

多種機器計測と分析データを活用した
食品の分類評価に関する研究

2021年3月

北海道科学大学大学院

合田 元清

目次

1章 序論	1-1
1.1 本研究の目的	1-2
1.2 研究手法の概要	1-3
参考文献	1-4
2章 計量化学的手法の原理	2-1
2.1 計量化学(ケモメトリックス)	2-2
2.2 説明変数と目的変数	2-3
2.3 量的データと質的データ	2-4
2.4 データの標準化	2-4
2.5 線形回帰モデル	2-5
2.6 分散分析と多変量分散分析	2-6
2.7 マハラノビス距離	2-10
2.8 クラスタ分析	2-12
2.9 判別分析	2-18
2.10 ニューラルネットワーク	2-23
参考文献	2-30
3章 食品分類に関わる先行研究	3-1
3.1 序論	3-2
3.2 食肉加工品に対する官能・物理特性による評価	3-2
3.3 市販豚肉製品「ロース」における保水力と筋間脂肪含有量の評価	3-3
3.4 ラマン分光法による脂肪結晶状態測定による評価	3-4
3.5 豚肉製品中に含まれるイノシン酸の考察	3-5
3.6 豚肉製品分類法に関わる検討(クラスタ分析)	3-6
3.7 豚肉製品分類法に関わる検討(クラスタ分析・主成分分析)	3-7
3.8 食肉製品(豚・牛・鶏)に関わる検討(クラスタ分析・主成分分析)	3-9
参考文献	3-11

4章 多変量解析手法を用いた食肉製品分類評価の検討	4-1
4.1 緒言	4-2
4.2 先行研究の結果	4-4
4.3 豚肉製品を対象とした検討	4-7
4.4 牛肉製品を対象とした検討	4-30
4.5 本章のまとめ	4-56
参考文献	4-58
5章 ニューラルネットワークを用いた食肉製品分類評価の検討	5-1
5.1 緒言	5-2
5.2 本研究における検証手法	5-3
5.3 本章における結果	5-6
5.4 本章における結果の考察	5-9
5.5 本章のまとめ	5-14
参考文献	5-15
6章 水産食品の分類に寄与する化学成分の評価	6-1
6.1 緒言	6-2
6.2 本研究における検証手法	6-2
6.3 本章における結果	6-6
6.4 本章における結果の考察	6-13
6.5 本章のまとめ	6-17
参考文献	6-19
7章 結論と今後の課題	7-1
参考文献	7-5

謝辞

関連業績及びその他の研究業績

1 章 序論

1.1 本研究の目的

数理科学、統計学、機械学習、パターン認識等を複合し、化学分野における様々な問題解決の一助となる手法として、計量化学(ケモメトリクス)が注目されている。食品科学の分野においても例外ではなく、膨大な化学分析結果から、品質管理手法に直結する1つの要素を見出す手法として利用されている。既往研究では、食肉を含めた食料品の品質管理、産地情報等の安全保障を確保可能なシステム構築に向けた計量化学的手法の導入、特に画像処理、近赤外分光法、ハイパースペクトルカメラによるスペクトルデータ解析等により、食肉製品の化学的、物理的特性を確認し、動物種類の特定や品質管理に応用する技術が検討されている。 [1][2][3][4][5][6][7][8]

一方、食肉製品に含まれている栄養成分を利用し、計量化学的手法を導入した品質管理や分類に関わる研究は遅れており、食肉製品中の無機成分、脂質測定による食肉製品中の栄養価を定性・定量分析する研究に留まる。そこで本研究は、多種多様な機器計測で得られた栄養成分である化学成分値を用い計量化学的手法により、食品分類利用への有用性を評価・検討することが目的である。

本論文は、豚肉製品、牛肉製品、水産食品中に含まれている多種機器計測にて得られる無機成分、ビタミン成分等を中心とした化学成分含有量を文部科学省のデータベース [9]から取得し、それぞれの食品における製品種類や部位、調理法等への分類に必要な化学成分を計量化学的手法で評価した。この結果を用い、化学成分による食品分類の可能性を示した。 [9][10][11][12][13]

本論文は、第4章以降に検討を行っている。第4章では、豚肉製品 88 種類、牛肉製品 132 種類に対し、分散分析、判別分析による化学成分の抽出を試み、分類評価を行った。第5章では、第4章と同様に豚肉製品、牛肉製品に対し、非線形回帰分析であるニューラルネットワークで特定の化学成分含有量による食品分類を評価した。第6章は、水産食品の「製品種類」に対し、判別分析、ニューラルネットワークにて分類の評価を実施した。

1.2 研究手法の概要

本研究では、豚肉製品、牛肉製品、水産食品を対象に食品の化学成分含有量データを抽出し、計量化学的手法(多変量解析法、ニューラルネットワーク)により製品の各項目(「製品種類」「部位」「調理法」等)への分類に寄与する化学成分を探索し評価した。基本的な流れは下図に示す通りである。

各章には検討手法について詳細事項を述べている。

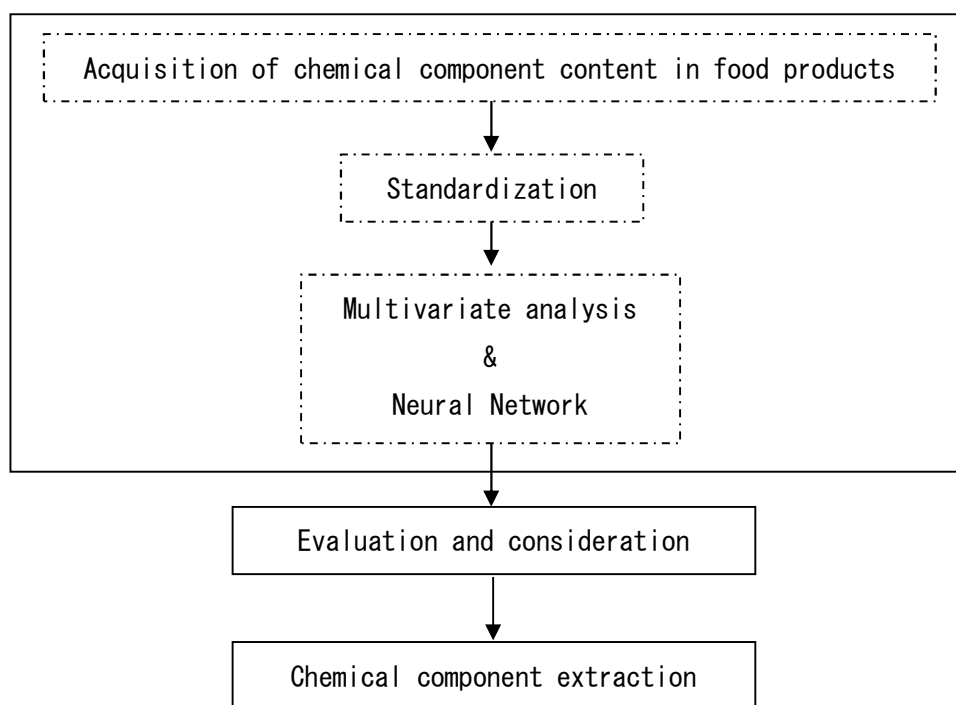


Fig.1-2-1 Research flow.

参考文献

1. Aleixos.N, ほか. Multispectral inspection of citrus in real-time using vision and digital signal processors. : Computers and Electronics in Agriculture.Vol.33,No.2, 2002.
2. Amamcharla.K.J, ほか. Fourier transform infrared spectroscopy (FTIR) as a tool for discriminating Salmonella typhimurium contaminated beef. : Food Qual.Vol.4, 2010.
3. Ampuero.S , Bosset.O.J. The electronic nose applied to dairy products: a review. : Sensors and Actuators.Vol.94, 2003.
4. Andres.S, ほか. Prediction of sensory characteristics of lamb meat samples by near infrared reflectance spectroscopy. : Meat Science.Vol.7, 2007.
5. Ariana.P.D , Lu.R. Evaluation of internal defect and surface color of whole pickles using hyperspectral imaging. : Journal of Food Engineering.Vol.96, 2010.
6. Barbin.D, ほか. Near-infrared hyperspectral imaging for grading and classification of pork. : Meat Science.Vol.90, 2012.
7. Dobrinas.S, ほか. Quality control of some traditional meat products. : Scientific study & reseaech .Vol.14, 2013.
8. Guidetti.R, Beghi.R , Giovezana.V. Chemometrics in food thchnology. : Intechopen, 2011.
9. 文部科学省. 食品成分データベース. (オンライン) 2018 年 7 月. <https://fooddb.mext.go.jp/>.
10. 合田元清 , 小島洋一郎. 計量化学的手法を用いた豚肉製品分類・照合可能性の検討. : 産業応用工学会, 2018.
11. 合田元清, 小島洋一郎. ニューラルネットワークと判別分析による水産食品分類条件の検討. : 産業応用工学会論文誌, Vol.7, No.1, 2019.
12. 合田元清, 小島洋一郎. 水産食品の化学成分値を用いた美味しさ決定要因特定に向けた基礎的検討. : 日本味と匂学会誌,Vol.24,No.3, 2018.
13. 合田元清, 小島洋一郎 , 岩波俊介. 化学成分値を用いた牛肉製品の分類・照合に向けた基礎的検討. : 産業応用工学会論文誌, Vol.8, No.1, 2020.
14. Goda.Motoki , Kojima.Yohichiro. Possible classification of pork products by ICP-MS . : Journal of the Institute of Industrial Applications Engineers, 2020.

2 章 計量化学的手法の原理

2.1 計量化学(ケモメトリックス) [1]

計量化学(ケモメトリックス)とは、数理科学、統計学、機械学習、パターン認識、データマイニング等の手法により、化学分野における諸問題を解決しようとする分析化学の一分野である。実験で得られる膨大なデータに対し、次元の圧縮・視覚化・回帰・分類などを行うことで、構造的に理解しやすい形態に加工し、データの解釈に重要な情報を提供することを目的とする。

今日、計量化学は、科学技術の発展に伴う大量のデータ処理とそのデータから見出す新たな知見を用いる、新たな化学の一分野としての地位を確立したが、その成立は、科学計算がようやく一般的な利用となった 1960 年代まで遡る。それ以前は、FORTRAN、ALGOL によるプログラミング、パンチカードの利用で計算方式を採用しており、大規模計算機としてのイメージが強く、限られた研究者のみが利用を許されていた。1960 年代には化学分野を含めた多くの科学者がコンピュータを利用することが可能となり、数学者が担った大規模計算機開発の重要性が低下した。その代わり、様々な科学者が自分自身の研究に合わせ、これら計算機を発展することが可能となり、多くの分野で様々な利用方法が確立された。 [2]

理論化学の分野として、量子化学が代表的であり、コンピュータによる計算技術が発達する前は、膨大な手計算により成果を出さざるを得なかった。しかし、現在は、コンピュータの発展とともに化学反応速度論、分子モデリングに必要な量子化学計算を容易に行うことが可能となった。これは Gaussian としてソフトウェアパッケージとして発表され、当該分野で急激な発展を見せることとなった。 [1]

計量化学の誕生は、1960 年代から 1970 年初頭にかけて、コンピュータ科学志向の化学者が用語として記載し始めた。1974 年には Wold と Kowalski と共同で国際計量化学協会を設立し、体系的な利用が行われ始めた。

計量化学と分析化学の違いは大きな争点として挙げられ、計量化学を分析化学の 1 体系として指す研究者も存在した。しかし、計量化学は、膨大な化学分析データを対象に多変量解析的手法を用いることが主題であるため、分析化学における単変量的な統計学的手法とは一線を画くという考えもある。その後、実験計画法の考え方も浸透し、計量化学は分析化学と異なる研究領域の一分野として重要な位置を占め、工学における化学の利用を考える上で重要な考え方となっている。Davies らはこれらの手法を書籍として出版し、現在においても参照される重要な文献である。 [3]

1980 年以降、コンピュータ科学の発展とともに計量化学の手法も発展し、欧米を中心に膨大な化学分析データから情報を取得する手法として重用されている。 [4] [5] [6]

2.2 説明変数と目的変数 [7][8]

2.2.1 説明変数 [7][8]

回帰分析において、指定したある 1 個の変数 Y に対する予測値 Y_{hat} が、 p 個の変数 $X_i(i=1,2,\dots,p)$ によって $Y_{\text{hat}}=b_0+b_1 \cdot X_1+b_2 \cdot X_2+\dots+b_p \cdot X_p$ という重回帰式で定義される場合、 X_i を説明変数と呼ぶ。

例えば、実験中における様々な条件により取得される結果が変化する場合、結果(目的変数)は実験条件(説明変数)により規定される。説明変数と呼称される理由として、目的変数の規定を説明することが由来となる。

本研究では、食品中に含まれる種々の化学成分値を説明変数として食品の「製品種類」「部位」「調理法」等のカテゴリーである目的変数に寄与するとして検討した。

2.2.2 目的変数 [7][8]

回帰分析において、指定した、ある 1 個の変数 Y に対する予測値 Y_{hat} が、 p 個の変数 $X_i(i=1,2,\dots,p)$ によって $Y_{\text{hat}}=b_0+b_1 \cdot X_1+b_2 \cdot X_2+\dots+b_p \cdot X_p$ という重回帰式で定義される場合、 Y を目的変数と呼ぶ。

詳細については 2.2.1 節に記載しているが、実験中における様々な条件により取得される結果が目的変数である。

本研究では、食品中に含まれる種々の化学成分値を説明変数として食品の「製品種類」「部位」「調理法」等の目的変数に寄与する考えた。

2.3 量的データと質的データ [7] [8]

2.3.1 量的データ

観測される変数と数値を対応させる基準として用いられるデータの中で、数値差のみに意味がある間隔尺度、数値差とともに数値比を意味として用いる比例尺度、正確に与えられた数値データである連続変数等、数値に関わるデータについて量的データと呼称する。

本研究では、多種多様な機器で計測された化学成分値が量的データである。

2.3.2 質的データ

単純に数値の連続で表されないデータのことを指す。大小関係や順序関係が存在しない(例えば、男・女)変数である名義尺度、大小関係や順序関係が成立する(優・良・可・不可)順序尺度のことをまとめて質的データと呼ぶ。

本研究では、「製品種類」(赤肉、脂身つき、皮下脂肪なし、加工品 等)、「部位」(かた、かたロース、もも、そもそも 等)の分類・評価の目的となる項目を指す。

2.4 データの標準化 [9]

本研究で取り扱う食品中に含まれる化学成分値データは、多変量解析手法を実施する際に標準化操作を行った。

標準化とは引用するデータ値の平均を 0 として、標準偏差を 1 とする手法である。

元の数値を x 、データ数を n として、標準偏差 s を、

$$s = \sqrt{\frac{(\sum(x-m)^2)}{(n-1)}} \quad (2.1)$$

となる。

その後、標準偏差 s を用い、標準化を行う。数値の平均を m 、標準化後のデータを u とすると、

$$u = \frac{(x-m)}{s} \quad (2.2)$$

と表す。

2.5 線形回帰モデル [10] [11] [12] [13]

回帰モデルは、1つの目的変数と1つまたは複数の説明変数の関係を記述することを基本とする。

基本的な多重線形回帰モデルは以下の通りに記述する。

$$y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \cdots + \beta_k X_{ip} + \varepsilon_i \quad i = 1, \dots, n \quad (2.3)$$

ここで、 y_i は*i*番目の目的変数、 β_k は*k*番目の係数として、 β_0 はモデルの定数項である。 X_{ij} は*j*番目の説明変数 $j=1, \dots, p$ の *i*番目の観測値を指す。最後に記述している ε_i は*i*番目のノイズ項、確率的誤差を示す。

通常の線形回帰モデルは以下の形式として記述される。

$$y_i = \sum_{k=1}^k \beta_k f_k(X_{i1}, X_{i2}, \dots, X_{ip}) + \varepsilon_i \quad i = 1, \dots, n \quad (2.4)$$

線形回帰モデルにおける線形性は、係数 β_k の線形性を表現する。すなわち、応答変数 y は、係数 β_k の線形関数を表す。

一般的な線形回帰モデルの例としては、一次式、二次式、累乗式、指数式、対数式等の図表上にて近似式として線形表現可能なものである。係数 β_k に対し線形性を表現できるものを指す。

