



Title	咀嚼圧力分布解析に基づく食品テクスチャ推定システムに関する研究
Author(s)	柴田, 暁秀
Citation	大阪大学, 2018, 博士論文
Version Type	VoR
URL	https://doi.org/10.18910/69565
rights	
Note	

The University of Osaka Institutional Knowledge Archive : OUKA

<https://ir.library.osaka-u.ac.jp/>

The University of Osaka

博士学位論文

咀嚼圧力分布解析に基づく
食品テクスチャ推定システムに関する研究

柴田 暁 秀

2018年1月

大阪大学大学院工学研究科
機械工学専攻

概要

本論文では、食品テクスチャの客観的・定量的評価手法について議論し、「ヒトが舌上で感知するテクスチャを評価指標として数値で提示する」ロボットセンシングシステムを提案する。高齢者向けの介護用食品として、舌と口蓋を使って押しつぶして喫食するゲル食品が開発されており、咀嚼・嚥下の安全性と美味しさが高水準で両立することが望まれている。美味しさの重要要素であるテクスチャの評価は、ヒトによる官能評価試験が基準となるが、時間、コスト、信頼性の問題が懸案となっており、物理的測定によって定量的に評価する手法が求められている。テクスチャは、機械的特性（もちもち感、ねっとり感、など）や幾何学的特性（つるつる感、ざらざら感、など）に分類され、機械的特性に関する測定機器が実用化されている一方、幾何学的特性を含めたヒトが舌上で受ける繊細な印象と関連付けて食品テクスチャを評価する手法は確立されていない。以上を踏まえ、本論文では、ゲル食品を対象とし、ヒトに代わって食品テクスチャを評価するロボットセンシングシステムの開発を目的とする。簡易的な咀嚼ロボットを開発し、食品圧縮・破断過程の圧力分布（咀嚼圧力分布）データとテクスチャ官能評価値との関係を表す数理モデルに基づくテクスチャ推定手法を構築する。まず、圧力分布データに画像テクスチャ解析手法を適用して特徴量を算出し、主成分分析および重回帰分析に基づくテクスチャ官能評価値の推定モデルを作成する。テクスチャ推定実験により、ゲル食品のテクスチャについて、機械的特性のみでなく幾何学的特性も高精度に官能評価値を推定できることを確認する。続いて、画像特徴量の抽出手法について検討する。テクスチャ評価項目は多岐に渡るため、それぞれを評価する際に必要となる特徴量も異なることが予想される。そこで、画像特徴量の定義自体が学習の対象となっている畳み込みニューラルネットワークを導入し、汎用性の高い推定モデル作成方式の構築を試みる。テクスチャ推定実験によって、画像テクスチャ解析手法を用いた特徴量定義方式よりも多くのテクスチャ評価項目に対応できることを確認する。さらに、ヒトの舌の弾性変形を考慮したシステムへと拡張する。咀嚼ロボットに対する模擬舌の導入に向け、ヒトの舌弾性を測定するための筋電位センサを備えたグリッパ式計測システムを開発する。ここでは、舌筋の弛緩時に比べ、収縮時の方が、約4倍弾性が高いことを示す。続いて、弾性可変機構を有するシリコーン製模擬舌を提案し、プロトタイプによってヒトの舌の弾性を弛緩状態から収縮状態まで再現可能なことを示す。咀嚼ロボットに模擬舌を導入し、模擬舌の弾性状態による咀嚼圧力分布の違いを示すとともに、テクスチャ評価項目に応じて、テクスチャ推定精度を向上させるための最適な模擬舌の弾性が変化することを明らかにする。

目次

第 1 章	緒論	1
1.1	背景	1
1.2	目的	2
1.3	論文構成	3
1.4	従来研究	4
1.4.1	食品テクスチャ評価に関する研究	4
1.4.2	その他の咀嚼・嚥下ロボットに関する研究	5
第 2 章	咀嚼圧力分布解析に基づくテクスチャ推定システム	7
2.1	はじめに	7
2.2	テクスチャ推定システム	7
2.2.1	システムの全容	7
2.2.2	咀嚼ロボットによる圧力分布測定	9
2.2.3	テクスチャ推定モデルの作成	13
2.3	テクスチャ推定実験	18
2.3.1	実験条件・手順	18
2.3.2	実験結果	20
2.4	まとめ	27
第 3 章	畳み込みニューラルネットワークを用いたテクスチャ推定	29
3.1	はじめに	29
3.2	テクスチャ推定システムの全容	30
3.3	提案する CNN	31
3.3.1	入力画像の作成	32
3.3.2	CNN の構造	33

3.4	テクスチャ推定実験	34
3.4.1	実験条件・手順	34
3.4.2	実験結果	35
3.5	まとめ	43
第4章	模擬舌導入に向けたヒトの舌弾性計測	45
4.1	はじめに	45
4.2	等価舌ヤング率計測システムの開発	45
4.2.1	等価舌ヤング率の定義	45
4.2.2	実験システムおよび測定方法	47
4.3	基礎実験	50
4.3.1	ばねのヤング率測定	50
4.3.2	シリコーンのヤング率測定	50
4.4	等価舌ヤング率の計測実験	55
4.4.1	実験条件	55
4.4.2	実験結果	56
4.4.3	考察	56
4.5	まとめ	59
第5章	弾性可変型模擬舌の導入	61
5.1	はじめに	61
5.2	テクスチャ推定システムの全容	62
5.3	弾性可変型模擬舌	63
5.3.1	弾性可変原理	63
5.3.2	プロトタイプによる弾性可変特性の確認	64
5.4	模擬舌を用いたテクスチャ推定	70
5.4.1	実験システム	70
5.4.2	模擬舌の弾性状態に対する圧力分布の相違	72
5.4.3	テクスチャ推定実験	73
5.5	まとめ	81
第6章	結論	83
6.1	まとめ	83
6.2	今後の課題	84

参考文献	87
謝 辞	95
業 績	97

目次

1.1	Nursing-care foods for elderly people.	2
1.2	Texture Profile Analysis ⁶⁾ and Texture Analyser ⁷⁾	2
2.1	The overview of the proposed method. (a) In preparation, reference values of sensory evaluation of gels are obtained from panelists. (b) The pressure distribution of the gel is measured through the artificial mastication. (c) The relationship between the pressure distribution and the value of sensory evaluation is modeled based on the image texture analysis, and the equation for estimating the value of sensory evaluation is derived.	8
2.2	Experimental setup.	9
2.3	Force response of a gel.	10
2.4	Compression and fracture of a representative gel.	12
2.5	Pressure distributions. (a) Gel I, (b) Gel II, and (c) Gel III. From left, initial contact, compression, and fracture.	12
2.6	Feature values with respect to frame number. (a) Energy, (b) Entropy, (c) Inertia, (d) Correlation, and (e) Local homogeneity.	15
2.7	Fracture characteristics of the tested gel foods.	19
2.8	Relationship between values of sensory evaluation n_1 and estimated values \hat{n}_1 in <i>elasticity</i> ($i = 1$).	25
2.9	Relationship between values of sensory evaluation n_2 and estimated values \hat{n}_2 in <i>smoothness</i> ($i = 2$).	25
2.10	Relationship between values of sensory evaluation n_3 and estimated values \hat{n}_3 in <i>stickiness</i> ($i = 3$).	26

2.11	Relationship between values of sensory evaluation n_4 and estimated values \hat{n}_4 in <i>granularity</i> ($i = 4$).	26
2.12	Application software for texture evaluation.	27
3.1	The overview of the proposed method. (a) In preparation, reference values of sensory evaluation of gels are obtained from panelists. (b) The pressure distributions of the gels are measured using artificial mastication. (c) An input image of the CNN is preprocessed. The CNN outputs an estimation of the texture through a sensory evaluation.	31
3.2	Selection of frames of pressure distribution image.	32
3.3	Architecture of CNN.	33
3.4	Examples of input image. (Gel A - Gel L)	37
3.5	Examples of input image. (Gel M - Gel W)	38
3.6	Examples of input image of gel foods with maximum and minimum texture value.	39
3.7	Error with $P = 15$ image.	40
3.8	Error with $P = 2$ image.	40
3.9	Estimation result with $P = 15$ image.	41
3.10	Estimation result with $P = 2$ image.	42
3.11	Coefficients of determination.	43
4.1	Gripper type stiffness sensing.	46
4.2	An overview of experimental system.	48
4.3	Gripper type stiffness sensing system.	49
4.4	Experiment for sensing Young's modulus of a spring.	51
4.5	Experimental results showing Young's modulus of springs with different length.	51
4.6	Experiment for sensing Young's modulus of a silicone.	52
4.7	Experimental results showing pressure of silicones with different thickness.	53
4.8	Experimental results showing Young's modulus of silicones with different thickness.	53
4.9	Explanation of coupling effect.	54

4.10	An overview of experiment.	55
4.11	An experimental result under no muscle contraction.	57
4.12	An experimental result under muscle contraction.	57
4.13	Experimental results of E	59
5.1	Outline of the proposed texture sensing method. (a) In preparation, reference values of sensory evaluation of gels are obtained from panellists. (b) The pressure distribution of the gel is measured using artificial mastication with imitation tongue. (c) The relationship between the pressure distribution and the value of sensory evaluation is modeled based on the image texture analysis, and the equation for estimating the value of sensory evaluation is derived.	62
5.2	Imitation tongue by naked silicone.	65
5.3	Basic principle of variable elasticity type imitation tongue.	65
5.4	Development of the imitation tongue with variable elasticity. (a) Prototype of the imitation tongue. (b) Measurement of the elasticity of the imitation tongue. (c) Measurement of the elasticity of the human tongue.	67
5.5	Prototype of the imitation tongue with different Δs	68
5.6	Relationship between pushing depth Δb , reaction force F , pre-compression Δs , in imitation tongue with and without sheet.	69
5.7	Relationship between pushing depth Δb and reaction force F in human and imitation tongue.	69
5.8	Comparable elasticity between human and imitation tongues.	70
5.9	Experimental system.	71
5.10	Pressure distribution.	72
5.11	Examples of feature values with respect to time (\bullet local maximum, \circ local minimum, $*$ $p < 0.05$, and $**$ $p < 0.01$).	76
5.12	Estimation with relaxed imitation tongue.	78
5.13	Estimation with contracted imitation tongue.	79
5.14	Estimation with rigid base.	80
5.15	Coefficients of determination in different conditions of imitation tongue.	81

表目次

2.1	Values of sensory evaluation n_1 and estimated values \hat{n}_1 in <i>elasticity</i> ($i = 1$).	21
2.2	Values of sensory evaluation n_2 and estimated values \hat{n}_2 in <i>smoothness</i> ($i = 2$).	22
2.3	Values of sensory evaluation n_3 and estimated values \hat{n}_3 in <i>stickiness</i> ($i = 3$).	23
2.4	Values of sensory evaluation n_4 and estimated values \hat{n}_4 in <i>granularity</i> ($i = 4$).	24
4.1	E under no muscle contraction ($\times 10^3$) [Pa].	58
4.2	E under muscle contraction ($\times 10^3$) [Pa].	58
5.1	Constant term and partial regression coefficients.	75

第1章

緒論

1.1 背景

高齢者向けの介護用食品として、食材をあらかじめ細かく切り刻んだ「きざみ食」、柔らかく煮込んだ「やわらか食」、ゼリーやプリンなどのゲル食品やペースト状食品が存在する (Fig. 1.1)。ここでは、舌と口蓋を使って押しつぶすこと (以下、舌式咀嚼と呼ぶ) が可能な水分および栄養補給用のゲル食品に注目する。このような介護食用ゲル食品においては、Quality of Life の観点から、咀嚼・嚥下の安全性と美味しさが高次元で両立することが望まれる¹⁾。美味しさは、食品の化学的性質=味や香りのみでなく、咀嚼・嚥下過程における食品の物理的性質=テクスチャ (舌触り、口溶け、喉越しなど) にも強く依存する^{2),3)}。テクスチャは、機械的特性 (かたさ、もろさ、など) や幾何学的特性 (滑らかさ、ざらつき、など) に分類され^{4),5)}、その評価は、ヒトが試食してアンケート形式で数値化する官能評価試験が基準となるが、時間、コスト、信頼性の問題が懸案となっている。機械的特性に関しては、物理的測定によって食品テクスチャを定量的に評価する手法の開発が試みられており、Fig. 1.2 に示すように、食品圧縮試験から得られる力応答を用いたテクスチャプロファイル法⁶⁾が確立され、測定機器が実用化⁷⁾⁻¹⁰⁾されている。これに対して、幾何学的特性の物理的計測を試みた研究例は存在するものの、ヒトが咀嚼時に受ける繊細な印象と関連付けて食品テクスチャを評価する手法は確立されていないのが現状である。

一方で、従来手法では、剛体プローブや剛体プレートを用いて食品の圧縮・破断操作を行っている点に注意されたい。実際のヒトの舌は柔軟性を有し、食品を咀嚼する際、柔軟物同士の力学的および幾何学的な相互作用を通じて圧縮・破断操作が行われている。このため、剛体のみで構成される機器測定環境と柔軟な舌を用いるヒトの口腔内環境とでは、



Fig. 1.1 Nursing-care foods for elderly people.

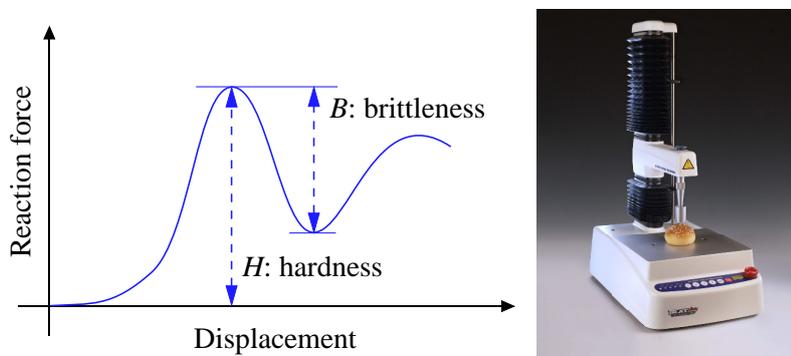


Fig. 1.2 Texture Profile Analysis⁶⁾ and Texture Analyser⁷⁾.

食品の破断状態（破断片の大きさ，広がり方）が大きく異なる恐れがある．したがって，機器測定によるテクスチャ評価結果をヒトの官能評価結果に近づけるためには，直感的に，両者の環境を近づけることが望ましい．さらに，舌の弾性は，舌筋の弛緩状態から収縮状態で大きく変化する点にも注意が必要である．このようなヒトの舌の弾性変化と舌上で感知する繊細なテクスチャとを関連づけて評価する手法は確立されていないのが現状である．

1.2 目的

本研究では，食品テクスチャの客観的・定量的評価手法を確立することを目的とし，従来困難であった「ヒトが舌上で感知する繊細なテクスチャを評価指標として数値で呈示する」ロボットセンシングシステムを提案する．ここでは，舌で押しつぶして喫食することが可能な高齢者向けゲル食品を対象とする．ヒトの舌式咀嚼原理に基づく咀嚼ロボットを開発し，咀嚼中の圧力分布データとテクスチャ官能評価値との関係を表す数理モデルに基

づくテクスチャ推定手法を構築する。さらに、ヒトの舌の弾性変形を考慮した模擬舌を導入し、模擬舌弾性とテクスチャ推定精度との関係を明らかにする。

1.3 論文構成

本論文の構成を以下に示す。

第1章 緒論: 研究背景および研究目的についてまとめ、従来研究との比較から本研究の位置付けについて示す。

第2章 咀嚼圧力分布解析に基づくテクスチャ推定システム: 物理的測定により食品テクスチャを客観的かつ定量的に評価するために、咀嚼ロボットによる食品圧縮・破断中の圧力分布（咀嚼圧力分布）からテクスチャの官能評価値を評価する手法を提案する。圧力分布データに画像テクスチャ解析手法を適用し、算出された特徴量と官能評価値との数理モデルを構築する。複数種類のゲルを用いた実験により、提案手法が、機械的特性および幾何学的特性の両者について高精度に官能評価値を推定できることを確認する。

第3章 畳み込みニューラルネットワークを用いたテクスチャ推定: 畳み込みニューラルネットワーク (CNN) を用いたゲル食品のテクスチャ推定手法について議論する。特徴量の定義自体を CNN の学習により獲得することで、多様な食品テクスチャの推定が期待できる。CNN への入力には圧力分布データを画像として時系列順に複数フレーム結合したものをを用いる。CNN では畳み込み・プーリング層において特徴量の抽出が行われ、続く全結合層において特徴量と官能評価値との数理モデルが構築される。検証実験を行い、提案手法によって第2章の手法では推定が困難であったテクスチャ評価項目にまで対応可能なこと、食品破断時および圧縮終了時の高々2フレームから成る入力画像でテクスチャ推定が可能なことを明らかにする。

第4章 模擬舌導入に向けたヒトの舌弾性計測: 模擬舌の設計と評価に向け、in vivo で舌組織の弾性を評価する計測システムについて議論する。グリップ式弾性計測機構を採用し、舌の厚さ変化に依存することなく評価するために、弾性の評価指標として等価舌ヤング率を導入する。また、筋電位センサを用いた舌筋の収縮状態識別機能を実装する。模擬対象モデルを用いた基礎実験により、適切な接触部を用いれば、対象物の厚さにかかわらず組織の弾性を妥当に評価できることを示す。次に、ヒトの舌に対する計測実験により、等価舌ヤング率を定量的に評価し、舌筋の弛緩時に比べ、収縮時の方が、約4倍弾性が高くなることを示す。

第5章 弾性可変型模擬舌の導入: ヒトの舌の弾性変形を考慮し、舌式咀嚼を人工的に再現するための模擬舌を咀嚼ロボットに導入する。弾性可変機構を有するシリコーン製模擬舌を提案し、製作したプロトタイプによってヒトの舌の弾性を弛緩状態から収縮状態まで再現可能なことを示す。模擬舌を導入した咀嚼ロボットを開発し、模擬舌の弾性状態による圧力分布の違いを示すとともに、テクスチャ推定実験を通じて、テクスチャ評価項目およびゲル食品の種類に応じて、推定精度を向上させるための適切な模擬舌の弾性が存在することを明らかにする。

第6章 結論: 本論文で得られた結果をまとめ、今後の展望について述べる。

1.4 従来研究

1.4.1 食品テクスチャ評価に関する研究

機器を用いた物理測定によって食品のテクスチャを評価する研究として、一般的には、食品を圧縮・破断する際の1軸反力を計測し、その最大値や範囲、周波数などから機械的特性を評価する手法が採用されている^{6),11)}。中でもテクスチャプロファイル法⁶⁾に基づく食品圧縮試験は実用化され、広く食品産業界で用いられている⁷⁾⁻¹⁰⁾。また、ロボティクス技術を駆使したテクスチャ評価に関する研究が行われており、Iwataらはヒトが食品を噛む力を呈示する力覚装置を開発している¹²⁾。Sunらは咀嚼ロボットを開発し、食品咀嚼中の3次元力を測定している¹³⁾。Xuらは咀嚼ロボットで食品を噛むために必要なアクチュエータトルクを評価している¹⁴⁾⁻¹⁸⁾。Meullenetaらは咀嚼ロボットを開発し、食品咀嚼中の顎で測定した力と1軸の圧縮試験機による力を比較・評価している^{19),20)}。これらの研究は力やトルク応答に基づいた機械的特性の評価に対応する。一方、幾何学的特性の評価に向けた研究として、Hoeblerらはパスタ²¹⁾を、Tournierらはパン²²⁾を対象とし、ヒトが咀嚼した後の食品の幾何学的状態(破断片の大きさ、形状、など)を画像解析により評価している。Arvisenetらは人工咀嚼装置を開発し、リンゴ破断片の状態を画像解析により識別している²³⁾。Ishiharaらは、咀嚼による食品の形態変化を評価するために咀嚼後の食品粒度を計測している²⁴⁾。今井らは、口腔内で食品粒子を認識する際の最小粒度および粒子の大きさの識別程度を官能試験によって評価している²⁵⁾。Kohyamaらはクラッカーの水分と咀嚼する際に口腔内で生じる圧力分布との関係について議論している²⁶⁾。また、すり身ゲルおよび羊羹、食パン、人参の咀嚼について口腔内の圧力分布特性について議論している^{27),28)}。Johnsonらは、対象物の3次元形状と大きさを計測できるGelSightセンサを開発し、クッキーの精細な表面形状を検知している

29),30). 以上のように、幾何学的特性の物理的計測を試みた研究例は存在するものの、ヒトが咀嚼時に受ける繊細な印象と関連付けて食品テクスチャを評価する手法は確立されていないのが現状である。また、以上の従来研究では剛体機器が使用されており、ヒトの舌の弾性変形は考慮されていない。実際、神山らのグループは、食品と舌を模倣したゴム状弾性体を重ねた状態で破壊試験を行い、「舌で潰して食べられる食品か、あるいは歯で噛まなくてはならない食品か」を判定可能なことを示している³¹⁾。ただし、舌の弾性は、舌筋の弛緩状態と収縮状態で変化し、さらに年齢や健康状態に依存する可能性がある点に注意されたい³²⁾。このようなヒトの舌の弾性変化と舌上で感知する繊細なテクスチャとを関連づけて評価する手法は確立されていないのが現状である。なお、近年、柔軟性を有するエンドエフェクタを用いて、食品^{33),34)}や生体組織³⁵⁾⁻³⁷⁾などの柔軟対象物をセンシング・マニピュレーションする研究が行なわれているが、テクスチャ評価への適用例は見当たらない。

1.4.2 その他の咀嚼・嚥下ロボットに関する研究

テクスチャ評価以外を目的とする咀嚼ロボットとして、林らは解剖学的構造や生理学的知見に基づいた顎運動の再現を目的とするロボットを開発しており³⁸⁾⁻⁴¹⁾、模擬食品を対象として咬合力を計測している。高西らは顎運動障害についての訓練や咀嚼運動の評価を目的とするロボットの開発に取り組んでいる⁴²⁾⁻⁶²⁾。また、咀嚼中の香気フレーバーの放散を評価するために、模擬歯を有する咀嚼模擬装置の開発が行われており、Wodaらはピーナッツと生ニンジン⁶³⁾、Sallesらはピーナッツやチーズ⁶⁴⁾を対象として咀嚼を試みている。また、小林らは嚥下時の舌の動作を再現している舌ロボットを開発し、コンニャクや粘性液体を飲み込むときの舌の動作についてヒトとの比較を行っている^{65),66)}。水沼らは食塊の嚥下をシミュレーションで再現し、嚥下評価のための舌・咽頭ロボットモデルについて提案している^{67),68)}。

第 2 章

咀嚼圧力分布解析に基づくテクスチャ推定システム

2.1 はじめに

本章では、舌式咀嚼と介護用ゲル食品を対象として取り上げ、機械的特性と幾何学的特性の両者に関して食品テクスチャの客観的・定量的な評価手法を構築することを目的とする。ヒトは舌式咀嚼する際に、食品破断中の形態変化と力応答を同時に感知し、何らかの印象を受けて食品テクスチャを評価している。本章ではこの基本原理を工学的に再現し、咀嚼ロボットを用いて得られる圧力分布に基づく食品テクスチャ推定手法を提案する。

2.2 テクスチャ推定システム

2.2.1 システムの全容

Fig. 2.1 に提案する手法の全容を示す。以下の手順により官能評価値の推定を行う数理モデルを構築する。

【官能評価値の事前準備】 Fig. 2.1(a) に示すように、教師データとして、素材の異なる複数種類のモデリング用ゲル食品の官能評価値を準備しておく。官能評価値は、実際にヒトが舌式咀嚼により試食する官能評価試験により取得する。官能評価値 n_i は、0 - 100 の範囲でテクスチャ評価項目 i (例えば、“もちもち感 : $i = 1$ ”, “つるつる感 : $i = 2$ ”, など) ごとに設定する。

【咀嚼ロボットを用いた圧力分布計測】 Fig. 2.1(b) に示すような咀嚼ロボットを構築する。

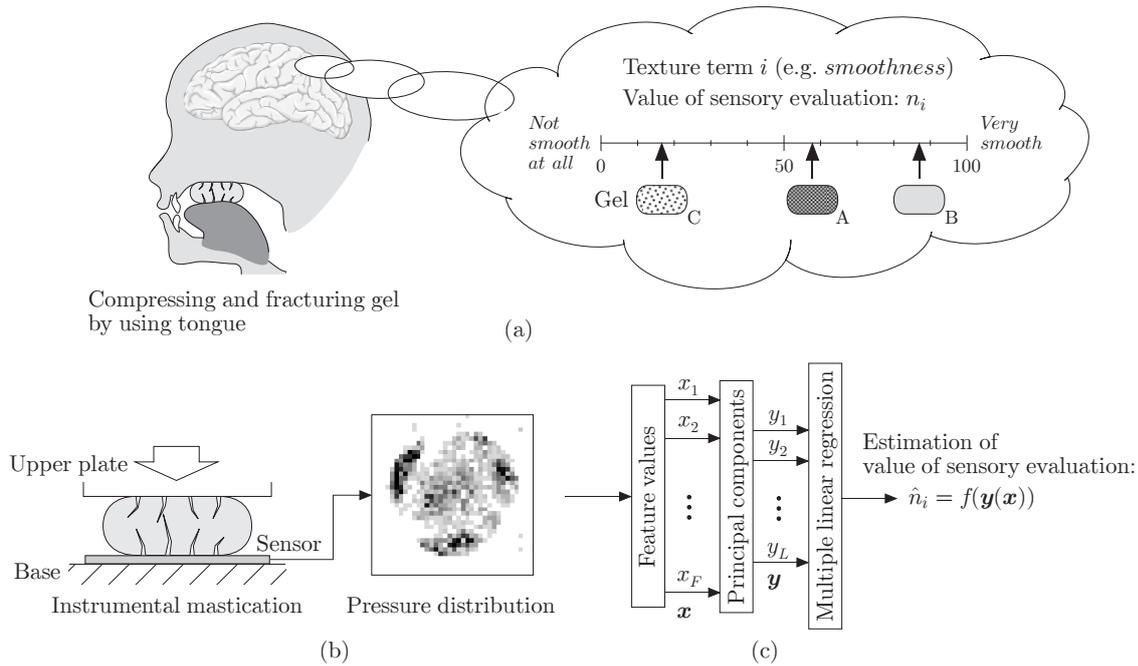


Fig. 2.1 The overview of the proposed method. (a) In preparation, reference values of sensory evaluation of gels are obtained from panelists. (b) The pressure distribution of the gel is measured through the artificial mastication. (c) The relationship between the pressure distribution and the value of sensory evaluation is modeled based on the image texture analysis, and the equation for estimating the value of sensory evaluation is derived.

ヒトは、舌式咀嚼において、舌と口蓋を用いて食品破断中の形態変化と力応答を同時に感知している。この基本原理に基づいて、圧縮用プレートおよび圧力分布センサから構成される咀嚼ロボットを構築する。ゲルの圧縮破断過程における圧力分布を計測することで、咀嚼中の機械的、幾何学的特性の両方に関連する情報を同時に取得することができる。圧力分布は時系列データとして記録し、画像フレームとして扱うことができる。以上のようにして、官能評価値が異なるモデリング用ゲル食品の圧力分布データを収集する。

【テクスチャ推定式の導出】 Fig. 2.1(c) に示すように、圧力分布データと官能評価値との関係を示す数理モデルを作成する。はじめに、圧力分布データ \mathbf{P} に画像テクスチャ解析手法である空間濃度レベル依存法⁶⁹⁾を適用し、特徴量ベクトル \mathbf{x} を算出する。続いて、主成分ベクトル \mathbf{y} を特徴量ベクトルより算出する。最後に、主成分ベクトル \mathbf{y} を説明変数、官能評価値 n_i を目的変数とした重回帰モデルを作成し、テクスチャ推定式 $\hat{n}_i = f_i(\mathbf{y})$ を導出する。なお、重回帰モデルはテクスチャ評価項目 i ごとに作成する。

以上の手順で得たテクスチャ推定式を用いることにより、未知のゲル食品の圧縮・破断時の圧力分布データ \mathbf{P} からテクスチャの官能評価値 n_i を推定することができる。

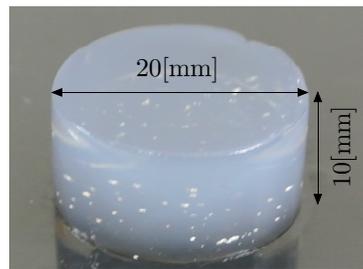
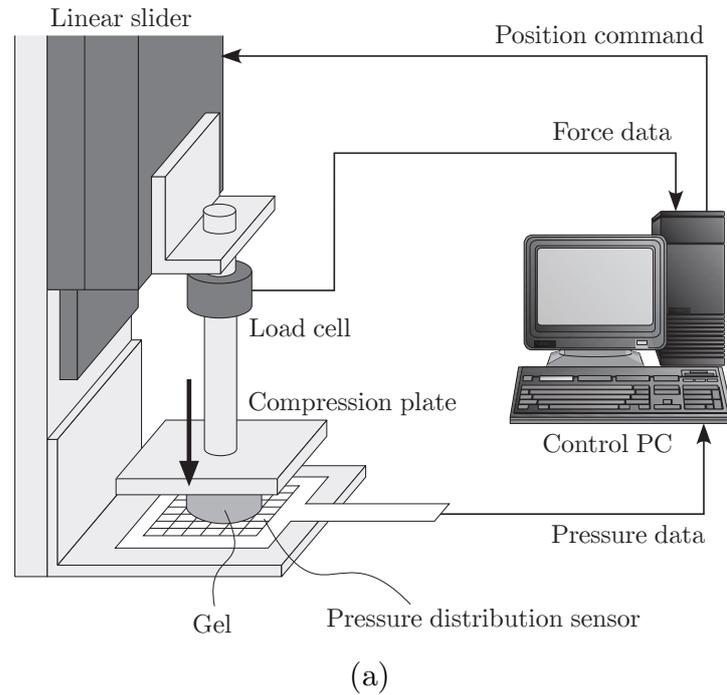


Fig. 2.2 Experimental setup.

詳細は、次節以降に実験データとともに示す。

2.2.2 咀嚼ロボットによる圧力分布測定

2.2.2.1 咀嚼ロボット

Fig. 2.2(a) は人工咀嚼を行う実験システムである。上面プレートは PC により制御されたリニアスライダにより駆動され、下面プレートは土台に固定されている。試験用ゲルは Fig. 2.2(b) に示した直径 20[mm]、高さ 10[mm] の円柱状の形状のものを用いる。試験用ゲルは上面プレートの下降により圧縮・破断される。圧力分布センサ（ニッタ株式会社製：空間分解能 1[mm]、時間分解能 10[ms]、測定範囲 44[mm]×44[mm]、圧力分解能

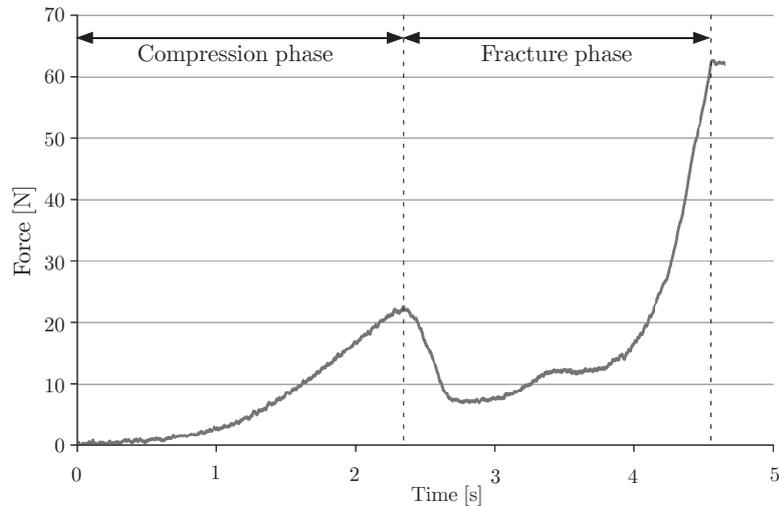


Fig. 2.3 Force response of a gel.

