$ 通り) の距離を使用する．左右の切断点は症例毎に定義されるため，解剖学的特徴点と切断面の順序関係は症例によって異なる．そこで左右の切断点と11点の解剖学的特徴点の距離は，互いの位置関係を情報として保持するために符号付き距離として定義する．解剖学的特徴点と切断点の位置を比べ，特徴点が切断面よりも切除領域側にある場合には正，逆側にある場合には負とする．最後に切除領域の広さを表すために左右の切断点の距離を使用する．以上より11点の解剖学的特徴点と2点の切断点から以下の78次元の特徴量を定義し，F1, F2, ..., F78とする．

- 11点の解剖学的特徴点相互の距離：55次元
- 左右の切断点と11点の解剖学的特徴点の符号付き距離：22次元
- 左右の切断点間の距離：1次元

本実験では下顎骨のスケールを揃えるために，特徴量を算出後，各症例内で左右の下顎頭の距離が1になるように正規化する．

2.2 改良手法の概要

本研究では，下顎骨再建術に重要となる特徴量を抽出し，解釈可能な手術計画モデルを生成することを目指す．解釈可能とは低次元かつ用いる特徴量が単純で人間の理解が容易であることを意味する．特に肋骨片数に関する意思決定は下顎骨の形態に関する低次元特徴量に基づいてなされるという仮説から，肋骨片数の決定問題で高い推定性能を持つ，解釈性の高い n 次元特徴量を提示することを目的としている．本目的に対し，我々はこれまでに Lasso 解列挙を多クラス分類に拡張し，下顎骨の解剖学的特徴点から定義される N 次元特徴量の中から手術計画を高い正解率で再現可能な n 次元特徴量 ($N \gg n$) の抽出アルゴリズムを提案している．本論文ではこれを提案手法と呼ぶ．提案手法は，推定性能が高くなる見込みの薄い特徴量組も含めて網羅的に探索しているため計算量が大きい点が課題として残っている．また，これまでの試みから推定性能が高い特徴量組に共通の特徴量が存在すること

が分かっている．そこで，列挙の途中の段階で提案手法において高い頻度で抽出される特徴量の選出を確定し，その後それらを含んだ特徴量組の列挙を行うことを考える．この探索法を本論文では改良手法と呼ぶ．

次に，本研究における変数の定義と処理の流れを図3に示す．まず症例 i の三次元 CT 画像に対して， N 次元特徴量を算出し特徴ベクトル $\mathbf{d}^{(i)} = [d_1, d_2, \dots, d_N]^T$ を作成する．さらに特徴ベクトルを行方向に並べることで特徴行列 $\mathbf{D}_f = [\mathbf{d}^{(1)}, \mathbf{d}^{(2)}, \dots, \mathbf{d}^{(m)}]^T$ を作成する． m はトレーニングデータ数を表す．次に本研究では肋骨片数の多クラス分類を行うが，二値分類器を用いて多クラス分類を行う場合の手法の一つに one-versus-rest 法 [10] が知られている．肋骨片数が1本，2本，3本の3クラス分類を行う場合，症例 i に対し3次元ベクトル $\mathbf{y}^{(i)} = [y_1^{(i)}, y_2^{(i)}, y_3^{(i)}]^T$ を用いて以下のようにラベリングする．

- クラス1 肋骨片数が1本の場合： $\mathbf{y}^{(i)} = [1, 0, 0]$
- クラス2 肋骨片数が2本の場合： $\mathbf{y}^{(i)} = [0, 1, 0]$
- クラス3 肋骨片数が3本の場合： $\mathbf{y}^{(i)} = [0, 0, 1]$