2.6 分散分析と多変量分散分析

2.6.1 分散分析 [14][15]

一方の変数 X が化学成分含有量などの量的データ、他方の変数 Y が食品の種類、部位といった名義尺度であり、量的変数 X に関するデータが名義尺度の変数 Y によって g 個のグループに分かれたとする。

グループ y_1, y_2, \dots, y_g のデータ数をそれぞれ n_1, n_2, \dots, n_g (ただし、 $\sum_{i=1}^g n_i = n$) とし、グループ別の平均値を $\bar{x}^{(1)}, \bar{x}^{(2)}, \dots, \bar{x}^{(g)}$ とする。このとき、 i 番目 ($i=1, 2, \dots, g$) のグループに属する j 個目 ($j=1, 2, \dots, n_i$) のデータを $x_j^{(i)}$ 、対象となる食品データの平均値を \bar{x} とすると、平均偏差 $x_j^{(i)} - \bar{x}$ は(2.5)式に分解される。

$$(x_j^{(i)} - \bar{x}) = (\bar{x}^{(i)} - \bar{x}) + (x_j^{(i)} - \bar{x}^{(i)}) \quad (2.5)$$

ここで、(2.5)式に示す三つの n 次元列ベクトル \mathbf{x}_T 、 \mathbf{x}_B 、 \mathbf{x}_W を定義する。

$$\mathbf{x}_T = \begin{bmatrix} x_1^{(1)} - \bar{x} \\ x_2^{(1)} - \bar{x} \\ \vdots \\ x_{n_1}^{(1)} - \bar{x} \\ x_1^{(2)} - \bar{x} \\ \vdots \\ x_{n_2}^{(2)} - \bar{x} \\ \vdots \\ x_1^{(g)} - \bar{x} \\ \vdots \\ x_{n_g}^{(g)} - \bar{x} \end{bmatrix} \quad \mathbf{x}_B = \begin{bmatrix} \bar{x}^{(1)} - \bar{x} \\ \bar{x}^{(1)} - \bar{x} \\ \vdots \\ \bar{x}^{(1)} - \bar{x} \\ \bar{x}^{(2)} - \bar{x} \\ \vdots \\ \bar{x}^{(2)} - \bar{x} \\ \vdots \\ \bar{x}^{(g)} - \bar{x} \\ \vdots \\ \bar{x}^{(g)} - \bar{x} \end{bmatrix} \quad \mathbf{x}_W = \begin{bmatrix} x_1^{(1)} - \bar{x}^{(1)} \\ x_2^{(1)} - \bar{x}^{(1)} \\ \vdots \\ x_{n_1}^{(1)} - \bar{x}^{(1)} \\ x_1^{(2)} - \bar{x}^{(2)} \\ \vdots \\ x_{n_2}^{(2)} - \bar{x}^{(2)} \\ \vdots \\ x_1^{(g)} - \bar{x}^{(g)} \\ \vdots \\ x_{n_g}^{(g)} - \bar{x}^{(g)} \end{bmatrix} \quad (2.6)$$

(2.5)式、(2.6)式から、(2.7)式が成立する。

$$\mathbf{x}_T = \mathbf{x}_B + \mathbf{x}_W \quad (2.7)$$

ここで、 \mathbf{x}_B と \mathbf{x}_W は直交する、すなわち(2.8)式が成立する。

$$(\mathbf{x}_B, \mathbf{x}_W) = 0 \quad (2.8)$$

(2.7)式、(2.8)式から、以下の式が成立する。

$$\|\mathbf{x}_T\|^2 = \|\mathbf{x}_B\|^2 + \|\mathbf{x}_W\|^2 \quad (2.9)$$

すなわち、

$$\sum_{i=1}^g \sum_{j=1}^{n_i} (x_j^{(i)} - \bar{x})^2 = \sum_{i=1}^g n_i (\bar{x}^{(i)} - \bar{x})^2 + \sum_{i=1}^g \sum_{j=1}^{n_i} (\bar{x}_j^{(i)} - \bar{x}^{(i)})^2 \quad (2.10)$$

ここで、(2.10)式における各項について、

$$S_T = \sum_{i=1}^g \sum_{j=1}^{n_i} (x_j^{(i)} - \bar{x})^2, \quad S_B = \sum_{i=1}^g n_i (\bar{x}^{(i)} - \bar{x})^2, \quad S_W = \sum_{i=1}^g \sum_{j=1}^{n_i} (\bar{x}_j^{(i)} - \bar{x}^{(i)})^2 \quad (2.11)$$

とおくと、(2.10)式および(2.11)式から、(2.12)式が成り立つ。

$$S_T = S_B + S_W \quad (2.12)$$

それぞれ、全変動 S_T 、群間変動 S_B 、群内変動 S_W という。また、 S_B 、 S_W を自由度(g -

1)、($n-g$)で割った値、すなわち

$$V_B = \frac{S_B}{g-1}, \quad V_W = \frac{S_W}{n-g} \quad (2.13)$$

これらを群間分散 V_B 、群内分散 V_W と呼称する。

分散分析は、グループ y_1 、 y_2 、 \dots 、 y_g ごとの平均値 $\bar{x}^{(1)}$ 、 $\bar{x}^{(2)}$ 、 \dots 、 $\bar{x}^{(g)}$ に対し、

(2.9)式に示す帰無仮説 H_0 を検定する際に用いられる。

$$H_0 : \bar{x}^{(1)} = \bar{x}^{(2)} = \dots = \bar{x}^{(g)} \quad (2.14)$$

検定には、群間分散と群内分散の比である、(2.15)式を用いた。

$$F = \frac{V_B}{V_W} \quad (2.15)$$

(2.15)式の F 値は、自由度($g-1, n-g$)の F 分布に従う。 F 値が上側 5%の値以上のときには、グループ y_1 から y_g の平均値間に差があると見なし、(2.14)式の仮説を棄却する。

本研究では分散分析を、変数の分布と偏差の算出、対象試料分類に対する化学成分値の順位付け、クラスター分析をはじめとする多変量解析的手法への応用を目的として使用している。

2.6.2 多変量分散分析 [10][15]

食品中に g 個あるグループに対し、 p 個の変数(本研究では化学成分値) X_1, X_2, \dots, X_p に関する測定データがあるとする。

ここで、 i 番目のグループに属する j 個目のデータにおける q 個目($q=1,2,\dots,p$)の変数を $x_{qj}^{(i)}$ とおき、 q 個目の変数におけるグループ別の平均値を $\bar{x}_q^{(1)}, \bar{x}_q^{(2)}, \dots, \bar{x}_q^{(g)}$ 、 q 個目の変数における全データの平均値を \bar{x}_q とおく。このとき、(2.6)式における $\mathbf{x}_T, \mathbf{x}_B, \mathbf{x}_W$ を、 q 個目の変数に対するものに置き換えた $\mathbf{x}_{qT}, \mathbf{x}_{qB}, \mathbf{x}_{qW}$ を、(2.16)式に示す。

$$\mathbf{x}_{qT} = \begin{bmatrix} x_{q1}^{(1)} - \bar{x}_q \\ x_{q2}^{(1)} - \bar{x}_q \\ \vdots \\ x_{qn_1}^{(1)} - \bar{x}_q \\ x_{q1}^{(2)} - \bar{x}_q \\ \vdots \\ x_{qn_2}^{(2)} - \bar{x}_q \\ \vdots \\ x_{q1}^{(g)} - \bar{x}_q \\ \vdots \\ x_{qn_g}^{(g)} - \bar{x}_q \end{bmatrix} \quad \mathbf{x}_{qB} = \begin{bmatrix} \bar{x}_q^{(1)} - \bar{x}_q \\ \bar{x}_q^{(1)} - \bar{x}_q \\ \vdots \\ \bar{x}_q^{(1)} - \bar{x}_q \\ \bar{x}_q^{(2)} - \bar{x}_q \\ \vdots \\ \bar{x}_q^{(2)} - \bar{x}_q \\ \vdots \\ \bar{x}_q^{(g)} - \bar{x}_q \\ \vdots \\ \bar{x}_q^{(g)} - \bar{x}_q \end{bmatrix} \quad \mathbf{x}_{qW} = \begin{bmatrix} x_{q1}^{(1)} - \bar{x}_q^{(1)} \\ x_{q2}^{(1)} - \bar{x}_q^{(1)} \\ \vdots \\ x_{qn_1}^{(1)} - \bar{x}_q^{(1)} \\ x_{q1}^{(2)} - \bar{x}_q^{(2)} \\ \vdots \\ x_{qn_2}^{(2)} - \bar{x}_q^{(2)} \\ \vdots \\ x_{q1}^{(g)} - \bar{x}_q^{(g)} \\ \vdots \\ x_{qn_g}^{(g)} - \bar{x}_q^{(g)} \end{bmatrix} \quad (2.16)$$

このとき、(2.7)式と同様に(2.17)式が成立する。

$$\mathbf{x}_{qT} = \mathbf{x}_{qB} + \mathbf{x}_{qW} \quad (q = 1, 2, \dots, p) \quad (2.17)$$

(2.8)式と同様に、(2.17)式に対して(2.18)式が成立する。

$$(\mathbf{x}_{kB}, \mathbf{x}_{lW}) = 0 \quad (k, l = 1, 2, \dots, p) \quad (2.18)$$

ここで、3つの(n,p)型行列 \mathbf{X}_T 、 \mathbf{X}_B 、 \mathbf{X}_W を、それぞれ以下のように定義する。

$$\begin{aligned} \mathbf{X}_T &= (\mathbf{x}_{1T}, \mathbf{x}_{2T}, \dots, \mathbf{x}_{pT}) \\ \mathbf{X}_B &= (\mathbf{x}_{1B}, \mathbf{x}_{2B}, \dots, \mathbf{x}_{pB}) \\ \mathbf{X}_W &= (\mathbf{x}_{1W}, \mathbf{x}_{2W}, \dots, \mathbf{x}_{pW}) \end{aligned}$$

このとき、(2.18)式より、(2.19)式が成立する。

$$\mathbf{X}'_B \mathbf{X}_W = \mathbf{0} \quad (2.19)$$

したがって、平均偏差得点を成分とする(n,p)型行列 \mathbf{X}_T について、(2.20)式に分解される。

$$\begin{aligned} \mathbf{X}'_T \mathbf{X}_T &= (\mathbf{X}_B + \mathbf{X}_W)' (\mathbf{X}_B + \mathbf{X}_W) \\ &= \mathbf{X}'_B \mathbf{X}_B + \mathbf{X}'_W \mathbf{X}_W \end{aligned} \quad (2.20)$$

ここで、(2.20)式における各項について、(2.21)式とおく。

$$\mathbf{T} = \mathbf{X}'_T \mathbf{X}_T \quad \mathbf{B} = \mathbf{X}'_B \mathbf{X}_B \quad \mathbf{W} = \mathbf{X}'_W \mathbf{X}_W \quad (2.21)$$

このとき、(2.20)式および(2.21)式から、以下に示す(2.22)式が成立する。

$$\mathbf{T} = \mathbf{B} + \mathbf{W} \quad (2.22)$$

(2.22)式における \mathbf{T} を「変動行列」といい、 \mathbf{B} を「群間変動行列」、 \mathbf{W} を「群内変動行列」という。

多変量分散分析は、分散分析における F 検定を、 X が 2 変数以上の場合に対し適用できるよう拡張したものである。多変量分散分析では、(2.15)式における F の代わりに、(2.12)式における S_W 、 S_T を用い、(2.23)式に示す統計量 Λ を適用する。

$$\Lambda = \frac{S_W}{S_T} \quad (2.23)$$

2 変数以上に拡張する場合、(2.12)式における S_W 、 S_T を、(2.21)式における W 、 T の行列式に置き換える。すなわち、以下の(2.24)式とする。

$$\Lambda = \frac{|W|}{|T|} \quad (2.24)$$

(2.23)式、(2.24)式はいずれも、「グループ間の変動の有無は、 Λ が 1 よりどのくらい小さくなるかによって定まる」という考えのもとに導かれている。この Λ は、Wilks の Λ と呼ばれる。

2.7 マハラノビス距離 [9] [10] [16]

マハラノビス距離は多変量における距離の取り方の 1 つであり、各変量の分布を考慮したものである。あるデータ \mathbf{x} の平均ベクトルを $\bar{\mathbf{x}}$ 、分散共分散行列を \mathbf{C} とおくと、2 つのデータ \mathbf{x} 、 \mathbf{y} 間のマハラノビス距離の 2 乗 d_s^2 は(2.25)式で定義される。

$$d_s^2(\mathbf{x}, \mathbf{y}) = (\mathbf{x} - \mathbf{y})' \mathbf{C}^{-1} (\mathbf{x} - \mathbf{y}) \quad (2.25)$$

また、集中楕円 E_c は(2.26)式で定義される。集中楕円について、Fig.2-7-1 に示す。

$$E_c = \{\mathbf{x} | d_s^2(\mathbf{x}, \bar{\mathbf{x}}) = c\} \quad (c : \text{正の定数}) \quad (2.26)$$




Fig.2-7-1 Scatter plots and concentrated ellipses. [16]

集中楕円は、散布図上においてマハラノビス距離が c となる点の集合である。集中楕円と散布図との傾向として、集中楕円の長軸方向(Fig.2-7-1、 a_1 方向)は点が疎であり、短軸方向(Fig.2-7-1、 a_2 方向)は点が密である(Fig.2-7-1 参照)。また、データ \mathbf{x} のマハラノビス距離は $d_5^2(\mathbf{x}, \bar{\mathbf{x}})$ で表される。

この距離の指標は、ある食品のグループが複数ある場合、それぞれの化学成分値に対する標準偏差がアンバランスである可能性がある。その際に、それぞれのグループへ食品を判別する場合、グループ毎の標準化された変量の絶対値となる距離で決定することが可能である。

本研究では、クラスター分析、判別分析における分類・評価の考え方として適用した。

2.8 クラスタ分析

2.8.1 クラスタ分析とは

クラスタ分析とは、多変量空間内に存在する集団個々の距離を定義し、その近接した対象を1つの分類群として纏める分析手法の総称を指す。

手法は次節に示すが、本論文では階層的分類法を用いているため、その説明を中心に行う。

2.8.2 クラスタ分析の種類 [9]

クラスタ分析の方法は、大別し、

- ・階層的分類法
- ・非階層的分類法

の2つに大きく分けられる。非階層的方法はk個の代表(平均)を用いて分類するため、K-means法と呼ばれる。観測対象が数百個までの小規模な場合は階層的分類法、観測対象が数千個以上の大規模な場合は非階層的分類法が適している。本研究においては数千単位の試料を対象としていないことから階層的分類法を使用した。

階層的分類法では、最初にすべての観測対象それぞれが独立したクラスター(塊)として考える。次にこれらの中で多変量空間において互いに最も近い2点を見つけ、これら2点間の多変量平均の1点で置き換えて新たなクラスターとする。このプロセスをクラスターの数が1個になるまで繰り返すと樹形図が形成され、観測対象間の距離を確認することができる。形成される樹形図の例を Fig.2-8-1 に示す。




Fig.2-8-1 Example of tree diagram by hierarchical classification [9]

なお、計算方法の違いによって5種類の方法がある。

2.8.2.1 群平均法 [9] [8] [11] [13] [17]

2つのクラスターに属する対象試料間全ての組み合わせにより距離を算定し、その平均値をクラスター間の距離として用いる手法である。各クラスター内の対象個数を n_1 個、 n_2 個とすると試料対象間の組み合わせは $n_1 \times n_2$ 個存在し、その距離の総和を $n_1 \times n_2$ で除したものがクラスターの距離として表現される。

群平均法は分散が小さくなるクラスターが結合され、クラスターの分散が等しくなる傾向がある。

下式は D_{KL} を距離とし、分子に各クラスター内の対象間距離の総和を分母に対象個数の組み合わせにて除すことで表現している。

$$D_{KL} = \frac{\sum_i \sum_j d(x_i, x_j)}{N_K N_L} \quad (2.27)$$

2.8.2.2 重心法 [9] [8] [11] [13] [17]