0.2[kPa]) は下面プレート上に設置されている。ゲルが圧縮・破断されている間、圧力分布は時系列データとして記録される。同時に、ゲル圧縮中の力応答がリニアスライダと上面プレートの間に取り付けられたロードセルにより記録されている。以上の計測は上面プレートが圧力分布センサの上方 10[mm] の位置から開始する。プレートは 2[mm/s] の速さで 9[mm] 下降し停止する。試験用ゲルの高さや形状歪みの個体差を考慮し、上面プレートと試験用ゲルの接触開始時間はロードセルの計測値により決定する。

2.2.2.2 圧力分布計測

Fig. 2.3 にロードセルから得た反力応答の一例を示す。ここでは、プレートによってゲルを圧縮するにつれ、反力が上昇する。その後、2.3[s] においてゲルの破断し始め、反力が低下する。プレートとゲルが接触してからゲルの破断開始までの間を圧縮フェーズと定義する。その後もプレートは下降を続けているため、一度低下した反力は再び上昇に転じる。ゲルの破断開始後からプレート停止までの間を破断フェーズと定義する。Fig. 2.4 にゲルの圧縮・破断の様子を示す。

圧力分布センサから得られた圧力値を 0[kPa] から 80[kPa] の範囲で 16 の圧力レベルに変換する。このように変換された圧力分布データは 16 段階の濃度レベルを持つ 44 × 44[pixel] の画像データのフレーム群として取り扱う。Fig. 2.5(a)–(c) に圧力分布の例として 3 種類の異なるゲル食品 I, II, III の圧力分布の画像を示す。Fig. 2.5(a)–(c) には圧縮破断中の特徴的なフレームが示されており、左から圧縮開始直後、圧縮フェーズ中、破

断フェーズ中のものである。画像中の濃いピクセルは高い圧力レベルを示している。左と中央の画像ではセンサと接触しているゲル底面が円形状を保ちつつ圧力が上昇していることが確認できる。続く右の画像ではゲルは破断し、幾何学的状態、機械的状态のいずれについても違いがあることが観察できる。圧力分布を見比べると、ゲル I はゲル II やゲル III と明確に異なるとはいえるものの、ゲル II とゲル III の違いについて圧力分布の見た目から説明することは難しい。

一方で、一連の圧力分布には、ゲル食品が押しつぶされ、ゲル本体およびその破断片が水平面方向に広がっていく情報が含まれており、幾何学的テクスチャに結びつく情報が取得できていると期待できる。ヒトが舌を動かしてテクスチャを評価するためには、押しつぶし動作だけでなく、ゲル食品の表面に沿った方向（水平面方向）にも動かしている。これに対して、提案手法では鉛直方向のみに運動自由度を有し、水平面方向に関する運動自由度や力覚センサを付加せずとも、ゲルが水平面方向に移動することにより、圧力分布センサのみを用いてゲルの変位や速度、摩擦といった情報を獲得することが可能となっている。

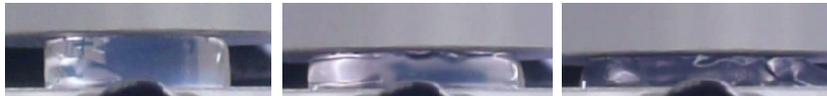


Fig. 2.4 Compression and fracture of a representative gel.

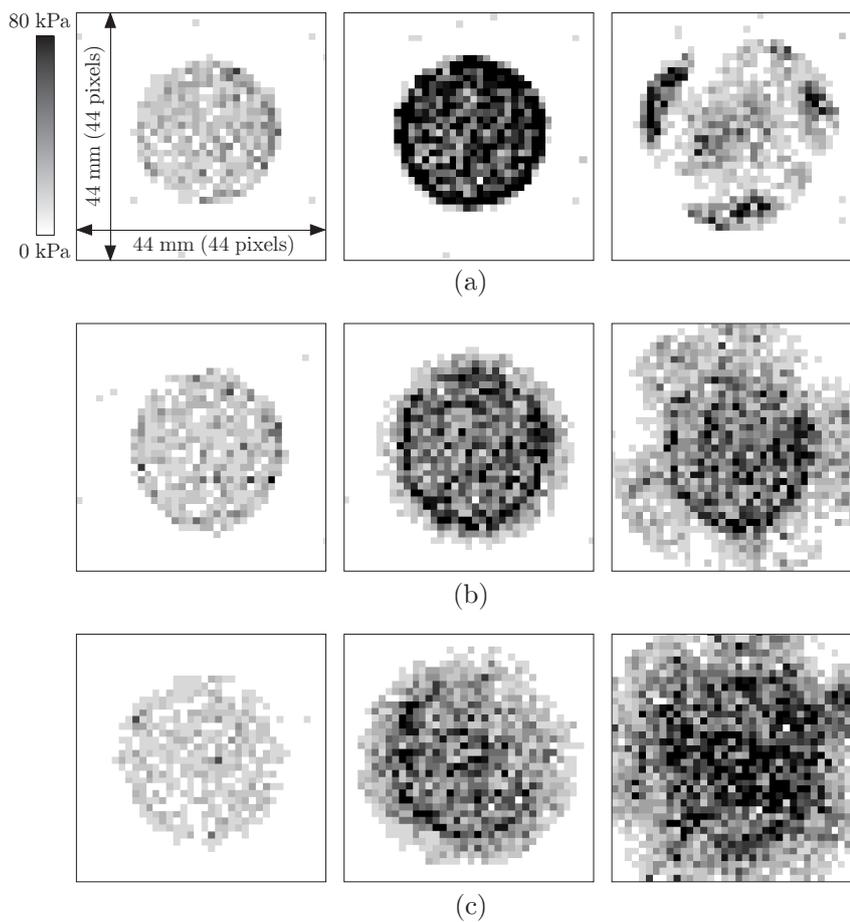


Fig. 2.5 Pressure distributions. (a) Gel I, (b) Gel II, and (c) Gel III. From left, initial contact, compression, and fracture.

2.2.3 テクスチャ推定モデルの作成

2.2.3.1 圧力分布の特徴量算出

空間濃度レベル依存法⁶⁹⁾を用いて、圧力分布から得た画像データの各フレームについてテクスチャ特徴量を算出する。まず、画像データから濃度共起行列を算出する。濃度共起行列とは、画像内におけるピクセル間の濃度関係を表す行列である。 $g(x, y)$ をピクセル (x, y) の濃度レベル、 d, θ をそれぞれ走査距離、走査方向とする。画像内において、相対的な位置関係が (d, θ) で与えられるピクセル対 (x_1, y_1) および (x_2, y_2) について、濃度対が $g(x_1, y_1) = p$ および $g(x_2, y_2) = q$ であるとする。ただし、 $p = \{0, 1, \dots, N-1\}$, $q = \{0, 1, \dots, N-1\}$, N は濃度レベル数である。このとき、濃度共起行列 $\mathbf{S}_{(d,\theta)}$ の第 (p, q) 要素をカウントアップする。画像内の全ピクセルに対して、 (d, θ) に関する走査を行うことにより、濃度対 (p, q) の存在頻度を示す濃度共起行列 $\mathbf{S}_{(d,\theta)} \in \mathfrak{R}^{N \times N}$ が決定する。ここでは、各フレームについて、 $d = 1, 2, 4, 8, 16[\text{pixel}]$, $\theta = 0, 45, 90, 135[\text{deg}]$ を組み合わせた計 20 通りの濃度共起行列 $\mathbf{S}_{(d,\theta)}$ を算出する。ここで、 $\mathbf{S}_{(d,\theta)}$ の各要素 $S_{(d,\theta)}(p, q)$ を、次式で表される確率値 $P_{(d,\theta)}(p, q)$ に変換する。

$$P_{(d,\theta)}(p, q) = \frac{S_{(d,\theta)}(p, q)}{\sum_{p=0}^{N-1} \sum_{q=0}^{N-1} S_{(d,\theta)}(p, q)} \quad (2.1)$$

このようにして得た行列 $\mathbf{P}_{(d,\theta)} \in \mathfrak{R}^{N \times N}$ を、以下に示す式 (2.2)~(2.6) に代入し、5 種類の特徴量として、エネルギー、エントロピー、慣性、相関、局所一様性を算出する。

- エネルギー

$$E \{ \mathbf{P}_{(d,\theta)} \} = \sum_{p=0}^{N-1} \sum_{q=0}^{N-1} \{ P_{(d,\theta)}(p, q) \}^2 \quad (2.2)$$

- エントロピー

$$H \{ \mathbf{P}_{(d,\theta)} \} = - \sum_{p=0}^{N-1} \sum_{q=0}^{N-1} P_{(d,\theta)}(p, q) \log P_{(d,\theta)}(p, q) \quad (2.3)$$

- 慣性

$$I \{ \mathbf{P}_{(d,\theta)} \} = \sum_{p=0}^{N-1} \sum_{q=0}^{N-1} (p - q)^2 P_{(d,\theta)}(p, q) \quad (2.4)$$

- 相関

$$C \{ \mathbf{P}_{(d,\theta)} \} = \frac{\sum_{p=0}^{N-1} \sum_{q=0}^{N-1} pq P_{(d,\theta)}(p, q) - E_x E_y}{D_x D_y} \quad (2.5)$$

- 局所一様性

$$L \{ \mathbf{P}_{(d,\theta)} \} = \sum_{p=0}^{N-1} \sum_{q=0}^{N-1} \frac{P_{(d,\theta)}(p, q)}{1 + (p - q)^2} \quad (2.6)$$

式 (2.5) の E_x, E_y, D_x, D_y は

$$E_x = \sum_{p=0}^{N-1} \left\{ p \sum_{q=0}^{N-1} P_{(d,\theta)}(p, q) \right\} \quad (2.7)$$

$$E_y = \sum_{q=0}^{N-1} \left\{ q \sum_{p=0}^{N-1} P_{(d,\theta)}(p, q) \right\} \quad (2.8)$$

$$D_x^2 = \sum_{p=0}^{N-1} \left\{ (p - E_x)^2 \sum_{q=0}^{N-1} P_{(d,\theta)}(p, q) \right\} \quad (2.9)$$

$$D_y^2 = \sum_{q=0}^{N-1} \left\{ (q - E_y)^2 \sum_{p=0}^{N-1} P_{(d,\theta)}(p, q) \right\} \quad (2.10)$$

である。以上の計算によって、各フレームにつき、濃度共起行列 20 通り × 特徴量 5 種類 = 計 100 種類の特徴量を算出する。Fig. 2.6 に、 $d = 1$ [pixel]、 $\theta = 0$ [deg] の濃度共起行列 $\mathbf{P}_{(d,\theta)}$ から算出された 5 種類の特徴量を示す。ただし、左列が圧縮フェーズ、右列が破断フェーズの間の特徴量である。Fig. 2.6 に示すように、特徴量の値は、フレームごとに時々刻々と変化する。また、テクスチャ評価項目によって、圧縮フェーズで評価される項目、破断フェーズで評価される項目、両方のフェーズで評価される項目が存在するものと想定される。以上を踏まえ、ここでは、圧縮フェーズおよび破断フェーズについて、それぞれのフェーズにおける特徴量の平均値、標準誤差、最大値、最小値、範囲を代表特徴量として採用する。以上より、1 つの食品の圧力分布データに対して、1000 個の代表特徴量を得る。これに圧縮フェーズと破断フェーズのフレーム数を加えた $F = 1002$ 次元の特徴量ベクトル $\mathbf{x} = [x_1, x_2, \dots, x_F]^T \in \mathfrak{R}^F$ を得る。

2.2.3.2 主成分分析による特徴量の絞り込み

特徴量間での高い相関関係を除去するために主成分分析を施し、特徴量ベクトル \mathbf{x} の次元を圧縮する。咀嚼実験から得た圧力分布データの総数を M とし、圧力分布データ

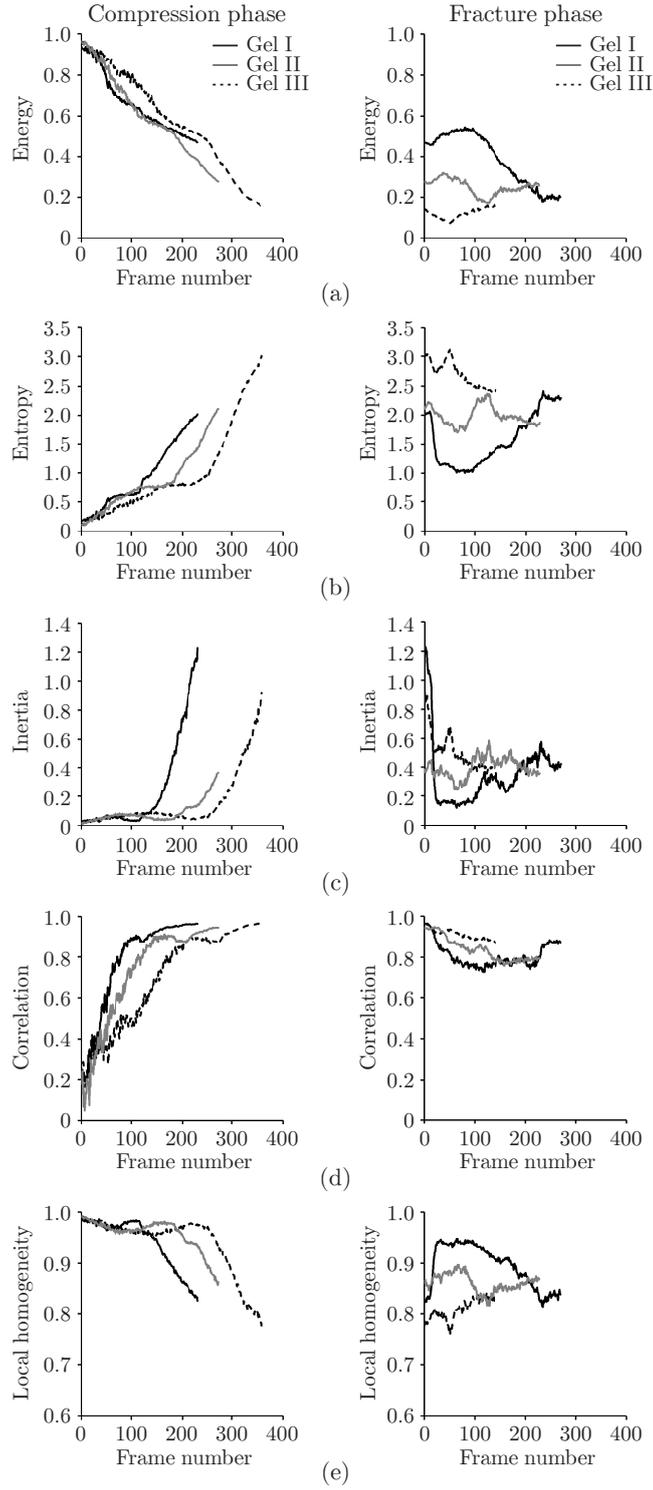


Fig. 2.6 Feature values with respect to frame number. (a) Energy, (b) Entropy, (c) Inertia, (d) Correlation, and (e) Local homogeneity.

m ($m = 1, 2, \dots, M$) から得た特徴量ベクトルを

$$\mathbf{x}_m = [x_{m1}, x_{m2}, \dots, x_{mF}]^T \in \mathfrak{R}^F \quad (2.11)$$

とする. 次式のように, 全特徴量ベクトルを並べた行列 \mathbf{X} を作成する.

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \mathbf{x}_2^T \\ \vdots \\ \mathbf{x}_M^T \end{bmatrix} \in \mathfrak{R}^{M \times F} \quad (2.12)$$

さらに, 次式のような列ベクトル $\boldsymbol{\chi}_j \in \mathfrak{R}^M$ を定める.

$$\mathbf{X} = [\boldsymbol{\chi}_1 \quad \boldsymbol{\chi}_2 \quad \cdots \quad \boldsymbol{\chi}_F] \in \mathfrak{R}^{M \times F} \quad (2.13)$$

次に, 行列 \mathbf{X} の相関係数行列 \mathbf{R} を算出し, 行列 \mathbf{R} の固有値 λ_j ($j = 1, 2, \dots, F$) と大きさ 1 の固有ベクトル \mathbf{u}_j から成る行列 \mathbf{U} を次式のように算出する.

$$\mathbf{R} = \begin{bmatrix} r_{1,1} & r_{1,2} & \cdots & r_{1,F} \\ r_{2,1} & r_{2,2} & & \vdots \\ \vdots & & \ddots & \vdots \\ r_{F,1} & \cdots & \cdots & r_{F,F} \end{bmatrix} \in \mathfrak{R}^{F \times F} \quad (2.14)$$

$$= \mathbf{U} \begin{bmatrix} \lambda_1 & 0 & \cdots & 0 \\ 0 & \ddots & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & \lambda_F \end{bmatrix} \mathbf{U}^{-1} \quad (2.15)$$

$$\mathbf{U} = [\mathbf{u}_1 \quad \mathbf{u}_2 \quad \cdots \quad \mathbf{u}_F] \in \mathfrak{R}^{F \times F} \quad (2.16)$$

ただし, $r_{j,k}$ はベクトル $\boldsymbol{\chi}_j$ ($j = 1, \dots, F$) と $\boldsymbol{\chi}_k$ ($k = 1, \dots, F$) の相関係数を表す. 行列 \mathbf{U} から, $\lambda_j \geq 1$ の固有値に対応する固有ベクトル \mathbf{u}_j を抽出し, 次式の行列 $\mathbf{U}_{\lambda \geq 1} \in \mathfrak{R}^{F \times \mathcal{L}}$ を作成する.

$$\mathbf{U}_{\lambda \geq 1} = [\mathbf{u}_{(1)} \quad \mathbf{u}_{(2)} \quad \cdots \quad \mathbf{u}_{(\mathcal{L})}] \in \mathfrak{R}^{F \times \mathcal{L}} \quad (2.17)$$

ただし, \mathcal{L} は $\lambda_j \geq 1$ を満たす固有値の総数であり, $\mathbf{u}_{(l)}$ ($l = 1, 2, \dots, \mathcal{L}$) は $\lambda_j \geq 1$ を満たす固有値に対応する固有ベクトル \mathbf{u}_j である. 次に, 行列 \mathbf{X} を構成する $\boldsymbol{\chi}_j$ を標準化して, 次のような行列 $\bar{\mathbf{X}}$ を用意する.

$$\bar{\mathbf{X}} = [\bar{\boldsymbol{\chi}}_1 \quad \bar{\boldsymbol{\chi}}_2 \quad \cdots \quad \bar{\boldsymbol{\chi}}_F] \in \mathfrak{R}^{M \times F} \quad (2.18)$$

ただし,

$$\bar{\boldsymbol{\chi}}_j = [\bar{\chi}_{j1}, \bar{\chi}_{j2}, \dots, \bar{\chi}_{jM}]^T \in \mathfrak{R}^M \quad (2.19)$$

$$\bar{\chi}_{j m} = \frac{\chi_{j m} - \mu_j}{\sigma_j} \quad (2.20)$$

$$\mu_j = \frac{1}{M} \sum_{m=1}^M \chi_{j m} \quad (2.21)$$

$$\sigma_j^2 = \frac{1}{M} \sum_{m=1}^M (\mu_j - \chi_{j m})^2 \quad (2.22)$$

最後に, 主成分ベクトルにより構成される行列 \mathbf{Y} を次式のように算出する.

$$\mathbf{Y} = \bar{\mathbf{X}} \mathbf{U}_{\lambda \geq 1} \quad (2.23)$$

$$= \begin{bmatrix} \mathbf{y}_1^T \\ \mathbf{y}_2^T \\ \vdots \\ \mathbf{y}_M^T \end{bmatrix} \in \mathfrak{R}^{M \times \mathcal{L}} \quad (2.24)$$

式 (2.24) 中の \mathbf{y}_m が, 圧力分布データ m に対応する主成分ベクトル

$$\mathbf{y}_m = [y_{m1}, y_{m2}, \dots, y_{m\mathcal{L}}]^T \in \mathfrak{R}^{\mathcal{L}} \quad (2.25)$$

である.

2.2.3.3 重回帰分析による官能評価値推定式の導出

テクスチャ評価項目の総数を K とし, テクスチャ評価項目 i ($i = 1, 2, \dots, K$) の官能評価値を n_i とする. テクスチャ評価項目ごとに, 主成分ベクトル \mathbf{y} を説明変数, 官能評価値 n_i を目的変数として重回帰モデルを作成し, 官能評価値の推定式を獲得する. 主成分ベクトル \mathbf{y} と官能評価値 n_i の関係が, 線形回帰式

$$n_i = a_{i0} + a_{i1}y_{i1} + a_{i2}y_{i2} + \dots + a_{i\mathcal{L}}y_{i\mathcal{L}} \quad (2.26)$$

すなわち,

$$n_i = \mathbf{a}_i^T \begin{bmatrix} 1 \\ \mathbf{y} \end{bmatrix} \quad (2.27)$$

$$\mathbf{a}_i = [a_{i0} \ a_{i1} \ \dots \ a_{i\mathcal{L}}]^T \in \mathfrak{R}^{\mathcal{L}+1} \quad (2.28)$$

で与えられるものと仮定する. ただし, a_{i0} は定数項, a_{il} ($l = 1, 2, \dots, \mathcal{L}$) は各主成分に対する偏回帰係数である. 全ての試験食品データ n_{im} , \mathbf{y}_m ($m = 1, 2, \dots, M$) に式 (2.27)

を適用し，次式を得る．

$$\mathbf{n}_i = \mathbf{Z} \mathbf{a}_i \quad (2.29)$$

ただし，

$$\mathbf{n}_i = [n_{i1} \quad n_{i2} \quad \dots \quad n_{iM}]^T \in \mathfrak{R}^M \quad (2.30)$$

$$\mathbf{Z} = \begin{bmatrix} 1 & \mathbf{y}_1^T \\ \vdots & \vdots \\ 1 & \mathbf{y}_M^T \end{bmatrix} \in \mathfrak{R}^{M \times (\mathcal{L}+1)} \quad (2.31)$$

式 (2.29) より，定数項と偏回帰係数の推定値を次式で算出する．

$$\hat{\mathbf{a}}_i = \mathbf{Z}^\# \mathbf{n}_i \quad (2.32)$$

ただし， $\mathbf{Z}^\# = (\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T$ は \mathbf{Z} の擬似逆行列である．以上の手順により，圧力分布データ m から得た主成分ベクトル \mathbf{y}_m に対するテクスチャ評価項目 i の官能評価値の推定式

$$\hat{n}_{im} = \hat{\mathbf{a}}_i^T \begin{bmatrix} 1 \\ \mathbf{y}_m \end{bmatrix} \quad (2.33)$$

を得る．なお，定数項および偏回帰係数 $a_{il} = 0$ の帰無仮説について検定を行い，危険率 5% 以上の定数項あるいは偏回帰係数項が存在する場合はこれらを除き，再度重回帰分析を行う．この作業を，全ての定数項および偏回帰係数の危険率が 5% 以下になるまで繰り返し，最終的な官能評価値の推定式を決定する．

2.3 テクスチャ推定実験

2.3.1 実験条件・手順

今回，試験食品として，素材や配合の異なる 23 種類のゲル食品 A～W を使用する．Fig. 2.7 にゲル食品 A～W の破断特性を示す．テクスチャ評価項目として，“もちもち感 (*Elasticity*: $i = 1$) ”，“つるつる感 (*Smoothness*: $i = 2$) ”，“ねっとり感 (*Stickiness*: $i = 3$) ”，“ざらざら感 (*Granularity*: $i = 4$) ” の 4 種類を用いる*1．なお，“もちもち感”と“ねっとり感”は機械的特性，“つるつる感”と“ざらざら感”は幾何学的特性に属する．事前に，Visual analog scale 法⁷⁰⁾に基づく官能試験を実施する．Fig. 2.1(a)に

*1 “もちもち感”：破断前の柔らかく伸び，舌を押し返す印象，“つるつる感”：破断前の表面の滑らかさ，“ねっとり感”：破断後の付着して押し広げにくい印象，“ざらざら感”：破断後の表面のざらつき．テクスチャ評価の内容が異なるように例題的に選定した．

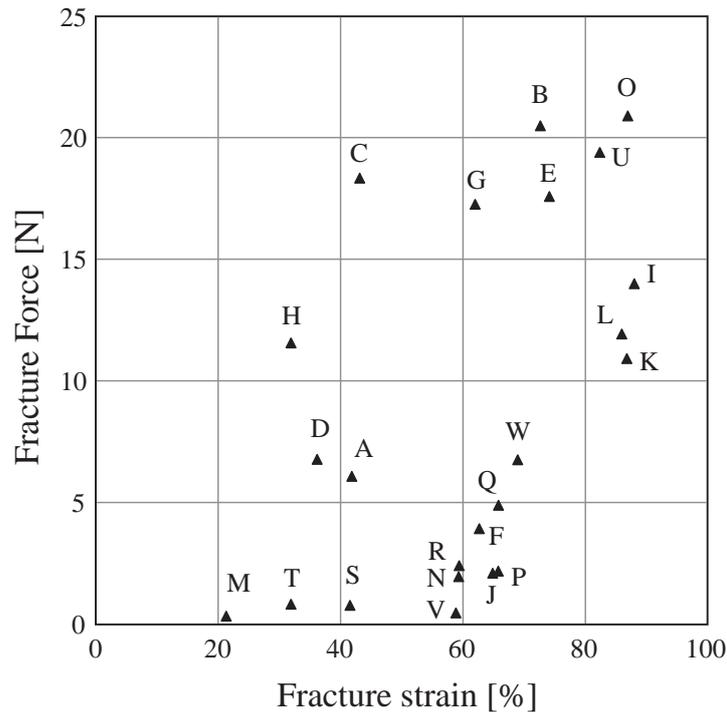


Fig. 2.7 Fracture characteristics of the tested gel foods.

示すように，試験員にテクスチャ評価項目 i ごとに官能評価の度合いをマークする用紙を与える．この用紙には長さ 100[mm] の直線が描かれ，その左端には「全く“テクスチャ”を感じない」，右端には「非常に“テクスチャ”を感じる」と記述してある．試験員は，ゲル食品 A～W について，試食した際に舌上で感じたテクスチャの度合いを直線上にマークする．マークされた位置を 0～100[mm] の整数値として測定し，この値を各ゲル食品の官能評価値とする．今回，試験員 8 名で上記の官能試験を実施した．ただし，試験員は官能評価の基準として，印象の度合いが中央であるゲル食品を試験前に試食する．印象の最小値 0 および最大値 100 の基準については，絶対的基準の提示が困難であることに鑑み，各試験員のゲル食品の喫食経験によるものとした．Table 2.1～Table 2.4 に官能評価試験の統計的結果を示す．2 列目と 3 列目に 4 つのテクスチャ評価項目における平均値と標準偏差，および範囲を示す．4 列目に示した試験員の平均値を官能評価値 n_i とするにあたり，“つるつる感”のみ $41.6 \leq n_{20} \leq 85.5$ と狭い範囲をとることから，今回，“つるつる感”については最大値と最小値が他のテクスチャ評価項目の最大値の平均値，最小値の平均値になるよう n_{20} を線形に換算し， n_2 とする．5 列目に n_2 を示す．

2.3.2 実験結果

圧力分布データは全 138 (ゲル食品 23 種類 × 圧縮試験 6 回ずつ) 個のゲルについて咀嚼ロボットにより取得した。推定には、Leave-one-out 交差検定法 (LOOCV)⁷¹⁾ を用いている。LOOCV とは、全データ数を M 個としたときに、 $M - 1$ 個のデータでモデルを作成、推定式を導出し、モデル化に使用されていない 1 個のデータに対して推定を行う作業を、 M 回繰り返すものである。推定される情報はモデル化には一切使用されていないため、未知の食品に対する推定実験の結果であるとみなせる。

Fig. 2.8~Fig. 2.11 に 4 種類のテクスチャ評価項目について、テクスチャの官能評価値と推定値の関係を示す。具体的な数値として、Table 2.1, Table 2.3, Table 2.4 の 5 列目と 6 列目、Table 2.2 の 6 列目と 7 列目に 4 種類のテクスチャ評価項目における推定値の統計的結果を示す。テクスチャの推定精度を決定係数 R^2 で評価すると、機械的特性である“もちもち感”と“ねっとり感”ではそれぞれ $R^2 = 0.95$, $R^2 = 0.68$ とある程度の精度で推定ができています。一方、幾何学的特性である“つるつる感”と“ざらざら感”はそれぞれ $R^2 = 0.71$, $R^2 = 0.90$ と同程度の精度を示している。テクスチャ評価項目によって推定精度に違いはあるものの、決定係数は $R^2 \geq 0.68$ であり、提案手法により、機械的特性、幾何学的特性の両者について、官能評価値を推定が可能であるといえる。

また、Fig. 2.7 に示した破断特性が近いゲル N とゲル R に注目すると、Fig. 2.9 の■プロットで示すように、幾何学的特性である“つるつる感”について、提案手法が破断特性の近い両者をはっきりと判別できていることが確認できる。この結果は圧力分布を用いる提案手法の有効性を示すものといえる。

Table 2.1 Values of sensory evaluation n_1 and estimated values \hat{n}_1 in *elasticity* ($i = 1$).

Gel	Sensory evaluation		n_1	\hat{n}_1	
	Mean \pm S.D.	Range		Mean \pm S.D.	Range
A	11.8 \pm 10.3	3–35	11.8	9.4 \pm 5.0	3.8–17.4
B	82.0 \pm 8.7	69–90	82.0	72.6 \pm 6.8	59.1–78.1
C	19.5 \pm 17.0	2–43	19.5	26.3 \pm 4.5	18.5–32.3
D	13.0 \pm 11.0	2–36	13.0	12.7 \pm 5.1	7.5–22.0
E	83.9 \pm 14.1	57–95	83.9	80.0 \pm 3.4	75.8–84.8
F	19.8 \pm 12.2	12–48	19.8	20.6 \pm 4.4	13.4–24.9
G	26.4 \pm 20.7	4–65	26.4	30.0 \pm 2.9	26.4–33.6
H	10.1 \pm 10.0	1–31	10.1	5.4 \pm 3.3	2.5–10.9
I	73.6 \pm 16.9	48–95	73.6	75.1 \pm 4.3	69.1–81.3
J	52.1 \pm 19.8	20–81	52.1	52.4 \pm 4.4	46.7–59.8
K	70.4 \pm 21.4	31–94	70.4	70.8 \pm 2.5	66.9–73.1
L	79.0 \pm 12.9	52–91	79.0	78.8 \pm 8.9	73.1–96.5
M	5.0 \pm 4.5	1–12	5.0	11.5 \pm 3.1	7.4–15.2
N	43.4 \pm 21.1	11–68	43.4	52.4 \pm 3.9	47.3–57.1
O	86.1 \pm 7.7	72–95	86.1	87.5 \pm 3.2	82.8–91.8
P	46.4 \pm 20.1	16–69	46.4	39.2 \pm 2.2	36.6–42.1
Q	41.9 \pm 24.2	14–72	41.9	48.5 \pm 3.4	44.2–54.1
R	40.1 \pm 21.0	12–61	40.1	41.2 \pm 4.5	34.3–46.6
S	12.3 \pm 14.9	3–47	12.3	11.6 \pm 1.7	9.8–14.5
T	8.6 \pm 13.4	1–41	8.6	8.1 \pm 7.2	0.0–20.3
U	71.4 \pm 14.4	52–88	71.4	72.0 \pm 5.4	66.7–81.8
V	21.5 \pm 13.7	10–45	21.5	20.6 \pm 4.0	16.0–26.9
W	64.5 \pm 9.5	54–79	64.5	63.3 \pm 5.9	52.4–68.9

Table 2.2 Values of sensory evaluation n_2 and estimated values \hat{n}_2 in *smoothness* ($i = 2$).

Gel	Sensory evaluation		n_{2o}	n_2	\hat{n}_2	
	Mean \pm S.D.	Range			Mean \pm S.D.	Range
A	77.3 \pm 13.5	53–90	77.3	70.7	74.6 \pm 4.3	68.6–79.2
B	72.3 \pm 19.7	41–93	72.3	61.7	64.4 \pm 8.1	51.5–74.3
C	85.1 \pm 15.3	51–97	85.1	85.0	77.9 \pm 9.3	61.6–90.1
D	78.8 \pm 21.2	39–96	78.8	73.5	77.7 \pm 3.8	72.9–84.2
E	50.5 \pm 28.1	5–85	50.5	22.2	29.9 \pm 20.0	–10.4–41.4
F	81.9 \pm 13.1	57–96	81.9	79.1	78.8 \pm 3.2	72.8–81.8
G	85.5 \pm 14.8	54–98	85.5	85.7	91.6 \pm 5.6	83.1–99.1
H	79.4 \pm 23.8	33–99	79.4	74.6	68.3 \pm 6.4	58.3–77.7
I	67.6 \pm 8.9	49–81	67.6	53.3	47.4 \pm 3.4	40.6–50.1
J	80.3 \pm 14.0	51–90	80.3	76.2	50.2 \pm 6.7	39.0–58.5
K	62.3 \pm 25.4	10–88	62.3	43.5	44.0 \pm 4.2	39.0–50.0
L	66.1 \pm 27.0	10–91	66.1	50.6	51.5 \pm 8.8	43.2–67.5
M	41.6 \pm 35.5	6–86	41.6	6.1	29.8 \pm 2.7	25.3–32.9
N	60.3 \pm 27.7	16–90	60.3	39.9	36.6 \pm 3.2	32.4–40.8
O	78.4 \pm 16.7	51–96	78.4	72.8	72.1 \pm 5.5	62.5–77.1
P	59.4 \pm 26.2	9–80	59.4	38.3	49.2 \pm 3.8	42.9–53.5
Q	73.5 \pm 22.2	27–90	73.5	63.9	61.7 \pm 4.8	55.4–70.3
R	74.1 \pm 21.3	33–91	74.1	65.1	57.3 \pm 1.4	55.0–58.8
S	69.0 \pm 27.2	11–92	69.0	55.8	41.5 \pm 4.2	34.8–47.6
T	66.5 \pm 23.7	23–89	66.5	51.2	42.5 \pm 6.3	34.5–50.6
U	76.3 \pm 17.0	41–91	76.3	68.9	66.7 \pm 3.7	60.1–69.9
V	49.1 \pm 16.9	19–73	49.1	19.6	26.1 \pm 5.1	18.7–32.5
W	64.3 \pm 24.6	26–88	64.3	47.2	55.5 \pm 2.6	51.0–58.5

Table 2.3 Values of sensory evaluation n_3 and estimated values \hat{n}_3 in *stickiness* ($i = 3$).