各手術計画データに対しラベリングを行い，各成分ごとに並べて正解ラベル群 $\mathbf{y}_1 = [y_1^{(1)}, y_1^{(2)}, \dots, y_1^{(m)}]^T$, $\mathbf{y}_2 = [y_2^{(1)}, y_2^{(2)}, \dots, y_2^{(m)}]^T$, $\mathbf{y}_3 = [y_3^{(1)}, y_3^{(2)}, \dots, y_3^{(m)}]^T$ を作成し，特徴行列 $\mathbf{D}_f$ と合わせて入力データとする．正解ラベル群 $\mathbf{y}$ に対し Lasso 回帰を用いて 0, 1 の二値分類を行うと，回帰係数である β が算出される．本研究では， β から後述する評価値 E を用いて特徴量組 T を抽出する．しかし，Lasso 回帰を一度適用するだけでは一組の特徴量組しか得られないため，抽出された T に基づき特徴行列 $\mathbf{D}_f$ を更新して再度 Lasso 回帰を行う．これにより T を複数列挙することが可能となる．列挙された特徴量組に基づき頻出特徴量 T_f を決定し，頻出特徴量を優先して選出するという条件のもとで再度特徴量組の列挙を行うことで， T_f を含んだ特徴量組を複数列挙する．

最後に，手術計画モデルを生成する方法について説明する．抽出された n 次元特徴量の情報のみを格納した特徴行列 $\mathbf{D}_f$ を新たに作成し，次節に示す式 (1) を解くことで β を得る．これらと手術計画データの特徴ベクトルの内積を計算することで肋骨片数の推定を行う．

2.3 頻出特徴量の優先選出に基づく Lasso 解探索

まず，前節で定義した $\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3$ に対して，二値分類を行う

方法について説明する．各特徴量のスパースな重み付き線形結合によって正解ラベル群 $\mathbf{y}$ を表現するために，重みベクトル $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_N]^T$ に対し，目的関数を式 (1) で定義し，これを最小化することでスパースな重みベクトル $\boldsymbol{\beta}^*$ を得る [5]．本研究では $\boldsymbol{\beta}^*$ の算出に ADMM 法 [11] を用いた．

$$L(\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{D}_f \boldsymbol{\beta}\|_2^2 + \lambda \|\boldsymbol{\beta}\|_1 \quad (1)$$

ここで λ は $\boldsymbol{\beta}$ のスパース性を制御するパラメータであり，正則化係数と呼ばれる．本研究では多クラス分類問題を対象としており，各クラスに対して $\boldsymbol{\beta}$ は算出される．クラス $c (c = 1, 2, \dots, s)$ に対する重みベクトルを $\boldsymbol{\beta}_c$ と表記する．ここで， $\boldsymbol{\beta}_c = [\beta_{c1}, \beta_{c2}, \dots, \beta_{cN}]$ であり，本研究では3クラス分類問題を対象としているため， $s = 3$ となる．得られた各クラスの重み $\boldsymbol{\beta}_1^*, \boldsymbol{\beta}_2^*, \boldsymbol{\beta}_3^*$ と手術計画データの特徴ベクトル $\mathbf{d}^{(i)}$ の内積を計算し，最も大きい値となったクラスが推定する腓骨片数となる．例えば，症例 i に対して内積を計算し (0.1, 0.7, 0.3) が得られたとすると，推定された腓骨片数は2本となる．

次に，提案する特徴量を自動抽出するアルゴリズムについて説明する．このアルゴリズムでは Lasso 解列挙を導入することで，Lasso 回帰では得られなかった特徴量を含む複数の特徴量組を列挙することを試みる．Hara らの手法 [6] では Lasso 回帰により算出された各特徴量の重みの大きさに注目し特徴量組を抽出する．しかし本研究が対象とする多クラス分類では，図 4(a), (b), (c) の例に示すように，クラスごとに大きさが異なる重み $\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \boldsymbol{\beta}_3$ が得られ，そのままでは各特徴量について得られた重みを比較できない．そこで，特徴量 j が腓骨片数の多クラス分類に与える影響を指標化するために式 (2) で定義される評価値 E を新たに導入する．

$$E = \sum_{c=1}^s \frac{|\beta_{cj}|}{\|\boldsymbol{\beta}_c\|_1} \quad (2)$$

本指標では，特徴量 j に対して得られる重みは各クラス内で正規化されて評価される．本研究では，全ての特徴量 j に対し，式 (2) に基づいて評価を行う．図 4(d) に (a), (b), (c) より算出される評価値を例として示す．評価値 E が大きい特徴量ほど，多クラス分類を行う上で重要な特徴量であると考えられる．これにより特徴量間の比較が可能となる．評価値 E を特徴量抽出の指針として Lasso 解列挙に導入することで多クラス分類に拡張し，評価値の大きさ上位 n 個の特徴量組を列挙する枠組みが与えられる [7] [8]．