各クラスターの代表点を重心として設定し、重心間の距離をクラスター間距離として設定する手法である。重心とは、各変量における平均値座標にあたる点を示す。

あるクラスター内に n 個の対象試料が $(x_{11}, x_{12}, \dots, x_{1p})$ 、 $(x_{21}, x_{22}, \dots, x_{2p})$ 、 \dots 、 $(x_{n1}, x_{n2}, \dots, x_{np})$ が存在する場合、各変量の平均値をとった $(\bar{x}_1, \bar{x}_2, \dots, \bar{x}_p)$ が重心となる。2つのクラスターを合成し、新たな重心を求める際には、各クラスター内の試料数を重みとする重み付き平均を採用する。

下式は D_{KL} を距離とし、各クラスターに存在する試料各変量の平均値の差で表している。

$$D_{KL} = \|\bar{x}_K - \bar{x}_L\|^2 \quad (2.28)$$

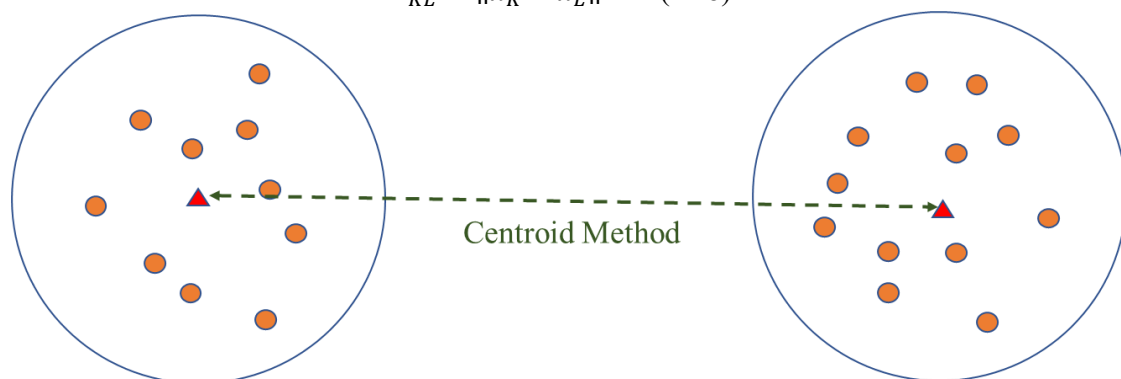


Fig.2-8-2 Cluster distance by Centroid Method [11]

2.8.2.3 最短距離法 [9] [8] [11] [13] [17]

2つのクラスターから1点ずつ選択したときに、距離が最短になる2点間の距離をクラスター間の距離とする方法である。最短距離法はクラスターの形状が制約されないため、長く伸びたクラスターが構成されやすくなる。これより、コンパクトなクラスターを形成できないことがある。

$$D_{KL} = \min_i \min_j d(x_i, x_j) \quad (2.29)$$

2.8.2.4 最長距離法 [9] [8] [11] [13] [17]

2つのクラスターから1点ずつ選択したとき、距離が最長になる2点間の距離をクラスター間の距離とする方法である。最長距離法では、クラスター内の距離がほぼ同じになる傾向が強く、それほど極端ではない外れ値にも影響されてしまうことがある。

$$D_{KL} = \max_i \max_j d(x_i, x_j) \quad (2.30)$$

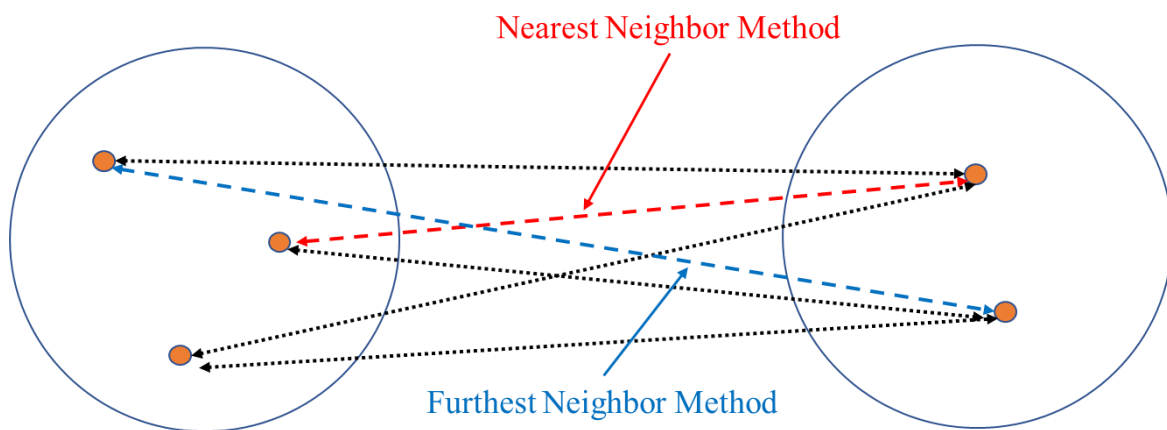


Fig.2-8-3 Cluster distance by Nearest Neighbor Method and Furthest Neighbor Method [11]

2.8.2.5 Ward 法 [9] [8] [11] [13][17]

Ward 法は、様々な分野における分類・照合問題に適用され、データ集合から有用なパターンを比較的容易に検出することが可能である。したがって、実用性の高い階層的分類手法として広く用いられる。

本手法は、試料に含まれるデータの分散に基づいて逐次クラスターを形成する分類法である、平方ユークリッド距離を基本的に用いる。

上記に示した通り、Ward 法は鎖効果（長く伸びたクラスターが生成される）の起きにくい実用性の高い方法である。

① 1次元データ集合の分散[15]

ある試料に含まれている変数に関し観測された n 個の 1次元データ集合 $S = \{x_1, x_2, \dots, x_b\}$ を分類対象とする。データのばらつきの程度、分散を測る指標として、下式に示す偏差平方和を用いる。

$$\sum_{i=1}^n (x_i - \bar{x})^2, \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.31)$$

1次元データ集合 S は、 m 個のクラスター

$$C_1 = \{x_1^{(1)}, x_2^{(1)}, \dots, x_{n_1}^{(1)}\}, \dots, C_m = \{x_1^{(m)}, x_2^{(m)}, \dots, x_{n_m}^{(m)}\} \quad (2.32)$$

に分割されたと考えると、各クラスター内の偏差平方和は、

$$W_j = \sum_{i=1}^{n_j} (x_i^{(j)} - \bar{x}_j)^2, \quad \bar{x}_j = \frac{1}{n_j} \sum_{i=1}^{n_j} x_i^{(j)} \quad j = 1, 2, \dots, m \quad (2.33)$$

で与えられる。この式では、 n_j は、 j 番目のクラスターに含まれるデータ個数とする。このとき、クラスター内全偏差平方和は、 $W = W_1 + W_2 + \dots + W_m$ で定義され、形成された全クラスター $\{C_1, C_2, \dots, C_m\}$ のばらつき度合いを示す。

各個体を 1 つのクラスターとした場合における全偏差平方和は 0 となる。

階層的分類法では、2つのクラスターが結合し、新たなクラスターを形成した場合の結合距離が樹形図にて表現される。これより、相対的なクラスター間距離を視覚的に把握することが可能となる。Ward法では、2つのクラスター

$$C_\alpha = \{x_1^{(\alpha)}, x_2^{(\alpha)}, \dots, x_{n_\alpha}^{(\alpha)}\}, \quad C_\beta = \{x_1^{(\beta)}, x_2^{(\beta)}, \dots, x_{n_\beta}^{(\beta)}\} \quad (2.34)$$

に対し、 C_α と C_β の偏差平方和を、それぞれ W_α と W_β とし、結合したクラスター $C_\alpha \cup C_\beta$ の偏差平方和を $W_{\alpha\beta}$ とすると、結合の水準は、以下の通りに定義される。

$$d(C_\alpha, C_\beta) = W_{\alpha\beta} - W_\alpha - W_\beta \quad (2.35)$$

これは、2つのクラスターが結合されることにより生じる偏差平方和の増分を示す。

② 多次元データ集合の分散[15]

分類・照合対象の試料 n 個の p 次元データ集合 $S = \{x_1, x_2, \dots, x_n\}$ からなる場合、データのばらつきの程度、分散を測る指標を定義する。基本的には、一次元データ集合と同様、偏差平方和を用いる。本節の定義は、以下に示す通りとなる。

$$S = (s_{jk}) = \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T, \quad \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.36)$$

このとき、多次元データに対するデータのばらつきは、

$$(i) \operatorname{tr} S = s_{11} + s_{22} + \dots + s_{pp}, \quad (ii) |S| \quad (2.37)$$

で測ることが可能となる。(i)は各変数における偏差平方和の総和であり、(ii)は一般化分散と呼称され、それぞれの多次元データ集合における分散の程度を示すために用いられる。

分類・照合対象である n 個の p 次元データ集合 S は、 m 個のクラスターに分割るとし、 j 番目のクラスターを $C_j = \{x_1^{(j)}, x_2^{(j)}, \dots, x_{n_j}^{(j)}\}$ ($j = 1, 2, \dots, m$) とする。このクラスターに含まれている n_j 個の p 次元データに基づく偏差平方和行列 S_j とするとき、クラスター C_j 内のばらつきは、 $W_j = \operatorname{tr} S_j$ または、 $W_j = |S_j|$ で計測する。したがって、データ集合 S が m 個のクラスターに分割された際のばらつきを示す指標は、

$$(i) W = \operatorname{tr} S_1 + \operatorname{tr} S_2 + \dots + \operatorname{tr} S_m, \quad (ii) W = |S_1| + |S_2| + \dots + |S_m|$$

で与えられる。各クラスターが1つのデータからなる初期条件においては、 $W = 0$ である。多次元データ集合からなる2つのクラスター C_α と C_β が結合した時の結合の水準は、1次元で用いた偏差平方和に基づき、

$$(i) d(C_\alpha, C_\beta) = \operatorname{tr} S_{\alpha\beta} - \operatorname{tr} S_\alpha - \operatorname{tr} S_\beta, \quad (ii) d(C_\alpha, C_\beta) = |S_{\alpha\beta}| - |S_\alpha| - |S_\beta| \quad (2.38)$$

で与えられる。ただし、 S_α と S_β は、各クラスター C_α と C_β 内のデータに基づく偏差平方和行列、また、 $S_{\alpha\beta}$ は、2つのクラスター C_α と C_β に含まれる全データから求めた偏差平方和行列となる。

2.9 判別分析

2.9.1 判別分析とは [9]

判別分析は、ある対象が所属するグループを予測するための手法である。例えば k 個 ($k \geq 2$) のグループが存在し、どのグループに属するか既知である観測対象について、何らかのデータが収集されている際、どのグループに属するか不明な対象が得られた場合、すでに収集されているデータに基づいて、その対象が所属するグループを予測することをいう。グループの予測とは、2つ以上に分類されるグループの中で、どのグループに属するかを予測することで、このような予測は判別と呼ばれる。グループの数が2つの場合を2群の判別、グループの数が3つ以上の場合を多群の判別という。

本報告では、食品に対する複数の分類項目についての分類・照合可能性を確認するために多群判別法を用いる。

2.9.2 統計的判別分析 [11]

統計的判別分析は、1930年代に R.A.Fisher によって基本的な考え方が紹介されており、その後、P.C.Mahalanobis や C.R.Rao らの研究によって、現在の手法になった。これら手法は、主に変数の線形結合で表現される線形判別法が中心である。

本論文にて用いる判別分析は、線形判別分析によるものであり、次節からその原理について説明する。

2.9.3 線形判別分析 [11]

線形判別分析は、2群で考えた場合、これら2つのカテゴリーに最も正しく判別できる直線を導出する手法である。これにより、試料それぞれが2つのカテゴリー、どちらに属するか判別することが可能となる。

簡単な例として、2変量を有する食品が A、B の2種類のグループに分類可能と考える。その際、2変量のデータを散布図に表現すると Fig.2-9-1 となる。その際、○が A、△が B に属する食品とする。Fig.2-9-1 より○、△それぞれのグループを円で囲んだ場合、別れて分布していることが確認できる。その分布上に適当な直線を引くことにより、多くの○試料が直線より上に分布していることが確認できる。一方、△は直線の下に多く分布している。そこで、新しく分布する試料についてはどこに予測するべきであるかを決定することが判別分析の基本的な考え方となる。

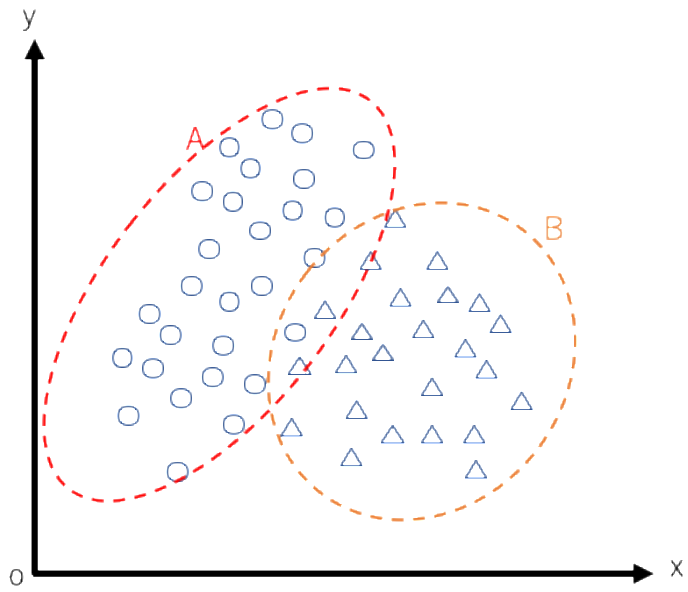


Fig.2-9-1 Image of discriminant analysis (1) [11]




Fig.2-9-2 Image of discriminant analysis (2) [11]

グループを判別するための直線、判別直線の考え方は、 x 、 y の平均をプロットした点 (\bar{x}, \bar{y}) を通過する直線 l を考える。この直線に対し、 (\bar{x}, \bar{y}) を 0 とする。




Fig.2-9-3 Image of discriminant analysis (3) [11]

各試料を示す点から、直線 l に垂線を下ろし、垂線と当たった位置を読み取る。点 (x_i, y_i) の時の垂線の目盛りを z_i とする。 z_i を x_i, y_i の関数とした場合、 z_i は線形判別関数と呼ばれる。

この線形判別関数である z_i の相関比を計算した上で、この相関比が高いほど、 z_i の値による分類・照合が妥当であることを示す。したがって、相関比が最大になる直線 l を導出する必要がある。この時、 (\bar{x}, \bar{y}) を通過する直線 l に垂直な直線 m が判別直線と称される。判別直線 m 上の点から l に垂線を引き下ろすと垂線と交わる位置は (\bar{x}, \bar{y}) となるため、判別直線 m 上の点は、線形判別関数 z_i の値が 0 と示される。




Fig.2-9-4 Image of discriminant analysis (4) [11]

線形判別分析では、「群内共分散行列は全てのグループで等しい」と仮定されるため、共通した共分散行列はと S_p 推定される。解析試料(本節ではオブザベーションとする)から分類対象グループへの Mahalanobis 距離は、以下の通りに定義される。[16] [17] [18]

$$d_t^2 = (y - \bar{y}_t)' S_p^{-1} (y - \bar{y}_t) \quad (2.38)$$

グループ t 内のオブザベーション y の尤度は、以下の通り求められる。

$$l_t = (2\pi)^{-\frac{T}{2}} |S_p|^{-\frac{1}{2}} \exp\left(-\frac{(y - \bar{y}_t)' S_p^{-1} (y - \bar{y}_t)}{2}\right) \quad (2.39)$$

$$= (2\pi)^{-\frac{T}{2}} |S_p|^{-\frac{1}{2}} \exp(-d_t^2/2) \quad (2.40)$$

推定されるパラメータの個数は、プールした共分散行列における $p(p + 1)/2$ 個と、平均

ベクトルにおける T_p 個である。よって、線形判別分析において推定されるパラメータの総数は $p(p+1)/2 + T_p$ 個である。

グループ t に属する事後確率は、次式により求められる。

$$p(t|y) = \frac{q_t l_t(y)}{\sum_{u=1}^T q_u l_u(y)} = \frac{1}{1 + \sum_{u \neq t} \exp(-[(d_u^2) - 2\log(q_u)] - (d_t^2) - 2\log(q_t)]/2)} \quad (2.40)$$