Gel	Sensory evaluation		n_3	\hat{n}_3	
	Mean \pm S.D.	Range		Mean \pm S.D.	Range
A	11.5 \pm 13.0	2–39	11.5	6.6 \pm 4.8	2.4–15.5
B	21.9 \pm 21.7	6–70	21.9	36.2 \pm 3.4	31.8–41.5
C	12.5 \pm 17.2	3–54	12.5	8.8 \pm 4.0	2.6–13.2
D	10.9 \pm 14.9	1–45	10.9	6.6 \pm 2.8	2.6–10.6
E	85.0 \pm 12.2	66–98	85.0	69.4 \pm 25.6	55.8–121.1
F	13.5 \pm 11.5	2–32	13.5	23.3 \pm 1.7	21.6–26.0
G	15.5 \pm 15.6	3–42	15.5	14.5 \pm 4.2	10.8–22.5
H	8.8 \pm 12.9	1–40	8.8	11.7 \pm 10.9	–5.5–25.9
I	64.6 \pm 19.2	23–84	64.6	64.9 \pm 6.2	56.1–74.5
J	29.0 \pm 16.6	6–55	29.0	44.2 \pm 5.3	39.2–52.3
K	72.3 \pm 10.6	58–87	72.3	68.7 \pm 9.7	56.3–84.1
L	66.1 \pm 8.5	50–77	66.1	69.2 \pm 3.4	65.6–75.6
M	10.8 \pm 13.0	1–38	10.8	38.9 \pm 2.1	35.2–40.8
N	65.4 \pm 10.7	49–81	65.4	61.3 \pm 4.1	54.7–66.3
O	23.1 \pm 22.7	1–61	23.1	20.1 \pm 7.4	12.3–29.1
P	29.8 \pm 18.7	8–53	29.8	40.9 \pm 4.6	37.0–49.7
Q	20.3 \pm 14.7	3–45	20.3	24.7 \pm 3.3	20.8–30.5
R	25.1 \pm 15.5	3–51	25.1	32.7 \pm 3.1	28.7–37.0
S	69.9 \pm 8.4	56–83	69.9	33.2 \pm 4.3	28.7–39.7
T	23.6 \pm 22.5	1–67	23.6	29.5 \pm 5.2	24.6–38.8
U	47.8 \pm 18.9	18–67	47.8	47.9 \pm 5.4	41.1–55.1
V	59.6 \pm 17.1	31–81	59.6	48.7 \pm 5.4	41.9–56.1
W	68.6 \pm 16.1	51–87	68.6	58.2 \pm 4.2	52.7–64.6

Table 2.4 Values of sensory evaluation n_4 and estimated values \hat{n}_4 in *granularity* ($i = 4$).

Gel	Sensory evaluation		n_4	\hat{n}_4	
	Mean \pm S.D.	Range		Mean \pm S.D.	Range
A	61.5 \pm 16.8	40–85	61.5	61.5 \pm 4.4	55.4–68.7
B	45.0 \pm 18.5	23–75	45.0	54.2 \pm 3.9	50.3–59.7
C	86.0 \pm 15.4	49–96	86.0	83.7 \pm 3.9	80.3–90.0
D	53.5 \pm 24.7	17–96	53.5	55.5 \pm 1.8	53.1–57.0
E	34.8 \pm 22.0	9–68	34.8	37.0 \pm 11.2	29.3–59.0
F	45.0 \pm 22.7	15–84	45.0	43.4 \pm 2.9	39.5–47.8
G	79.6 \pm 14.9	46–92	79.6	76.8 \pm 2.0	73.9–80.2
H	84.6 \pm 15.0	58–98	84.6	81.8 \pm 5.0	74.4–88.8
I	25.3 \pm 18.9	4–62	25.3	18.7 \pm 2.5	15.9–22.6
J	22.0 \pm 13.6	6–39	22.0	19.9 \pm 4.2	13.4–23.7
K	16.4 \pm 11.7	5–36	16.4	21.2 \pm 3.2	18.1–25.2
L	18.4 \pm 15.4	3–48	18.4	21.5 \pm 2.1	19.1–25.1
M	38.0 \pm 31.0	7–93	38.0	19.9 \pm 2.8	15.4–23.4
N	14.6 \pm 13.2	2–43	14.6	16.5 \pm 2.5	12.7–19.5
O	26.4 \pm 21.3	0–55	26.4	23.6 \pm 3.9	16.6–28.2
P	21.1 \pm 15.0	4–48	21.1	13.6 \pm 0.8	12.6–14.7
Q	39.4 \pm 22.9	2–79	39.4	39.6 \pm 2.1	36.8–42.1
R	18.9 \pm 11.8	6–40	18.9	21.8 \pm 1.9	18.7–23.7
S	4.6 \pm 3.4	1–11	4.6	18.6 \pm 1.2	17.3–20.2
T	8.8 \pm 5.9	1–20	8.8	18.5 \pm 2.5	13.9–21.0
U	37.5 \pm 17.3	18–58	37.5	39.3 \pm 3.8	34.0–42.7
V	9.9 \pm 10.1	3–30	9.9	6.9 \pm 1.6	4.1–8.7
W	35.5 \pm 16.5	16–53	35.5	32.1 \pm 3.2	28.1–35.2

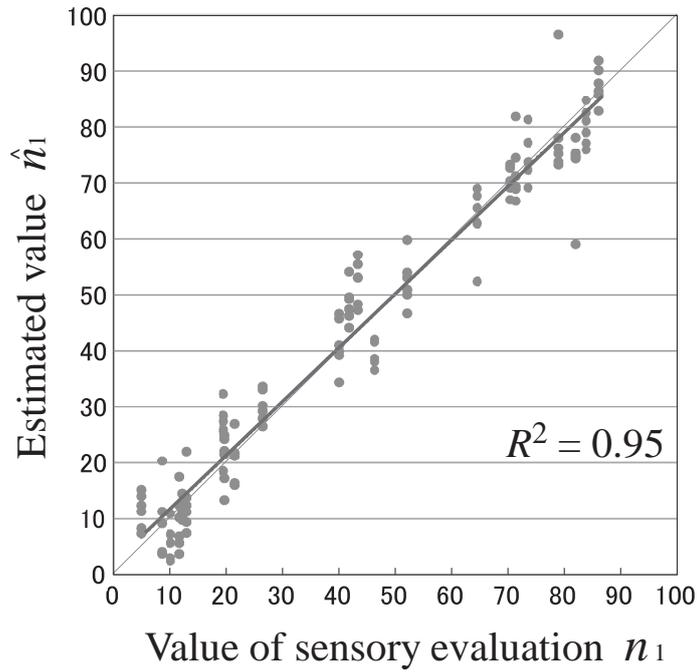


Fig. 2.8 Relationship between values of sensory evaluation n_1 and estimated values \hat{n}_1 in *elasticity* ($i = 1$).

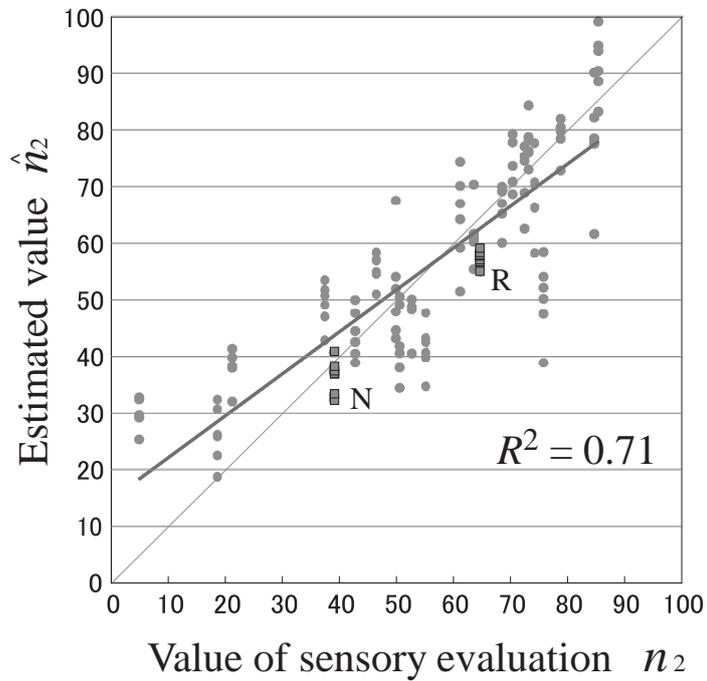


Fig. 2.9 Relationship between values of sensory evaluation n_2 and estimated values \hat{n}_2 in *smoothness* ($i = 2$).

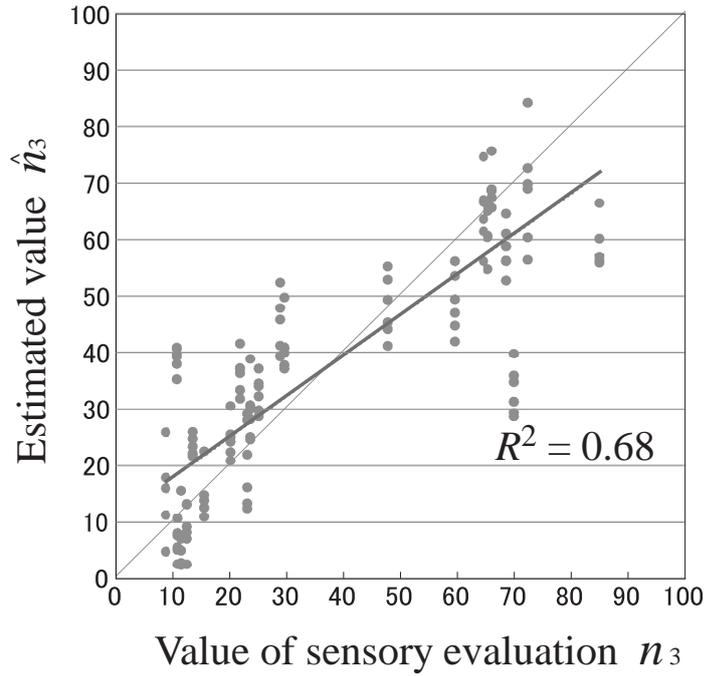


Fig. 2.10 Relationship between values of sensory evaluation n_3 and estimated values \hat{n}_3 in *stickiness* ($i = 3$).

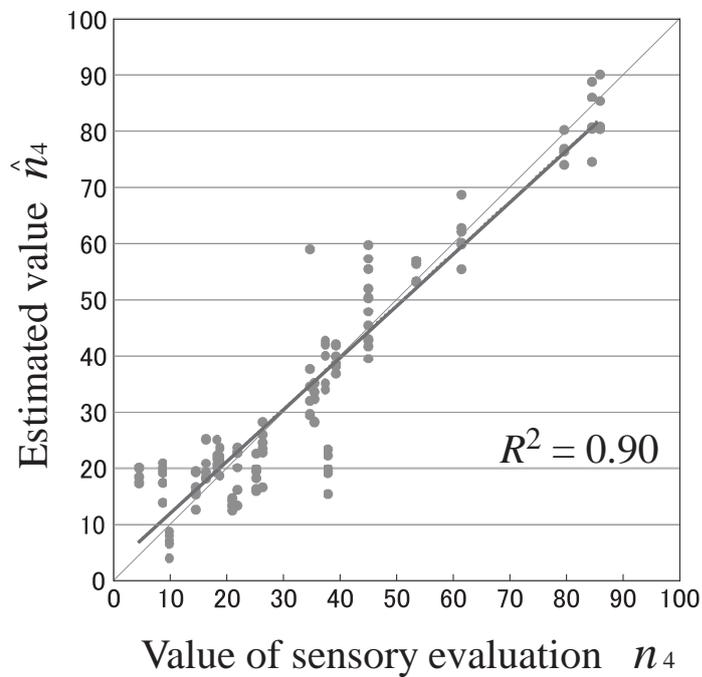


Fig. 2.11 Relationship between values of sensory evaluation n_4 and estimated values \hat{n}_4 in *granularity* ($i = 4$).

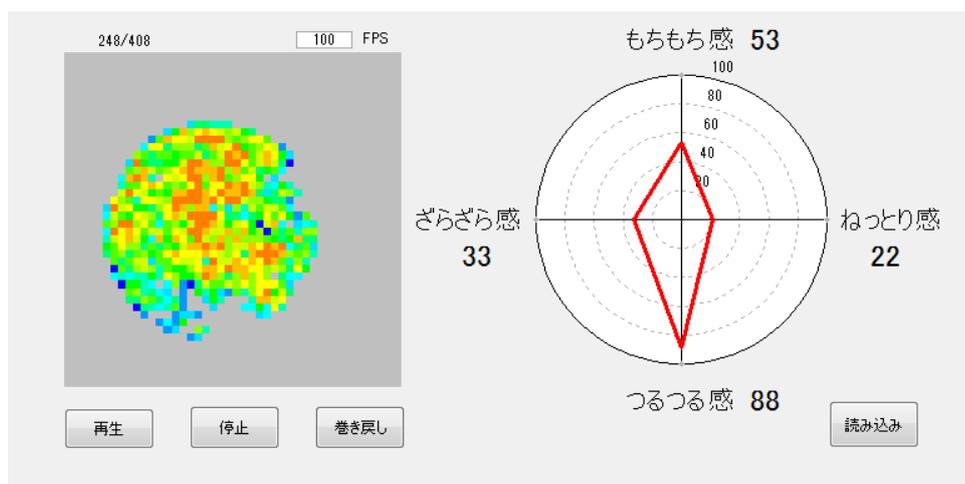


Fig. 2.12 Application software for texture evaluation.

2.4 まとめ

本章では、咀嚼時の圧力分布解析に基づく食品テクスチャ推定手法について議論した。物理的測定により食品テクスチャを客観的かつ定量的に評価するために、圧縮破断中の圧力分布から官能評価値を評価する手法を提案した。ここでは、圧力分布データに画像テクスチャ解析手法を適用して特徴量を算出し、特徴量の主成分と官能評価値との関係について、テクスチャ評価項目ごとに重回帰モデルを作成することで、官能評価値の推定式を導出した。素材と配合の異なる23種類のゲル食品を用いた実験により、提案手法が、機械的特性および幾何学的特性の両者について官能評価値を推定できることを確認した。

Fig. 2.12 は食感評価アプリケーションソフトウェアの実行画面例である。これは、テクスチャ推定モデルを内部に搭載したアプリケーションであり、咀嚼ロボットによって測定したゲル食品の圧力分布データファイルを指定して読み込ませる。画面左側には、一連の圧力分布画像のアニメーションを表示し、画面右側にはテクスチャ評価項目ごとの推定値をレーダーチャートで表示することで、圧力分布とテクスチャを同時かつ視覚的に提示することができる。

第3章

畳み込みニューラルネットワークを用いたテクスチャ推定

3.1 はじめに

前章では、測定平面（食品と圧縮用プレートとの境界面）の圧力分布を画像として取り扱い、空間濃度レベル依存法⁶⁹⁾によって画像内に含まれる画素値の一様性、局所変化、複雑さ、などに対応した特徴量を算出し、これら特徴量から食品のテクスチャを推定する回帰モデルを作成している。このように、従来、食品の状態を示す特徴量はモデル作成者の経験に基づいてあらかじめ定義されてきた。この場合、一般に、モデルの推定性能はどのような特徴量を用いるかによって変化する。また、かたさ、滑らかさ、ねっとりさ、などテクスチャ評価項目は多岐に渡るため、それぞれを評価する際に必要となる特徴量も異なることが予想される。以上のように、繊細かつ多様な食品のテクスチャを推定するための特徴量を、モデル作成者が事前に設計するのは容易ではない。一方で、近年、画像認識技術の分野において畳み込みニューラルネットワーク（Convolutional Neural Network, CNN）が高い成果をあげている⁷²⁾⁻⁷⁶⁾。その大きな特徴は、画像特徴量による推定式のパラメータだけでなく、画像特徴量の定義自体が学習の対象となっていることである。このようなCNNを食品のテクスチャ推定に導入すれば、“モデル作成者の経験・意図に依存することなく多様なテクスチャ評価項目に対応できる”といった観点で汎用性の高い推定モデル作成手法の構築が期待できる。ただし、CNNによって得られる画像特徴量がどのような物理的特性と対応しているのかについて、明確に表現することは一般に困難となる。

本章では、咀嚼圧力分布に関する物理的意味の理解よりも推定性能を優先し、CNNを

用いた食品テクスチャ推定手法を提案する。提案手法は、第2章の手法に準拠し、咀嚼ロボットによる食品圧縮・破断操作、および圧力分布解析に基づくテクスチャ推定処理から構成される。今回、テクスチャ推定精度の向上に向けて、咀嚼ロボットとその制御はそのままに、テクスチャ推定処理のソフトウェア面をCNNの導入により一新する。はじめに、提案するCNNの入出力と構造について示す。人工咀嚼で取得された圧力分布画像を、時系列順に複数フレーム結合することで入力画像を作成する。ここでは、人工咀嚼の全過程から一様に取り出した15フレームから成る入力画像、ならびに、食品破断時および圧縮終了時といった代表的な2フレームのみから成る入力画像、という2種類の入力画像について示す。CNNは、このような入力画像を入力、ヒトのテクスチャ官能評価値を出力とし、7層の畳み込み・プーリング層と2層の全結合層から構成される。畳み込み・プーリング層において圧力分布画像の特徴量を学習する。次に、提案するCNNの検証実験の結果を示す。ここでは、第2章の手法および2種類の入力画像による提案手法を比較し、提案手法によって高精度に食品のテクスチャが推定可能なこと、第2章の手法では推定が困難であったテクスチャ評価項目にまで対応可能なこと、2フレームから成る入力画像で十分に推定可能なことを示す。

3.2 テクスチャ推定システムの全容

提案するテクスチャ推定手法は、第2章に準拠し、テクスチャ官能評価値の事前準備 (Fig. 3.1(a))、咀嚼ロボットによる圧力分布計測 (Fig. 3.1(b))、テクスチャ推定モデルの構築 (Fig. 3.1(c)) から構成される。ただし、Fig. 3.1(c) に示す圧力分布を入力としたテクスチャ推定モデルが一新されている。具体的には、第2章の「空間濃度レベル依存法による特徴量計算」→「主成分分析」→「重回帰モデル」が、提案手法では「入力画像作成」→「CNNモデル」に置き換えられている。概要を以下に示す。

【官能評価値の事前準備 (Fig. 3.1(a))】 教師データとして、素材の異なる複数種類のモデリング用ゲル食品の官能評価値を準備しておく。官能評価値は、実際にヒトが舌式咀嚼により試食する官能評価試験により取得する。官能評価値 n_i は、テクスチャ評価項目 i (例えば、“もちもち感 : $i = 1$ ”, “つるつる感 : $i = 2$ ”, など) ごとに設定する。

【咀嚼ロボットを用いた圧力分布計測 (Fig. 3.1(b))】 ヒトは、舌式咀嚼において、舌と口蓋を用いて食品の形態変化と力応答を同時に感知している。この基本原理に基づいて、土台、圧縮用プレートおよび圧力分布センサから構成される咀嚼ロボットを使用する。この装置を用いて食品を圧縮・破断し、その過程の圧力分布を計測し、画像として保存する。教師データとして、モデリング用ゲル食品の圧力分布画像を収集する。

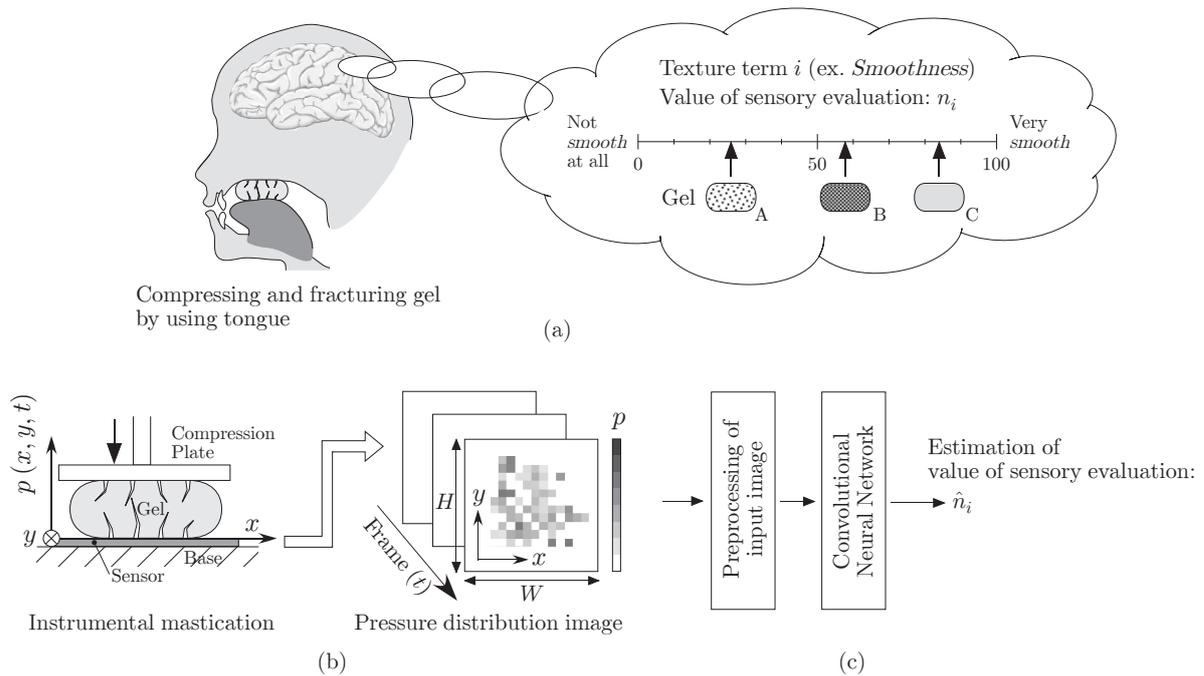


Fig. 3.1 The overview of the proposed method. (a) In preparation, reference values of sensory evaluation of gels are obtained from panelists. (b) The pressure distributions of the gels are measured using artificial mastication. (c) An input image of the CNN is preprocessed. The CNN outputs an estimation of the texture through a sensory evaluation.

【テクスチャ推定モデルの構築 (Fig. 3.1(c))】まず、時系列順の圧力分布画像から複数フレームを抽出、結合することでCNNモデルへの入力画像を作成する。続いて、入力画像に対してテクスチャ官能評価値を出力するCNNモデルを作成する。教師データを用いて、真値 n_i と推定値 \hat{n}_i の誤差が小さくなるよう誤差逆伝播法によるネットワークの学習を行う。

以上の手順で得たテクスチャ推定モデルを用いることにより、ゲル食品の圧縮・破断時の圧力分布画像からテクスチャ官能評価値を推定することができる。

3.3 提案する CNN

本節では、テクスチャ推定部 (Fig. 3.1(c)) について、入力画像の作成処理とCNNの構造の詳細を述べる。

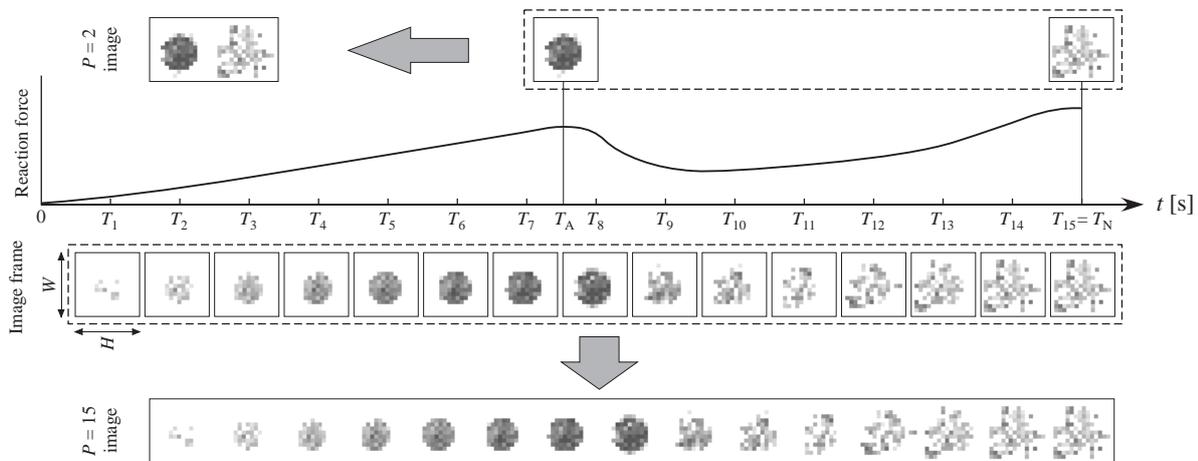


Fig. 3.2 Selection of frames of pressure distribution image.

3.3.1 入力画像の作成

前述の通り，圧力分布データは時系列の画像フレーム群として扱うことができる．これまでに時系列画像，すなわち動画を CNN への入力とする様々な手法が提案されている (77), (78)．Saitoh らは発話内容を動画から認識することを目的として，一連の発話中の画像フレーム群の表現方法として concatenated frame image (CFI) を提案し，CFI を入力とする CNN モデルを用いて発話内容の分類性能を評価している．CFI は発話中の動画から一定の時間間隔でフレームを取り出し，画像的に連結して作成される．このアプローチを参考に，本章では圧力分布画像群より代表するフレームを取り出して一方向連結したものを入力画像とする．ただし，各フレームには値が 0，幅 2 ピクセルの外枠を付与している．これは CNN による画像処理において隣接フレーム間の影響が少なくなることを期待したものである．これにより 1 フレームのサイズは $H \times W = 48 \times 48$ ピクセルとなる．Fig. 3.2 内のグラフは，ゲル食品を圧縮・破断する過程の反力（圧力分布の空間積分）の時間的変化を示している．反力は，圧縮プレートの下降に伴い上昇するものの，ゲルの破断が起きると一旦下降する．このような破断開始時刻を T_A とする．さらに圧縮プレートの下降を続けると反力は再び上昇する．圧縮プレートが停止する時刻を T_N とする．以上のような反力応答に基づき，今回，フレーム数および取り出し方の異なる二種類の入力画像を作成する．一つ目は，Fig. 3.2 下段に示すように，人工咀嚼の全過程から一様に取り

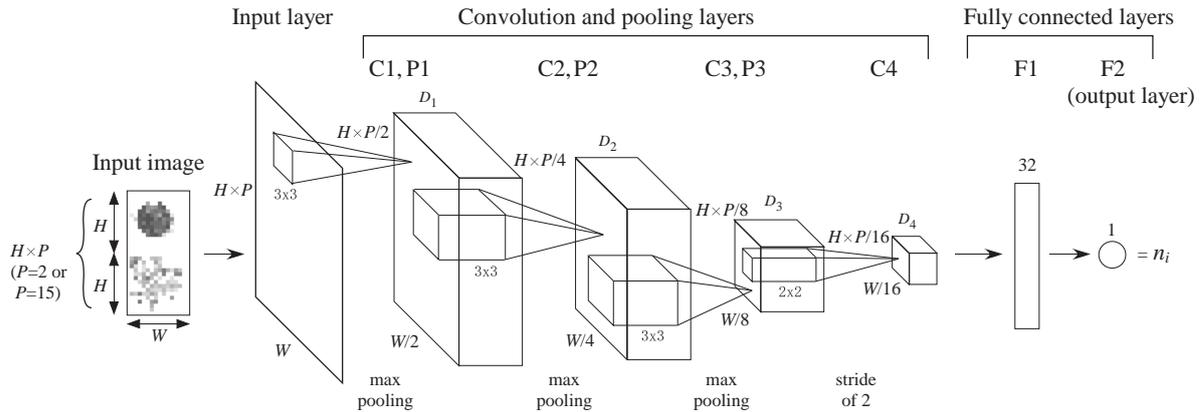


Fig. 3.3 Architecture of CNN.