改良手法では，特徴量組の列挙とその結果に基づく頻出特徴量の追加を数回繰り返し，頻出特徴量 T_f を決定する．次に頻出特徴量を優先して選出するという条件のもとで再度特徴量組の列挙を行うことで， T_f を含んだ特徴量組を複数列挙することが可能となる．具体的なアルゴリズムを以下に示す．

頻出特徴量の優先選出に基づく列挙アルゴリズム

STEP 1 提案手法を用いて重複を許さない k 回の特徴量組の列挙を行い，各特徴量の抽出頻度を算出する．最も高い確率で抽出された特徴量 j に着目し，その確率が $p\%$ 以上であれば， j を頻出特徴量 T_f に追加する．




図4 Lasso 回帰により抽出された重みおよび評価値の例，(a) 重み $\boldsymbol{\beta}_1$ ，(b) 重み $\boldsymbol{\beta}_2$ ，(c) 重み $\boldsymbol{\beta}_3$ ，(d) 評価値 E

STEP 2 T_f にある特徴量を全て含み，かつ，重複を許さない k 回の特徴量組の列挙を行う．抽出頻度を算出し，最も高い確率となった特徴量 j が $p\%$ 以上であれば T_f に追加する．

STEP 3 $p\%$ 以上の特徴量が存在しなくなるまで STEP 2 を繰り返す．

STEP 4 頻出特徴量 T_f にある特徴量を全て含んだ特徴量組の列挙を行う．

STEP 1,2,3 で頻出特徴量 T_f の選出を行い，STEP 4 で T_f を優先選出した特徴量組の列挙を行う．

改良手法の特徴として，特徴量組の総数を大幅に減らすことができる点が挙げられる．例えば，78 次元から 5 次元の特徴量を抽出する場合を考える．本来ならば，特徴量の組み合わせ総数は ${}_{78}C_5$ 通りとなり，この中から推定性能が高い特徴量組を探索する問題となる．改良手法では，頻出特徴量として 2 次元特徴量が得られた場合，STEP 4 において 76 次元から残りの 3 次元を探索するため組み合わせ総数は ${}_{76}C_3$ 通りとなり大幅に減らすことができ，提案手法より少ない計算量で性能の高い特徴量組を見つけやすくなる．

頻出特徴量の選出は，選出時に列挙する特徴量組の数 k と選出を行う閾値 p に依存する．以降，試行回数 k ，選出の閾値 p と呼ぶ．試行回数 k が大きい場合，選出を行う際の計算量が増えるのに対し， k が小さい場合，頻度を算出する際のサンプルが少なく，重要度の低い特徴量が選出される可能性がある．選出の閾値 p が大きい場合，頻出特徴量としてみなす基準が厳しく，選出される特徴量数が減る一方で， p が小さい場合，重要度の低い特徴量が選出される可能性がある．改良手法を用いる際は，高い推定性能を持つ頻出特徴量を安定に得られるパラメータを決定する必要がある．

3. 実験

3.1 探索パラメータと特徴量抽出の関係

本実験では、改良手法で選出される頻出特徴量組と推定性能の関係を調査し、改良手法で用いる試行回数 k と選出の閾値 p の検討を行う。腓骨片数の決定問題を対象とし、改良手法を用いて 6 次元特徴量の抽出実験を行う。データの偏りをなくするために、腓骨片が 1 本、2 本、3 本の手術計画データを SMOTE [12] によるオーバーサンプリングにより 150 症例ずつに揃えた計 450 例のデータを使用する。手術計画モデルを生成する際、各クラス 150 症例からランダムに 12 症例ずつ取り出した計 36 症例をテストデータとし、残りの 414 症例をトレーニングデータとして使用する。データの分割からテストまでを 5 回繰り返し、抽出された特徴量組の評価を行う。数回の試行から、特徴量を抽出する際には正則化係数 $\lambda = 10^{-3}$ 、手術計画モデルを生成する際には正則化係数 $\lambda = 10^{-5}$ を使用することとした。また改良手法では、複数回特徴量組の列挙を行うが、合わせて 10000 組列挙し、その中で最も高い正解率に注目する。以上の条件のもと、試行回数 $k = 10, 20, \dots, 80$ 、および選出の閾値 $p = 50, 60, \dots, 90$ の 40 通りで実験を行い、高い推定性能を持つ頻出特徴量を安定に得られるパラメータを決定する。