オブザベーション y は、事後確率の値が最も大きいグループに割り当てられる。

2.9.4 評価方法と判別率

判別分析を実施後、結果の評価として判別率を求める。判別率を求める方法として、判別分析の結果として、帰属されたグループが本来所属すべきグループであれば正判別されたと判断し、異なれば誤判別されたと判断する。全体試料の分析結果からどの程度正判別されたかを正判別率として算出し評価する。

$$Determination\ rate(\%) = \frac{Positive\ discrim\ samples}{All\ samples} \times 100 \quad (2.42)$$

2.10 ニューラルネットワーク

2.10.1 ニューラルネットワークとは [19][20]

人間の脳には約 140 億個の神経細胞があり、それぞれの神経細胞はある規則的に従い結合され神経回路を形成している。Fig.2-10-1 に神経細胞を肉眼で確認したものを示す。Fig.2-10-1 は、大脳皮質の薄い切片を肉眼で確認できるよう処理したものである。このように見える神経細胞は全体の 2%に過ぎないと言われている。




Fig.2-10-1 Specimen of neural cell connection status [21]

神経細胞が結ばれた神経回路をモデル化したものを人工ニューラルネットワーク、通常、ニューラルネットワークと呼称される。ニューラルネットワークに関する研究の発端は、1943 年の W.S.McCulloch et al. [22]に遡り、その後、数回の研究ブームの起伏を経て研究が進められてきた。日本では、1990 年頃から画像認識、音声認識、株予測等に応用されている。 [23][24]

Fig.2-10-2 の神経回路を構成する最小単位である神経細胞は細胞体、軸索、樹状突起、シナプスにより構成されている。




Fig.2-10-2 Neuronal morphology [19]

神経細胞体は、他の細胞から送信された信号を処理し、ある条件を満たすと次の神経細胞に信号を送信する。出力先である軸索は出力信号を次の神経細胞に送信する経路となる。樹状突起は、細胞体から多数分布している樹状繊維の集合体である。シナプスは軸索についた粒状物質であり、他の神経細胞の樹状突起と接続・切断する機能を有する。神経細胞間はシナプスという接触点を通じて結び付けられ信号の転送を実施する。軸索から流れる電気信号を神経インパルスと呼称する。

上記、神経細胞が並列的に接続された場合の全体機能を数理的にモデル化したものがニューラルネットワークである。ニューラルネットワークの構成要素は形式神経細胞であり、数理モデルである。神経細胞の

- ・ 樹状突起とシナプスによる情報の装飾
- ・ 細胞体内の信号加算
- ・ 出力信号の生成

に着目しモデル化を行っている。形式神経細胞の構造を次頁の Fig.2-10-3 に示す。

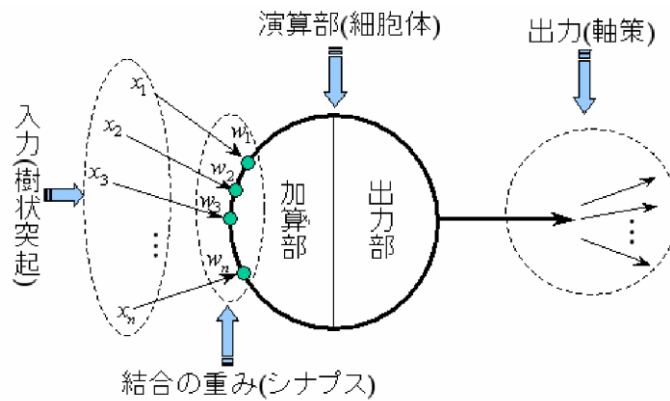


Fig.2-10-3 Structure of formal neuron [19]

Fig.2-10-3 の $x_1, x_2, x_3, \dots, x_p$ は樹状突起による入力信号であり、 $w_1, w_2, w_3, \dots, w_p$ はそれぞれ入力信号に対応するシナプスの結合の重みである。加算部ではそれぞれの入力値 x_i に重み w_i を掛けた代数和 $u = \sum_{i=1}^p w_i x_i$ を求め、出力部は出力信号を生成する。ニューラルネットワークはこのような形式神経細胞の相互結合により情報の転送・処理を行う。形式神経細胞における入力と出力の関係は、通常、次のような関数、

$$y = f(u) = \begin{cases} 0 & u \geq \theta \\ 1 & u < \theta \end{cases} \quad (2.43)$$

θ : 結合の重み等のパラメータ総量

あるいは、

$$y = f(u) = \frac{1}{1 + e^{-u}} \quad (2.44)$$

(ただし、 $u = \sum_{i=1}^p w_i x_i$ である。)

で表現される。それぞれの関数グラフ例は Fig.2-10-4 に示す。




Fig.2-10-4 Output function [19]

出力関数 $y = f(u)$ は u の関数であり、 u は入力変数 x_i と重み w_i の線形結合である。ニューラルネットワークにおける結合の重み w_i は、初期の段階で、ランダムに小さい値が与えられ、学習を通じて、徐々に最適な値に置き換えられる。

2.10.2 ニューラルネットワークモデル

複数の形式神経細胞がネットワーク状に結合したものをニューラルネットワークと呼称されるが、その結合様式によりニューラルネットワークの構造が決定し、構造が異なるとネットワークの機能と特徴も異なる。このネットワーク構造をモデルと呼ぶ。最も多く用いられるモデルは階層型と非階層型に大別される。

以下にそれぞれの特徴を整理した。

2.10.2.1 階層型ネットワーク [19][20][25]

階層型ネットワークは、最も多く用いられているニューラルネットワークモデルである。階層型ネットワークは複数の形式神経細胞が Fig.2-10-5 のように階層的に結合した構造を取っている。入力層、中間層、出力層が基本的な構成であり、各ユニットの出力信号が伝達されていく。このようなニューラルネットワークモデルは、次式で定式化することができる。




Fig.2-10-5 Hierarchical neural network model

$$y_k = \Phi_0(a_k + \sum_h w_{hk} \Phi_h(a_h + \sum_i w_{ih} x_i)) \quad (2.45)$$

ニューラルネットワークの特徴として学習機能が挙げられるが、学習に関するアルゴリズムは、大きく教師あり学習と教師なし学習に分類される。本節で述べた階層型ニューラルネットワークは教師あり学習に適している。

階層型ネットワークは信号の流れで考えた際、フィードフォワード型(前向きのみ)と呼ぶ。階層型ネットワークでは、中間層の層数及び中間層の神経細胞の数が学習回数及び収束に直接影響を与えるため、中間層及び中間層の神経細胞数の設定が問題となる。一般的には3層で多くの問題が解答できると考えられる。

2.10.2.2 非階層型ネットワーク [19][20]

非階層型ネットワークは、階層型ネットワークとは異なり、信号が入力層から中間層、出力層の単一方向に限らず、任意の方向に流れることを許可するネットワークモデルである。信号が逆方向、またはループ状に流れることもある。教師なし学習のアルゴリズムに適する。

2.10.3 ニューラルネットワークの学習プロセス [19][20]

ニューラルネットワークによるデータ解析は従来の手法と大きく異なる。その異なる点は、ニューラルネットワークが学習機能を有している点にある。学習とは、計算した結果(出力)を学習用データに近づくように重みの修正を繰り返し、最適な解を求めることである。ニューラルネットワークでは、

- ・ シナプスの結合の重み学習
- ・ 出力関数の学習
- ・ 中間層における神経細胞数の学習

等、学習機能が考えられる。その中で、最も基本的で、かつ重要なのはシナプスの結合の重みに関する学習である。ここでは階層型ネットワークにおけるシナプス結合の重みを定めるための学習について概論を示す。

階層型ネットワークにおける結合の重みを定めるための学習は次のステップに分割される。

- ① 入力データ $x_1, x_2, x_3, \dots, x_q$ をニューラルネットワークに与え、最初の段階で結合の重み $w_1, w_2, w_3, \dots, w_q$ に小さなランダム値を与え出力を求める。
- ② 出力結果と学習用データを比較し新しい結合の重み

$$w(j + 1) = w(j) + \eta \times \delta \times o_{net} \quad (2.46)$$

を計算する。ここで、

$w(j + 1)$: $j+1$ 回目の結合の重み

$w(j)$: j 回目の結合の重み

η : 定数

δ : ニューロンの出力結果と学習用のデータとの差に関する関数で、中間層、出力層によって異なる。

o_{net} : ニューロンの出力結果

である。

- ③ 新しい結合の重みに基づいて新たな出力値を求める。
- ④ 満足する結果が得られるまで $w(j+1)$ 重み計算を繰り返す。

ニューラルネットワークは、従来のデータ解析法より柔軟性を有する。現在に至るまで多くのアルゴリズムが実用され、商業用データ解析のソフトウェアパッケージに実装されている。

ニューラルネットワークが最も得意とする領域はパターン認識・分類、ノイズが混在しているデータ処理、関数の近似である。ニューラルネットワークが最も早く応用されたのは手書き文字の認識を含む画像パターン認識、音声認識等の情報工学に関連する分野であった。その後、医学の病名診断、財務分析、経済分析、市場分析等、様々な分野に応用されている。最近では、人文科学領域への研究にも応用されている。

参考文献

1. Brereton.G.R. A short history of chemometrics: a personal view. : CHEMOMETRICS, 2014.
2. Maliowski.R.E, Weiner.H.P , Levinstone.R.A. Factor analysis of solvent shifts in proton magnetic resonance. : J. Phys. Chem, 1970.
3. Davies.OL. Statistical Methods in Research and Production. : Oliver and Boyd: London, 1947.
4. 宮下芳勝 , 佐々木慎一. ケモメトリックス 化学パターン認識と多変量解析. : 共立出版, 1995.
5. 相島鐵郎. ケモメトリックス : 化学データからの情報抽出. : 食品衛生学雑誌, 1994.
6. Gasteiger.J , Engel.T. ケモインフォマックス-予測と設計のための化学情報学-. : 丸善株式会社, 2005.
7. 内田治, 松本秀明 , 上野真由美. すぐわかる JMP による統計解析. : 東京図書株式会社, 2002.
8. 内田治, 松本秀明 , 上野真由美. すぐわかる JMP による多変量解析. : 東京図書株式会社, 2002.
9. 廣野元久 , 林俊克. JMP による多変量データ活用術. : 海文堂出版, 2004.
10. 奥野忠一, ほか. 多変量解析法<改訂版>. : 日科技連, 1981.
11. 小西貞則. 多変量解析入門 一線形から非線形へ. : 岩波書店, 2010.
12. 永田靖 , 棟近雅彦. ライブラリ新数学大系 E20 多変量解析入門. : サイエンス社, 2001.
13. 石井俊全. まずはこの一冊から 意味がわかる多変量解析. : ベル出版, 2014.
14. 鐵健司. 新版 品質管理のための統計的方法入門. : 日科技連, 2000.
15. Owen.L.D, Peter.L.G. Statistical Methods in Research and Production. : Longman, 1984.
16. 竹村彰通. 統計第 2 版共立講座 21 世紀の数学 14. : 共立出版, 2007.
17. JMP Ver.11 多変量解析法. SAS 社. 2014, ページ: 76-78.
18. SAS Institute Inc. 「判別分析」プラットフォームの技術的詳細.(オンライン)2020 年 3 月. <https://www.jmp.com/support/help/ja/14-2/mm-discriminant-analysis-22.shtml#>.
19. 金明哲. R と WEKA によるニューラルネットワーク. フリーソフトによるデータ解析・マイニング 第 23 回 . 2020 年 3 月. https://www1.doshisha.ac.jp/~mjn/R/Chap_23/23.html.
20. 斎藤康毅.ゼロから作る Deep Learning Python で学ぶディープラーニングの理論と実装: オライリー・ジャパン, 2016.
21. Leroy Conel.J. The Postnatal Development of The Human Cerebral cortex. : Harvard Univ. Press, 1959.
22. McCulloch.S.W , Pitts.W. A logical calculus of the ideas immanent in neurons activity. : Bull.Math.Biophys.Vol.5, 1943.
23. 井岡良太, ほか. ニューラルネットワークによる物体認識技術の食品生産管理システムへの応用. : 第 34 回ファジィシステムシンポジウム講演論文集, 2018.
24. 佐竹隆顕, ほか. 家畜飼養管理システムへのニューラルネットワークの適用に関する研

究(1)-肥育豚の成長予測-. : 農業施設, 1994.

25. 荒木雅弘. フリーソフトではじめる機械学習入門. : 森北出版株式会社, 2014.

3章 食品分類に関わる先行研究

3.1 序論

食品に含まれる多種多様な分析機器にて計測される化学成分データは食品の品質管理手法として用いられることが少ない。一方で、画像処理技術、近赤外分光法、ハイパースペクトルカメラによるスペクトルデータ解析等の物性データ、脂質等の限られた化学成分値を測定し、計量化学的手法による評価を実施した先行研究が確認される。

本章では、これら先行研究を整理するとともに、化学成分に着目した品質管理手法の検討結果を整理する。

3.2 食肉加工品に対する官能・物理特性による評価 [1]

スモークベーコン、ソーセージ、パストラミ等、豚肉を原料として製造された食品を対象に特性評価を実施している。

官能・物理特性として、断面形状、匂い、味、粘度、微生物学特性として、サルモネラ菌、リステリア菌等の測定を実施している。

Fig.3-2-1 に、一部抜粋として、研究対象である食肉製品に対し実施した物理的特性(水分含有量・NaCl・灰分・総蛋白質量・脂肪含有量)の測定結果を示す。例えば、水分の最大値は、内臓を主成分としたソーセージの 57%であることを示している。また、灰分含有量は、無機成分値で評価し、結果、内臓主成分のソーセージが水分量同様最も含まれていることを確認している。このような結果を整理し、製品の特長付けを行っている。




Fig.3-2-1 Physical-chemical characteristics of studied meat products

(1- Smoked file; 2- Smoked bacon; 3- Pork sausages; 4- Sausage prepared from swine's entrails; 5- Pork pastrami; 6- Sheep sausages)

3.3 市販豚肉製品「ロース」における保水力と筋間脂肪含有量の評価 [2]

食肉製品、市販豚肉製品である「ロース」の保水力と筋間脂肪含有量に着目した評価を行っている。

保水力は食肉製品の品質管理において、重要な物性の1つであり、保水力低減は品質低下の遠因となるため、食肉加工業者等の関係者に大きな経済的損失を招く。その中で保水力低下は血液の流出等の視覚的評価が重要な指標となる。

筋間脂肪も食肉製品の品質への重要な指標であり、ジューシーさ等は筋間脂肪含有量が保水力とともに密接な関係があることを示している。

上記より、保水力、筋間脂肪の関係は豚肉製品の品質管理面において、重要な指標であることから、関係性について多くの研究が行われている旨を整理している。

本文献では、日本原産の三元豚に対し、保水力と筋間脂肪の関係性について調査を行い、豚肉製品全体の品質管理に資する資料収集を目的として研究を実施している。

本研究の結果としては、Table3-3-1 に示す通り、保水力と筋間脂肪含有量は有意な関係性が確認できず、pH 計測においても三元豚と一般的な豚肉製品との違いは確認できていない。これより、従来は筋間脂肪含有量と保水力の関係性が注目されていたが、保水力、筋間脂肪含有量は相関関係が見られなかったため、品質管理を行う際は、保水力、筋間脂肪含有量の双方に着目する必要があることを確認している。

Table3-3-1 Summary of pork loin quality traits

Traits	n	Average	Median	SD	Minimum	Maximum
IMF(%)	62	3.59	3.55	1.40	0.80	7.15
Moisture (%)	62	73.80	73.88	1.02	70.60	75.95
pH ¹⁾	60	5.93	5.93	0.14	5.71	6.29
Drip loss (%)	62	2.89	2.41	1.55	1.00	7.62
Cooking loss (%)	62	23.00	23.48	2.70	16.85	28.90

SD standard deviation; IMF intermuscular fat.

¹⁾ Due to problems with electrode, n = 60.