り出した複数フレーム群から成る入力画像である．ここでは，フレーム数 $P = 15$ とし， $t_i = \frac{T_N}{P}i$ ($i = 1, 2, \dots, P$) における画像を 1 方向に連結したものを入力画像とする．二つ目は，Fig. 3.2 上段に示すように，人工咀嚼中の代表的な 2 フレームのみから成る入力画像である．ここでは，食品破断時 T_A および圧縮終了時 T_N の画像を取り出し，これらを連結したものを入力画像とする． $P = 15$ の入力画像には圧力分布の時間的変化に関する情報が含まれるが， $P = 2$ の入力画像には最小限の情報しか含まれないことに留意されたい．

3.3.2 CNN の構造

従来，様々な CNN モデルが提案され，画像分類問題の精度は大いに改善されてきた^{72)–76)}．今回，使用する CNN モデルは典型的な CNN とされる AlexNet⁷²⁾ に基づいて設計した．Fig. 3.3 に本研究で用いる CNN の構造を示す．今回，簡単化のため，Local Response Normalization は用いていない．また，分類問題ではなく，回帰問題であるため，誤差関数には平均二乗誤差を用いた．CNN の入力は $P = 15$ あるいは $P = 2$ の入力画像，出力はテクスチャ官能評価値である．入力画像のサイズは縦 $H \times P$ ピクセル，横 W ピクセルとなる．CNN は 4 層の畳み込み層，3 層のプーリング層，2 層の全結合層，および出力層をもつ．畳み込み層 C1, C2, C3 にはそれぞれ 3×3 のフィルタが存在し，フィルタを動かすストライドは 1 である．各畳み込み層の後にはそれぞれプーリング層 P1, P2, P3 があり， 2×2 の max-pooling をストライド 2 で行う．畳み込み層 C4 には 2×2 のフィルタが存在し，ストライド 2 で適用する．各畳み込み層のフィルタ数は $D_1 = D_2 = D_3 = 96$ ， $D_4 = 32$ 種類である．全結合層 F1, F2 (出力層) による非線形回

帰モデルによって、テクスチャ官能評価値の推定値 \hat{n}_i が出力される。

3.4 テクスチャ推定実験

本節では、提案する CNN を用いたテクスチャ推定実験について示す。第 2 章の手法の推定結果と比較することにより、提案手法の有効性を確認する。

3.4.1 実験条件・手順

3.4.1.1 官能評価値の事前準備

モデリング用ゲル食品として、第 2 章で使用した、素材や配合の異なる 23 種類のゲル食品 A~W を使用する。

ゲル食品は、第 2 章と同形状の直径 20[mm]、高さ 10[mm] の円柱形とする。テクスチャ評価項目として、“もちもち感 (*Elasticity: i = 1*) ”、“つるつる感 (*Smoothness: i = 2*) ”、“ねっとり感 (*Stickiness: i = 3*) ”、“ざらざら感 (*Granularity: i = 4*) ” の 4 種類を用いる。第 2 章と同様に Visual analog scale 法⁷⁰⁾に基づく官能評価試験によって、0~100 の整数値として各ゲル食品の官能評価値を得る。今回、第 2 章の実験によって得られた、各ゲル食品の官能評価値 n_i を教師データとして用いる。 n_i の詳細は Table 2.1~Table 2.4 を確認されたい。

3.4.1.2 咀嚼ロボットを用いた圧力分布計測

Fig. 3.1(b) のように土台の上にゲル食品を置き、上方からプレートを下ろさせて圧縮・破断操作を行う。プレートはリニアスライダによって動作し、PC によって制御される。土台の上面には、圧力分布センサ（ニッタ株式会社製：空間分解能 1[mm]、時間分解能 10[ms]、測定範囲 44[mm]×44[mm]、圧力分解能 0.2[kPa]）が取り付けられている。今回の圧縮・破断操作は、以下の通りとする。剛体プレートに速度 2[mm/s] の下降動作を与え、ゲル食品の上面と接触した時刻を $t = 0$ [s] とする。そのまま下降動作を継続し、 $t = 4.5$ [s] でプレートを静止させる。なお、 $t = 4.5$ [s] の時点でプレートは土台上面から 1[mm] 上方に位置する。以上の間 ($0 \leq t \leq 4.5$ [s]) の圧力分布を計測し、以下のような処理で圧力分布画像フレーム群として PC に保存する。まず、空間分解能 1[mm]、測定範囲 44×44[mm] に基づき、44×44[pixel] の画像として取り扱う。ここで、各ピクセルの画素値は、測定された 0~45 [kPa] の圧力値を量子化した 0~255 の整数値とする。さらに、画像フレームを連結した際に境界が識別できるように、画素値 0、幅 2 ピクセル

の外枠を画像フレームに付加する。以上により、圧力分布画像 1 フレームのサイズは、 $H \times W = 48 \times 48[\text{pixel}]$ となる。

3.4.1.3 テクスチャ推定モデルの構築

Fig. 3.4, Fig. 3.5 に全 23 種類のゲル食品の $P = 15$ の入力画像および $P = 2$ の入力画像の例を示す。全種類の中で、各テクスチャ評価項目について、官能評価値が最小であるゲル食品の入力画像（上段（min））および最大であるゲル食品の入力画像（下段（max））を Fig. 3.6(a)~(d) に再掲している。ただし、Fig. 3.4~Fig. 3.6 においては、紙面上で視認しやすいように、CNN への入力画像の画素値を 2 倍にした表示用画像を用いている。また、Fig. 3.6(a), (c) の下段、 $P = 2$ の入力画像は、 T_N の画像フレームを二つ結合したものとなっている。これは、当該ゲルにおいて、反力が落ち込むようなゲルの破断が起らなかったため、 $T_A = T_N$ としたためである。

CNN の学習のために、教師データとしてゲル全 23 種類について各種類 6 個ずつ、計 138 個のゲル食品の圧力分布画像を取得する。今回、Leave-one-out 交差検証法⁷¹⁾を行う。モデル作成および推定値の計算手順は以下のとおりとする。全 138 個のデータ（圧力分布画像—官能評価値のセット）から、1 個を未知のデータとして取り除く。ほかの 137 個のデータの圧力分布画像に 4 種類の回転操作（ 0° , 90° , 180° , 270° ）を行い、計 548 個のデータを増やす。この 548 個のデータを用いて CNN モデルを作成し、取り除いた 1 個のデータに対して推定値を算出する。このようなモデル作成と推定を、全 138 個のデータそれぞれについて繰り返す。なお、以上の作業はテクスチャ評価項目 i ごとに行う。CNN の構築および学習は Chainer 1.21.0 を使用する。活性化関数は出力層では恒等関数、それ以外の層では ReLU 関数とし、最適化手法として Adam⁷⁹⁾ を用いる。ミニバッチ学習をバッチサイズ 8 で行い、エポック数は 200 とする。

3.4.2 実験結果

Fig. 3.7 と Fig. 3.8 にそれぞれ $P = 15$ の入力画像および $P = 2$ の入力画像を用いた際の学習による推定誤差の変化を示す。横軸はエポック、縦軸は推定誤差の絶対値の平均値を示している。実線は検証用データ、点線は学習用データによる結果であり、学習を重ねることでいずれも誤差が減少している。また、情報が多い $P = 15$ の入力画像の方が学習が速く進んでいることがわかる。ただし、テクスチャ評価項目によって学習速度は異なることから学習の停止条件を検討することが望ましいと考えられる。Fig. 3.9 と Fig. 3.10 に、4 種類のテクスチャ評価項目について、学習後の官能評価値 n_i と推定値 \hat{n}_i の関係を

示す。ただし、Fig. 3.9は $P = 15$ の入力画像を用いた場合、Fig. 3.10は $P = 2$ の入力画像を用いた場合である。以上の結果と同じ実験データを使用している第2章の推定結果について、テクスチャの推定精度を決定係数 R^2 で評価する。Fig. 3.11にテクスチャ評価項目ごとに上記3条件における決定係数を比較した結果を示す。4つのテクスチャ評価項目における決定係数の平均値 \bar{R}^2 は、提案手法において、 $P = 15$ の入力画像および $P = 2$ の入力画像のいずれの場合でも $\bar{R}^2 = 0.97$ であり、高い推定精度が得られている。4つのテクスチャ評価項目の全てにおいて、第2章の手法を上回る決定係数が得られており、提案手法の有効性が確認できる。とりわけ、テクスチャ評価項目“つるつる感 ($i = 2$)”および“ねっとり感 ($i = 3$)”においては第2章の手法の決定係数が著しく低く、第2章の手法で定義されていた画像特徴量が適切ではなかった可能性が伺える。一方、提案手法では、これらテクスチャ評価項目でも高い決定係数が得られている。これは、CNNによる画像特徴量学習効果が発揮されたためと想定され、多様なテクスチャ評価項目に対応可能という意味で汎用性が向上したものと期待できる。また、提案手法においては、 $P = 15$ の入力画像を用いた場合と $P = 2$ の入力画像を用いた場合で、決定係数に大きな差が見られない。このことから、食品破断時および圧縮終了時の画像フレームにはテクスチャ推定を行う上で十分な情報が含まれていることが想定される。これらを用いれば、高々2フレームの圧力分布画像でテクスチャ推定が可能なのが確認できる。ただし、例えば“ぷるぷる感”（舌の上でゲルが震える印象），“どろどろ感”（ゲルの食塊のどろつき）など速度依存性のあるテクスチャ評価項目を推定するには時間的特徴量が不足することが想定されるため、今回のモデルゲル、テクスチャ評価項目についての結論である点に留意されたい。

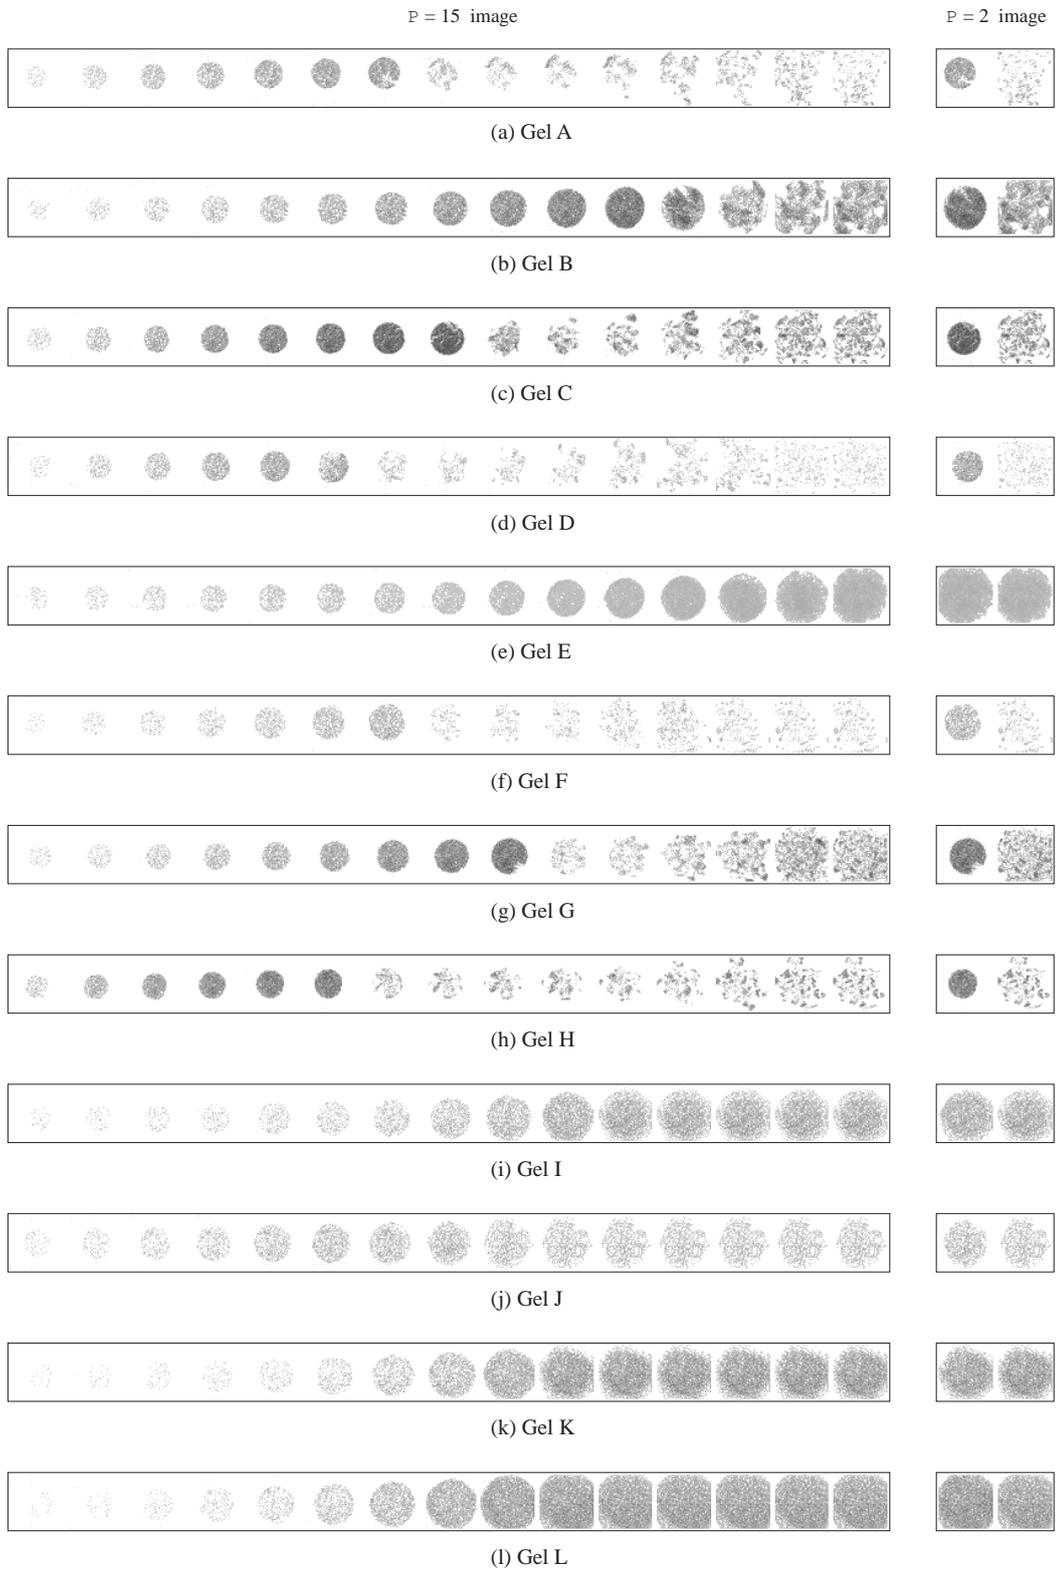


Fig. 3.4 Examples of input image. (Gel A - Gel L)

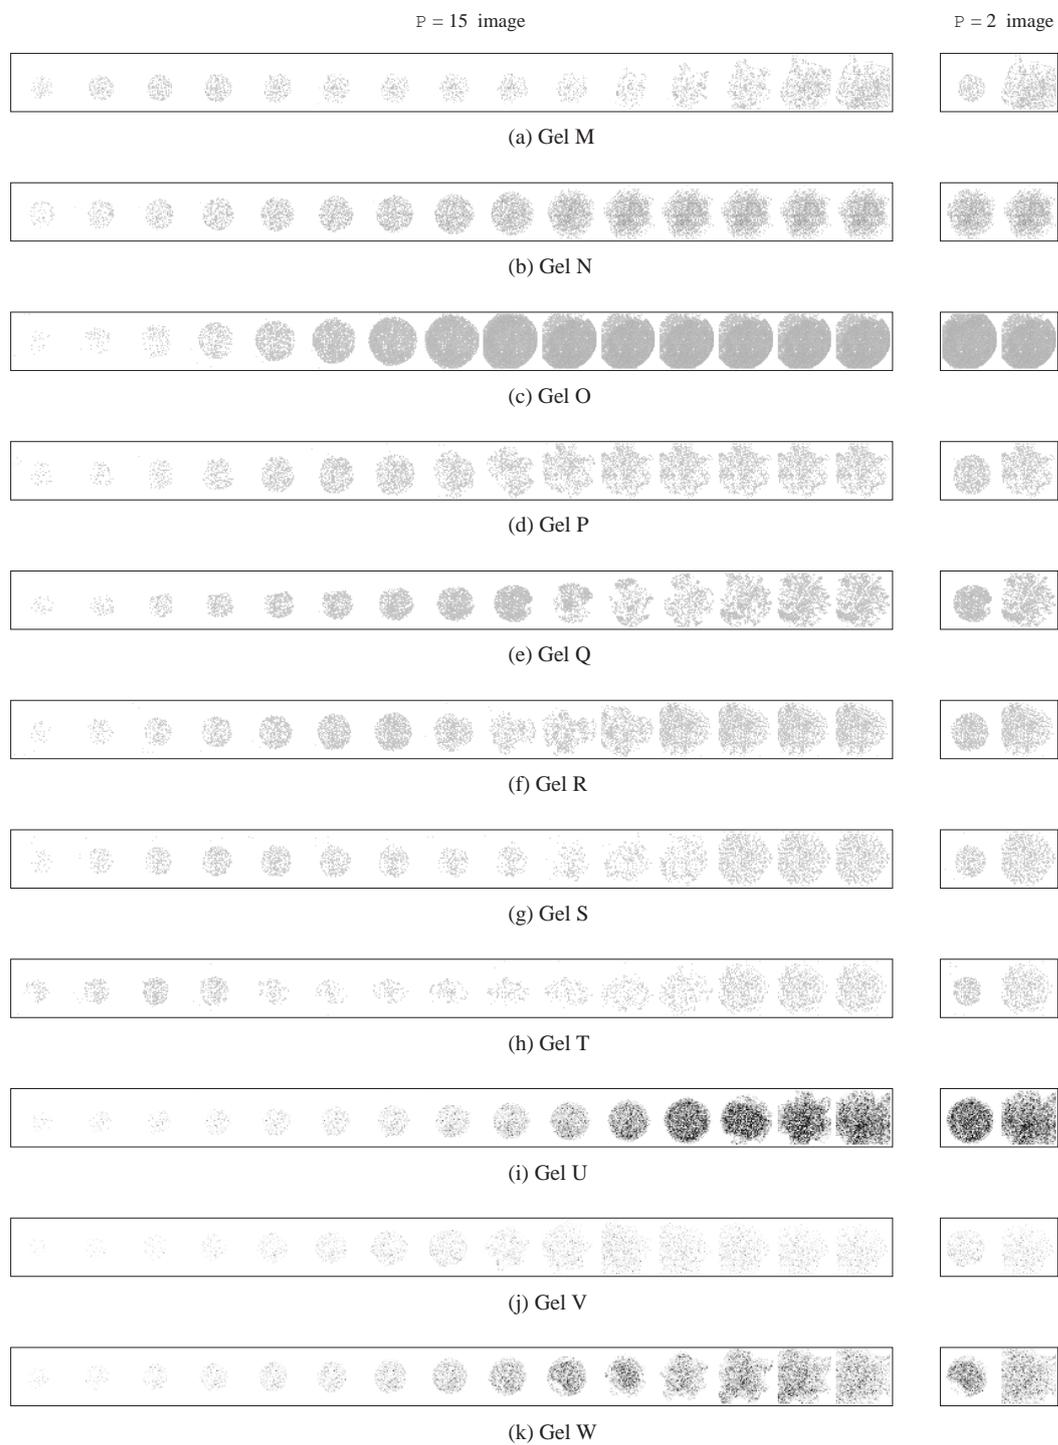


Fig. 3.5 Examples of input image. (Gel M - Gel W)

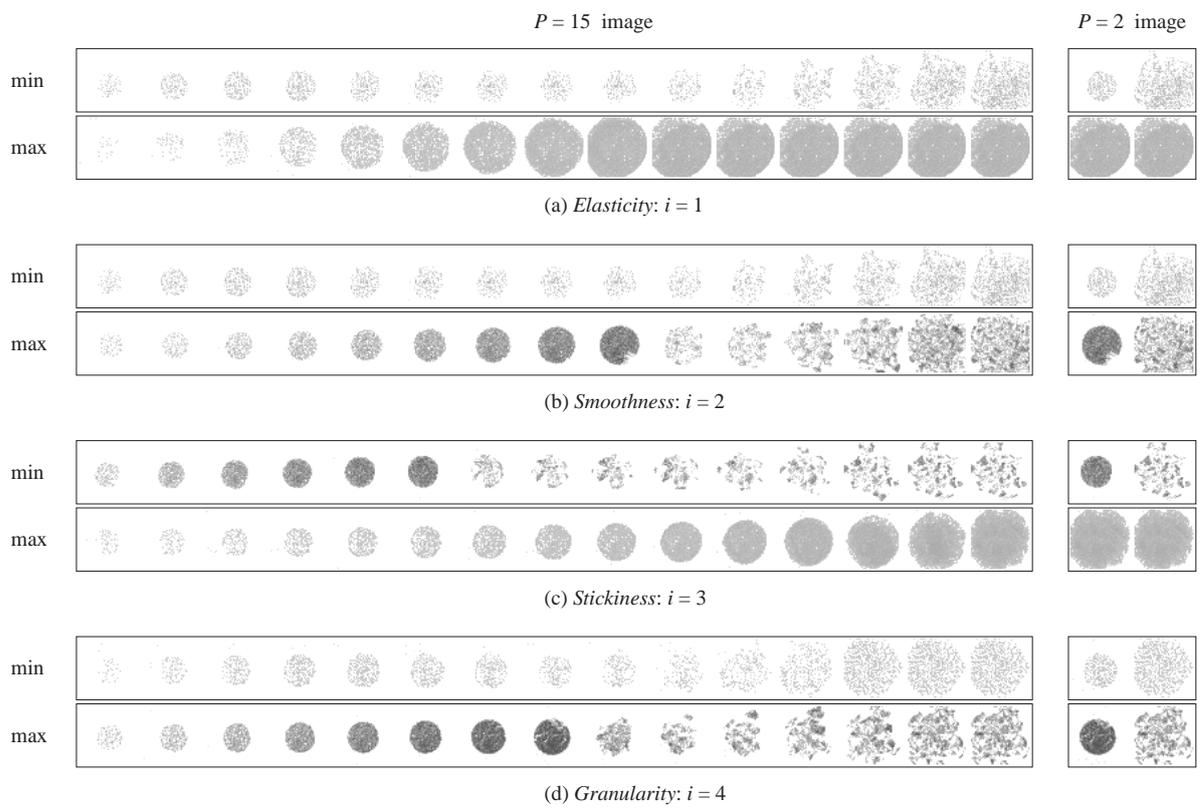


Fig. 3.6 Examples of input image of gel foods with maximum and minimum texture value.

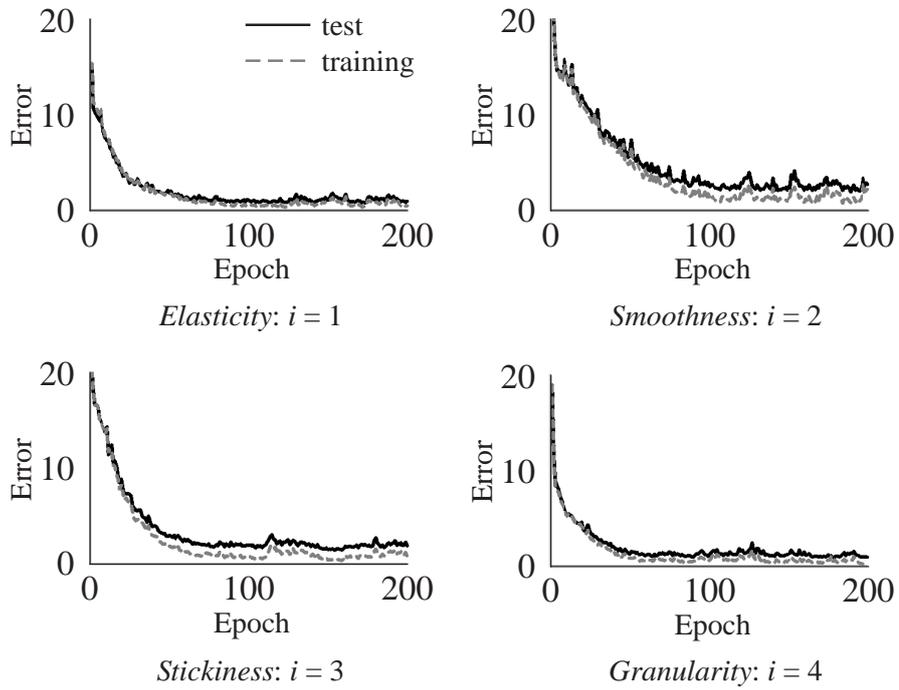


Fig. 3.7 Error with $P = 15$ image.

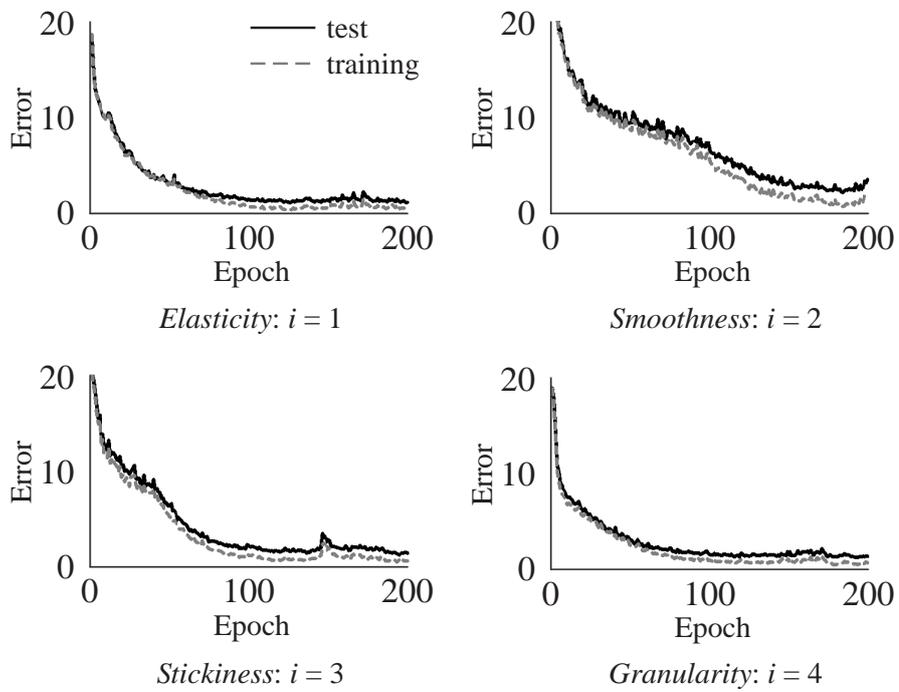
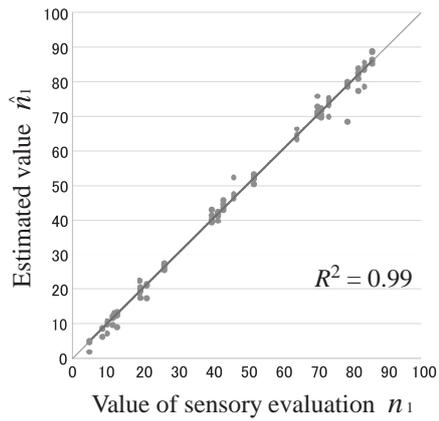
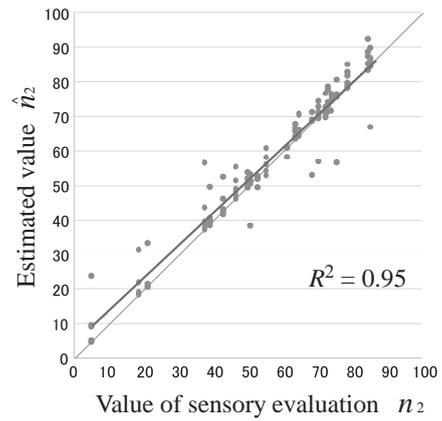


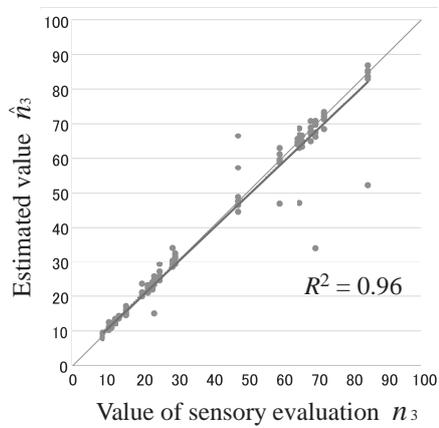
Fig. 3.8 Error with $P = 2$ image.



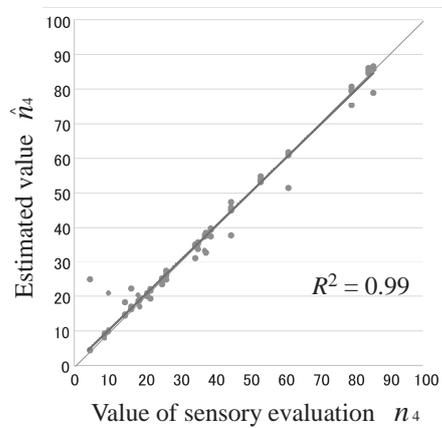
Elasticity: $i = 1$



Smoothness: $i = 2$

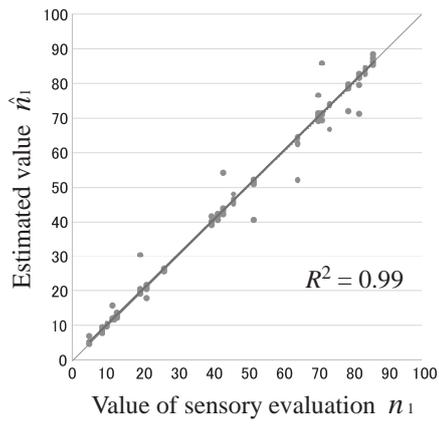


Stickiness: $i = 3$

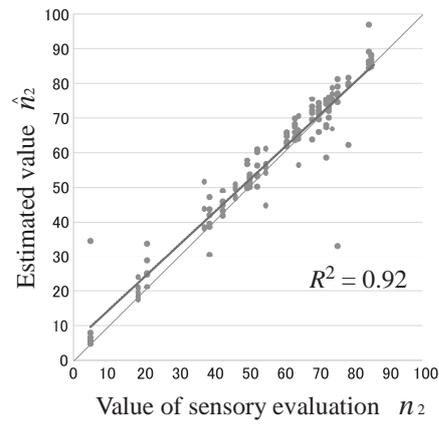


Granularity: $i = 4$

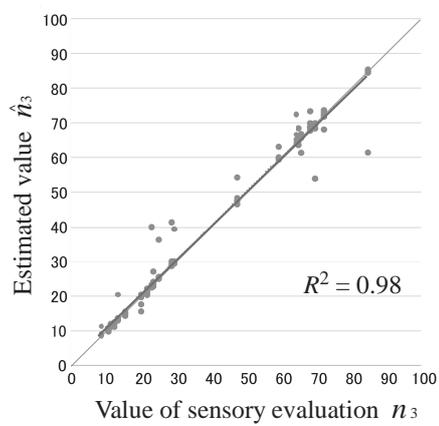
Fig. 3.9 Estimation result with $P = 15$ image.



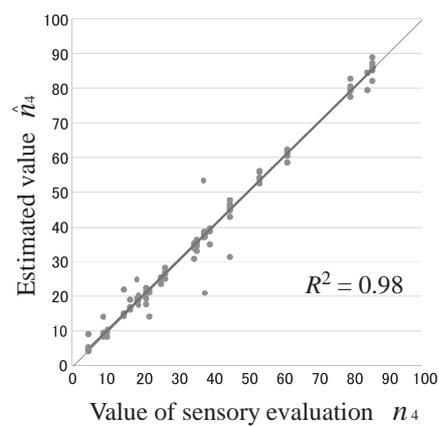
Elasticity: $i = 1$



Smoothness: $i = 2$



Stickiness: $i = 3$



Granularity: $i = 4$

Fig. 3.10 Estimation result with $P = 2$ image.

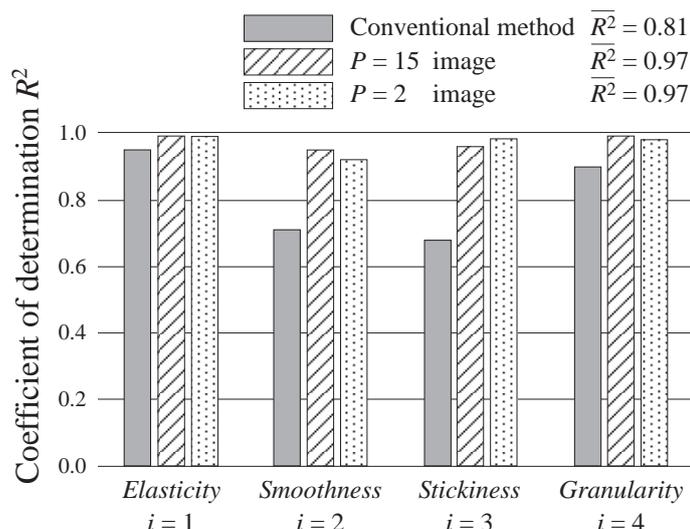


Fig. 3.11 Coefficients of determination.

3.5 まとめ

本章では、畳み込みニューラルネットワークを用いたゲル食品のテクスチャ推定手法について議論した。人工咀嚼によって得た圧力分布画像を入力とし、CNNを用いてテクスチャの官能評価値を推定する手法を提案した。提案手法では、特徴量の定義自体を学習により獲得することで、第2章よりも多様な食品テクスチャの推定を高精度で実現することが期待できる。今回、23種類のゲルおよび4種類のテクスチャ評価項目を用いた検証実験を行い、提案手法によって高精度に食品のテクスチャが推定可能なこと、第2章の手法では推定が困難であったテクスチャ評価項目にまで対応可能なこと、食品破断時および圧縮終了時の2フレームから成る入力画像でテクスチャ推定が可能なることを明らかにした。作成したCNNモデルの利用範囲は、モデル化に用いたゲル食品群と物理的特性およびテクスチャ表現が似通った食品に限定されることに留意されたい。したがって、ゲル食品と特性が全く異なる食品（固形食品、ペースト食品、ゲル・固形・ペースト食品の混合食品）の推定には利用できない。対象食品を適切に絞り、CNNを都度、作成する必要がある。

第4章

模擬舌導入に向けたヒトの舌弾性計測

4.1 はじめに

本章では，咀嚼ロボットへの弾性模擬舌導入に向け，ヒトの舌弾性を計測するシステムについて議論する．生体組織の計測において，他の部位と異なり，舌はその大部分が筋肉で構成されているという特徴を有している．したがって，計測時の外部刺激に対し，被験者が意識的にあるいは，無意識的に舌に力を入れることによって筋収縮が起こり，弾性の計測値に大きな影響を与えてしまうことが予想される．今回，in vivo で舌組織の弾性を評価する計測システムについて，特に，以下の2つのポイント

(1) 対象の厚さに依存することなく，生体組織が有する弾性を評価指標とする

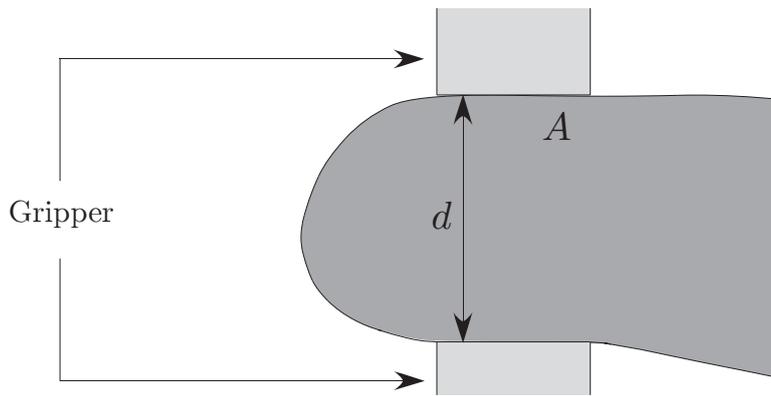
(2) 舌筋の筋電位を測定し，計測中の筋収縮状態を監視する

を導入した舌の弾性計測システムを開発することを目的とする．また，開発した計測システムによって，舌筋の収縮状態によって，どの程度舌組織の弾性が変化するのかを定量的に明らかにする．

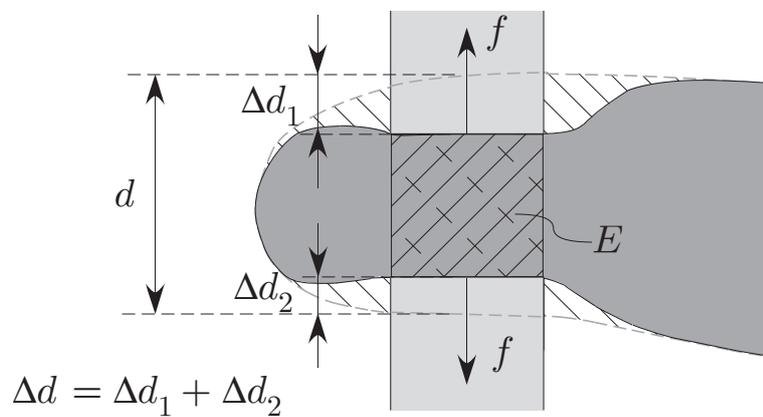
4.2 等価舌ヤング率計測システムの開発

4.2.1 等価舌ヤング率の定義

Fig. 4.1 に，グリッパ式弾性計測系の基本概念図を示す．ここで， A ， d ， Δd ， f は，それぞれグリッパと舌の接触面積，舌の厚さ，舌の変位，接触力である．Fig. 4.1(a) に示す



(a) Initial phase



(b) Gripping phase

Fig. 4.1 Gripper type stiffness sensing.