選出された頻出特徴量ごとに最大正解率の平均を算出した結果を図に示す。本実験では、40 通りの探索パラメータを用いて頻出特徴量の選出を行ったが、得られた頻出特徴量は全部で 6 通りであった。例えば頻出特徴量の一つの {F68, F70, F71, F78} は 7 通りの探索パラメータの組み合わせで選出されており、7 通りの最大正解率を平均することで 91.6% となる。試行回数あるいは選出の閾値が大きい場合、選出される頻出特徴量の次元は減るが、推定性能は高い水準で安定することが確認できる。本研究では、最大正解率の平均が最も大きい頻出特徴量 {F71, F78} が得られるパラメータに注目し、試行回数 $k = 40$ 、選出の閾値 $p = 90$ を代表として以降の実験で用いる。

3.2 探索アルゴリズムの性能評価

本実験では、腓骨片数の決定問題を対象とした特徴量の抽出を通じて、提案手法と改良手法の有効性を確認する。まず、以下の 3 手法を用いた特徴抽出の比較実験を行う。その後、提案手法と改良手法において特徴抽出に要した時間を比較することで、改良手法が効率良く探索を行えていることを示す。

手法 1 Lasso 回帰

手法 2 Lasso 解列挙を用いた特徴抽出（提案手法）

手法 3 頻出特徴量の優先選出に基づく Lasso 解探索（改良手法）

手法 1 では、Lasso 回帰を一度適用して算出された重みベクトル $\beta_1, \beta_2, \beta_3$ より式 (2) に基づいて評価値 E を算出し、評価値の大きさ上位 n 個の特徴量組を得る。探索効率を評価するために、手法 2 と手法 3 で特徴量組の探索を行う回数を 10000 組で揃える。得られた特徴量組の中で最も正解率が高くなった特徴量組を選択し、他手法と比較する。抽出する特徴量の次元は $n = 1, 2, \dots, 10$ とする。実験に用いるデータおよび正則化係




図 5 異なるパラメータセットによって選出される頻出特徴量と正解率, (a) 試行回数, 選出の閾値と頻出特徴量及び正解率の関係, (b) 頻出特徴量ごとの最高正解率の平均




図 6 各次元において得られた特徴量組の正解率




図 7 各次元において特徴量の探索に要した計算時間

数は実験 3.1 と同様とし、探索パラメータは $(k, p) = (40, 90)$ を用いる。

各手法を用いて得られた特徴量組による正解率を図 6 に示し、提案手法と改良手法において特徴量の探索に要した時間を図 7 に示す。また、 $n = 3, 5, 8$ において提案手法と改良手法によって得られた特徴量組と正解率をそれぞれ表 1、表 2 に示す。表 2 では $n = 3, 5, 8$ の場合に改良手法で選出された頻出特徴量を下線で示している。図 6 より各特徴量次元において、Lasso 回帰によって抽出される特徴量組より推定性能の高い特徴量組が提案手法、改良手法によって得られた。提案手法と改良手法で同程度の推定性能を示す n 次元特徴量を得られている一方で、計算時間に注目すると改良手法は $n = 2, \dots, 10$ において提案手法より少ない計算時間で特徴量組の探索が行えている。例えば提案手法、改良手法ともに 90% を超える 5 次元特徴量を抽出できているが、提案手法と比べ改良手法は約 76% の計算時間で探索を行えており、頻出特徴量を優先選出することで探索効率が向上したといえる。抽出された特徴量組に

n	正解率	特徴量番号
3	86.7%	F14, F62, F78
5	91.7%	F16, F37, F63, F71, F78
8	93.9%	F13, F14, F39, F63, F64, F68, F71, F78

表1 提案手法によって抽出された特徴量組と正解率の関係

n	正解率	特徴量番号
3	89.4%	F78, F63, F70
5	91.7%	F78, F40, F65, F66, F71
8	93.9%	F71, F78, F4, F60, F66, F67, F69, F73