3.4 ラマン分光法による脂肪結晶状態測定による評価 [3]

本文献では、豚肉製品を対象に脂肪結晶状態をラマン分光法により測定し、非破壊視覚による劣化度評価を考察している。

食肉製品である豚肉製品を対象に、脂肪構造情報を含むラマン分光スペクトルを計測し、脂肪結晶状態の画像を取得するプロセスを確立している。加えて、測定試料に対する染色等の前処理は不要であり、その場で測定することが可能である手法を検討している。これより、脂肪がベースとなる食品の物性的評価に影響を与える脂肪結晶状態を容易に確認することが可能となるため、品質特性を把握に繋げることが可能となる。

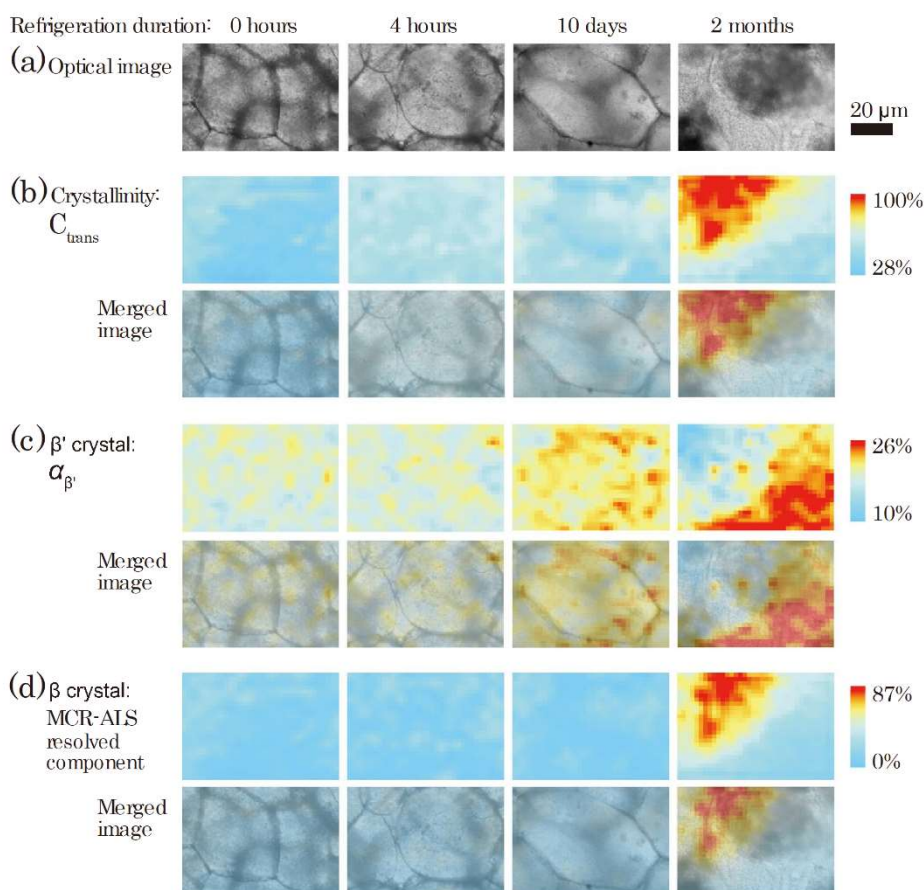


Fig.3-4-1 Simultaneous Raman microspectroscopic imaging of fat crystalline state of porcine adipose tissues refrigerated at 4 °C for different durations. Color scales are ranging from the minimum to the maximum values of the obtained result. (a) Optical microscopic images, (b) C_{trans} corresponding to the fat crystallinity, (c) $\alpha_{\beta'}$ corresponding to the amount of β' crystal polymorph, (d) concentration profile of an MCR-ALS-resolved component corresponding to β crystal polymorph.

3.5 豚肉製品中に含まれるイノシン酸の考察 [4]

イノシン酸やグアニル酸等の核酸関連物質は食肉製品の味形成において重要な役割を果たしている。その中で、豚肉製品の赤肉、速筋や遅筋といった筋肉型の違いが核酸関連物質含有量と構成に影響を与えている点に着目し、これらを明らかにするため、筋肉型の異なる豚肉製品の核酸関連物質を測定している。その結果、イノシン酸含有量は速筋型筋肉で有意に高いことが示されている。しかし、単純にイノシン酸含有量が品質項目として挙げられておらず、味形成の全てが作用しているわけではないことを結言で述べている。




Fig.3-5-1 Inosine 5' -monophosphate (IMP) content and total contents of ATP degradation products in the different porcine muscles.

3.6 豚肉製品分類法に関わる検討(クラスター分析) [5]

文部科学省のデータベースを用い、豚肉製品について分類・照合可能性を検討している。本検討では、原子吸光分析装置にて得られる無機成分5種類に限定し、クラスター分析を実施することで分類・照合傾向を確認している。

豚肉製品 83 種類の無機成分 5 つの含有量を用いてクラスター分析を実施している。その結果は Fig.3-6-1 に示した。

クラスター数は 5 つとし、赤肉が含まれている「製品種類」、「副生物」「脂身」「加工品」や「副生物」の軟骨が分類・照合できる可能性を示した。




Fig.3-6-1 Cluster coupling and coupling distance

3.7 豚肉製品分類法に関わる検討(クラスター分析・主成分分析) [6]

前節同様、豚肉製品を対象とした研究であり、「製品種類」の分類・照合を目指したものである。視覚でも確認が容易である「副生物」を除いた製品を対象に検討を行い、化学成分値は、前節同様 5 種類とした。また、実際の化学成分分析の現場において、測定誤差が生じることを鑑み元データに対し、人為的に±10%誤差を有するデータを追加しクラスター分析と主成分分析による分析を実施している。

クラスター分析の結果は Fig.3-7-1 に示す通りであり、各クラスター内に属する「製品種類」の比率から、①クラスターでは「脂身つき」「皮下脂肪なし」「赤肉」が混在している結果となった。これより、無機成分 5 成分ではこれらの赤肉が含まれている豚肉製品の分類は難しいことが確認できた。一方、②、③のクラスターはそれぞれ「脂身」「加工品」と赤肉の含まれる製品と判別することができた。

主成分分析の結果は Fig.3-7-1 のように示されており、クラスター分析結果同様、大きく 3 つのグループに分けることが可能である。

グループⅡは「脂身つき」「皮下脂肪なし」「赤肉」が混在しているグループ、Ⅰは「脂身」、Ⅲは「加工品」が集中している。これは測定誤差を与えているデータも同様の傾向であった。本論文では、この結果を受けてグループⅡに囲まれたデータ群のみを抽出して、その試料のみを同様の手段で主成分分析を実施している。その結果は Fig.3-7-2 に示す通りである。これより、グループ A で囲まれた「赤肉」のみ 1 つのグループとして見なすことが出来たが、グループ B、グループ C で囲まれている「脂身つき」「皮下脂肪なし」については、混在しており分類することが出来なかった。




Fig.3-7-1 Product type existence ratio of each cluster

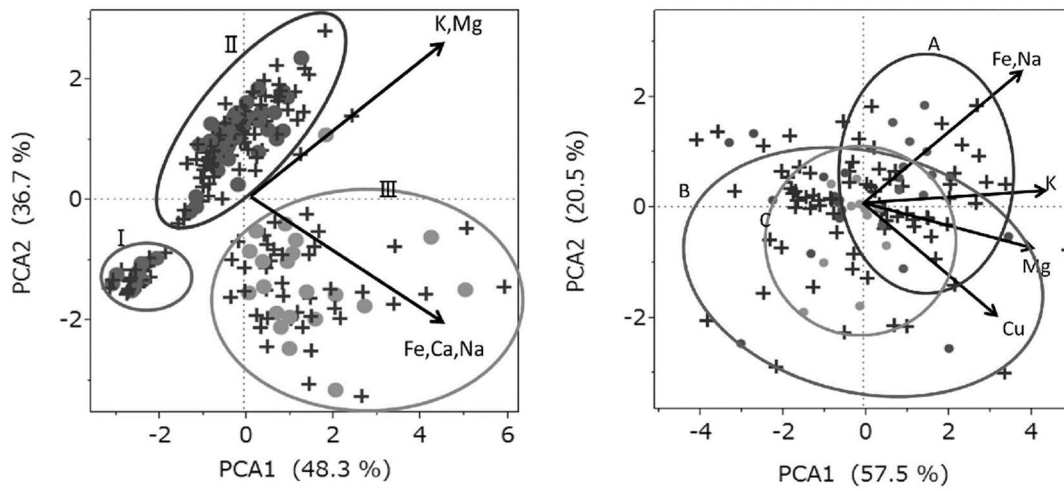


Fig.3-7-2 Principal component analysis results

3.8 食肉製品(豚・牛・鶏)に関わる検討(クラスター分析・主成分分析) [7]

本検討では、無機成分とは異なる味覚由来の化学成分を対象とした食肉製品の分類・照合を検討している。

具体的には、スポーツ選手が日常の食生活で味を堪能し、必要な栄養素を効率良く摂取する食材である豚・牛・鶏肉製品 29 品目を対象とし、味覚由来物質であるナトリウム、炭水化物、グルタミン酸の定量値データを分類指標とし、分析装置と生産地による定量誤差として±10%考慮したデータ値を加えデータベースを作成、計量化学的手法である、クラスター分析、主成分分析により様々な観点から分類が可能であるか検討を行った。

クラスター分析の結果は Fig.3-8-1 に示す通りである。この結果より、甘味由来物質である炭水化物、塩味由来物質であるナトリウム、旨味由来物質であるグルタミン酸を定量することにより赤肉に含まれる「赤肉」「皮下脂肪なし」「脂身つき」と「副生物」に分類・照合が可能であることを示した。特に③、④、⑤クラスターにおいては、動物種と副生物の部位で分類出来ているクラスターであり、味覚由来物質 3 種類をデータ解析に使用することにより特徴的な製品は分類が可能であることが判明した。①クラスターで「副生物 豚・牛肝臓、豚・じん臓以外」が混在していた。

主成分分析の結果は、Fig.3-8-2 に示す通り、Ⅲグループは、豚・牛の「副生物」肝臓製品、Ⅳグループは豚の「副生物」じん臓、Ⅱグループは、肝臓製品、豚肉のじん臓以外の「副生物」が存在するグループとなった。Ⅰのグループは各動物種関係なく赤肉を含む製品が集まっている。一方で、甘味、旨味、塩味の由来物資である炭水化物、グルタミン酸、ナトリウムの含有量が比較的少ない位置に存在するⅤグループは「脂身」と鶏の「かわ」が存在していることがわかった。これより、味覚由来物質を定量することで、「赤肉を含む製品(「赤肉」「脂身つき」「皮下脂肪なし」)」と「副生物」に分類することが出来る可能性を見出した。




Fig.3-8-1 Product type existence ratio of each cluster

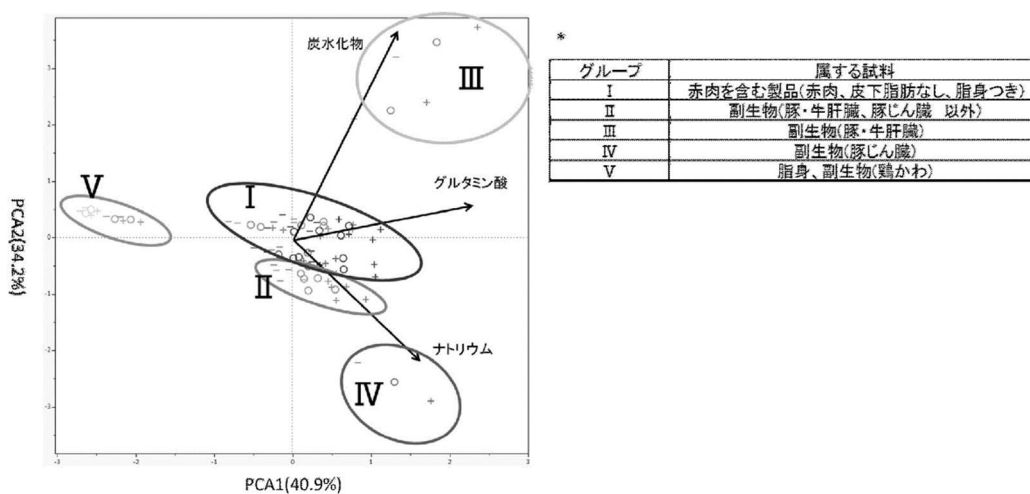


Fig.3-8-2 Principal component analysis

* O: sample without error, +: sample with + 10% error, -: sample with -10% error

参考文献

1. Dobrinas.S, ほか. Quality control of some traditional meat products: Scientific study & reseaech .Vol.14, 2013.
2. Watanabe.G, ほか. Relationship between water-holding capacity and intramuscular fat content in Japanese commercial pork loin: Asian-Australasian Jpurnal of Animal Sciences, 2018.
3. Motoyama.M, ほか. A raman spectroscopic method og evaliating fat crystalline states and its application in detecting pork fat: Japan Agricultural Research Quarterly, 2018.
4. 千国幸一, ほか. ブタ肉中のイノシン酸含有量におよぼす筋肉型の影響: 日本養豚学会誌, 2013.
5. 合田元清 小島洋一郎, 三上剛, 宇津野国治. 無機成分の化学分析値とクラスター分析を用いた豚肉製品分類法に関する基礎的検討. : 日本味と匂学会論文誌, 2011.
6. 合田元清, ほか. 無機成分含有量と多変解析による豚肉製品の分類: 味と匂学会, 2012.
7. 中島広基, ほか. 栄養成分データとケモメトリクスを用いた食品の識別方法 : 味と匂学会, 2013.

4章 多変量解析手法を用いた食肉製品 分類評価の検討

4.1 緒言

本章では、先行研究では成されていない、食肉製品に含まれる多様な化学成分含有量に注目した品質評価に繋がる分類・評価を行うため、主要な食肉製品である豚肉及び牛肉製品を対象に検討を行った。

具体的な手法として、化学分析機器から得られる化学成分含有量データを用い「製品種類」「部位」への分類とその評価を実施した。

昨今、日本においても注目されている計量化学(ケモメトリクス)は、数理科学、統計学、機械学習、パターン認識等を複合し、化学分野における様々な問題解決の一助となる手法として注目されている。食品科学の分野においても例外なく、膨大な化学成分分析結果から、品質管理手法に直結する1つの結果を見出す手法として研究が進められている。先行研究では、食肉を含めた食料品の品質管理、産地情報等の安全保障を確保可能なシステムの構築に向けた計量化学的手法の適応、特に画像処理、近赤外分光法、ハイパースペクトルカメラによるスペクトルデータ解析等により、食肉製品の化学的特性を確認し、動物種類の特定や品質管理に応用する技術を検討している。 [1][2][3][4][5][6][7][8]

一方で、食肉製品そのものに含まれている化学成分に着目した品質管理手法については研究が進めておらず、食肉製品中の無機成分、脂質測定による食肉製品の特性に関わる研究に留まる。

また、化学成分値を用いた多変量解析による食肉製品分類法の検討に関連した先行研究では、原子吸光分析装置にて定量可能な豚肉製品について、食肉製品中に果たす機能に応じた恣意的な選別を実施した上で、「製品種類」(赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身)に分類可能であるか検討をしている [9][10][11][12][13]。この結果、無機成分含有量では赤肉を含む生肉製品とその他の製品を分類することが可能ではあるが前者を完全に分類する事ができる結果には至ることがなかった。一方で、クラスター分析にて、豚肉製品を分類後、「製品種類」が混在するクラスターに対し、判別分析を行くことによって、「製品種類」を正確に分類できる可能性を見出せた。

しかし、上記結果からは、使用する無機成分を恣意的に決定し、あらかじめ5種類を用いる事を前提としており、その他の無機成分、主要な栄養成分については無視した結果となっている。先行研究で用いた無機成分5種類以外においても分類に有用な無機成分、主要な栄養成分が存在する可能性があるため、食品成分表に記載されている主要栄養成分から探索する必要がある。加えて、多変量解析手法を複合して利用することは、対象とする試料への二重解析に当たることから、単一手法による分類を検討する必要が