ように、初期状態として、接触力 $f = 0$ でグリッパと対象が接触しているものとする。ここで、一般に、グリッパによって加えた力 f をそのときの変位 Δd で割った値

$$K = \frac{f}{\Delta d} \quad (4.1)$$

が、弾性の評価指標として用いられることが多い。ただし、この場合、厚さ d を考慮していないため、対象の組織が有する弾性 (単位量あたりの硬さ) を評価できていないことに留意されたい。すなわち、一般に、物質のヤング率 E を考えた場合、

$$f = E \frac{\Delta d}{d} \quad (4.2)$$

であり、式 (4.2) を式 (4.1) へ代入し、次式の関係が成り立つ。

$$K = \frac{E}{d} \quad (4.3)$$

式 (4.3) に示すとおり、 E が同じ場合でも、厚さ d によって K の値は変化する。一方、舌圧は接触面積 A を考慮して、次式で定義されている³²⁾。

$$P = \frac{f(\Delta d)}{A} \quad (4.4)$$

ただし、 $f(\Delta d)$ は対象が Δd だけ変位した際の接触力を表す。この場合も、式 (4.2) より、 Δd が同じ場合でも、 d の値によって f が変化するため、組織の弾性を正当に評価したことにはならない。以上の点から、本章では、次式で表される弾性評価指標 E を定義する。

$$E = \frac{P}{\Delta d/d} \quad (4.5)$$

$$= \frac{fd}{A\Delta d} \quad (4.6)$$

ここで、上記 E は機械力学におけるヤング率そのものであり、 P は従来用いられていた舌圧 (=印加圧) に、 $\Delta d/d$ はひずみに対応する。この E を用いることによって、対象の厚さに依存することなく組織自体が有する弾性を評価することができる。生体部位は単一物質でなく、多様な細胞組織によって構成されることを踏まえ、本章では、上記 E を等価舌ヤング率と称することにする。

4.2.2 実験システムおよび測定方法

Fig. 4.2 に、実験システムの概要を示す。本システムは、グリッパ式弾性計測系と筋電位計測系から構成される。

4.2.2.1 等価舌ヤング率の測定

等価舌ヤング率の計測には、Fig. 4.3 に示すグリッパ式弾性計測装置を用いる。対象物をグリッパで挟み込むことで、弾性を計測する。リニア式エンコーダ (Fig. 4.3(b)) と力センサ (Fig. 4.3(c)) が内蔵されており、リニア式エンコーダで舌の厚さ d とプローブを押し当てた際の舌の変位 Δd を、力センサで対象との接触力 f をそれぞれ計測することができる。これらの計測パラメータ $d, \Delta d, f$ を A/D ボードおよびエンコーダカウンタボードを経由して PC へ送信し、接触面積 A を用いて、式 (4.6) の等価舌ヤング率 E を算出することができる。

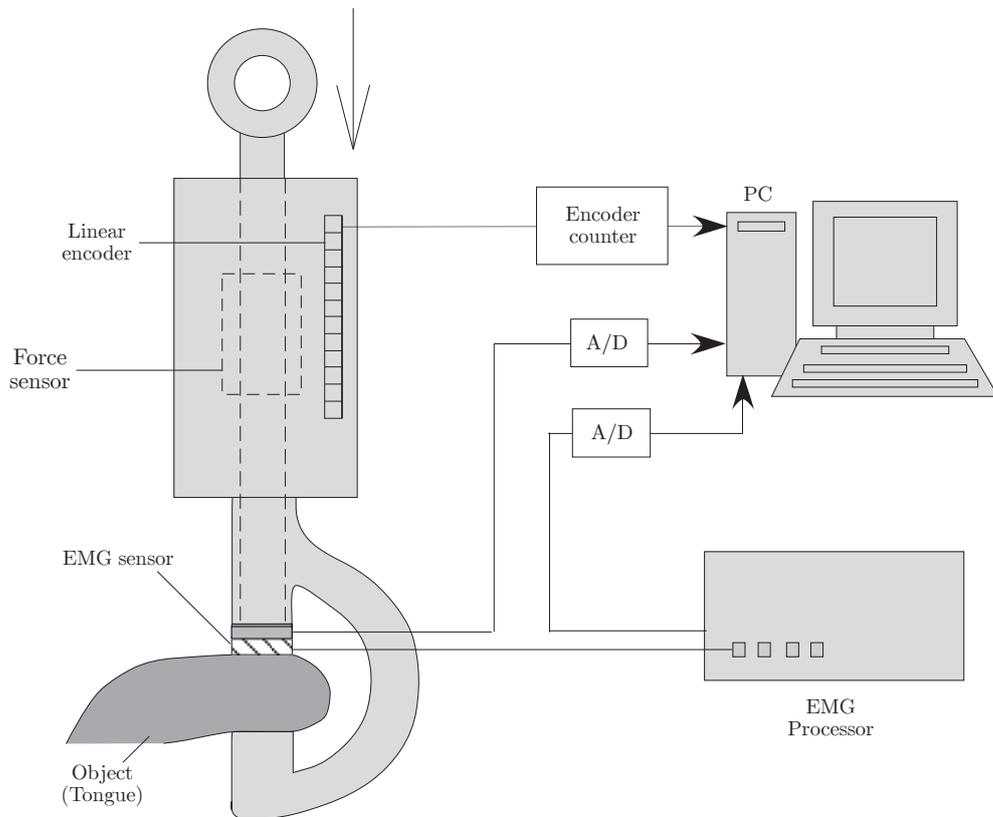


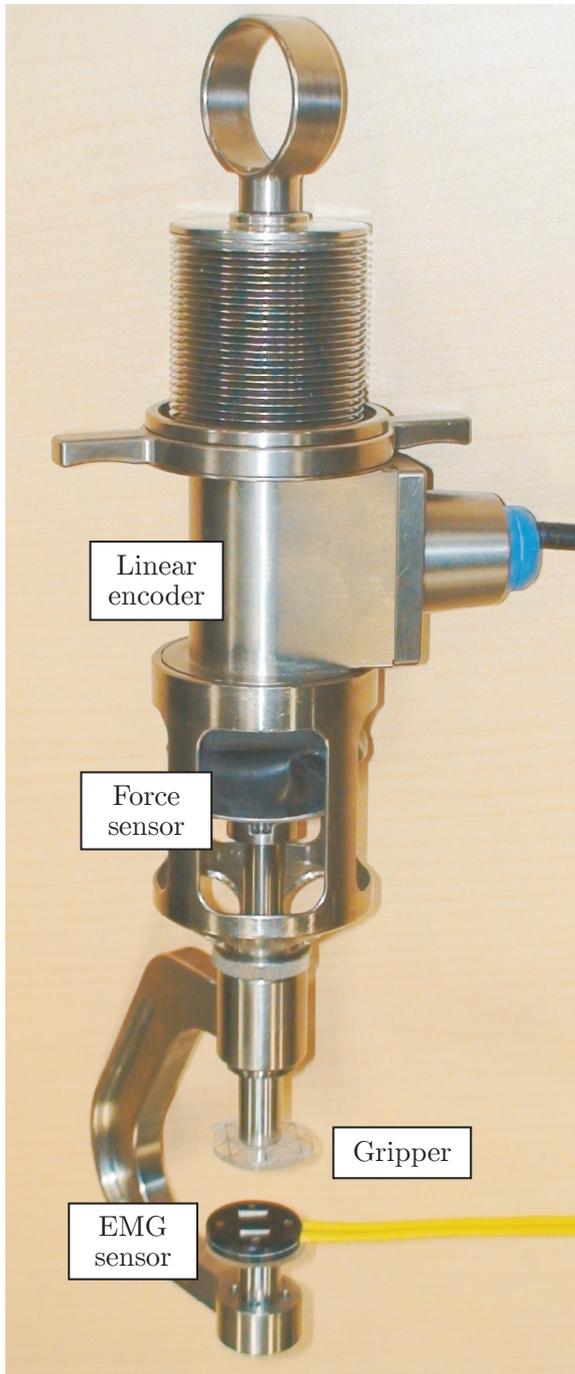
Fig. 4.2 An overview of experimental system.

4.2.2.2 筋収縮識別機能

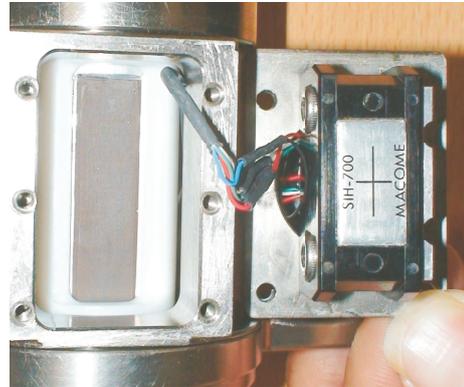
グリップにより舌を挟んだ際、被験者が意識的に、あるいは無意識的（反射的）に舌に力を入れてしまう場合がある。力を入れると筋収縮が起こり、弾性評価値が変化することが予想される。したがって、生体組織の弾性を評価する上での条件にばらつきが出てしまう。この点を踏まえ、本システムでは、筋電位センサを用いた筋収縮状態の識別機能を導入する。前節で示した弾性計測系グリップの先端に、筋電位センサ (Fig. 4.3(d)) を装着し、等価舌ヤング率を測定中の舌の筋電位信号を検出する。ここで得られた測定中の舌筋電位 G から、次式に基づき舌筋の収縮状態を判別する。

$$\begin{cases} \text{No contraction} & (G \leq G_0) \\ \text{Contraction} & (G \geq G_0) \end{cases} \quad (4.7)$$

ここで、 G_0 は弛緩/収縮を判別する閾値である。式 (4.7) によって被験者の意思に関係なく、舌筋の収縮状態を監視することができ、計測条件を統一することができる。



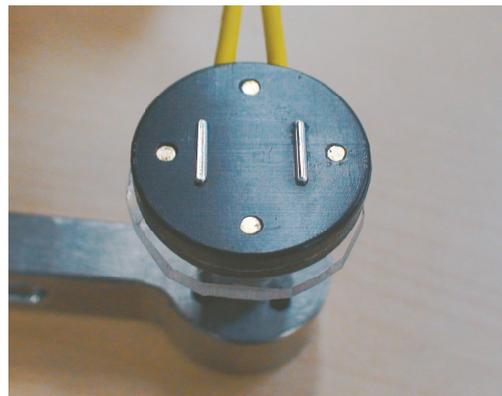
(a) Overview



(b) Linear encoder



(c) Force sensor



(d) EMG sensor

Fig. 4.3 Gripper type stiffness sensing system.

4.3 基礎実験

本章では、弾性計測系の基本特性を検証するための基礎実験について示す。

4.3.1 ばねのヤング率測定

Fig. 4.4 に示すように、同一素材でできた押しばねのヤング率を計測する。Fig. 4.5 に、ばねの長さを $d = 7.2, 13.1, 20.3, 28.5$ [mm] と変えたときのヤング率 E の測定結果と、すべての長さにおける E の平均値を示す。ただし、各長さのばねに対して、それぞれ5回ずつの測定を行っている。同一素材のため、理想的には長さ d が変化してもヤング率は同一となる。Fig. 4.5 から、長さ d が変化しても、平均誤差 17 % 以下で E が測定できることがわかる。

4.3.2 シリコンのヤング率測定

4.3.2.1 実験結果

Fig. 4.6(a) に示すように、同一材質で生成されたシリコンのヤング率を測定する。ここで、シリコンの厚さを $d = 5, 9, 15, 20$ [mm] と変えたときのヤング率 E を測定する。グリッパとの接触面積は円形とし、半径 $r = 2, 5, 11$ [mm] と変化させることによって、接触面積の大きさが測定結果にどのような影響を与えるのかを考察する。なお、Fig. 4.6(b), (c) に示すように、シリコン全体の大きさは、グリッパとの接触部より十分大きい $a = 65$ [mm], $b = 115$ [mm] であり、押し込み量は $\Delta d = 2$ [mm] とする。

Fig. 4.7, 4.8 に、それぞれ圧力 P , ヤング率 E の測定結果を示す。Fig. 4.7 から、グリッパ半径 $r = 2, 5, 11$ [mm] における測定において、シリコン厚さ d が増加すると、 $d = 20$ [mm] を除いて P が減少することがわかる。これは、式 (4.2) より、厚さ d が大きくなるにつれて、接触力 f の測定値が減少し、結果的に P の値も減少してしまうからである。 $d = 15$ [mm] から $d = 20$ [mm] にかけては、相対的に低ひずみ域であり、シリコンの応力-ひずみ特性における非線形性により、 P の減少幅は小さくなると考えられる。そのため、同一材質から生成した $d = 15$ [mm] と $d = 20$ [mm] の個体差の影響によりほぼ同じ P の値となった可能性がある。一方、Fig. 4.8 より、 $r = 5, 11$ [mm] の場合、 d の増加に対する E の上昇は現れず、ほぼ一定の値が計測できている。これにより、対象物の厚さ d に依存せず、組織が有する弾性を評価できていることがわかる。以上から、 E によって厚さ方向の弾性成分が正当に評価されていると期待できる。Fig. 4.8 は、従来議論され

ることのなかったグリップ接触面積と計測値の関係について示しており、接触面積が、組織が有する弾性を評価する上で注意すべき要因となっていることを示している。

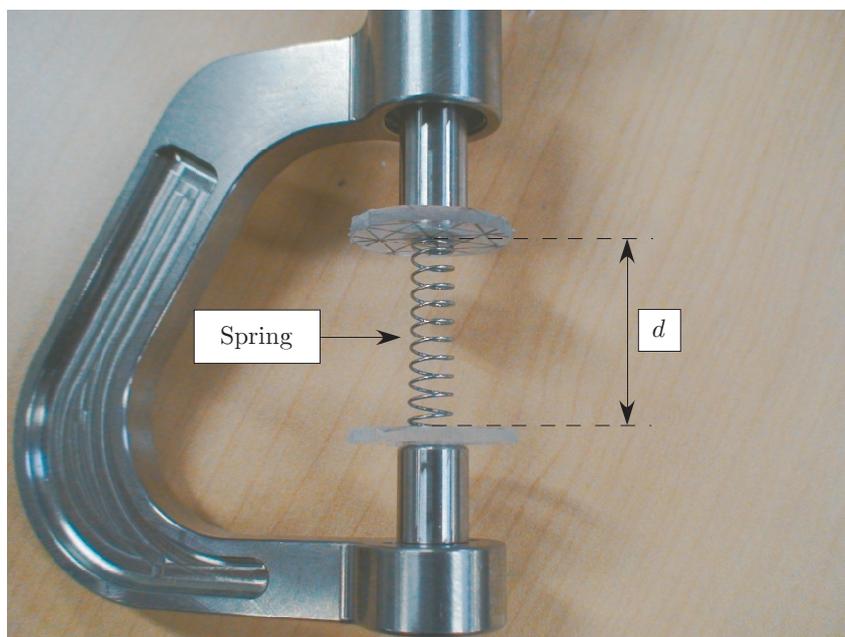


Fig. 4.4 Experiment for sensing Young's modulus of a spring.

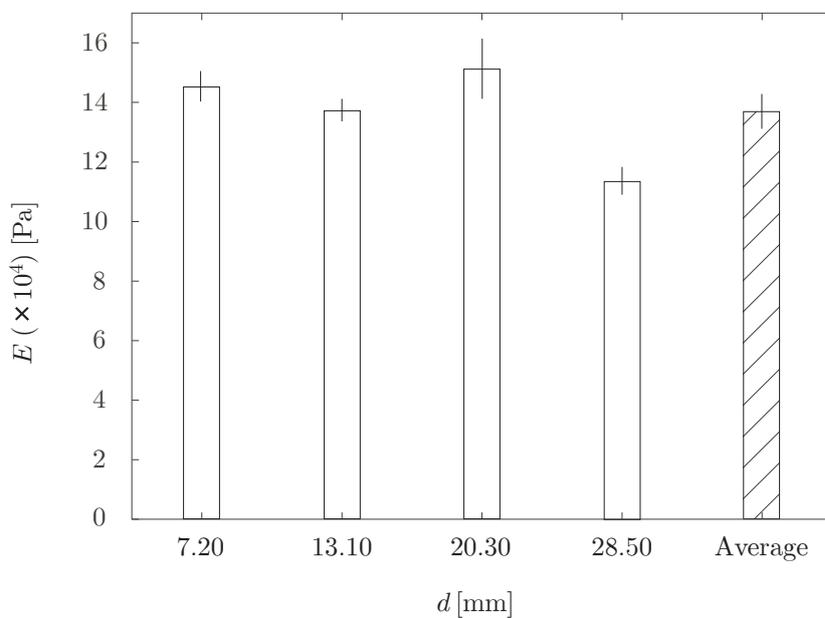


Fig. 4.5 Experimental results showing Young's modulus of springs with different length.

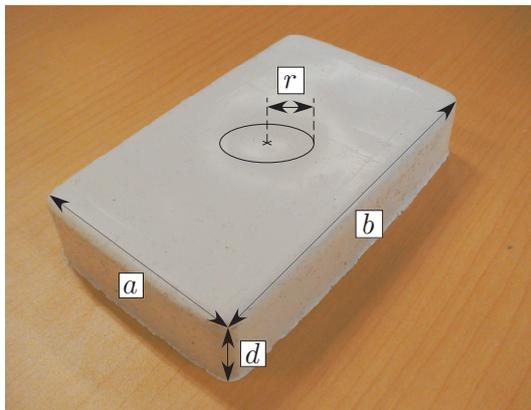
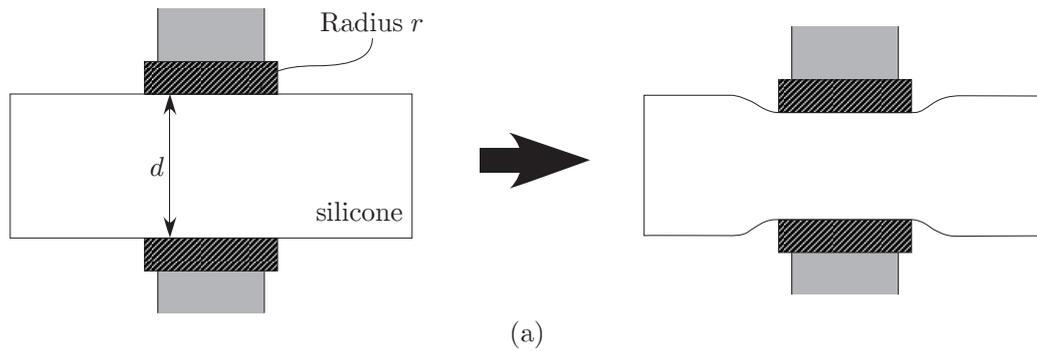


Fig. 4.6 Experiment for sensing Young's modulus of a silicone.

4.3.2.2 考察

Fig. 4.7, 4.8に示すように、 P , E の両者の値が、 $r = 2[\text{mm}]$ の場合には $r = 5, 11[\text{mm}]$ に比べ、極端に大きく算出されている。これは、 $r = 2[\text{mm}]$ で測定する場合、Fig. 4.9に示すように、グリッパとの接触面積 $A = \pi r^2$ に対する境界長 $l = 2\pi r$ の比率が大きいため、挟み込み方向(厚さ方向)の弾性成分に加え、接触部周辺の部位による挟み込み方向と直行する弾性成分の影響(ひきつれ効果)が大きくなったものと推察できる。一方で、Fig. 4.7, 4.8に示すように、 $r = 5, 11[\text{mm}]$ での測定値が同程度に収束しているのは、接触面積 A に対する境界長 l が十分小さいことで、 P , E の算出に対して、ひきつれ効果の影響が小さいためと考えられる。なお、次節で述べる等価ヤング率の測定には $r = 11[\text{mm}]$ のグリッパを用いるものとし、本章では、計測系に含まれるひきつれ効果については、これ以上の解析は行わないものとする。

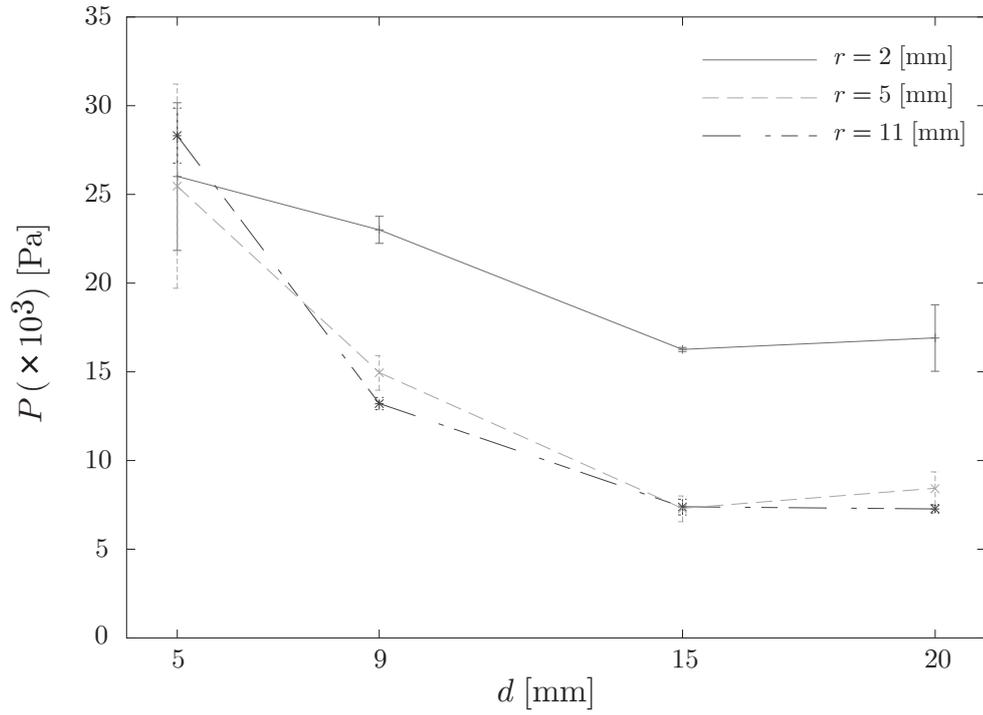


Fig. 4.7 Experimental results showing pressure of silicones with different thickness.

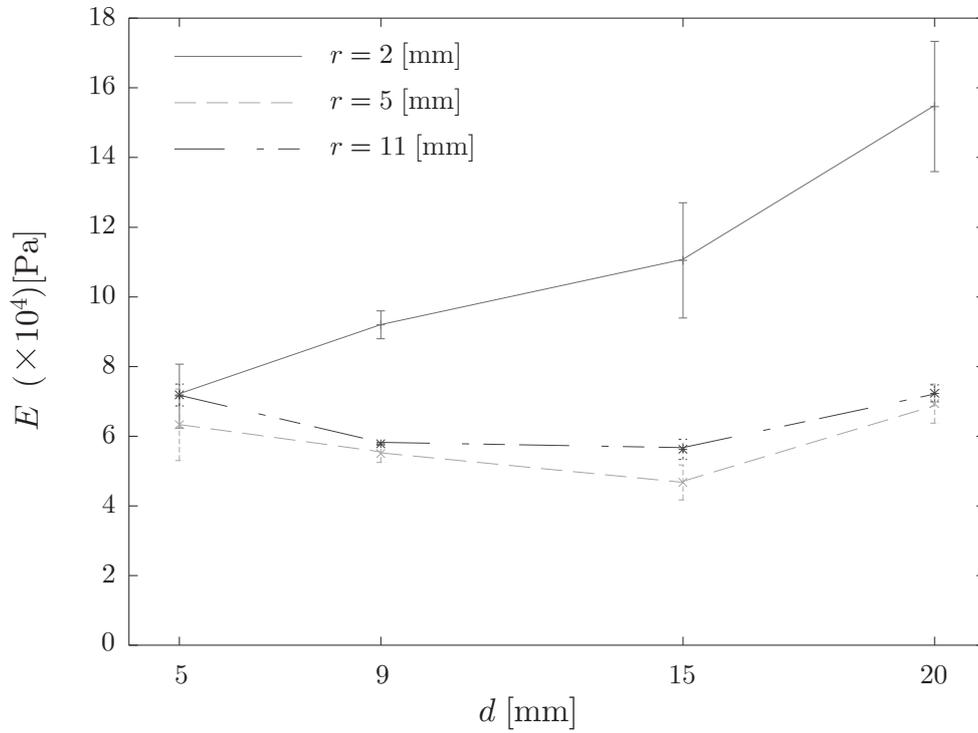


Fig. 4.8 Experimental results showing Young's modulus of silicones with different thickness.

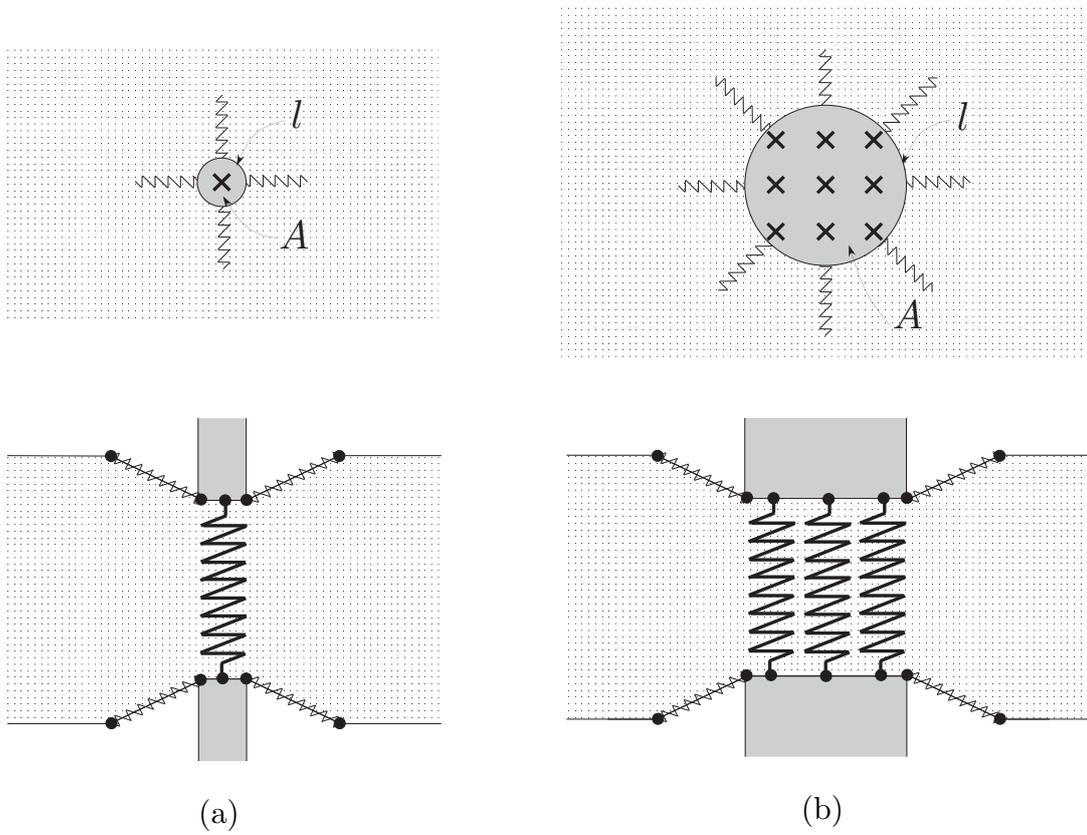


Fig. 4.9 Explanation of coupling effect.

4.4 等価舌ヤング率の計測実験

本節では、実際のヒトの舌を用いた等価舌ヤング率の計測実験について示す。

4.4.1 実験条件

Fig. 4.10 に示すように、22~23 歳の健常な舌を持つ被験者 10 人に対して、等価舌ヤング率 E を測定する。測定は 1 人につき弛緩状態、収縮状態についてそれぞれ 5 回ずつ行う。グリッパの挟み込みによる舌の変位を $\Delta d = 2[\text{mm}]$ 前後になるように与える。グリッパの接触部は半径 $r = 11[\text{mm}]$ の円形とし、 $A = 380[\text{mm}^2]$ である。また、実験時に被験者に対して、舌の力を抜く、入れるよう指示し、舌筋の弛緩/収縮の判定には、予備実験より得た $G_0 = 0.5[\text{mV}]$ を用いる。



Fig. 4.10 An overview of experiment.

4.4.2 実験結果

Fig. 4.11 に弛緩時における被験者 1 名の計測結果を示す。ただし、Fig. 4.11(a)~(d) はそれぞれ、筋電位 G 、舌の厚さ d 、舌の変位 Δd 、接触力 f を示し、(e) は $G \leq G_0$ における 2 秒間 ($4 \leq t \leq 6[\text{sec}]$) の E を示している。一方、Fig. 4.12 に収縮時における被験者 1 名の計測結果を示す。ただし、Fig. 4.12(a)~(d) はそれぞれ、筋電位 G 、舌の厚さ d 、舌の変位 Δd 、接触力 f を示し、(e) は $G \geq G_0$ における 2 秒間 ($4 \leq t \leq 6[\text{sec}]$) の E を示している。Fig. 4.11(a)、および Fig. 4.12(a) より、 $G_0 = 0.5[\text{mV}]$ に対して、それぞれ $G \leq G_0$ 、 $G \geq G_0$ の条件を満足し、舌筋がそれぞれ弛緩、収縮状態にあることが確認できる。Fig. 4.11(b)、および Fig. 4.12(b) より、収縮時の方が、舌の厚さ d が $10[\text{mm}]$ 程度大きくなり、約 2 倍に増加している。これは、筋収縮により舌が厚さ方向へ大きく膨張する性質に起因している。前節での基礎実験での結果を踏まえると、この d の増加を測定しない限り、組織の弾性を正當に測定できないことは明白である。また、Fig. 4.11(c)~(e)、および Fig. 4.12(c)~(e) より、グリッパによる押し込み動作が停止し、舌の変位 $\Delta d = 2[\text{mm}]$ 周辺で定常状態となると、 f および算出される E が安定する。この被験者の場合、2 秒間 ($4 \leq t \leq 6[\text{sec}]$) の平均等価舌ヤング率は、弛緩/収縮状態でそれぞれ $E = 25.3 \times 10^3[\text{Pa}]$ 、 $E = 111.6 \times 10^3[\text{Pa}]$ となる。

Table 4.1、Table 4.2 に、それぞれ舌筋が弛緩時、収縮時における被験者 10 名の等価舌ヤング率 E の計測結果を示す。ただし、各 E の値は、2 秒間の平均値である。また、Fig. 4.13(a) に、各被験者ごとに、弛緩/収縮状態での E の値を比較したものを示す。Fig. 4.13(b) に、全被験者の、弛緩/収縮状態での E の値を比較したものを示す。

4.4.3 考察

Fig. 4.13(a) より、被験者によって個人差はあるものの、弛緩状態と収縮状態で明らかに等価舌ヤング率 E の値が異なることがわかる。Fig. 4.13(b) に示すように、10 人の平均値から、等価舌ヤング率 E は、舌筋が弛緩時よりも収縮時の方が約 3.8 倍上昇することがわかる。これは、収縮時には、舌の筋繊維の密度が高くなることで、プローブを舌に $2[\text{mm}]$ 押し込むのに必要な接触力 f が増加し、結果的に舌組織の弾性が上昇することに起因しているものと考えられる。以上のように、舌の弾性は舌筋の収縮状態に敏感であることがわかる。

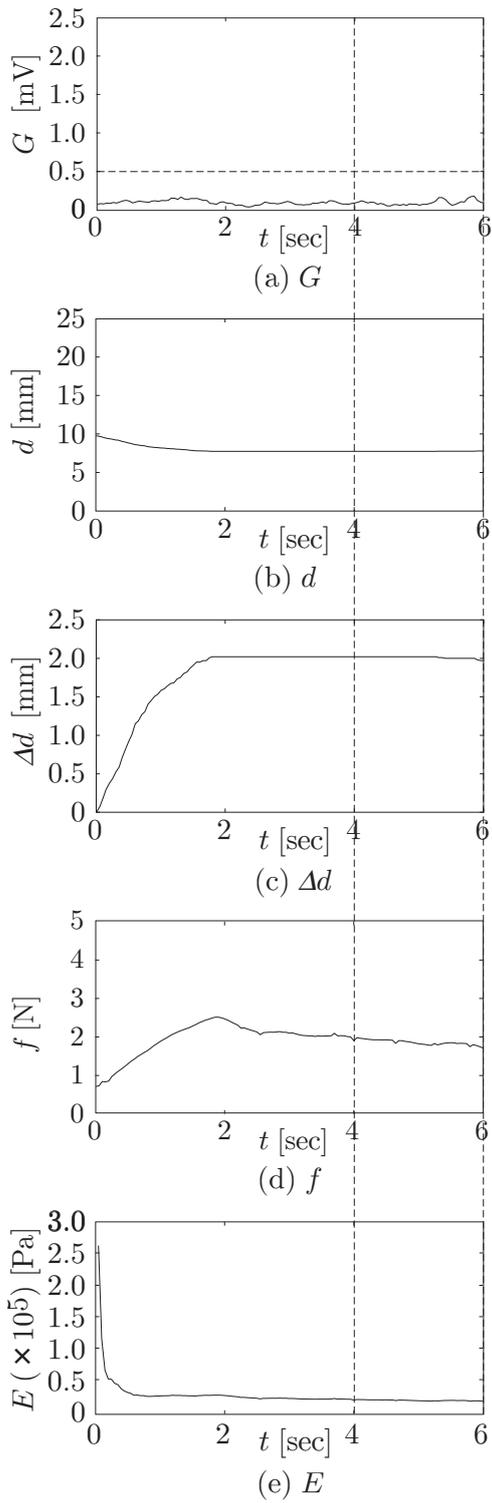


Fig. 4.11 An experimental result under no muscle contraction.