表2 改良手法によって抽出された特徴量組と正解率の関係




図8 抽出された次元特徴量

注目すると、探索領域の違いから提案手法と改良手法で異なる特徴量組が抽出されていた。また改良手法において頻出特徴量として選出された特徴量は、提案手法によって得られた特徴量組においても同様に含まれていることから、改良手法によって推定性能を向上させるために主要となる特徴量を早期に確定できたと考えられる。

3.3 低次元特徴量の解析

本実験では、腓骨片数の決定問題で重要な低次元特徴量の解析を行い、生成された手術計画モデルの推定結果について考察を行う。図6の改良手法の結果より、安定して正解率が90%を超える次元数のうち、下限となる91.7%を示す5次元特徴量に注目し解析を行う。

91.7%を示す5次元特徴量の下顎骨における該当部分を図8に示す。図8において、青点は解剖学的特徴点を示し、緑点および緑線は切断点および切断面を示す。赤の矢印は抽出された特徴量を示している。また、図は下側から見た下顎骨となっている。また、{F78}が頻出特徴量として選出されている。F78が頻出特徴量として選出されていることから、切除領域は特に重要であると考えられる。F66, F65, F71は切断面との距離となっているため、左右の切断面も考慮して腓骨片数を決定していると考えられる。右中間点との距離であるF65が抽出されていることから、下顎の丸みも腓骨片数を決める要因の一つとなっていると考えられる。また正中とオトガイ孔の距離としてF40が抽出されている。F40は所謂顎のしゃくれを表しており、患者のしゃくれ方も要因の一つとして考えられる。医師からオトガイ孔や中間点は立案の際に無意識に見ていた点であるとの意見が得られており、解釈可能な特徴量の抽出によって意思決定に重要となる解剖学的特徴を示

唆できたと考えられる。

4. 結 論

本研究では下顎骨再建計画を対象に、頻出特徴量を優先的に選出するLasso解列挙アルゴリズムを提案し、可読性の高い低次元特徴量群に基づく手術計画モデルの生成を試みた。改良手法によって、医師の手術計画を90%以上の正解率で再現する5次元特徴量を提案手法の約76%の計算時間で抽出できることを確認した。また、得られた特徴量組の解析を通じて手術計画を立案する際に重要視される下顎の特徴を明らかにした。本論文では腓骨片数の分類問題を扱うにとどまったが、腓骨片の接続位置の三次元座標を直接推定する手術計画モデルの生成方法の検討などが今後の課題として挙げられる。

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。

文 献

- [1] A. F. Flemming, M. D. Brough, N. D. Evans, H. R. Grant, M. Harris, D. R. James, M. Lawlor and I. M. Laws, "Mandibular Reconstruction Using Vascularised Fibula", *Brit. J. Plastic Surg.*, Vol. 43, No. 4, pp. 403-409, 1990.
- [2] J. S. Brown, C. Barry, M. Ho, R. Shaw, "A New Classification for Mandibular Defects after Oncological Resection", *The Lancet Oncology*, Vol. 17, No. 1, e23-e30, 2016.
- [3] 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.
- [4] 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.
- [5] 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.
- [6] S. Hara and T. Machara, "Enumerate Lasso Solutions for Feature Selection", *In Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence*, 2017.
- [7] 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)*, Vol. 119, No. 399, pp. 23-28, 2020.
- [8] K. Nagai, M. Nakao, N. Ueda, Y. Imai, T. Kirita and T. Matsuda, "Enumerated sparse extraction of important surgical planning features for mandibular reconstruction", *42nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 5519-5522, 2020.
- [9] 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.
- [10] U. Kressel, "Pairwise Classification and Support Vector Machines", *Advances in kernel methods: support vector learning*, The MIT Press, pp. 255-268, 1999.
- [11] S. Boyd, N. Parikh, E. Chu, B. Peleato, and J. Eckstein, "Distributed Optimization and Statistical Learning via the Alternating Direction Method of Multipliers", *Foundations and Trends in Machine Learning*, Vol. 3, No. 1, pp. 1-122, 2011.
- [12] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Oversampling Technique", *Journal of Artificial Intelligence Research*, Vol. 16, pp. 321-357, 2002.