ある。

したがって、本論文本章では、先行研究で報告されている豚肉製品に加え牛肉製品に含まれる主要栄養成分、無機成分及びビタミン成分を対象に分類の可能性を分散分析及び判別分析等、多変量解析により評価した。評価は、無機成分、ビタミン成分等を対象とし、分類の可能性と必要な成分の絞り込みを実施した。次節以降は、その内容について、詳細を取り纏めた。

4.2 先行研究の結果

先行研究で実施した、豚肉製品 82 種に含まれる、ナトリウム、カリウム、カルシウム、鉄、マグネシウムを対象とした際のクラスター分析の結果について Fig.4-2-1 [12] [13]に示す。




Fig.4-2-1 Cluster analysis results with inorganic components for 82 pork products [12]

上記結果より、豚肉製品 82 種は 5 つのクラスターに分類可能であることを確認した上で、概略樹形図を作成している。その結果は Fig.4-2-2 に示し、各クラスターの内容を Fig.4-2-3 [1]に示した。




Fig.4-2-2 Overview of cluster analysis for 82 pork products [12]




Fig.4-2-3 Characteristics of each cluster [12]

この結果より、①、②のクラスターは「製品の種類」が3~4種類混在しているのがわかる。2つのクラスターそれぞれに赤肉の有無が特徴として挙げられるが、「製品種類」が混在しているため、正確に分類されたと結論付けるのは難しい。一方、③、④、⑤クラスターは、それぞれ、肝臓の「加工品」、肝臓を除く「加工品」、軟骨である「副生物」と分類することができた。要因としては、肝臓の「加工品」は、ナトリウム、鉄の含有量が他製品と比較し多量に含まれることが考えられる。同じく、肝臓製品を除く「加工品」は、食塩含有量に直接関係があるナトリウム含有量が、軟骨は骨の主成分であるカルシウム含有量が高いため特異的なクラスターが形成されて分類が可能と評価した。

4.3 豚肉製品を対象とした検討

本研究における、化学成分値を用いた豚肉製品の分類可能性の評価手法について述べる。

4.3.1 実験手法

4.3.1.1 使用する豚肉製品データの取得

文部科学省 科学技術・資源調査分科会報告 7 訂増補日本食品成分表 2015 [14]における代表的な豚肉製品 88 種類を抽出し、これらを試料として解析対象とした(Table4-3-1)。

取得した豚肉製品に含まれる、無機成分 13 種類(ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅、マンガン、ヨウ素、セリン、クロム、モリブデン)、ビタミン成分 12 種類(レチノール、 β カロテン、ビタミン D、ビタミン K、ビタミン B1、ビタミン B2、ナイアシン、ビタミン B6、ビタミン B12、葉酸、パントテン酸、ビタミン C)の含有量も併せて取得した(Table4-3-2)。なお、「Tr」「-」「0」と記載のある場合、該当する化学成分の含有量が著しく低い、または、含まれていないことを示しているため、一律「0」とした。

Table4-3-1 Pork product data (88types in total) [5]

◎Large type breed(26 products) , Medium type breed(22 products) / Raw , Roasted , Boild <ul style="list-style-type: none">・ Picnic Shoulder (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat)・ Picnic Shoulder loin (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat)・ Belly (Lean and fat)・ Ham (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat)・ Outside Ham (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat)・ Fillet (Red meat)
◎Offal and by-products(10 products) /Raw , Boild
◎Meat substitute (28 products) Ham , Sausage , The other
◎Other (2 products) Ground meat

Table4-3-2 Types of inorganic components and vitamins [5]

<p>◎Inorganic components (13 species)</p> <p>Sodium , Potassium , Calcium , Magunesium Phosphorus , Iron , Zinc , Copper , Mamgan Iodate , Selenium , Chrome , Molybdenum</p>
<p>◎Vitamin components (12 species)</p> <p>Retinol , β-carotene , Vitamin D , Vitamin K Vitamin B1 , Vitamin B2 , Vitamin B3 , Vitamin B6 Vitamin B12 , Folate , Pantothenic acid , Vitamin C</p>

4.3.1.2 分散分析による化学成分値の順位付け

量的データである化学成分含有量を「製品種類」（赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身）、「部位」（かた、かたロース、そともも、ばら、ひれ、もも、ロース、肝臓、豚足、内臓、軟骨、ゼラチン、ひき肉、加工品）に分類されることを仮定し、分類される製品種類の決定に影響を与える化学成分値を製品が属する各分類項目同士の群間分散と各分類項目（「製品種類」「部位」）間に属する試料間の群内分散の比である F 値を算定し検定した。

4.3.1.3 判別分析による「製品種類」及び「部位」分類に寄与する化学成分値の特定

豚肉製品 88 種の「製品種類」、「部位」について、無機成分、ビタミン成分それぞれ 13 種を対象に何種類の成分があれば分類が可能か判別分析により評価した。

本節では、豚肉製品の「製品種類」「部位」をグループとし、それらを決定付けるデータを無機成分、ビタミン成分とした。それぞれの豚肉製品に含まれている成分含有量により、「製品種類」、「部位」毎に形成された多変量空間内において、豚肉製品がどの「製品種類」、「部位」に判別されるかを算定した。また、本検討で用いた判別分析法は、線形判別分析法を用い、どの「製品種類」、「部位」に判定するかは、Mahalanobis 距離 [6] [7] [8]により算定した。なお、評価に必要な指標は、適切な「製品種類」「部位」に判別された豚肉製品を正判別とし、全体の製品数 88 種に対し、正確に分類された製品の製品数より正判別率を判定した。この正判別率は、分散分析により算定した F 値による順位付けを行った無機成分、ビタミン成分の上位化学物質から順に選択変数とし、1 つずつ順番に成分数を増加する毎に算定、成分の増加による推移を示した。これより、何種類の化学成分含有量を用いる事で、「製品形態」「部位」を分類可能であるか評価した。

$$\text{Determination rate}(\%) = \frac{\text{Positive discrim samples}}{\text{All samples}} \times 100 \quad (4.1)$$

4.3.2 豚肉製品を対象とした検証結果

検証結果を以下に示す。

4.3.2.1 分散分析による分類に寄与する化学成分値の順位付け

分散分析による豚肉製品の「製品種類」、「部位」に寄与する化学成分値を分散分析により F 値 [9]を算定し、その多寡によってそれぞれの分類に寄与する化学成分を順位付けした。その結果を以下に示す。

(1) 「製品種類」に対する結果

豚肉製品の「製品種類」に対し無機成分含有量を用いた分散分析結果について説明する。F 値が最も高い結果となった無機成分は、ナトリウムであった。次点以降は、マグネシウム、カリウム、リン、マンガン、亜鉛と続き、最後 13 番目の無機成分はセレンとなった。これより、「製品種類」7 種類（赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身）の分類において重要な無機成分の順位を Fig.4-3-1 に示す F 値の通り決定した。

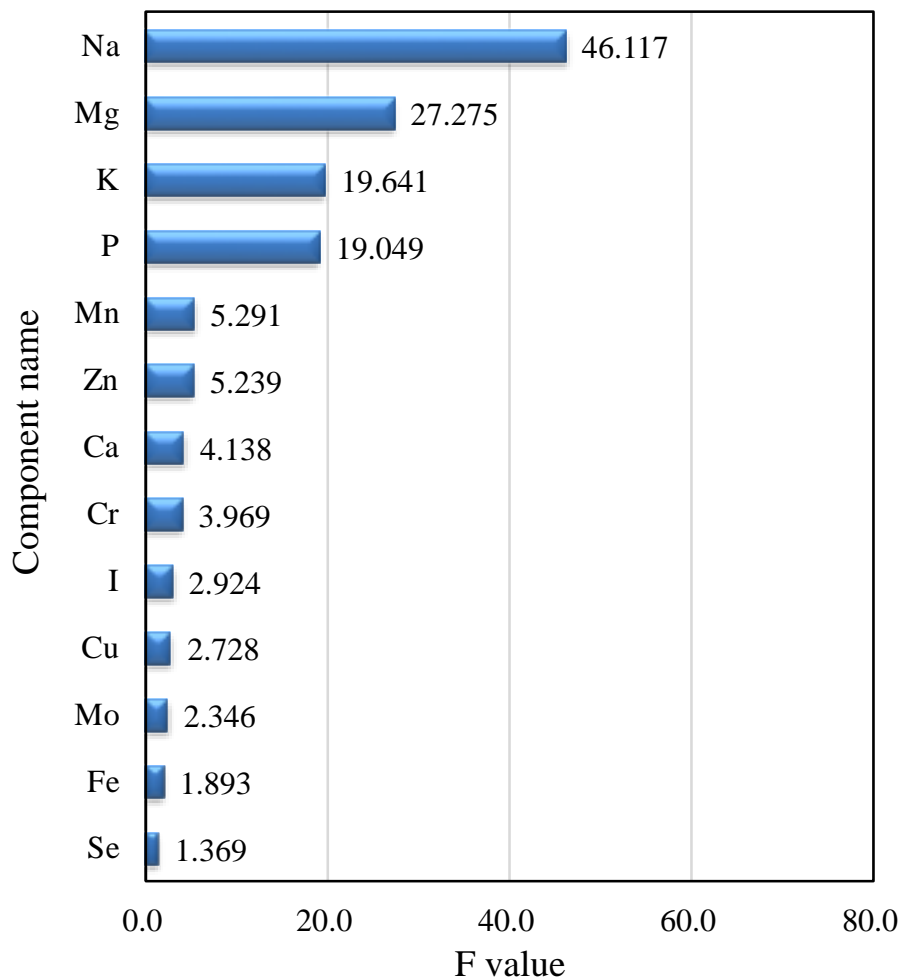


Fig.4-3-1 F value ranking for inorganic components (product type)

次に「製品種類」に対しビタミン成分含有量を用いた分散分析結果について説明する。このF値算定結果で最も大きな数値を示した物質は、ビタミンB1であった。これより順番に、ビタミンB6、ビタミンC、ビタミンD、ナイアシンと続き、12番目はレチノールとなった。

「製品種類」7種類（赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身）の分類において重要なビタミン成分の順位を Fig.4-3-2 [9]のF値の通り決定した。

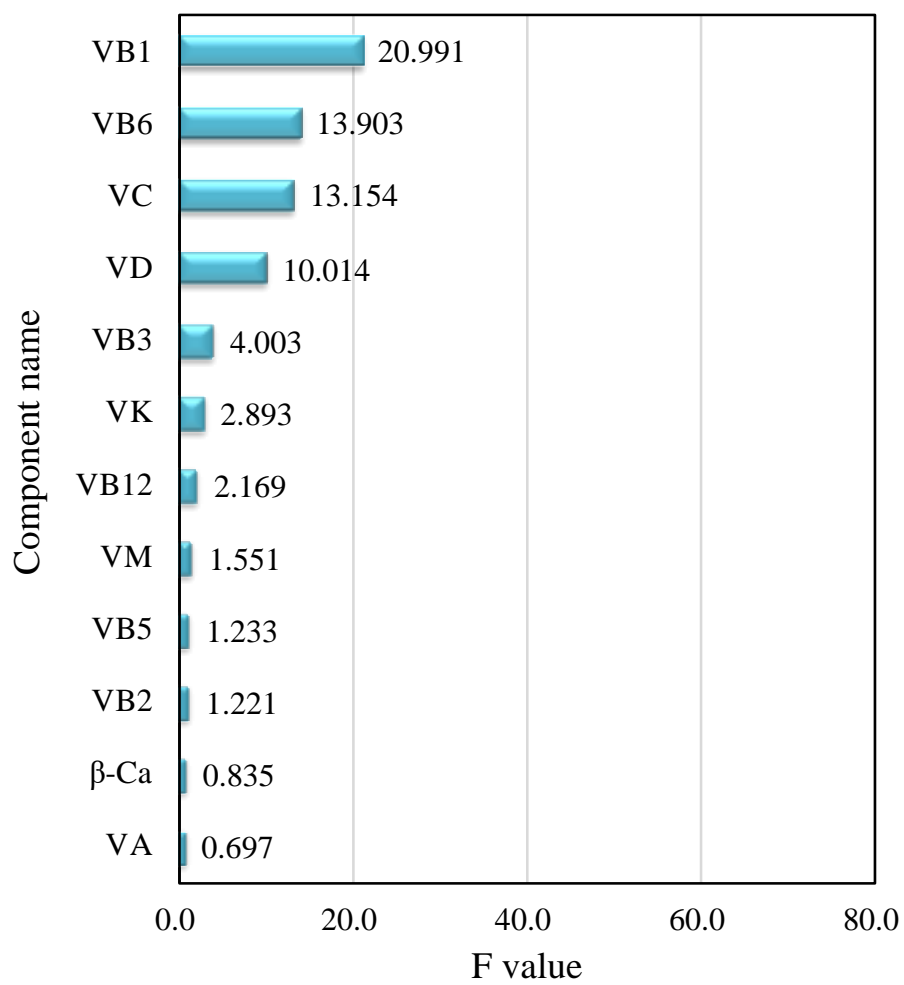


Fig.4-3-2 F value ranking for vitamins components(product type)

(2) 「部位」に対する結果

豚肉製品の「部位」に対する分散分析結果について説明する。

無機成分含有量で行った分散分析の結果、カルシウムが最も高いF値を示し、次点以降は、ナトリウム、クロム、リン、カリウムの順となった。なお、F値が13番目と最も低い値を示した無機成分は亜鉛であった。以上より、「部位」14種類（かた、かたロース、そともも、ばら、ひれ、もも、ロース、肝臓、豚足、内臓、軟骨、ゼラチン、ひき肉、加工品）の分類において重要な無機成分の順位を Fig.4-3-3 に示す F 値の通り決定した。

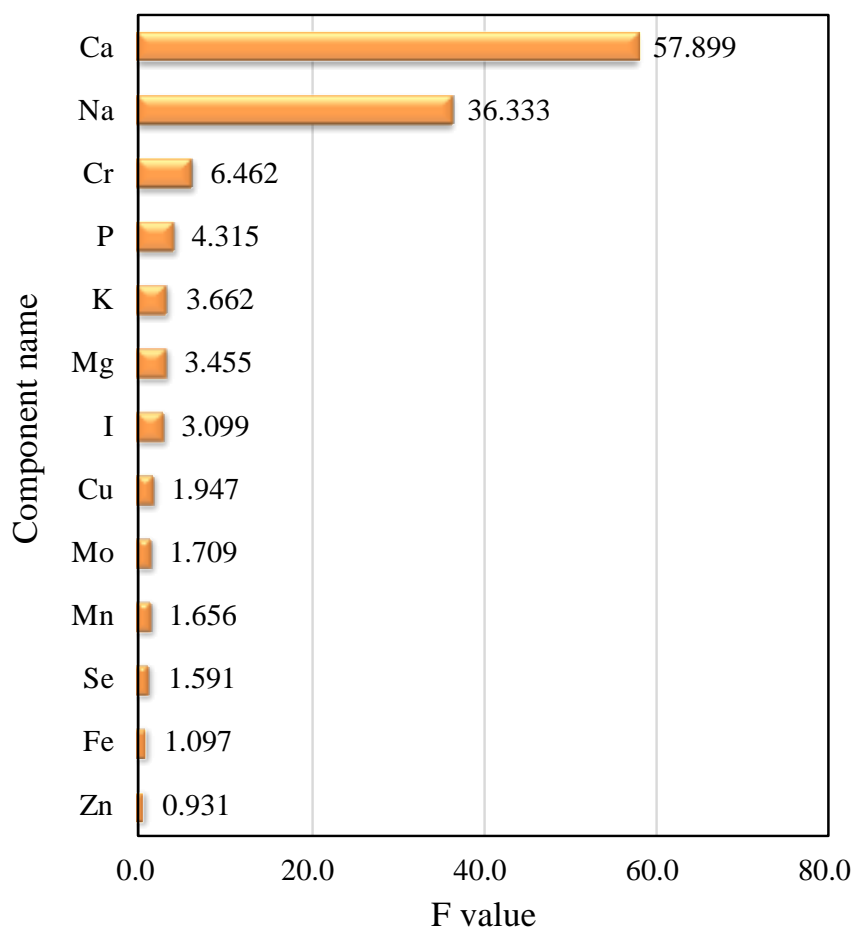


Fig.4-3-3 F value ranking for inorganic components (product part)