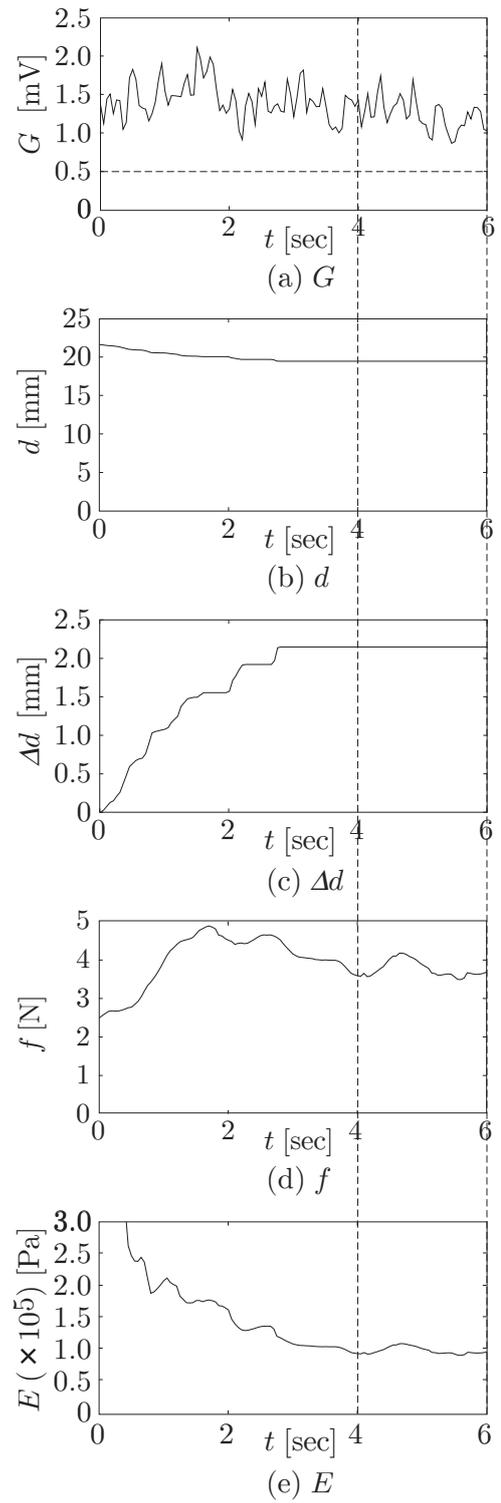


Fig. 4.12 An experimental result under muscle contraction.

Table 4.1 E under no muscle contraction ($\times 10^3$) [Pa].

Subject \ Trial	Trial					
	1st	2nd	3rd	4th	5th	Ave.
A	33.2	20.0	8.3	21.8	25.3	21.7
B	21.4	7.8	13.0	11.6	12.7	13.3
C	10.8	9.2	11.1	9.2	9.7	10.0
D	10.1	1.1	5.7	7.2	9.7	6.8
E	17.4	7.7	11.3	6.2	7.0	9.9
F	6.4	3.1	3.4	4.6	2.4	4.0
G	7.2	11.7	12.1	3.1	6.7	8.1
H	8.4	5.3	5.9	8.2	11.4	7.8
I	9.0	12.5	2.4	5.6	5.7	7.0
J	9.9	6.0	4.0	7.0	7.0	6.8

Table 4.2 E under muscle contraction ($\times 10^3$) [Pa].

Subject \ Trial	Trial					
	1st	2nd	3rd	4th	5th	Ave.
A	125.4	150.8	111.6	95.6	116.2	120.0
B	25.1	48.7	29.5	10.3	28.2	28.4
C	20.4	38.4	47.3	32.6	35.6	28.3
D	40.8	26.0	35.9	38.5	22.6	25.1
E	84.4	66.0	56.3	55.8	69.3	55.2
F	14.9	4.0	22.5	17.7	15.8	15.0
G	9.0	14.0	43.6	1.5	9.5	15.5
H	46.5	38.8	41.6	30.9	36.6	38.9
I	27.9	6.8	14.9	23.7	3.2	15.3
J	8.6	7.9	8.2	13.4	8.1	9.3

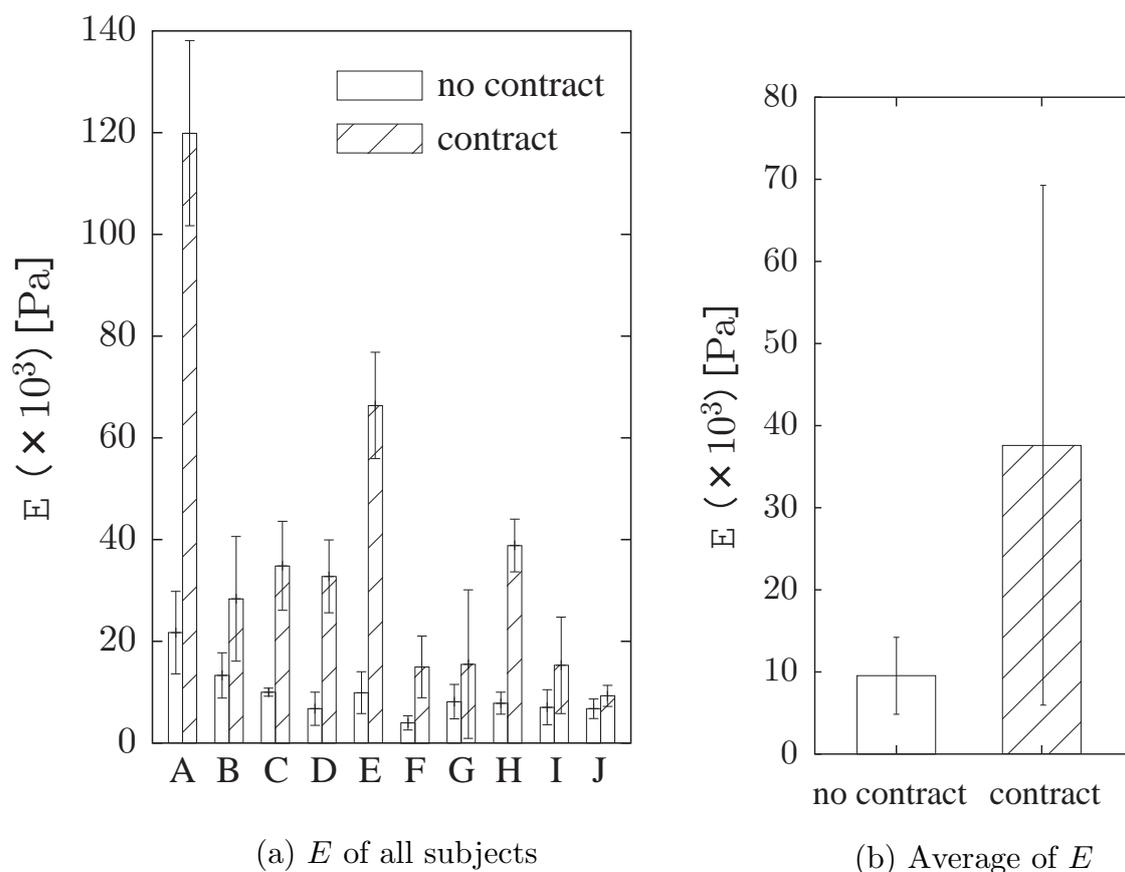


Fig. 4.13 Experimental results of E .

4.5 まとめ

本章では、ヒトの舌を対象として、生体組織が有する弾性を評価するための計測システムの開発について議論した。グリッパ式弾性計測機構を採用し、舌の厚さ変化に依存することなく組織が有する弾性を評価するために、弾性の評価指標として等価舌ヤング率を導入した。また、筋電位センサを用いた舌筋の収縮状態識別機能を実装した。模擬対象モデルを用いた基礎実験により、半径 5[mm] 以上の円形接触部を用いれば、対象物の厚さにかかわらず組織の弾性を妥当に評価できることを示した。最後に、ヒトの舌に対する計測実験により、等価舌ヤング率を定量的に評価し、舌の弾性が舌筋の弛緩時に比べ、収縮時の方が、約 4 倍になることを示した。

第 5 章

弾性可変型模擬舌の導入

5.1 はじめに

本章では，ヒトの舌の弾性変形を考慮した食品テクスチャ推定手法を構築することを目的とする．提案手法は，第 2 章の手法に準拠し，咀嚼ロボットにおける食品圧縮・破断操作，および圧力分布解析に基づくテクスチャ推定処理から構成される．今回，テクスチャ推定精度の向上に向けて，機器制御や推定処理といったソフトウェア面はそのままに，咀嚼ロボットのハードウェア面に工夫を凝らすアプローチを採用する．はじめに，新たに導入する弾性可変型模擬舌の基本原則について示す．模擬舌は，シリコーン弾性体をベースとし，側面・底面の拘束壁，上面のポリウレタン弾性シートから構成される．一つの拘束壁をピストン状に移動させてシリコーン弾性体に予圧縮を与えることで，シリコーン弾性体上面からの押し込み量に対する反力を調整できる仕組みとなっている．ここでは，プロトタイプによる基礎実験を行い，ヒトの舌の弛緩状態から収縮状態までの弾性を再現可能なことを示す．次に，模擬舌を用いたゲル食品の圧縮・破断実験を行い，その過程における一連の圧力分布を計測する．ここでは，模擬舌の弾性に応じて圧力分布が明快に異なることを明らかにする．最後に，圧力分布からテクスチャの官能評価値を推定する実験を行い，テクスチャ評価項目およびゲル食品の種類に応じて，推定精度を向上させるための適切な模擬舌の弾性が存在することを示す．

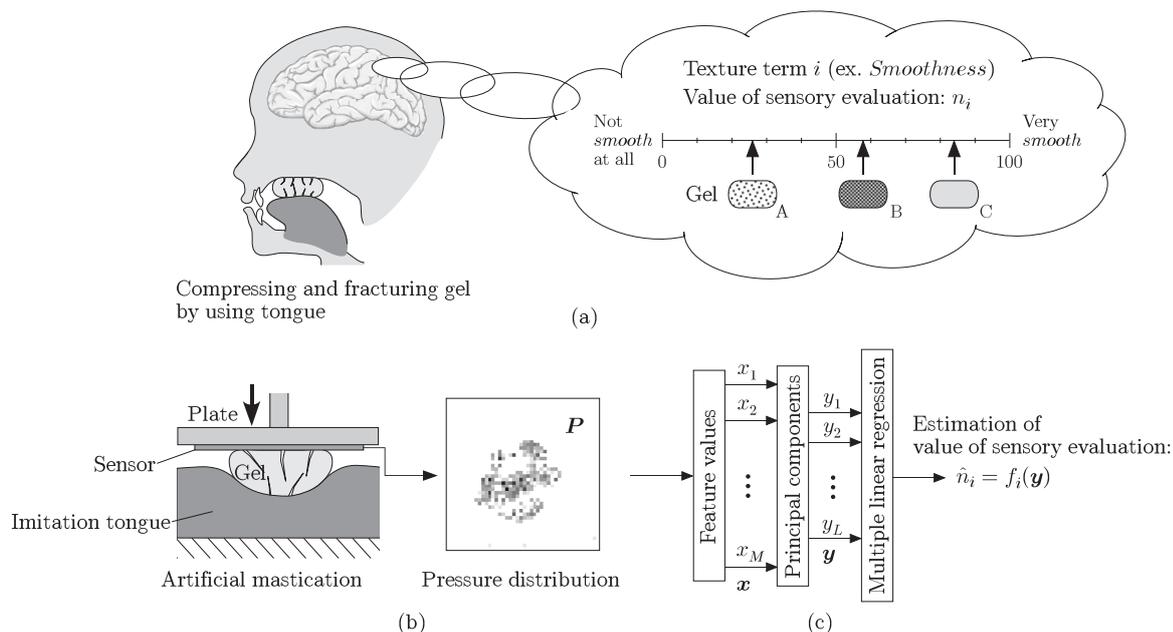


Fig. 5.1 Outline of the proposed texture sensing method. (a) In preparation, reference values of sensory evaluation of gels are obtained from panelists. (b) The pressure distribution of the gel is measured using artificial mastication with imitation tongue. (c) The relationship between the pressure distribution and the value of sensory evaluation is modeled based on the image texture analysis, and the equation for estimating the value of sensory evaluation is derived.

5.2 テクスチャ推定システムの全容

提案するテクスチャ推定手法は，第2章に準拠する．ただし，第2章では剛体プレートと剛体土台を用いた圧縮試験を行っていたのに対し，提案手法では，弾性可変型模擬舌を用いた食品の圧縮・破断操作を導入する点が決定的に異なる．概要を以下に示す．

【官能評価値の事前準備】 Fig. 5.1(a) に示すように，教師データとして，素材の異なる複数種類のモデリング用ゲル食品の官能評価値を準備しておく．官能評価値は，実際にヒトが舌式咀嚼により試食する官能評価試験により取得する．官能評価値 n_i は，テクスチャ評価項目 i (例えば，“もちもち感： $i = 1$ ”，“つるつる感： $i = 2$ ”，など) ごとに設定する．

【咀嚼ロボットを用いた圧力分布計測】 Fig. 5.1(b) に示すような咀嚼ロボットを構築する．ヒトは，舌式咀嚼において，舌と口蓋を用いて食品破断中の形態変化と力応答を同時に感知している．この基本原理に基づいて，弾性可変型模擬舌，剛体プレートおよび圧力分布

センサから構成される咀嚼ロボットを構築する。模擬舌上で食品を圧縮・破断し、その過程の圧力分布 \mathbf{P} を計測する。以上のようにして、官能評価値が異なるモデリング用ゲル食品の圧力分布データを収集する。

【テクスチャ推定式の導出】 Fig. 5.1(c) に示すように、圧力分布データと官能評価値との関係を示す数理モデルを作成する。はじめに、圧力分布データ \mathbf{P} に画像テクスチャ解析手法を適用し、特徴量ベクトル \mathbf{x} を算出する。続いて、主成分ベクトル \mathbf{y} を算出する。最後に、主成分ベクトル \mathbf{y} を説明変数、官能評価値 n_i を目的変数とした重回帰モデルを作成し、テクスチャ推定式 $\hat{n}_i = f_i(\mathbf{y})$ を導出する。

以上の手順で得たテクスチャ推定式を用いることにより、ゲル食品の圧縮・破断時の圧力分布データ \mathbf{P} からテクスチャの官能評価値 n_i を推定することができる。

5.3 弾性可変型模擬舌

本節では、咀嚼ロボットに新たに導入する弾性可変型模擬舌の基本原理を示し、プロトタイプを用いた弾性可変特性の検証実験について示す。

5.3.1 弾性可変原理

一般に、模擬生体組織（皮膚、臓器など）の主素材として、シリコンが用いられる。はじめに、Fig. 5.2(a-i) に示すようなシリコン弾性体をベースとした模擬舌を考える。弾性体の側面と底面は剛体壁で拘束されているものとし、Fig. 5.2(b-i) に示すように、一つの側壁はピストン状に並進移動できるものとする。ピストン壁の初期位置からの移動量を弾性体に与える予圧縮量 Δs とする。まず、Fig. 5.2(a-i) に示すように、ピストン壁がシリコン弾性体に接した状態 ($\Delta s = 0$) を考える。この状態で、Fig. 5.2(a-ii) に示すように、弾性体を上面から円柱プローブで Δb だけ押し込むと、弾性によって反力 $F_a(0)$ が生じる。次に、Fig. 5.2(b-i) に示すように、ピストン壁を移動させて弾性体に予圧縮を与えた状態 ($\Delta s > 0$) を考える。この場合、予圧縮により弾性体が上方に盛り上がる。Fig. 5.2(b-ii) に示すように、プローブを弾性体との初期接触位置から Δb だけ押し込んだ際の反力 $F_a(\Delta s)$ は、予圧縮の影響により元の反力 $F_a(0)$ と比べてわずかに上昇する。ただし、反力の大きさを広範囲で調整することは期待できない。

次に、Fig. 5.3(a-i) に示すように、シリコン弾性体の上面を薄膜状弾性シートで被った模擬舌を考える。なお、弾性シートのヤング率は、弾性体よりも十分大きいものとする。弾性シートの一端は側壁（図中右）に固定されており、もう一端はピストン壁上部の

開口部を經由して逆の側壁（図中左）に固定されている。このとき、弾性シートは自然状態として張力はゼロとする。Fig. 5.3(a-ii) に示すように、ピストン壁が弾性体に接した状態 ($\Delta s = 0$) において、上面からプローブを Δb だけ押し込むと反力 $F(0)$ が生じる。この反力 $F(0)$ は、弾性シートの弾性分だけ、Fig. 5.2(a-ii) の反力 $F_a(0)$ よりも大きくなる。次に、Fig. 5.3(b-i) に示すように、ピストンを移動させて弾性体に予圧縮を与えた状態 ($\Delta s > 0$) を考える。この場合、予圧縮により弾性体が上方に膨れ上がることで、弾性シートの張力 T が増加する。Fig. 5.3(b-ii) に示すように、プローブを押し込むとさらに張力 T は増加し、反力 $F(\Delta s)$ を $F(0)$ より大幅に増加させる効果が生じる。以上のように、弾性体を被う弾性シートの効果により、押し込み量 Δb に対する反力 $F(\Delta s)$ を、予圧縮量 Δs によって広範囲で調整することが可能となる（弾性シートのヤング率が小さい場合は Fig. 5.2 の弾性体単体模擬舌と等価となり、反力調整効果は生まれない）。以上のような予圧縮量 Δs によって調整される模擬舌の擬似的な可変弾性を、ばね定数 $K(\Delta s) = F(\Delta s)/\Delta b$ で表すことにする。なお、予圧縮による模擬舌上面の盛り上がりは模擬舌長に対して十分に小さいものとし、本章では、模擬舌の初期幾何学形状が対象の圧縮・破断に及ぼす影響については議論の対象外とする。

5.3.2 プロトタイプによる弾性可変特性の確認

Fig. 5.4(a) に、開発した弾性可変型模擬舌のプロトタイプの外観を示す。シリコーン弾性体は、幅 65[mm]、奥行き 50[mm]、高さ 35[mm] の直方体である。ヤング率は $E = 11.1[\text{kPa}]$ （圧縮量 2[mm] における応力 / ひずみ）であり、ヒトの舌弾性を再現できるように試行錯誤的に設定している。薄膜状弾性シートとして、厚さ 0.03[mm]、ヤング率約 700[kPa] のポリウレタンシートを用いている。側面および底面の拘束壁は ABS 樹脂製である。1つの側壁はリニアスライダによってピストン状に並進運動することができ、予圧縮量 Δs を調整可能となっている。Fig. 5.5 に予圧縮量を $\Delta s = 0[\text{mm}]$ 、 $\Delta s = 20[\text{mm}]$ としたときの模擬舌の様子を示す。このようなプロトタイプ模擬舌の弾性 $K(\Delta s)$ の可変特性について、第 4 章に基づいて実験的に調べる。

Fig. 5.6 の実線に、予圧縮量 Δs を変化させた際の押し込み量 Δb -反力 $F(\Delta s)$ 特性について示す。ただし、予圧縮量は $\Delta s = 0 \sim 20[\text{mm}]$ の範囲で 2[mm] ごとに変化させ、それぞれについて、Fig. 5.4(b) のように模擬舌の上面中央部を円筒プローブで $\Delta b=2[\text{mm}]$ まで押し込んでいる。円筒プローブの直径は $D = 20[\text{mm}]$ とし、これはテクスチャ推定実験（第 5.4 章）で用いる円柱状ゲル食品の直径と一致させている。プローブはリニアガイドによって鉛直方向に可動し、リニアエンコーダおよびロードセルで、それぞれ押し込

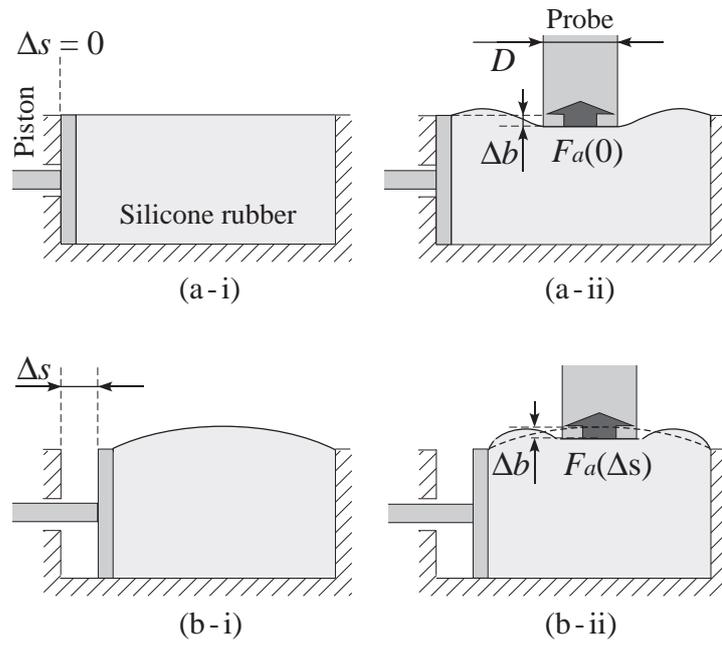


Fig. 5.2 Imitation tongue by naked silicone.

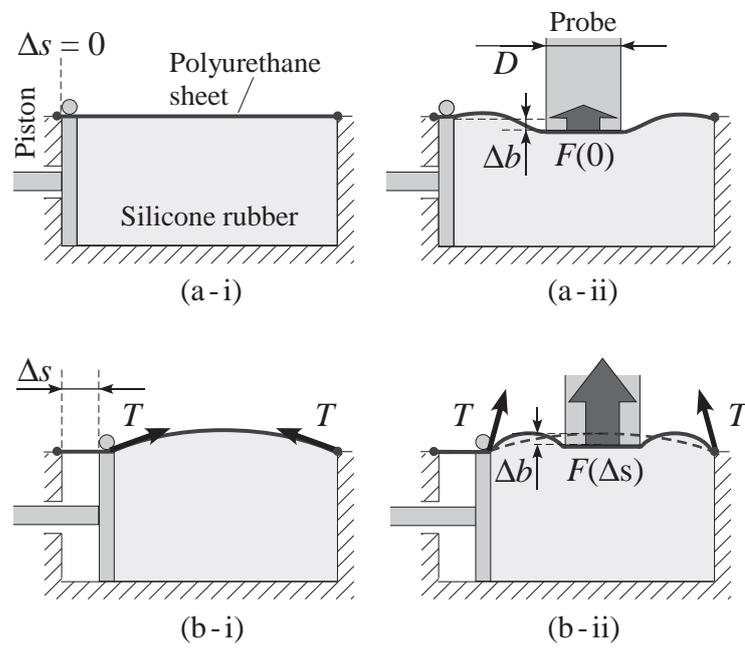
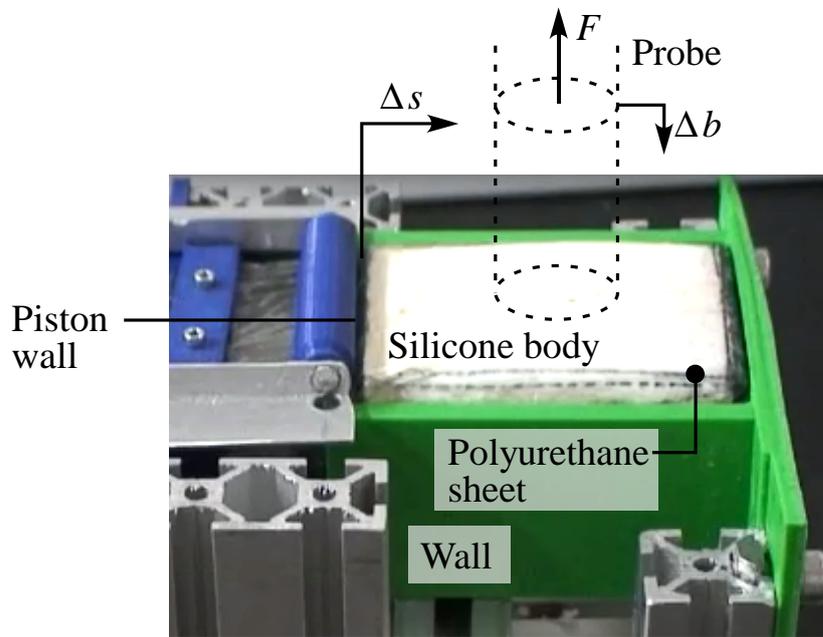


Fig. 5.3 Basic principle of variable elasticity type imitation tongue.

み量 Δb および反力 F を測定する。なお、今回は静特性のみに着目するものとして、押し込み速度は十分に遅くしている。Fig. 5.6 より、押し込み量 Δb の増加に応じて反力 F が増加すること、ならびに、予圧縮量 Δs の増加に対して Δb - F 特性線がほぼ一様に上昇していくことが確認できる。したがって、このような予圧縮量の範囲においては、模擬舌の弾性 $K(\Delta s)$ を任意に調整可能であることがわかる。また、薄膜状弾性シートを用いずにシリコン弾性体と拘束壁のみで構成された模擬舌における同特性を、Fig. 5.6 の破線で示す。予圧縮量 Δs を 0[mm] から 20[mm] へ増加させているにもかかわらず、両者の反力には大きな違いはない。このことから、模擬舌の可変弾性を実現する上での弾性シートの重要性を確認できる。

次に、弾性可変型模擬舌とヒトの舌の特性を比較する。Fig. 5.4(b) のように、舌をアルミ製土台に乗せ、上方からプローブで押し込んだ際の Δb と F を測定する。Fig. 5.7 の灰色線に、ヒトの舌の弛緩状態および収縮状態において測定を行って得た結果の一例を示す。被験者に対して、弛緩状態は舌に力を入れずに柔らかくするように、収縮状態は舌に力を入れて硬くするように指示している。なお、同図には、弾性可変型模擬舌に予圧縮量 $\Delta s=0$ [mm] および $\Delta s=20$ [mm] を設定した際の結果を再掲している。Fig. 5.7 より、ヒトの舌の弛緩状態と模擬舌の予圧縮量 $\Delta s=0$ [mm] の状態、ならびに、弛緩状態と予圧縮量 $\Delta s=20$ [mm] の状態は、それぞれよく一致していることがわかる。この結果に基づき、以降では、弾性可変型模擬舌に予圧縮量 $\Delta s=0$ [mm] および $\Delta s=20$ [mm] を与えた状態を、それぞれ模擬舌の弛緩状態および収縮状態と称することにする。Fig. 5.8 に、ヒトの舌および模擬舌について、 Δb - F 特性線を線形近似^{*1}して算出した弾性 K を示す。ただし、ヒトの舌に関しては、22 歳～24 歳の被験者 4 名×測定 5 回の平均値である。ヒトの舌は、弛緩状態で $K_{\text{relax}}=0.15$ [N/mm]、収縮状態で $K_{\text{cont}}=0.67$ [N/mm] である。なお、収縮状態のばらつきが大きいのは、計測中（約 5[s]）に一定の収縮状態にすることが難しく、被験者ごとの個人差が顕著となったことに起因している。一方、模擬舌は、弛緩状態で $K(0)=0.12$ [N/mm]、収縮状態で $K(20)=0.63$ [N/mm] である。弛緩状態から収縮状態になることで、ヒトの舌の弾性は 4.5 倍に、模擬舌の弾性は 5.3 倍に増加している。以上のように、今回開発した弾性可変型模擬舌によって、ヒトの舌の弾性可変特性を十分に再現できることがわかる。

*1 線形近似の R^2 値は、模擬舌の弛緩状態 $R^2 = 0.95$ および収縮状態 $R^2 = 0.97$ 、ヒトの舌の弛緩状態 $R^2 = 0.88$ および収縮状態 $R^2 = 0.97$ 。



(a)

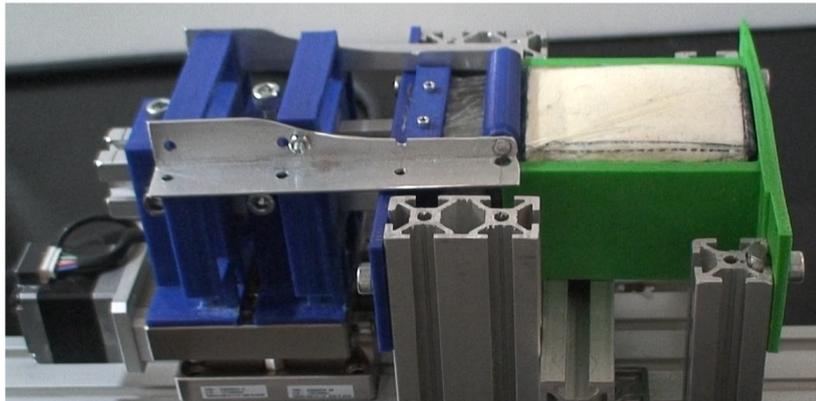


(b)

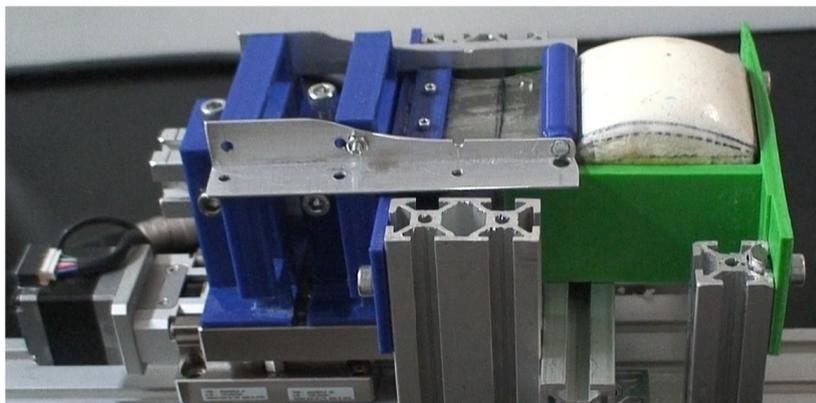


(c)

Fig. 5.4 Development of the imitation tongue with variable elasticity. (a) Prototype of the imitation tongue. (b) Measurement of the elasticity of the imitation tongue. (c) Measurement of the elasticity of the human tongue.



(a) $\Delta s = 0$ [mm]



(b) $\Delta s = 20$ [mm]

Fig. 5.5 Prototype of the imitation tongue with different Δs .

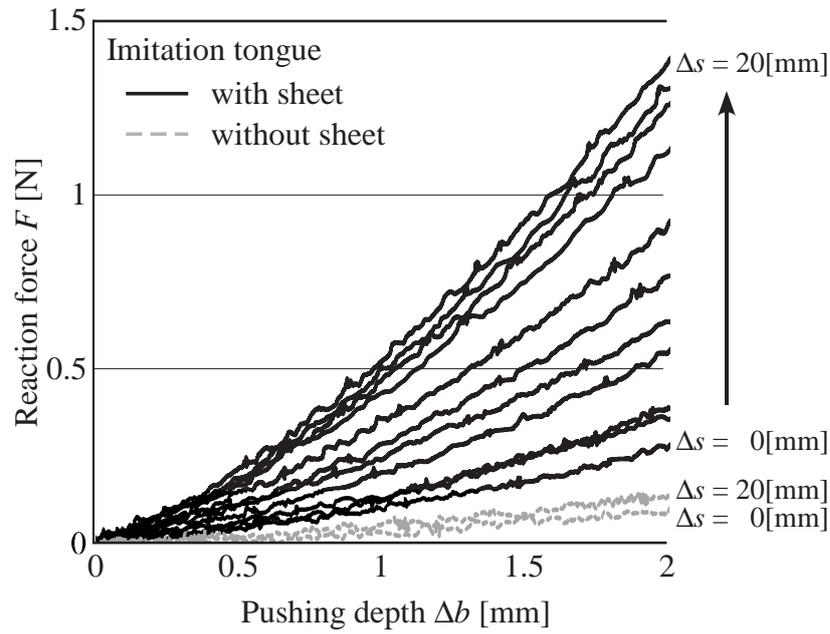


Fig. 5.6 Relationship between pushing depth Δb , reaction force F , pre-compression Δs , in imitation tongue with and without sheet.