対して、ビタミン成分含有量で行った結果は、ビタミンCが最も高いF値を示し、次点以降、ビタミンB1、ビタミンD、ビタミンB6、ビタミンKと続いた。レチノールのF値は「製品種類」同様最下位となった。これより、「部位」14種類（かた、かたローズ、そともも、ばら、ひれ、もも、ローズ、肝臓、豚足、内臓、軟骨、ゼラチン、ひき肉、加工品）の分類において重要なビタミン成分の順位を Fig.4-3-4 に示す F 値の通り決定した。




Fig.4-3-4 F value ranking for vitamin components (product part)

4.3.2.2 判別分析による「製品種類」及び「部位」分類に寄与する化学成分値の特定

4.3.2.1 節では、分散分析による豚肉製品の「製品種類」、「部位」に寄与する化学成分値を分散分析により F 値 [7] [6]を算定し、その多寡によってそれぞれの分類に寄与する化学成分を順位付けした。この結果を用い、判別分析による分類状況を評価した上で、これらに必要な化学成分の特定を試みた。

(1) 「製品種類」に対する結果

分散分析によって算定した F 値の順位に応じ、化学成分含有量を追加する操作を繰り返す、「製品種類」に対する豚肉製品 88 種の製品別判別率の推移を示し、何種類の化学成分を測定すれば正確に分類可能となるかを検証した。

初めに、無機成分で行った結果を Table4-3-3、Fig.4-3-5 に、ビタミン成分で行った結果を Table4-3-4、及び、Fig.4-3-6 に示した。

Fig.4-3-5 に示した無機成分による「製品種類」の判別分析結果では、F 値が最上位であるナトリウム 1 成分で判別率 62.5%となった。マグネシウムを追加した 2 成分では 72.7%、カリウムを加えた分析結果は、一時的に判別率の低下が見られたがリンを追加した 4 成分による分析の結果から、成分数を追加しても判別率が横ばいとなり 76.1%前後で推移した。12 種類（ナトリウム、マグネシウム、カリウム、リン、マンガン、亜鉛、カルシウム、クロム、ヨウ素、銅、モリブデン、鉄）で判別分析を行った場合、判別率は、最高 85.2%であった。

以上の結果より、無機成分の測定成分数を勘案すれば、4 種類（ナトリウム、マグネシウム、カリウム、リン）の F 値上位 4 成分の含有量を定量することで豚肉製品 88 種の「製品種類」は約 8 割程度判別することが可能であった。

Table4-3-3 Result of discriminant analysis using inorganic component for pork product type

Rank of F value	component name	Determination rate
1	Na	62.5%
2	Mg	72.7%
3	K	68.2%
4	P	76.1%
5	Mn	76.1%
6	Zn	76.1%
7	Ca	76.1%
8	Cr	75.0%
9	I	76.1%
10	Cu	76.1%
11	Mo	77.3%
12	Fe	85.2%
13	Se	83.0%

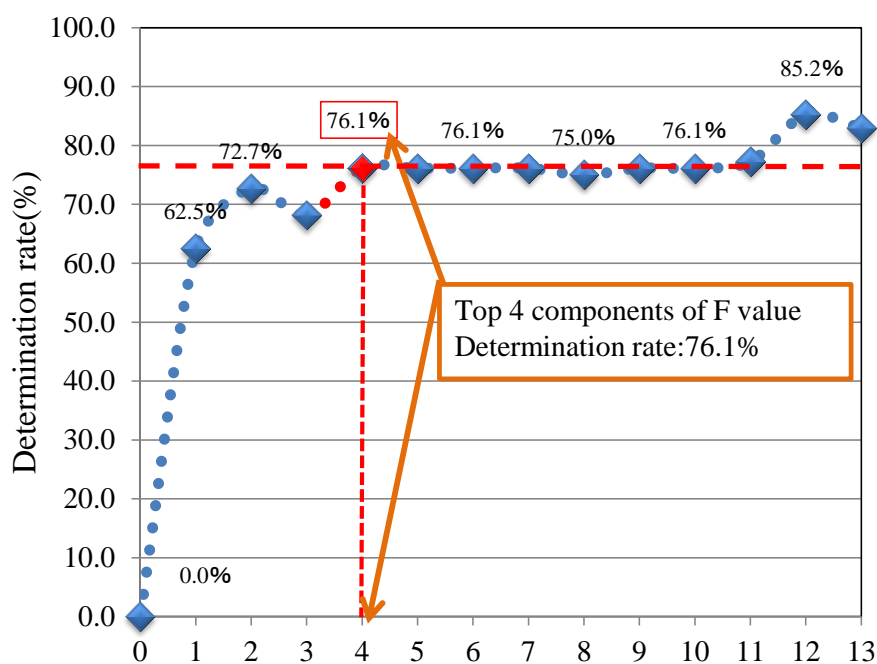


Fig.4-3-5 Result of discriminant analysis using inorganic component for pork product type

一方、Fig.4-3-6 に示したビタミン成分による「製品種類」の判別分析結果は、F 値最上位であるビタミン B1、1 成分による計算結果が 37.5%と低く、上位 7 成分（ビタミン B1、ビタミン B6、ビタミン C、ビタミン D、ナイアシン、ビタミン K、ビタミン B12）を追加した結果で正判別率 67.0%と 3 割以上が本来の「製品種類」とは異なる分類傾向を示した。

Table4-3-4 Result of discriminant analysis using vitamin component for pork product type

Rank of F value	component name	Determination rate
1	VB1	37.5%
2	VB6	35.2%
3	VC	50.0%
4	VD	53.4%
5	VN	54.5%
6	VK	62.5%
7	VB12	67.0%
8	VM	65.9%
9	VB5	65.9%
10	VB2	64.8%
11	β -Ca	64.8%
12	VA	63.6%

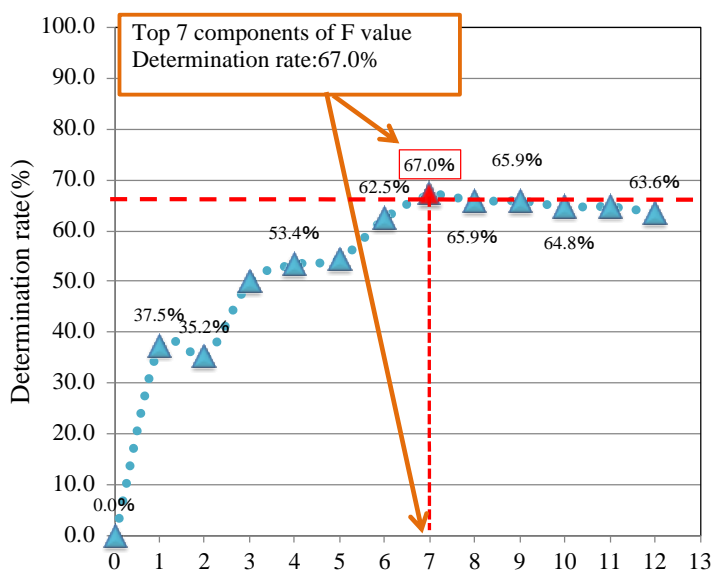


Fig.4-3-6 Result of discriminant analysis using vitamin component for pork product type

(2) 「部位」に対する結果

分散分析によって算定したF値の順位に応じ、化学成分を追加する操作を繰り返し行い、「部位」に対する豚肉製品88種の製品判別率の推移を示した上で、何種類の化学成分を定量すれば正確に分類可能となるかを評価した。

無機成分で行った結果を Table4-3-5、Fig.4-3-7、ビタミン成分で行った結果を Table4-3-5、Fig.4-3-8 にそれぞれ示した。

Fig.4-3-7 に示した無機成分による結果は、F値が最上位であるカルシウムのみを成分として行った結果、正判別率18.2%となった、その後、ナトリウムを追加し2成分とした場合、40.9%と向上した。カルシウム、ナトリウム、クロム、リンの4成分を対象とした分析では40.9%、F値上位10成分マンガンまでを対象とした場合は68.2%となった。なお、無機成分13種全成分を用いた分析結果は、正判別率72.7%となり、無機成分13種類を計測することで7割程度判別可能である。

Table4-3-5 Result of discriminant analysis using inorganic component for pork product parts

Rank of F value	component name	Determination rate
1	Ca	18.2%
2	Na	40.9%
3	Cr	44.3%
4	P	45.5%
5	K	52.3%
6	Mg	56.8%
7	I	58.0%
8	Cu	59.1%
9	Mo	59.1%
10	Mn	68.2%
11	Se	69.3%
12	Fe	68.2%
13	Zn	72.7%

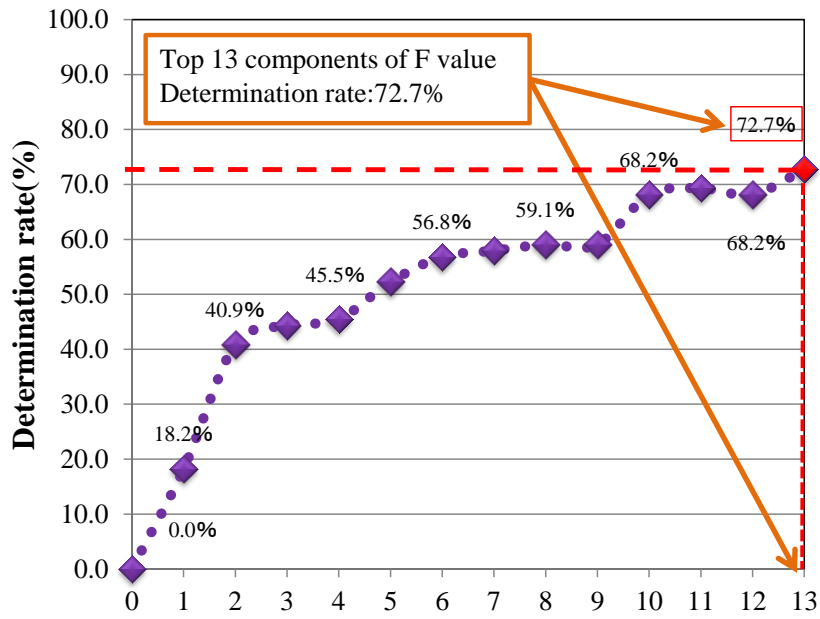


Fig.4-3-7 Result of discriminant analysis using inorganic component for pork product parts

ビタミン成分を対象とした判別分析結果の傾向は、F 値最上位であるビタミン C を対象とした分析結果は正判別率 23.9%と低く、ビタミン C、ビタミン B1、ビタミン D、ビタミン B6 の 4 成分を対象とした結果においても正判別率 42.0%と低水準であった。

ビタミン成分 10 成分で正判別率 65.9%となり、約 7 割を正しく分類できることを評価した。

Table4-3-6 Result of discriminant analysis using vitamin component for pork product parts

Rank of F value	component name	Determination rate
1	VC	23.9%
2	VB1	34.1%
3	VD	40.9%
4	VB6	42.0%
5	VK	46.6%
6	VB12	50.0%
7	VN	55.7%
8	β -Ca	56.8%
9	VM	58.0%
10	VB5	65.9%
11	VB2	64.8%
12	VA	64.8%




Fig.4-3-8 Result of discriminant analysis using vitamin component for pork product parts

4.3.2.3 結果のまとめ

本節の結果について整理する。

以上の結果より、豚肉製品の「製品種類」と「部位」判定に寄与すると考えられる、無機成分とビタミン成分の特定を行った。

特定は、正判別率の推移、化学成分値の種類数を限定することを考慮にいれ、「製品種類」の無機成分はF値上位4成分（ナトリウム、マグネシウム、カリウム、リン）、ビタミン成分は上位9成分（ビタミンB1、ビタミンB6、ビタミンC、ビタミンD、ナイアシン、ビタミンK、ビタミンB12、葉酸、パントテン酸）とした。同様に、豚肉製品の「部位」であれば無機成分は、4成分（ナトリウム、マグネシウム、カリウム、リン）、ビタミン成分であれば、10成分（ビタミンC、ビタミンB1、ビタミンD、ビタミンB6、ビタミンK、ビタミンB12、ナイアシン、 β -カロテン、葉酸、パントテン酸）とした。

これら結果より、それぞれ特定した化学成分値を計測することで7割前後の分類・評価が可能となる。

4.3.3 結果の考察

本節では、豚肉製品に含まれる化学成分値を用いた分類の可能性について評価した考察を示す。

4.3.3.1 「製品種類」に対する結果

豚肉製品の「製品種類」に対し無機成分で行った分散分析の結果、ナトリウム、マグネシウム、カリウム、リン、マンガン、亜鉛、カルシウム、クロム、ヨウ素、銅、モリブデン、鉄、セレンの順でF値が高い結果となった。この中で、F値が10以上であり、「製品種類」を決定づける要因として高いと予想されるナトリウム、マグネシウム、カリウム、リンについて抜粋し考察を行う。

初めに各豚肉製品の製品種類別に含まれているナトリウム、マグネシウム、カリウム、リンの平均含有量の平均値を Table4-3-7 に示した。これより、ナトリウム、リンの含有量が高い豚肉製品は、食塩、重合リン酸塩を始めとするナトリウム塩、リン酸塩由来の添加物 [5]が含まれていることから「加工品」と予想可能である。同様にマグネシウム、カリウム含有量で比較する場合であれば、「赤肉」、「皮下脂肪なし」、「ひき肉」といった豚肉の赤身が含まれている関係より「副生物」、「脂身」と比較し高い含有量を示す。以上の要因により、これら4無機成分含有量の多寡は、豚肉製品の「製品種類」に決定するために重要な要素になり得ることから、分散分析により高いF値を示したことが推察できる。

ビタミン成分を対象に実施した分散分析の結果は、ビタミンB1、ビタミンB6、ビタミンC、ビタミンD、ナイアシン、ビタミンK、ビタミンB12、葉酸、パントテン酸、ビタミンB2、βカロテン、レチノールの順でF値が高い結果となった。ビタミン成分も同様、各豚肉製品に含まれている12種類の物質から、10以上のF値を示したビタミンB1、ビタミンB6、ビタミンC、ビタミンDについて、含有量を平均化し、「製品種類」毎の平均値を Table4-3-8 に示した。これより、ビタミンB1、ビタミンB6の多寡により、赤身が可食部として割合の高い傾向にある「赤肉」、「ひき肉」、「皮下脂肪なし」、「脂身つき」と、割合の低い「副生物」、「脂身」、または、添加物を加え調理した「加工品」との傾向を明確に分けることが可能であった。ビタミンDであれば、ビタミンB1、ビタミンB6とは真逆の傾向を示し、含有量が高ければ、可食部として赤身が少ない「製品種類」、または「加工品」であることがわかる。ビタミンCは、加工・調理の段階で保存料として用いられるため、「加工品」のグループでは含有量が高い傾向を示している。以上より、これら4ビタミン成分含有量の多寡は、豚肉製品の「製品種類」に決定

するために重要な要素になり得ることから、分散分析により高いF値を示したと考察できる。

Table4-3-7 Average content of inorganic component by pork product types (Na、Mg、K、P)
(mg/100g)

Product types	Na	Mg	K	P
Red meat	57.769	26.615	398.462	222.308
Lean and fat	47.800	20.267	300.000	172.000
Without subcutaneous fat	50.583	23.750	340.000	198.333
Ground meat	68.500	24.500	365.000	145.000
Offal and by-products	102.636	11.818	135.364	137.455
Meat substitute	887.600	18.680	258.400	241.200
Fatty meat	19.900	5.800	110.100	57.600

Table4-3-8 Average content of vitamin component by pork product types
(VB1、VB6、VC、VD)

(mg or µg/100g)

Product types	VB1	VB6	VC	VD
Red meat	1.016	0.433	1.385	0.115
Lean and fat	0.694	0.310	1.000	0.167
Without subcutaneous fat	0.838	0.366	1.250	0.108
Ground meat	0.815	0.390	1.000	0.400
Offal and by-products	0.159	0.150	5.455	0.791
Meat substitute	0.483	0.243	23.600	0.520
Fatty meat	0.232	0.077	0.700	0.320