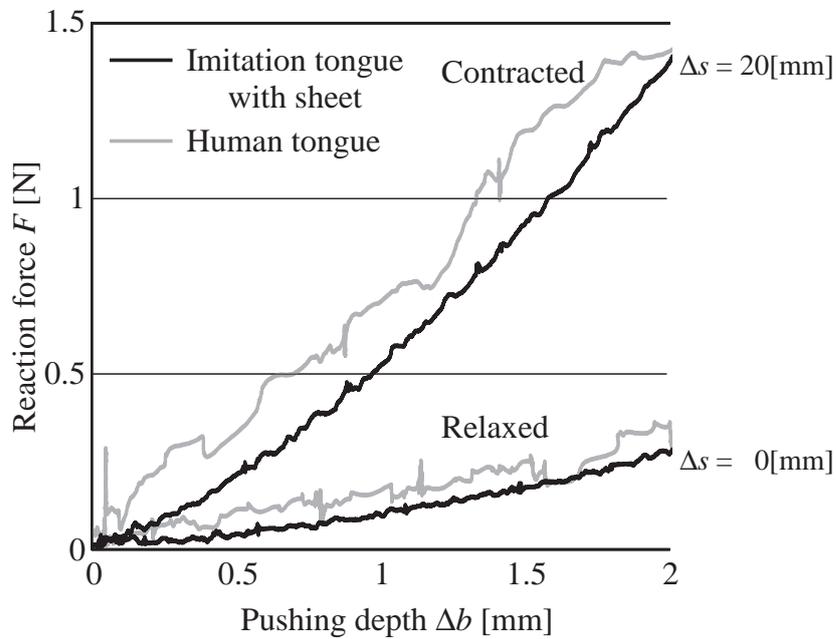


Fig. 5.7 Relationship between pushing depth Δb and reaction force F in human and imitation tongue.

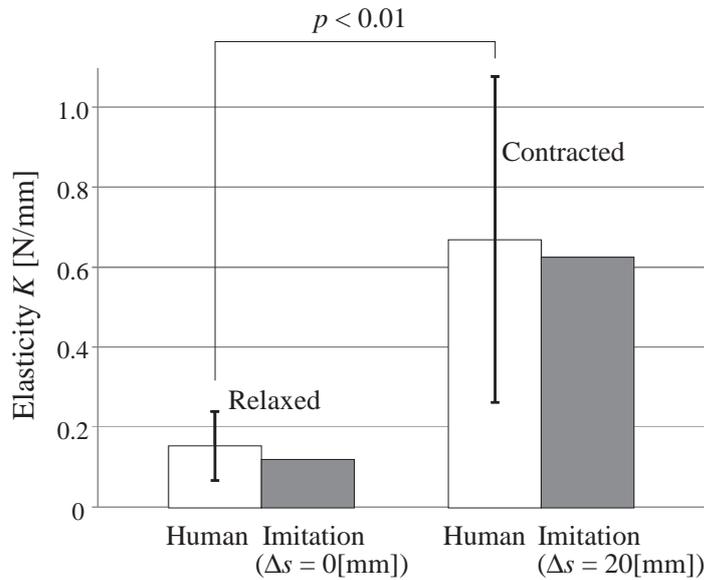


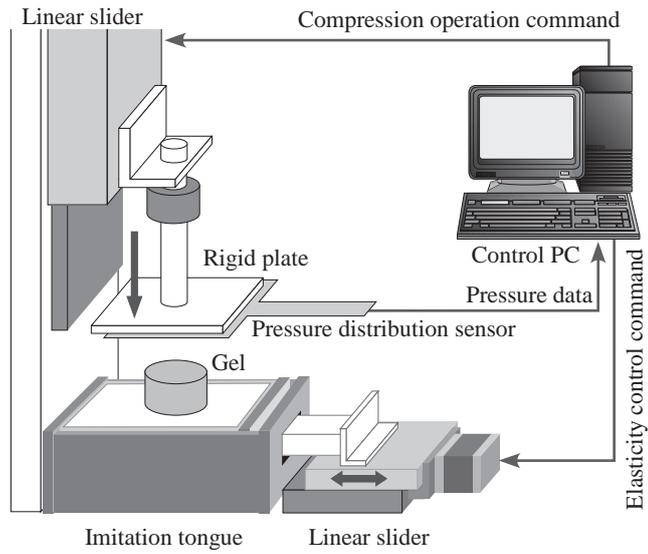
Fig. 5.8 Comparable elasticity between human and imitation tongues.

5.4 模擬舌を用いたテクスチャ推定

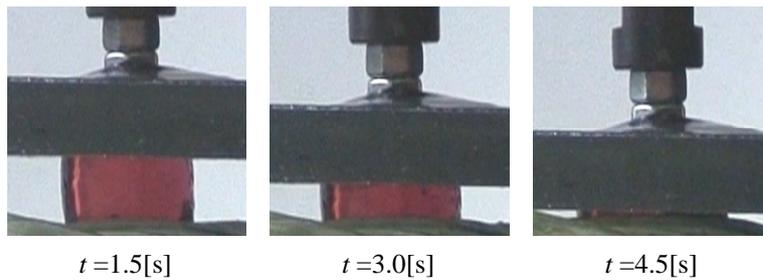
本節では，弾性可変型模擬舌を導入したテクスチャ推定システムを構築する．模擬舌の弾性状態に対して，ゲル食品を圧縮・破断した際の圧力分布がどのように変化するか，食品テクスチャの推定精度がどのように変化するか，について実験的に考察する．

5.4.1 実験システム

Fig. 5.9(a) に，実験システムの概要を示す．模擬舌の上にゲル食品を置き，上方から剛体プレートを下ろさせて圧縮・破断操作を行う．剛体プレートはリニアスライダによって動作する．模擬舌のピストン壁は別のリニアスライダによって動作し，予圧縮量を調整して模擬舌の弾性を変化させることができる．二つのリニアスライダは PC によって制御される．剛体プレートの下面には，圧力分布センサ（ニッタ株式会社製：空間分解能 1[mm]，時間分解能 10[ms]，測定範囲 44[mm]×44[mm]，圧力分解能 0.2[kPa]）が取り付けられている．ゲル食品は，直径 20[mm]，高さ 10[mm] の円柱形とし，模擬舌の上面中央付近に置かれる．今回の圧縮・破断操作は，以下の通りとする．剛体プレートに速度 2[mm/s] の下降動作を与え，ゲル食品の上面と接触した時刻を $t = 0$ [s] とする．そのまま下降動作を継続し， $t = 4.5$ [s] でプレートを静止させる．なお， $t = 4.5$ [s] の時点でプレー



(a)



(b)

Fig. 5.9 Experimental system.

トは模擬舌上面から 1[mm] 上方に位置する．今回，過大圧力の回避と接触判別（プレートーゲル食品／プレートー模擬舌）の簡単化のため，プレートと模擬舌との直接の接触は避けるものとし，この時点で操作を終了する．以上の間 ($0 \leq t \leq 4.5[s]$) の圧力分布を時系列データとして記録し，PC に保存する．Fig. 5.9(b) は，実験例として弛緩状態に設定された模擬舌上でゲル食品を圧縮・破断している様子を，カメラで側面から撮影した写真である．この場合，ゲル食品は模擬舌にめり込んでいき，圧縮・破断状況を視覚的に確認することはできない．

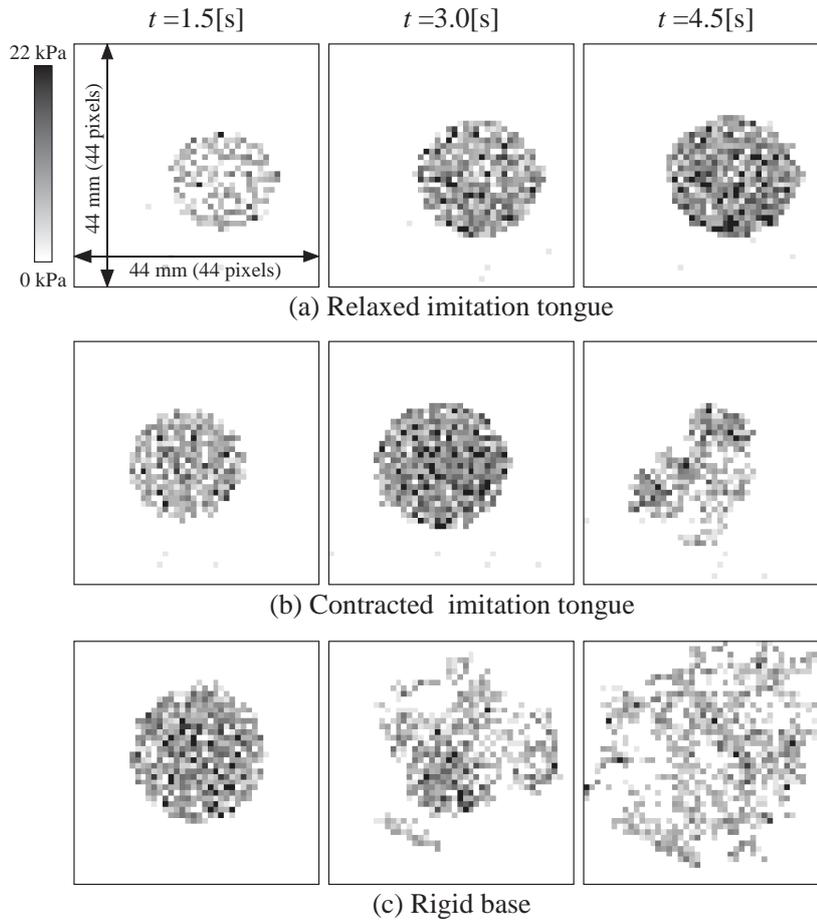


Fig. 5.10 Pressure distribution.

5.4.2 模擬舌の弾性状態に対する圧力分布の相違

Fig. 5.10 に、ゲル食品の圧縮・破断中の圧力分布データ例を示す。ただし、Fig. 5.10(a) は模擬舌を弛緩状態に設定した場合、Fig. 5.10(b) は模擬舌を収縮状態に設定した場合、Fig. 5.10(c) は模擬舌ではなく剛体土台を用いた場合（第 2 章に対応）である。図中において、ピクセル色が白から黒に変化していくほど、圧力値が高いことを示している。Fig. 5.10(a) に示すように、弛緩状態の模擬舌上では、圧力の立ち上がりは遅い ($t = 1.5[s]$)。これは、模擬舌表面が凹むように受動変形することに起因しており、プレート の下降が進んでもゲル食品の円筒形状に従った圧力分布が浮き彫りになっていくだけで ($t = 3.0[s]$)、破断を示す拡散するような圧力分布は最後まで見られない ($t = 4.5[s]$)。次に、Fig. 5.10(b) に示すように、収縮状態の模擬舌上では、弛緩状態と比較して圧力の立

ち上がりが早くなる ($t = 1.5[s]$). これは、模擬舌の弾性増加に伴って反力が大きくなることに起因している. その後、圧力は一層上昇する ($t = 3.0[s]$). 最終的にゲル食品は破断し、これに応じた圧力分布の散布状況が確認できる ($t = 4.5[s]$), このとき、ゲル食品は完全に細かく砕け散ることなく、ある程度大きな破断片を含む状態となっている. また、模擬舌は破断片を包み込むように受動変形するため、破断片は拡散することなく、ほぼ元々の領域内に収まっている. 最後に、Fig. 5.10(c) に示すように、剛体土台を用いた場合、圧縮開始後の早い段階で圧力が高くなり ($t = 1.5[s]$), ゲル食品の破断も早く起こり、これに応じた圧力分布の散布状況が見られる ($t = 3.0[s]$). プレートの下降に合わせて圧力分布は広く拡散した状態になっていく ($t = 4.5[s]$). このとき、ゲル食品はほぼペースト状になるまで細かく破断された状態になっている. 以上のように、同じゲル食品であっても模擬舌の弾性に応じて、 $0 \leq t \leq 4.5[s]$ における圧縮・破断状態が明快に異なることがわかる.

5.4.3 テクスチャ推定実験

ゲル食品のテクスチャ推定実験により、弾性可変型模擬舌を用いた提案手法の有効性を検証する.

5.4.3.1 実験条件・手順

モデリング用ゲル食品として、6種類の市販ゲル食品 A~F を使用する. テクスチャ評価項目として、“もちもち感 (*Elasticity*: $i = 1$)”, “つるつる感 (*Smoothness*: $i = 2$)”, “ねっとり感 (*Stickiness*: $i = 3$)”, “ざらざら感 (*Granularity*: $i = 4$)” の4種類を用いる. 以下、実験の手順は第2章と同様に行う. 今回、試験員8名で Visual analog scale 法⁷⁰⁾に基づく官能試験を実施して0~100の整数値として官能評価値を取得し、平均値を教師データとして用いる官能評価値 n_i とする. 次に、実験システムを用いて、1種類につき6個ずつ、計36個のゲル食品の圧縮・破断中の圧力分布データ \mathbf{P} を計測する. この圧力分布データ群に以下の解析を施し、テクスチャ推定式を導出する. 各圧力分布データに空間濃度レベル依存法⁶⁹⁾を適用し、特徴量ベクトル \mathbf{x} を算出する. なお、 \mathbf{x} の次元は $M = 1002$ である. 参考データとして、5.4.3.2に、Fig. 5.10(a)~(c)の圧力分布に対応した特徴量の例を示す. 続いて、特徴量ベクトルの次元を圧縮するとともに多重線形性を取り除くために主成分分析を施し、主成分ベクトル \mathbf{y} を算出する. 最後に、主成分ベクトル \mathbf{y} を説明変数、官能評価値 n_i を目的変数とした線形重回帰モデルを作成し、テクス

チャ評価項目 i のテクスチャ推定式

$$\hat{n}_i = a_{i0} + a_{i1}y_1 + a_{i2}y_2 + \cdots + a_{iL_i}y_{L_i} \quad (5.1)$$

を導出する．ただし， a_{i0} は定数項， a_{il} ($l = 1, 2, \dots, L_i$) は偏回帰係数である (Table 5.1)．導出された推定式を用いて，テクスチャ評価項目 i ごとに，ゲル食品 A～F のテクスチャ推定値 \hat{n}_i を算出する．以上のテクスチャ推定実験を，弛緩状態の模擬舌，収縮状態の模擬舌，および剛体土台を用いた 3 条件の下で実施し，それぞれについてテクスチャ推定値を算出する．

5.4.3.2 特徴量の例

Fig. 5.11 に，Fig. 5.10(a)～(c) の圧力分布に対応した特徴量の例を示す．Fig. 5.11 左列は，空間濃度レベル依存法⁶⁹⁾を用いて算出した特徴量，エネルギー，エントロピー，慣性，相関，局所一様性の時系列データである．走査距離は 8[pixel]，走査方向は 0[deg] である．灰色実線は弛緩状態の模擬舌 (Fig. 5.10(a))，黒実線は収縮状態の模擬舌 (Fig. 5.10(b))，黒破線は剛体土台 (Fig. 5.10(c)) を用いた場合の特徴量である．これらの時系列データより，模擬舌の弾性状態に依存して，圧力分布から得られる各特徴量の変遷が異なることが確認できる．収縮状態の模擬舌と剛体土台については，極大値および極小値をそれぞれ ● および ○ で示している．Fig. 5.11 右列に，収縮状態の模擬舌と剛体土台について，特徴量の極大値ならびに極小値を比較した統計データを示す (収縮状態の模擬舌と剛体土台について，それぞれ，同種類のゲル× 6 個のデータを使用)．局所一様性の極小値を除き，他の全ての極値について有意差 ($p < 0.05$) が認められる．これは，本実験条件の下で，収縮状態の模擬舌と剛体土台では，圧縮・破断操作中のゲル食品の状態が異なることに対応する．

Table 5.1 Constant term and partial regression coefficients.

	L_i	a_{i0}	a_{i1}	a_{i2}	a_{i3}	a_{i4}	a_{i5}	a_{i6}	a_{i7}	a_{i8}	a_{i9}
		a_{i10}	a_{i11}	a_{i12}	a_{i13}	a_{i14}	a_{i15}	a_{i16}	a_{i17}	a_{i18}	
		a_{i19}	a_{i20}	a_{i21}	a_{i22}	a_{i23}	a_{i24}	a_{i25}			
<i>Elasticity: $i = 1$</i>	6	31.92	-0.17	1.26	-1.56	-1.35	-0.97	-1.59			
<i>Smoothness: $i = 2$</i>	25	31.96	0.25	1.09	-0.90	-0.97	4.34	-0.95	1.39	1.79	-2.18
			-1.45	1.67	0.96	1.63	1.60	-1.74	2.05	0.82	-1.52
			2.48	-1.87	2.93	-4.43	6.19	4.84	-2.19		
<i>Stickiness: $i = 3$</i>	8	64.48	-0.34	-0.55	0.41	-1.78	0.90	-1.61	-1.80	-2.59	
<i>Granularity: $i = 4$</i>	10	28.71	-0.46	-0.26	-1.38	0.50	-0.56	1.18	-0.89	-0.93	0.88
			1.73								

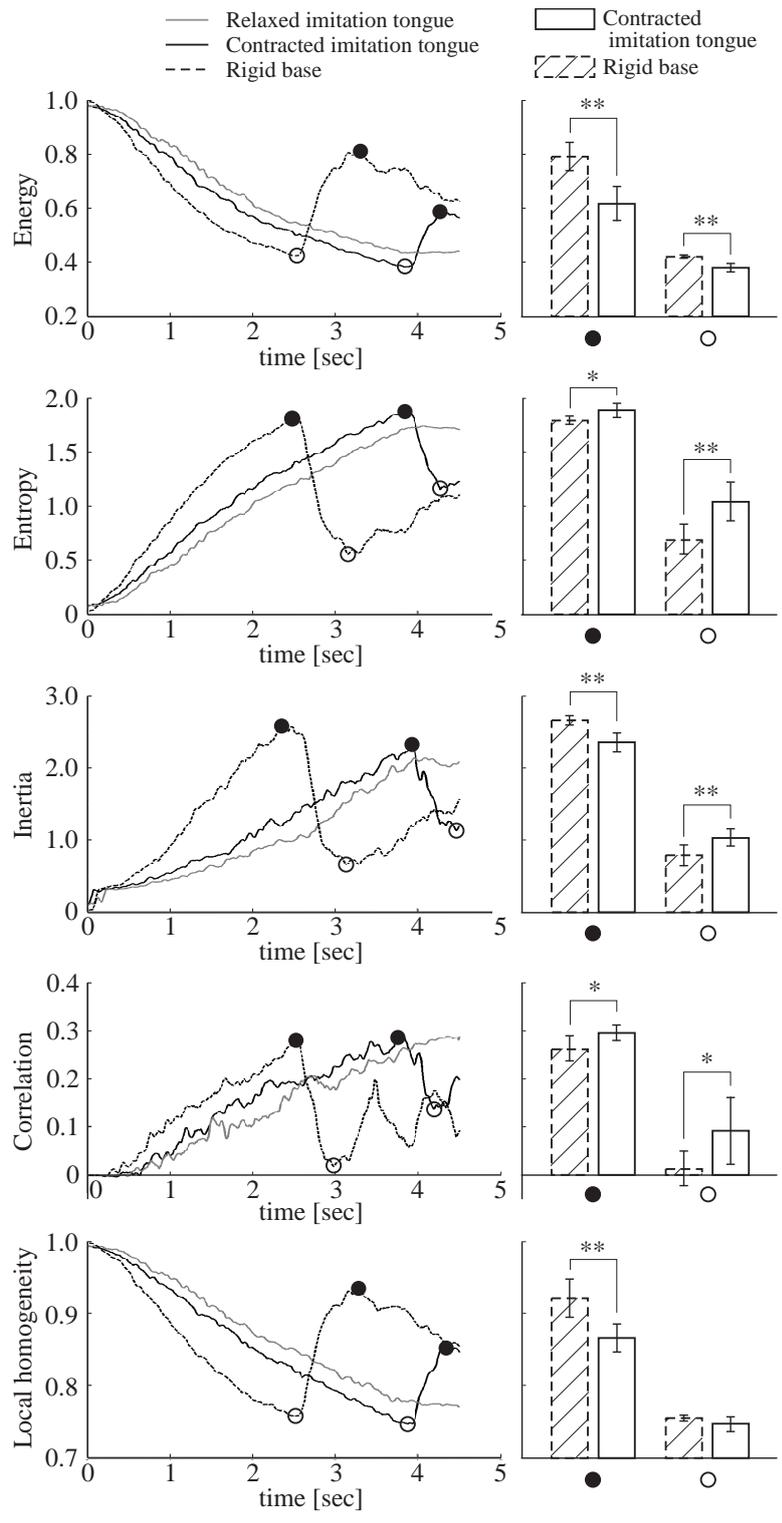
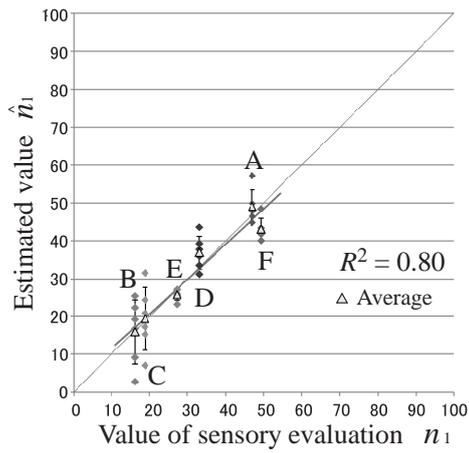


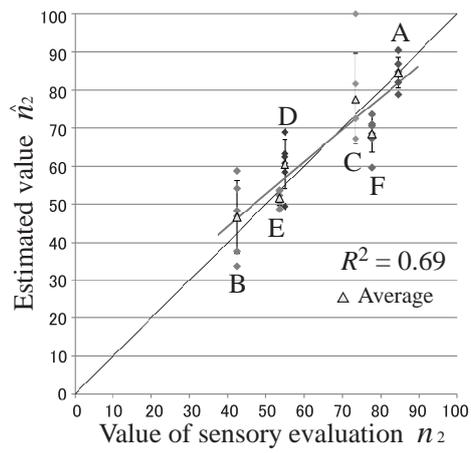
Fig. 5.11 Examples of feature values with respect to time (● local maximum, ○ local minimum, * $p < 0.05$, and ** $p < 0.01$).

5.4.3.3 実験結果

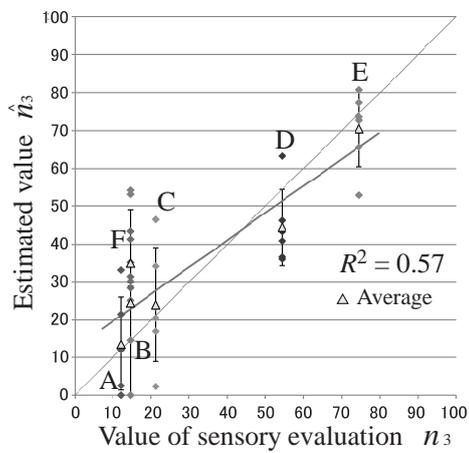
Fig. 5.12～5.14 に、4 種類のテクスチャ評価項目について、テクスチャの官能評価値と推定値の関係を示す。ただし、Fig. 5.12, Fig. 5.13, および Fig. 5.14 は、それぞれ弛緩状態、収縮状態、および剛体土台を用いた場合である。なお、Leave-one-out 交差検定法を用いている⁷¹⁾。以上の結果について、テクスチャの推定精度を決定係数 R^2 で評価する。Fig. 5.15 に、テクスチャ評価項目ごとに 3 つの模擬舌の弾性状態における決定係数を比較した結果を示す。4 つのテクスチャ評価項目における決定係数の平均値 \bar{R}^2 は、収縮状態の模擬舌を用いた場合が最大であり、今回の実験条件において弾性状態を統一するのであれば収縮状態が最適と言える。収縮状態の模擬舌を用いた場合は、すべてのテクスチャ評価項目において剛体土台を用いた場合よりも決定係数が上昇しており、第 2 章の手法と比較して、テクスチャの推定精度が平均で 10% 向上することがわかる。これは、推定対象がヒトの官能評価値であり、Fig. 5.10(b) に示すような圧力分布データにおいて、ゲルの圧縮と破断の二つの状態が、ヒトの舌式咀嚼に近いという観点でバランス良く含まれたためではないかと考えられる。一方で、興味深いことに、“もちもち感”については、弛緩状態の模擬舌を用いた場合に決定係数が最大となる。ヒトは、舌筋を軟化させることで、あえて舌の受動変形を大きくし、“もちもち感”の感度を向上させている可能性がある。弛緩状態の模擬舌が、このような状況に対応したことは十分に考えられる。また、弛緩状態の模擬舌では、“ねっとり感”と“ざらざら感”の決定係数が他よりも著しく低下している。これは、Fig. 5.10(a) の例で示したように、本来ヒトが舌筋を硬化させることで破断可能なゲル食品の中に、弛緩状態の模擬舌では破断不可能なものが存在したためと想定される。以上のように、テクスチャ評価項目とゲル食品の種類に応じた適切な模擬舌の弾性が存在することがわかる。



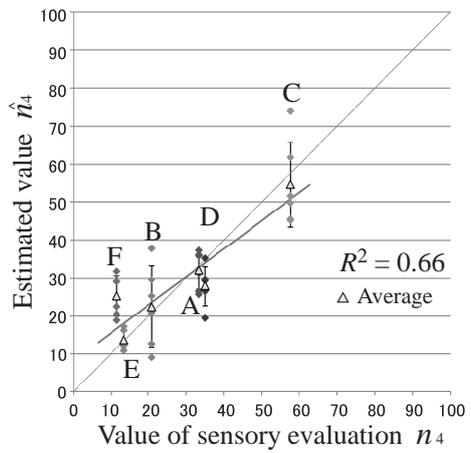
Elasticity: $i = 1$



Smoothness: $i = 2$

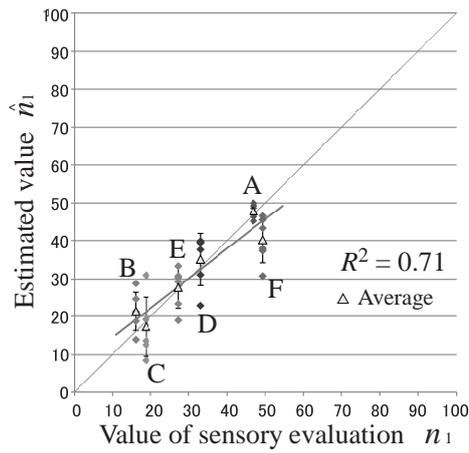


Stickiness: $i = 3$

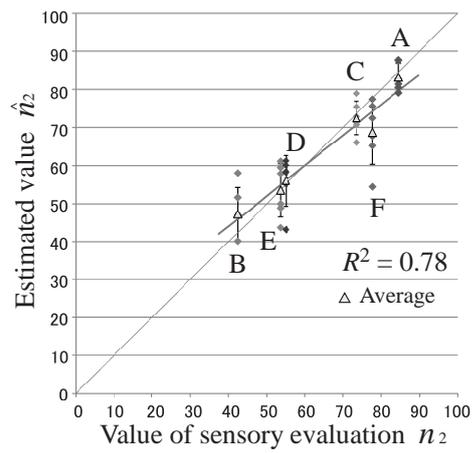


Granularity: $i = 4$

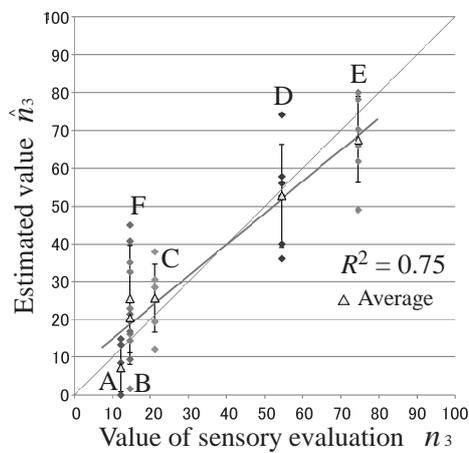
Fig. 5.12 Estimation with relaxed imitation tongue.



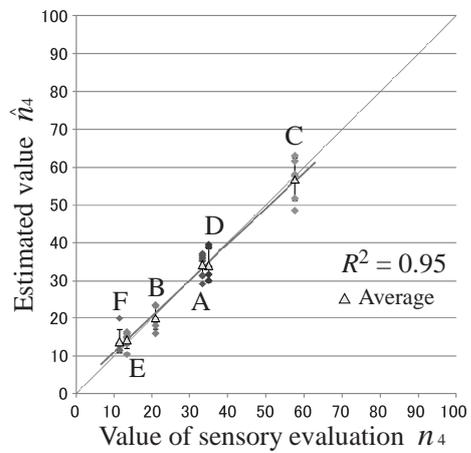
Elasticity: $i = 1$



Smoothness: $i = 2$

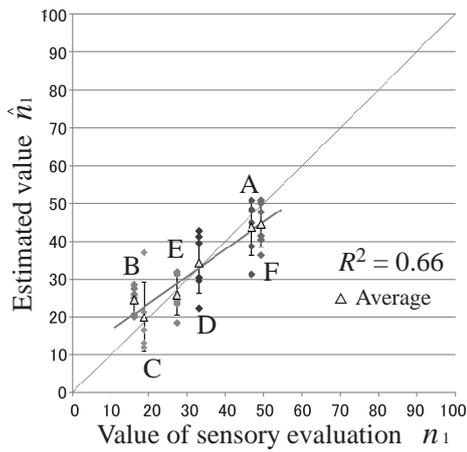


Stickiness: $i = 3$

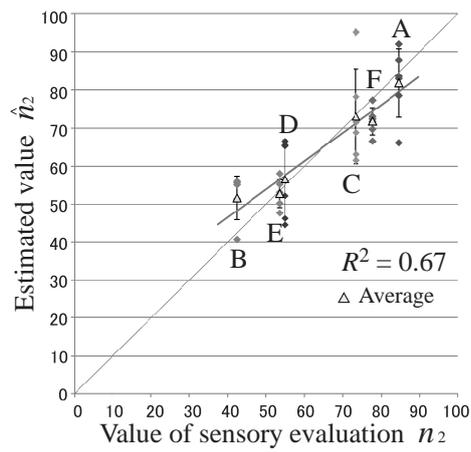


Granularity: $i = 4$

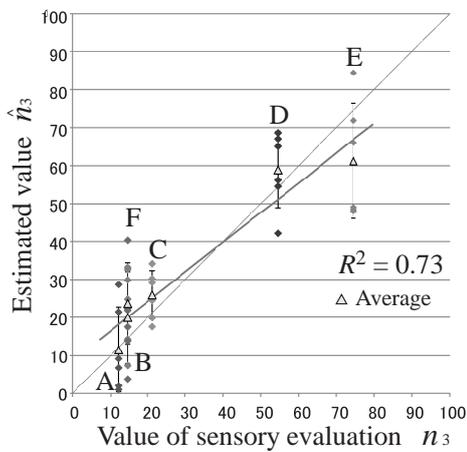
Fig. 5.13 Estimation with contracted imitation tongue.



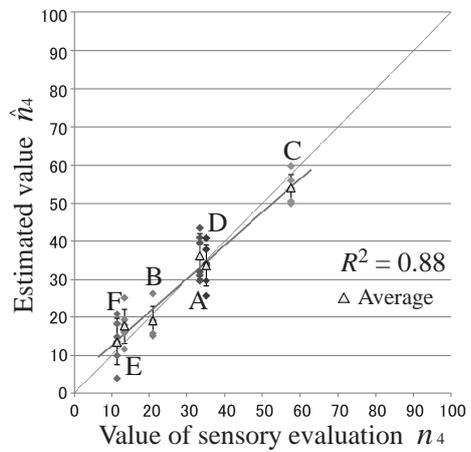
Elasticity: $i = 1$



Smoothness: $i = 2$



Stickiness: $i = 3$



Granularity: $i = 4$

Fig. 5.14 Estimation with rigid base.

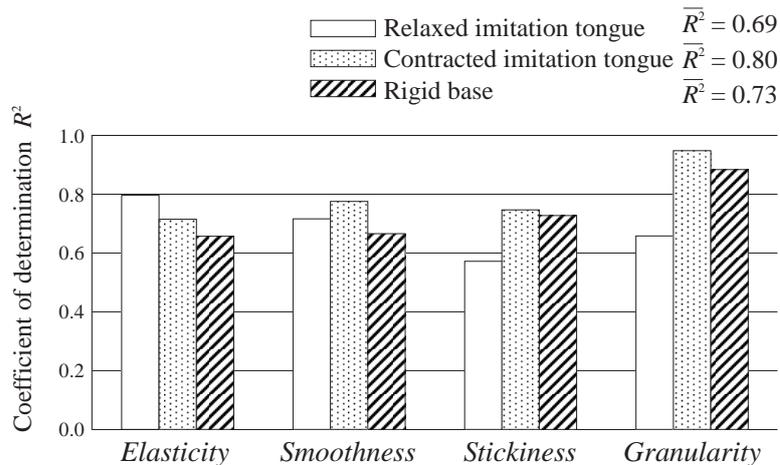


Fig. 5.15 Coefficients of determination in different conditions of imitation tongue.

5.5 まとめ

本章では、ヒトの舌の弾性変形を考慮したゲル食品のテクスチャ推定システムについて議論した。舌式咀嚼を人工的に再現するための模擬舌を提案し、その基本構造と弾性可変原理を示した。プロトタイプを製作し、ヒトの舌の弛緩状態から収縮状態までの弾性を再現可能なことを示した。さらに、模擬舌を導入した咀嚼ロボットを開発し、模擬舌の弾性状態に応じてゲル食品を圧縮・破断させた際の圧力分布が異なることを示すとともに、ゲル食品のテクスチャ推定実験を行い、テクスチャ評価項目およびゲル食品の種類に応じて、推定精度を向上させるための適切な模擬舌の弾性が存在することを明らかにした。

第6章

結論

6.1 まとめ

本研究では、食品テクスチャの客観的・定量的評価手法を確立することを目的とし、従来困難であった「ヒトが舌上で感知する繊細なテクスチャを評価指標として数値で呈示する」ロボットセンシングシステムを開発した。

第1章では、研究背景および研究目的についてまとめ、従来研究との比較から本研究の位置付けについて示した。

第2章では、物理的測定により食品テクスチャを客観的かつ定量的に評価するために、咀嚼ロボットによる食品圧縮破断中の圧力分布（咀嚼圧力分布）からテクスチャを評価する手法を提案した。圧力分布データに画像テクスチャ解析手法を適用し、算出された特徴量とテクスチャ官能評価値との数理モデルを構築した。複数種類のゲルを用いた実験により、提案手法が、機械的特性および幾何学的特性の両者についてテクスチャ官能評価値を推定できることを確認した。

第3章では、特徴量の定義自体を学習により獲得するために、畳み込みニューラルネットワークを用いたゲル食品のテクスチャ推定手法を提案した。この手法では前章よりも多様な食品テクスチャの推定を高精度で実現することが期待できる。CNNへの入力は圧力分布データを画像として時系列順に複数フレーム結合したものをを用いた。CNNは7層からなる畳み込み層・プーリング層と2層からなる全結合層によって構成した。検証実験を行い、提案手法によって高精度に食品のテクスチャが推定可能なこと、第2章の手法では推定が困難であるテクスチャ評価項目にまで対応可能なこと、食品破断時および圧縮終了時の2フレームから成る入力画像でテクスチャ推定が可能なことを明らかにした。

第4章では、模擬舌の設計と評価に向け、in vivoで舌組織の弾性を評価する計測シス

テムについて議論した。グリッパ式弾性計測機構を採用し、舌の厚さ変化に依存することなく評価するために、弾性の評価指標として等価舌ヤング率を導入した。また、筋電位センサを用いた舌筋の収縮状態識別機能を実装した。模擬対象モデルを用いた基礎実験により、適切な接触部を用いれば、対象物の厚さにかかわらず組織の弾性を妥当に評価できることを示した後、ヒトの舌に対する計測実験により、等価舌ヤング率を定量的に評価し、舌筋の弛緩時に比べ、収縮時の方が、約4倍弾性が高くなることを示した。

第5章では、舌式咀嚼を人工的に再現するための模擬舌を提案し、製作したプロトタイプによってヒトの舌の弾性を弛緩状態から収縮状態まで再現可能なことを示した。模擬舌を導入した咀嚼ロボットを開発し、模擬舌の弾性状態による圧力分布の違いを示すとともに、テクスチャ推定実験を通じて、テクスチャ評価項目およびゲル食品の種類に応じて、推定精度を向上させるための適切な模擬舌の弾性が存在することを明らかにした。

6.2 今後の課題

本論文で提案したテクスチャ推定手法について、推定精度・信頼性の向上、および実用化に向けたいくつかの改善点を検討している。なお、本論文ではCNNと模擬舌を同時に導入したテクスチャ推定実験は行っていないが、CNNによって圧力分布の解析能力を向上させることと、模擬舌によってヒトの咀嚼圧力分布に近づけることは、いずれも重要である。今後は両者を導入したシステムを用いてテクスチャの推定を行う。推定実験全般について、現在のところ、モデル化に使用したゲル食品と同種類のゲル食品の推定実験を行い、十分な推定精度が確認できた段階である。今後は、モデル化に使用していないゲル食品、すなわち完全未知なゲル食品のテクスチャ推定実験を実施し、提案手法の信頼性を検討しなければならない。当然、完全未知なゲル食品の推定は容易ではなく、その精度は現在達成している推定精度から大きく悪化することが予想される。提案システムの各要素について改善点を検討する。まず、咀嚼ロボットの圧縮・破断動作の変更が考えられる。現在は2 [mm/s] という十分にゆっくりなプレート下降動作を指令しており、これに応じたゲル食品の圧縮・破断スピードも緩やかといえよう。これに対して、ヒトの舌の押しつぶし動作に準拠し、ロボットに高速動作や繰り返し動作を指令することで、ゲル食品の圧縮・破断スピードや様相にも変化が生まれ、これを圧力分布測定によって捉えることができれば、現在は見いだせていない特徴量を抽出できる可能性がある。このとき、圧力分布データに含まれる空間的特徴量のみでなく、時間的特徴量の重要性が増すであろう。とりわけ、速度依存性のあるテクスチャ評価項目を推定するために必要な改善点であると考えられる。現在、特徴量の定義を学習するCNNについて、AlexNet⁷²⁾ ベースのCNNを試

した段階であるが、今後、他の CNN モデル⁷³⁾⁻⁷⁷⁾を導入する。どのようなネットワーク構造が、適切に食品テクスチャと結び付く時空間特徴量を捉え切ることができるのか探求したい。さらには、模擬舌弾性の最適化問題も興味深い課題の一つと睨んでいる。第5章にて、テクスチャ評価項目に応じて最適な模擬舌弾性が変化することを指摘した。ただし、ロボットの圧縮・破断動作が変化すれば、最適弾性が変化する可能性もある。さらには、ヒトは咀嚼する過程で、意識的あるいは無意識的に舌弾性を動的に変化させ、圧縮・破断とテクスチャ感知を巧みに切り替えながら喫食する。これをロボットシステムの振る舞いに反映させ、食品圧縮・破断の最中に模擬舌弾性を変化させることで、新たな咀嚼圧力分布パターンの生成および特徴量の獲得も期待できる。以上、咀嚼ロボット（プレート運動、模擬舌弾性）、および CNN（特徴量抽出、テクスチャ推定モデル）の両面から提案システムをブラッシュアップしていきたい。

提案手法の推定精度・信頼性が向上し、超高齢化社会に向け、介護用食品の評価・開発支援に役立てられることを期待している。同時に、本システムを通じて、咀嚼圧力分布とテクスチャとの本質的な関係を浮き彫りにし、ヒトの感覚と動作、両方の観点から官能評価処理メカニズムの解明に貢献したい。

参考文献

- 1) K. Nishinari: “Texture and Rheology in Food and Health,” *Food Science and Technology Research*, vol. 15, pp. 99–106, 2009.
- 2) T. Funami: “Next Target for Food Hydrocolloid Studies: Texture Design of Foods Using Hydrocolloid Technology,” *Food Hydrocolloids*, vol. 25, pp. 1904–1914, 2011.
- 3) K. Nishinari: “Rheology, Food Texture and Mastication,” *Journal of Texture Studies*, vol. 35, pp. 113–124, 2004.
- 4) A. S. Szczesniak: “Texture is a Sensory Property,” *Food Quality and Preference*, vol. 13, pp. 215–225, 2002.
- 5) K. Nishinari, F. Hayakawa, C. -F. Xia, L. Huang, J. -F. Meullenet, and J. -M. Sieffermann: “Comparative Study of Texture Terms: English, French, Japanese and Chinese,” *Journal of Texture Studies*, vol. 39, pp. 530–568, 2008.
- 6) M. C. Bourne: “Food Texture and Viscosity, Second Edition: Concept and Measurement,” Academic Press, 2002.
- 7) Stable Micro Systems Ltd.,
<http://www.stablemicrosystems.com/>
- 8) Illinois Tool Works Inc.,
<http://www.instron.com/>
- 9) 株式会社山電,
<http://www.ymdninc.co.jp/>
- 10) 株式会社島津製作所,
<http://www.an.shimadzu.co.jp/test/products/mtr103/index.htm>
- 11) S. Okada, H. Nakamoto, F. Kobayashi, and F. Kojima: “A Study on Classification of Food Texture with Recurrent Neural Network,” *ICIRA 2016: Intelligent*

- Robotics and Applications, Lecture Notes in Computer Science, pp. 247–256, 2016.
- 12) H. Iwata, H. Yano, T. Uemura, and T. Moriya: “Food Texture Display,” Proc. of the 12th Int. Symp. on Haptic Interfaces for Virtual Environment and Teleoperator Systems, pp. 310–315, 2004.
 - 13) C. Sun, J. E. Bronlund, L. Huang, M. P. Morgenstern, and W. L. Xu: “A Linkage Chewing Machine for Food Texture Analysis,” Proc. of the 15th Int. Conf. on Mechatronics and Machine Vision in Practice, pp. 299–304, 2008.
 - 14) W. L. Xu, J. Bronlund, and J. Kieser: “Choosing new ways to chew: a robotic model of the human masticatory system for reproducing chewing behaviors,” IEEE Robotics & Automation Magazine, Vol. 12, Issue 2, pp. 90-100, 2005.
 - 15) D. Lewis: “A robotic chewing device for food evaluation,” Massey University, 2006.
 - 16) W. L. Xu, D. Lewis, J. E. Bronlund, and J. -S. Pap: “Design of a biologically inspired parallel robot for foods chewing,” IEEE Trans. on Industrial Electronics, Vol. 55, Issue 2, pp. 832–841, 2008.
 - 17) W. L. Xu, D. Lewis, J. E. Bronlund, and M. P. Morgenstern: “Mechanism, design and motion control of a linkage chewing device for food evaluation,” Mechanism and Machine Theory, Vol. 32, pp. 376-389, 2008.
 - 18) W. L. Xu, J. D. Torrance, B. Q. Chen, J. Potgieter, J.E. Bronlund, and J. -S. Pap: “Kinematics and Experiments of a Life-Sized Masticatory Robot for Characterizing Food Texture,” IEEE Trans. on Industrial Electronics, Vol. 55, Issue 5, pp. 2121–2132, 2008.
 - 19) J. -F. Meulleneta and R. K. Gandhapunenib: “Development of the BITE Master II and its application to the study of cheese hardness,” Physiology & Behavior, Vol. 89, Issue 1, pp. 39–43, 2006.
 - 20) J. -F. Meullenet, M. L. Finney, and M. Gaud: “Measurement of biting velocities, and predetermined and individual crosshead speed instrumental imitative tests for predicting cheese hardness,” Journal of Texture Studies, Vol. 33, pp. 45–59, 2007.
 - 21) C. Hoebler, A. Karinthe, M. F. Devaux, F. Guillon, D. J. Gallant, B. Bouchet, C. Melegari, and J. L. Barry: “Physical and Chemical Transformations of Cereal Food During Oral Digestion in Human Subjects,” British Journal of Nutrition,

- vol. 80, issue 5, pp. 429–436, 1998.
- 22) C. Tournier, M. Grass, D. Zope, C. Salles, and D. Bertrand: “Characterization of Bread Breakdown During Mastication by Image Texture Analysis,” *Journal of Food Engineering*, vol. 113, no. 4, pp. 615–622, 2012.
 - 23) G. Arvisenet, L. Billy, P. Poinot, E. Vigneau, D. Bertrand, and C. Prost: “Effect of Apple Particle State on the Release of Volatile Compounds in a New Artificial Mouth Device,” *Journal of Agricultural and Food Chemistry*, vol. 56, no. 9, pp. 3245–3253, 2008.
 - 24) S. Ishihara, M. Nakauma, T. Funami, S. Odake, and K. Nishinari: “Viscoelastic and Fragmentation Characters of Model Bolus from Polysaccharide Gels after Instrumental Mastication,” *Food Hydrocolloids*, vol. 25, pp. 1210–1218, 2011.
 - 25) 今井悦子, 田丸理恵, 畑江敬子, 島田淳子: “口腔における粒子の認識と粒度の識別におよぼす食品物性の影響”, *日本家政学会誌*, vol. 49, no. 3, pp. 243–253, 1998.
 - 26) K. Kohyama, M. Nishi, and T. Suzuki: “Measuring Texture of Crackers with a Multiple-Point Sheet Sensor,” *Journal of Food Science*, vol. 62, pp. 922–925, 1997.
 - 27) K. Kohyama, T. Sakai, T. Azuma, T. Mizuguchi, and I. Kimura: “Pressure Distribution Measurement in Biting Surimi Gels with Molars Using a Multiple-Point Sheet Sensor,” *Bioscience, Biotechnology, and Biochemistry*, vol. 65, pp. 2597–2603, 2001.
 - 28) H. Dan, T. Azuma, and K. Kohyama: “Characterization of Spatiotemporal Stress Distribution During Food Fracture by Image Texture Analysis Methods,” *Journal of Food Engineering*, vol. 81, no. 4, pp. 429–436, 2007.
 - 29) M. K. Johnson and E. H. Adelson: “Retrographic sensing for the measurement of surface texture and shape,” *Proc. of IEEE Conf. on Computer Vision and Pattern Recognition*, pp. 1070–1077, 2009.
 - 30) W. Yuan, M. A. Srinivasan, E. H. Adelson: “Estimating object hardness with a GelSight touch sensor,” *IEEE/RSJ International Conf. on Intelligent Robots and Systems (IROS)*, 2016.
 - 31) 神山かおる, 他: “舌で押しつぶして食しやすい固形状食品の簡易評価法”, 特開 2013–64691, 2013.
 - 32) 佐藤仁: “口腔粘膜病変の硬さ測定に関する研究”, *口腔病学会誌*. vol. 6, pp. 374–396, 1994.

- 33) H. Iwamasa and S. Hirai: “Binding of Food Materials with a Tension-Sensitive Elastic Thread,” Proc. IEEE Int. Conf. on Robotics and Automation, pp. 4298–4303, 2015.
- 34) N. Sakamoto, M. Higashimori, T. Tsuji, and M. Kaneko: “An Optimum Design of Robotic Hand for Handling a Visco-Elastic Object Based on Maxwell Model,” Proc. of the IEEE Int. Conf. on Robotics and Automation, pp. 1219–1225, 2007.
- 35) 遠藤和美, 張鵬林, 平井慎一, 徳本真一: “柔軟物の内部変形計測による非一様 FE モデルの力学パラメータ同定方法の検証”, 第 8 回計測自動制御学会システムインテグレーション部門講演会 (SI2007) 論文集, pp. 1170–1171, 2007.
- 36) 田中由浩, 堂本和樹, 佐野明人, 藤本英雄: “バルーンの膨張現象を利用した触覚センサー生体適合型センサシステムの開発”, 日本ロボット学会誌, vol. 28, no. 7, pp. 811–820, 2010.
- 37) H. Okayasu, J. Okamoto, M. G. Fujie, and H. Iseki: “Development of a Hydraulically-Driven Flexible Manipulator Including Passive Safety Method,” Proc. of the IEEE Int. Conf. Robotics and Automation, pp. 2901–2907, 2005.
- 38) 青木たまよ, 林豊彦, 中嶋新一, 小林博, 宮川道夫: “自律顎運動ロボットの顎体と咬合力センサの試作”, 信学技報, MBE 93-75, pp. 115–122, 1993.
- 39) 中嶋 新一, 小林 祐司, 林 豊彦, 小林 博: “二次元型顎運動シミュレータ (JSN/S1) ～かみしめを伴う開閉口運動制御～”, 日本ロボット学会誌, Vol. 15, No. 5 pp. 722–727, 1997.
- 40) 林豊彦, 宮嶋晃子, 中村康雄, 他: “自律顎運動シミュレータ JSN/2C の咀嚼運動シミュレータとしての基本性能評価”, バイオメカニズム vol. 18, pp. 141–152, 2006.
- 41) 林豊彦, 川田充洋, 中嶋新一, 井上誠, 前田義信: “自律顎運動シミュレータ JSN/3X の開発”, バイオメカニズム vol. 12, pp. 179–191, 2012.
- 42) 大月佳代子, 大西正俊, 緒方宏昭, 渡井幸雄, 中野佳央, 高西淳夫, 高信英明: “咀嚼ロボット・メカニズムの応用による開口訓練装置開発についての検討”, 第 8 回日本顎関節学会総会, 1995.
- 43) 大月佳代子, 大西正俊, 辻政秀, 渡井幸雄, 高西淳夫, 高信英明: “咀嚼ロボットの応用による開閉口訓練装置の開発についての検討”, 日本顎関節学会誌. vol. 7, no. 3, pp. 69–78, 1995.
- 44) 大月佳代子, 渡井幸雄, 辻政秀, 大西正俊, 高西淳夫, 高信英明, 矢島武幸: “咀嚼ロボットを応用した開閉口訓練装置 (WY-1) の開発についての検討”, 第 50 回日本口腔科学会総会, 1996

- 45) 大月佳代子, 渡井幸雄, 辻政秀, 大西正俊, 高西淳夫, 高信英明, 矢島武幸: “咀嚼ロボットを応用した開閉口訓練装置の開発についての検討”, 第9回日本顎関節学会総会, 1996.
- 46) 高信英明, 高西淳夫, 矢島武幸, 大西正俊, 大月佳代子: “デンタルロボティクスの提案－開閉口訓練システムの開発－”, 第14回日本ロボット学会学術講演会, 1996.
- 47) 大月佳代子, 辻政秀, 渡井幸雄, 大西正俊, 高西淳夫, 高信英明, 矢島武幸: “咀嚼ロボット開閉口訓練装置1号機 Waseda Yamanashi-1 (WY-1) の開発”, 第41回日本口腔外科学会総会, 1996.
- 48) 高西淳夫, 高信英明, 矢島武幸, 大月佳代子, 大西正俊: “デンタルロボティクスの研究－ロボット開閉口訓練装置 WY-2 (Waseda Yamanashi-2) の開発－”, 第10回日本顎関節学会総会, 1997.
- 49) 高信英明, 矢島武幸, 高西淳夫, 大月佳代子, 大西正俊: “デンタルロボティクスの研究－咀嚼ロボットを応用した開閉口訓練装置の開発と治療への適用－”, 第36回計測自動制御学会学術講演会, 1997.
- 50) 高信英明, 高西淳夫, 大月佳代子, 大西正俊: “デンタルロボティクスの研究－開閉口訓練ロボット WY-2 の開発－”, 第51回日本口腔科学会総会, 1997.
- 51) 高信英明, 矢島武幸, 高西淳夫, 大月佳代子, 大西正俊: “デンタルロボティクスの研究－咀嚼ロボットと開閉口訓練ロボット－”, 第18回バイオメカニズム学術講演会, 1997.
- 52) H. Takanobu, T. Yajima, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Mouth Opening and Closing Training Robot WY-1,” IEEE Int. Workshop on Robot and Human Communication (RO-MAN '98), pp. 71–76, 1998.
- 53) H. Takanobu, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Dental Robotics-Mouth Opening and Closing Training Robot-,” CISM-IFTToMM Symposium on Theory and Practice of Robots and Manipulators (Ro.Man.Sy.'98), pp. 427–434, 1998.
- 54) H. Takanobu, T. Yajima, M. Nakazawa, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Quantification of Masticatory Efficiency with a Mastication Robot,” IEEE Int. Conf. on Robotics and Automations (ICRA '98), pp. 1635–1640, 1998.
- 55) H. Takanobu, M. Nakazawa, T. Maruyama, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Robotic Training for Mouth Opening and Closing Disorders,” IEEE Int. Conf. on Robotics and Automations (ICRA '99), pp. 23–28, 1999.

- 56) H. Takanobu, M. Nakazawa, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Clinical Training with Mouth Opening and Closing Training Robot WY-3,” IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS ’99), pp. 1604–1609, 1999.
- 57) H. Takanobu, T. Yajima, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Three Degrees of Freedom Mouth Opening and Closing Training Robot,” IEEE Systems, Man and Cybernetics Conference (SMC’99), pp. II-448–453, 1999.
- 58) H. Takanobu, R. Soyama, A. Takanishi, K. Ohtsuki, D. Ozawa, and M. Ohnishi: “Remote Treatment with 6-DOF Mouth Opening and Closing Training Robot,” IEEE Int. Conf. on Intelligent Robots and Systems, pp. 553–558, 2000.
- 59) H. Takanobu, T. Maruyama, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Universal Dental Robot –6-DOF Mouth Opening and Closing Training Robot WY-5,” CISM-IFTToMM Symposium on Theory and Practice of Robots and Manipulators (RoManSy 13), pp. 275–284, 2000.
- 60) H. Takanobu, T. Maruyama, A. Takanishi, K. Ohtsuki, and M. Ohnishi: “Mouth Opening and Closing Training with 6-DOF Parallel Robot,” IEEE Int. Conf. on Robotics and Automation (ICRA 2000), pp. 1384–1389, 2000.
- 61) H. Takanobu and A. Takanishi: “Dental Robotics for Remote Training between Tokyo and Yamanashi 120 km,” 2001 Int. Workshop on Bio-Robotics and Teleoperation (IWBRT2001), pp. 68–75, 2001.
- 62) 高信英明, 中澤正幸, 高西淳夫: “咀嚼機械の試作とそれを用いた咀嚼効率の定量化”, 日本機械学会論文集 C 編, Vol. 68, pp. 1239–1244, 2002.
- 63) A. Woda, A. Mishellany-Dutour, L. Batier, O. François, J. -P. Meunier, B. Reynaud, M. Alric, and M. -A. Peyron: “Development and validation of a mastication simulator,” J. Biomechanics, vol. 43, pp. 1667–1673, 2010.
- 64) C. Salles, A. Tarrega, P. Mielle, J. Maratray, P. Gorria, J. Liaboeuf, and J. J. Liodenot: “Development of a chewing simulator for food breakdown and the analysis of in vivo flavor compound release in a mouth environment,” J. Food Eng., vol. 82, pp. 189–198, 2007.
- 65) 提坂清志, 小林宏, 道脇幸博: “飲み込むメカニズム解明のための嚥下ロボットの開発”, ロボティクス・メカトロニクス講演会講演概要集, 1A2-C03, 2013.
- 66) 道脇幸博: “舌ロボットによる嚥下運動の再現”, 臨床バイオメカニクス, Vol. 33, pp. 63–68, 2012.
- 67) H. Mizunuma, M. Sonomura, K. Shimokasa, H. Ogoshi, S. Nakamura and N.

- Tayama: “Numerical Modeling and Simulation on the Swallowing of Jelly,” *Journal of Texture Studies*, Vol. 40, pp. 406–426, 2009.
- 68) 小暮孝彦, 矢野亜紀子, 中村達也, 水沼博: “食物のえん下評価のための舌・咽喉ロボットモデル”, 日本ロボット学会学術講演会, 1L23, 2002.
- 69) R. M. Haralick, K. Shanmugam, and I. Dinstein: “Textural Features for Image Classification,” *IEEE Trans. on Systems, Man and Cybernetics*, vol. SMC-3, no. 6, pp. 610–621, 1973.
- 70) M. E. Wewers and N. K. Lowe: “A Critical Review of Visual Analogue Scales in the Measurement of Clinical Phenomena,” *Research in Nursing and Health*, vol. 13, pp. 227–236, 1990.
- 71) S. Arlot: “A Survey of Cross-Validation Procedures for Model Selection,” *Statistics Surveys*, vol. 4, pp. 40–79, 2010.
- 72) A. Krizhevsky, I. Sutskever, and G. E. Hinton: “ImageNet Classification with Deep Convolutional Neural Networks,” *Proc. of Advances in Neural Information Processing Systems 25 (NIPS 2012)*, pp. 1097–1105, 2012.
- 73) Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner: “Gradient-based learning applied to document recognition,” *Proc. of the IEEE*, vol. 86, pp. 2278–2324, 1998.
- 74) K. Simonyan and A. Zisserman: “Very Deep Convolutional Networks for Large-Scale Image Recognition,” *arXiv technical report*, 2014.
- 75) C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich: “Going Deeper with Convolutions,” *Proc. of 2015 IEEE Conf. on Computer Vision and Pattern Recognition*, 2015.
- 76) K. He, X. Zhang, S. Ren, and J. Sun: “Deep Residual Learning for Image Recognition,” *Proc. of 2016 IEEE Conf. on Computer Vision and Pattern Recognition*, pp. 770–778, 2016.
- 77) D. Tran, L. Bourdev, R. Fergus, L. Torresani and M. Paluri: “Learning Spatiotemporal Features With 3D Convolutional Networks,” *Proc. of IEEE Int. Conf. on Computer Vision (ICCV)*, pp. 4489–4497, 2015.
- 78) T. Saitoh, Z. Zhou, G. Zhao and M. Pietikainen: “Concatenated Frame Image Based CNN for Visual Speech Recognition,” *Computer Vision – ACCV 2016 Workshops Part II*, pp. 277–289, 2016.
- 79) D. P. Kingma and J. Ba: “Adam: A Method for Stochastic Optimization,” 3rd

Int. Conf. on Learning Representations, 2015.

謝 辞

本論文の執筆に際して様々なご指導を頂きました東森充准教授には、研究の最初期から大変貴重なご指導・ご鞭撻を賜るとともに、挫けそうになるところを何度も叱咤激励いただき心より感謝いたします。また、金子真教授，大須賀公一教授，山田克彦教授には，ご多忙の中，本論文の審査を担当して頂き誠にありがとうございます。高山俊男准教授，洞出光洋助教，伊藤弘明特任研究員をはじめ，日ごろから多くのご支援，ご助言を頂き，素晴らしい環境で研究させていただいた金子・東森・高山研究室の皆様にご心より感謝申し上げます。食品に関して有益な助言をいただき，試料を提供してくださった三栄源エフ・エフ・アイ株式会社 第一事業部 テクスチャーデザイン基盤研究室の中馬誠様，池上聡様，中尾理美様，石原清香様に深く感謝申し上げます。串田啓介氏，黒瀬優介氏，Ixchel Georgina Ramirez-Alpizar 氏，山本武氏，熊倉駿氏，最後に，私の研究活動に理解を示し，温かく見守ってくれた家族に心から感謝します。

業 績

学術論文

1. A. Shibata, A. Ikegami, M. Nakauma, and M. Higashimori: Convolutional Neural Network based Estimation of Gel-like Food Texture by a Robotic Sensing System, *Robotics (MDPI)*, vol. 6, no. 4, 37, 2017.
2. 柴田曉秀, 石原清香, 中尾理美, 池上聡, 中馬誠, 東森充: 弾性可変型模擬舌を用いた食品テクスチャセンシング, *日本ロボット学会誌*, vol. 34, no. 9, pp. 631–639, 2016.

国際会議

Full-Paper Review

1. A. Shibata, A. Ikegami, S. Nakao, S. Ishihara, M. Nakauma, and M. Higashimori: Food Texture Sensing by Using Imitation Tongue with Variable Elasticity, *Proc. of 2016 IEEE/SICE Int. Symposium on System Integration (SII2016)*, (Sapporo, Japan, 2016.12.14), pp. 421–427.
2. A. Shibata, M. Higashimori, I. G. Ramirez-Alpizar, and M. Kaneko: Tongue Elasticity Sensing with Muscle Contraction Monitoring, *Proc. of the 2012 ICME Int. Conf. on Complex Medical Engineering (CME2012)*, (Kobe, Japan, 2012.7.2), pp. 511–516.

国内会議

1. 柴田暁秀, 池上聡, 中馬誠, 東森充: 畳み込みニューラルネットワークを用いた食品テクスチャ推定, 第18回計測自動制御学会システムインテグレーション部門講演会 (SI2017) 論文集, 2D4-08, 2017.
2. 柴田暁秀, 東森充: 弾性可変型模擬舌を用いたゲル状食品の食感評価システム, 生体医工学シンポジウム, 1A-2-6, 2016.
3. 柴田暁秀, 山本武, 東森充, 石原清香, 中馬誠: 弾性可変型模擬舌を用いたゲル食品のテクスチャセンシング, 日本機械学会ロボティクス・メカトロニクス部門ロボティクス・メカトロニクス講演会 2015 講演論文集, 2A2-W09, 2015.

その他

1. 熊倉駿, 柴田暁秀, 池上聡, 中尾理美, 石原清香, 中馬誠, 東森充: 弾性模擬舌による凝集性抽出効果に基づくペースト状食品の食感評価システム, 計測自動制御学会論文集, vol. 52, no. 8, pp. 411–418, 2016.
2. S. Kumakura, A. Shibata, and M. Higashimori: Texture Evaluation System of Paste Food by Using Elastic Imitation Tongue, Proc. of the 2016 IEEE Int. Conf. on Systems, Man, and Cybernetics (SMC 2016), (Budapest, Hungary, 2016.10.11), pp. 4781–4786.
3. J. Nishiyama, C. Tsai, M. Quigley, I. Kao, A. Shibata, M. Higashimori, and M. Kaneko: An Experimental Study of Biologically Inspired Artificial Skin Sensor Under Static Loading and Dynamic Stimuli, Proc. of the IEEE Int. Conf. on Robotics and Automation (ICRA2011), (Shanghai, China, 2011.5), pp. 1778–1773.
4. C. Tsai, I. Kao, A. Shibata, K. Yoshimoto, M. Higashimori, and M. Kaneko: Experimental Study of Creep Response of Viscoelastic Contact Interface Under Force Control, Proc. of the IEEE/RSJ Int. Conf. on Intelligent Robots and Systems (IROS2010), (Taipei, Taiwan, 2010.10.20), pp. 4257–4280.
5. 三輪昌徳, 柴田暁秀, 東森充, 池上聡, 中馬誠: 擬似咽頭通過に基づく食感評価システムに関する基礎研究, 第40回日本バイオレオロジー学会年会, OS7-02, 2017.

6. 柴田曉秀, 三木恵理子, 東森充, 池上聡, 中馬誠, 堀一浩, 小野高裕: 半波リサージ図形に基づく摂食舌圧解析, 日本機械学会第 29 回バイオエンジニアリング講演会講演論文集, 1D37, 2017.
7. 熊倉駿, 柴田曉秀, 東森充, 池上聡, 中馬誠, 堀一浩, 小野高裕: リサージ図形を用いたゲル摂食舌圧の可視化と特徴量抽出, 生体医工学シンポジウム, 1A-2-7, 2016.
8. 柴田曉秀, 東森充, 熊倉駿, 池上聡, 中馬誠, 堀一浩, 小野高裕: 多点舌圧センシングに基づくゲル摂食挙動の時空間解析, 日本機械学会ロボティクス・メカトロニクス部門ロボティクス・メカトロニクス講演会 2016 講演論文集, 1A2-13a1, 2016.
9. 熊倉駿, 柴田曉秀, 東森充, 池上聡, 中尾理美, 石原清香, 中馬誠: 模擬舌-ペースト食系の圧力分布解析に基づく食品テクスチャ評価法, 日本機械学会ロボティクス・メカトロニクス部門ロボティクス・メカトロニクス講演会 2015 講演論文集, 2A2-W07, 2015.
10. 石井亮平, 柴田曉秀, 東森充, 金子真, 玉置俊介, 坂田泰史, 山本一博: 小型実験動物のためのバルーン式左室弾性センシング, 第 11 回計測自動制御学会システムインテグレーション部門講演会 (SI2010) 論文集, 1D4-3, pp.249-250, 2010.
11. 柴田曉秀, ティオン ホー ヒー マイケル, 多田隈建二郎, 東森充, 金子真, 上村大輔, 坂田泰史, 山本一博: 輪切りモデルを用いたマウス左心室の弾性センシング, 日本機械学会ロボティクス・メカトロニクス部門ロボティクス・メカトロニクス講演会 2010 講演論文集, 2A2-G24, 2010.
12. 金子真, 水田知宏, 柴田曉秀, 東森充: アクティブ虚血ダイナミクスと医療診断への応用, 第 8 回計測自動制御学会システムインテグレーション部門講演会 (SI2007) 論文集, 1B2-2, pp.65-66, 2007.
13. 金子真, 柴田曉秀, 水田知宏, 東森充: 医療診断に向けたアクティブ虚血ダイナミクス, 第 25 回日本ロボット学会学術講演会予稿集, 1J35, 2007.

受賞

1. 日本ロボット学会 学会誌論文賞 (2017), (学術論文 2)
2. 計測自動制御学会関西支部技術賞 (2017), (その他 1)
3. Best Student Paper Award, 2016 IEEE/SICE Int. Symp. on System Integration (SII2016) (2016), (国際会議 1)
4. Best Paper Award Finalist, 2016 IEEE/SICE Int. Symp. on System Integration

(SII2016) (2016), (国際会議 1)

5. Best Conference Paper Award Finalist, The 2016 IEEE Int. Conf. on Systems, Man, and Cybernetics (SMC 2016) (2016), (その他 2)