豚肉製品の「製品種類」に対し無機成分、ビタミン成分それぞれで行った判別分析の結果に対し考察を行う。なお、詳細は Table4-3-9 に示す。

全 13 無機成分を用い、F 値によって順位付けした順番で変数として追加し、正判別率を算出した結果、ナトリウムのみで 62.5%、マグネシウムの追加で 72.7%と正判別率は増加傾向にあった。しかし、カリウムを追加した時点で 68.2%と一時的に正判別率が減少した。これは、製品種類である「赤肉」と「皮下脂肪なし」に属する製品のカリウム含有量平均値が同程度であることから、判別分析の一部計算結果より「赤肉」製品が「皮下脂肪なし」に、または「皮下脂肪なし」の製品が「赤肉」に属することとなった。

したがって、正判別率が一時的ではあるが低下したと考えられる。また、F 値上位 4 無機成分により行った分析結果による「製品種類」別正判別率は、「ひき肉」: 100.0%、「加工品」: 92.0%、「脂身」: 100.0%と正確に判別可能である結果が示唆された。一方、可食部として赤身が含まれる「赤肉」「脂身つき」「皮下脂肪なし」、内臓製品、ゼラチン等の「副生物」は正判別率が 58.3~66.7%となり正確な分類を行うためには、ナトリウム、マグネシウム、カリウム、リンのみでは不足していることがわかる。

全 12 ビタミン成分を用い、F 値によって順位付けした順番で変数として追加し判別分析を行った結果は、ビタミン成分を増やすにつれ、正判別率が増加傾向を示すが、7 成分（ビタミン C、ビタミン B1、ビタミン D、ビタミン B6、ビタミン K、ビタミン B12、ナイアシン）を対象成分とした時点で正判別率が 67.0%となり、これ以上の増加は見られなかった。この結果より、ビタミン成分は 7 種類定量すれば 7 割程度判別可能であることが確認できた。「製品種類」別の正判別率を見た場合、「ひき肉」、「脂身」が 100%正しく判別された。また、「加工品」についても、正判別率: 76.0%と「赤肉」、「皮下脂肪なし」、「脂身つき」、「副生物」と比較して高い結果を示した。これは、「脂身」が脂肪分を多く含み、ビタミン成分が他の「製品種類」と比較し少量であることが要因である。また、「ひき肉」は、ビタミン D が他の赤身を含む「製品種類」と比較し多く含まれ、ビタミン C が少量であることが高い判別結果を示した要因である。「加工品」は保存料に含まれるビタミン C 含有量が他比較して特異的に高いことが要因として挙げられる。

Table4-3-9 Discrimination analysis result by pork product types.

Selected Chemical components	Determination rate	
	Inorganic Na, Mg, K, P	Vitamin VB1, VB6, VC, VD, VN, VK, VB12
Red meat	61.5%	53.8%
Lean and fat	66.7%	40.0%
Without subcutaneous fat	63.6%	63.6%
Ground meat	100.0%	100.0%
Offal and by-products	63.6%	63.6%
Meat substitute	92.0%	76.0%
Fatty meat	100.0%	100.0%

4.3.3.2 「部位」に対する結果

豚肉製品の「部位」に対し行った分散分析の結果は、カルシウム、ナトリウム、クロム、リン、カリウム、マグネシウム、ヨウ素、銅、モリブデン、マンガン、セレン、鉄、亜鉛の順でF値が大きい結果となった。この中で、F値が上位4無機成分について、「部位」ごとの平均含有量を Table4-3-10 に示した。これより、カルシウム含有量は、軟骨のみ特異的に高く、他の部位と差別化されているためF値が高い数値を示していることがわかる。同様にナトリウムは、食塩が添加物として加えられていることから「製品種類」と同様、「加工品」であることがわかる。また、「ゼラチン」、「軟骨」、「豚足」、「ひれ」は、他の部位と比較し、高い含有量を示していることから、これら「部位」を特定するための重要な無機成分の1つとして挙げられることが確認できる。クロムは、含まれている部位が少なく、「ばら」、「ひれ」、「もも」、「ロース」、「ひき肉」のみ含まれているため、上記部位を特定する無機成分となり得る。リンは赤身が多く含まれる程、含有量が高くなる傾向にあり、「ひれ」、「もも」、「ロース」、「内臓」全般に多く含まれている。また、「製品種類」と同様、「加工品」は、リン酸塩由来の添加物が含まれていることから高含有量になることがわかる。以上より、F値上位4無機成分は13無機成分の中で、豚肉製品の「部位」を特定しうる要因となる成分であることがわかる。

ビタミン成分で行った分散分析の結果は、ビタミンC、ビタミンB1、ビタミンD、ビタミンB6、ビタミンK、ビタミンB12、ナイアシン、βカロテン、葉酸、パントテン酸、ビタミンB2、レチノールの順でF値が高い結果となった。無機成分と同様にF値が上位である4ビタミン成分含有量について、部位ごとの平均含有量を Table4-3-11 に示した。

ビタミンCは「製品種類」と同様に加工・調理の段階で保存料として用いられることから、「加工品」のグループでは含有量が高い傾向を示している。ビタミンB1は、赤身部分に豊富に含まれているため、「ひれ」、「もも」、「ひき肉」等の製品に多量に含まれる。したがって、これら部位を特定する際の1つのビタミン成分となることがわかる。ビタミンDは、「豚足」、「内臓」、「ゼラチン」、「加工品」に多く含まれており、「かた」、「かたロース」、「ひれ」、「もも」等の赤身を可食部とする部位製品の含有量は少ない。ビタミンB6は、「ひれ」、「そともも」、「ひき肉」等が他部位と比較し含まれている。一方、「ゼラチン」、「ばら」、「加工品」、「軟骨」は少量である。

以上より、F値上位4ビタミン成分は、12ビタミン成分の中では、豚肉製品の「部位」を特定しうる成分である。

Table4-3-10 Average content of inorganic component by pork product parts
(Ca, Na, Cr, P)

(mg or µg/100g)

Product parts	Ca	Na	Cr	P
Picnic shoulder	3.750	47.500	0.000	156.750
Picnic shoulder loin	3.500	48.625	0.000	149.375
Outside ham	3.250	45.750	0.000	160.875
Belly	3.333	49.667	0.333	130.000
Fillet	7.500	84.000	0.250	272.500
Ham	3.600	42.300	0.100	182.100
Loin	4.727	43.727	1.364	168.091
Pig's feet	12.000	110.000	0.000	32.000
Visceral meat	9.625	79.875	0.000	169.125
Cartilage	100.000	120.000	0.000	120.000
Gelatin	16.000	260.000	0.000	7.000
Ground meat	6.500	68.500	2.000	145.000
Meat substitute	10.652	953.913	0.000	242.174

Table4-3-11 Average content of vitamin component by pork product parts
(VC, VB1, VD, VB6)

(mg or µg/100g)

Product parts	VC	VB1	VD	VB6
Picnic shoulder	1.500	0.598	0.175	0.269
Picnic shoulder loin	1.375	0.589	0.213	0.268
Outside ham	1.125	0.675	0.138	0.308
Belly	0.667	0.510	0.400	0.240
Fillet	1.000	1.430	0.225	0.528
Ham	0.900	0.827	0.140	0.317
Loin	0.909	0.675	0.164	0.303
Pig's feet	0.000	0.050	1.000	0.020
Visceral meat	7.250	0.203	0.900	0.198
Cartilage	2.000	0.080	0.500	0.050
Gelatin	0.000	0.000	0.000	0.000
Ground meat	1.000	0.815	0.400	0.390
Meat substitute	25.565	0.445	0.522	0.237

豚肉製品の「部位」に対し無機成分、ビタミン成分それぞれで行った判別分析の結果に対し考察した。結果の詳細は Table4-3-12 に示す。

全 13 無機成分を用い、F 値によって順位付けした順で変数として追加し正判別率を算出した結果、無機成分数を多くすることで判別率は増加する傾向にあった。マンガンまでの上位 10 成分を条件として加えた結果が正判別率 68.2%、亜鉛までの 13 成分全てを対象とした結果では 72.7%と無機成分の定量を行うことで「部位」は 7 割程度、判別が可能となる。各「部位」の正判別率を比較すると「そもそも」が正判別率：12.5%と低く、「もも」、「ばら」に誤判別された。これは、「そもそも」の無機成分組成が「もも」、「ばら」の試料と近いことが要因である。また、「ロース」においても正判別率：36.4%と低く、背中中央部の部位である「ロース」に近接する「もも」、「ひれ」、「ばら」に誤判別されたと考えられる。一方、脂肪分が多い「ばら」、「ひき肉」、食塩を用いる「加工品」は正判別率：100%となった。

全 12 ビタミン成分を用い、F 値によって順位付けした順で変数として追加し正判別率を算出した結果、ビタミン成分数を多くすることで判別率は増加する傾向にあった。葉酸までの上位 10 成分を条件として加えた結果が正判別率 65.9%、レチノールまでの 12 成分全てを対象とした結果では 64.8%となり、上位 10 成分を用いる事で豚肉製品の「部位」を 6 割以上の精度で判別可能となる可能性を示した。各「部位」の正判別率を比較すると「かたロース」が正判別率：37.5%、「かた」が正判別率：50.0%と低い値となっている。これは、ビタミン成分自体が豚肉製品に微量に含まれている中で、「ヒレ」以外の赤身が含まれる「部位」は、大きな成分比率の変化がないことから、誤判別されたと考えられる。「内臓」は、豚肉製品に多量に含まれるビタミン B 群が他の部位と比較し少量であるため、同じく少量の「軟骨」「豚足」に誤判別された。したがって、正判別率が 25.0%と低い。一方で、「ヒレ」は豚肉製品に豊富に含まれるビタミン B1 が特に多く含まれており、ビタミン成分を用いた場合は 100.0%判別できた。同様に、「ゼラチン」、「豚足」、「軟骨」の製品数が少なく、特異的な部位についても 100.0%の正判別率であった。また、「加工品」は、保存料にビタミン C が含まれていることが要因で正判別率:78.3%と「内臓」、「ロース」等と比較して高い値となっている。

Table4-3-12 Discrimination analysis result by pork product parts.

	Determination rate	
	Inorganic	Vitamin
Selected Chemical components	Ca, Na, Cr, P, K, Mg, I, Cu, Mo, Mn, Se, Fe, Zn	VC, VB1, VD, VB6, VK, VB12, VN, β -Ca, VM, VB5
Picnic shoulder	62.5%	50.0%
Picnic shoulder loin	75.0%	37.5%
Outside ham	12.5%	75.0%
Belly	100.0%	66.7%
Fillet	75.0%	100.0%
Ham	60.0%	70.0%
Loin	36.4%	63.6%
Pig's feet	100.0%	100.0%
Visceral meat	75.0%	25.0%
Cartilage	100.0%	100.0%
Gelatin	100.0%	100.0%
Ground meat	100.0%	100.0%
Meat substitute	100.0%	78.3%

4.3.4 豚肉製品に対する検討結果のまとめ

豚肉製品 88 種類に含まれる化学成分値の中から、原子吸光分析装置等で定量可能な無機成分 13 種(ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅、マンガン、ヨウ素、セリン、クロム、モリブデン)、高速液体クロマトグラフィー等で定量可能なビタミン成分 12 種(レチノール、 β カロテン、ビタミン D、ビタミン K、ビタミン B1、ビタミン B2、ナイアシン、ビタミン B6、ビタミン B12、葉酸、パントテン酸、ビタミン C)の含有量データを抽出、最適化し、その後、各種多変量解析の手法(分散分析、判別分析)を用いる事で「製品種類」「部位」による分類が可能となる化学成分を評価した。

豚肉製品の「製品種類」(赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身)の判別は、分散分析と判別分析の結果より、無機成分であれば、ナトリウム、マグネシウム、カリウム、リンの含有量を特定することで、7割以上の精度で分類が可能であることを示した。また、ビタミン成分であればビタミン B1、ビタミン B6、ビタミン C、ビタミン D、ナイアシン、ビタミン K、ビタミン B12 の 7 成分を定量することで約 7割の判別が可能であることを示した。

同様に豚肉製品の「部位」(かた、かたロース、そともも、ばら、ひれ、もも、ロース、肝臓、豚足、内臓、軟骨、ゼラチン、ひき肉、加工品)は、無機成分であれば全 13 成分で 7割以上、ビタミン成分では、ビタミン C、ビタミン B1、ビタミン D、ビタミン B6、ビタミン K、ビタミン B12、ナイアシン、 β カロテン、葉酸、パントテン酸の 10 成分を定量すれば約 7割の精度で識別可能なことを示した。

これら結果は、製品の産地差、化学成分含有量の測定現場における分析誤差を考慮していないが、無機成分、ビタミン成分それぞれで分類可能となる可能性を見出した。

今後は誤差を用いた分析や無機成分、ビタミン成分を全て対象とし、「製品種類」「部位」について、より正しく分類可能となる化学成分の抽出を検討する必要がある。また、「部位」については、脂質含有量、不飽和脂肪酸、一価不飽和脂肪酸等の成分を無機成分やビタミン成分に追加することで、正判別率の向上に寄与する可能性について検証する。

4.4 牛肉製品を対象とした検討

本節では、前節にて実施した豚肉製品とは異なる牛肉製品による化学成分値を用いた分類の評価を行った。

検討は、牛肉製品 132 種類に含まれる化学成分値の中から、主要構成物質であるタンパク質、脂質、原子吸光分析装置などで測定可能である無機成分 8 種(ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅)、高速液体クロマトグラフィーで定量可能なビタミン類 6 種(ビタミン B1、ビタミン B2、ナイアシン、ビタミン B6、ビタミン B12、パントテン酸)の化学成分含有量データを抽出、最適化し、その後、各種計量化学的手法(分散分析、判別分析)を用いる事で「製品種類」「部位」「牛の種類」それぞれについて分類が可能となる化学成分を特定した。その後、分類傾向について、多変量解析的手法であるクラスター分析を用い検証した。

4.4.1 実験手法

4.4.1.1 検証手法

本研究における、化学成分値を用いた牛肉製品の分類可能性の検討手法について述べる。文部科学省 科学技術・資源調査分科会報告 7 訂日本食品標準成分表 2015 における牛肉製品 132 種を対象データとし、 $\pm 10\%$ 誤差をランダムで付与したダミーデータを作成した。これは豚肉製品とは異なり、分析機器測定誤差、産地、製造工場による環境誤差を付与することでより現場的な検証を行うためである。

このダミーデータ(+10%:132 種類、-10%:132 種類)を加えた合計 396 種類のデータについて、「製品種類」「部位」「牛の種類」への分類に繋がる可能性のある化学成分を分散分析、判別分析の傾向により特定した。次に特定した化学成分を用いてクラスター分析を実施し、分類傾向について視覚的に整理した。

4.4.1.2 使用する牛肉製品データの取得

文部科学省 科学技術・資源調査分科会報告 7 訂増補日本食品成分表 2015 における代表的な牛肉製品 132 種類を抽出し、これらを試料として解析対象とした(Table4-4-1)。

取得した牛肉製品に含まれる、タンパク質、脂質、無機成分 8 種(ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅)、ビタミン類 6 種(ビタミン B1、ビタミン B2、ナイアシン、ビタミン B6、ビタミン B12、パントテン酸)の含有量も併せて取得した(Table4-4-2)。なお、「Tr」「-」「0」と記載のある場合、該当する化学成分の含有量が著しく低い、または、皆無であることを示しているため、一律「0」とした。

Table4-4-1 Beef product data (132 types in total)

<p>◎Japanese beef cattle (30 products) , Imported beef (30 products) , Dairy fattened steer (32 products) , Crossbred steer (14 products) , Veal (3 products) /Raw , Roasted , Boild</p> <ul style="list-style-type: none"> ・ Chuck (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat) ・ Chuck roll (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat) ・ Sirloin (Lean and fat) ・ Libloin (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat) ・ Outside ham (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat) ・ Ham (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat) ・ Brlly (Lean and fat , Without subcutaneous fat , Red meat , Fatty meat) ・ Fillet (Red meat) ・ Rump (Red meat)
◎Offal and by-products (16 products) / Raw , Boild
◎Meat substitute (5 products)
◎Other (2 products) Ground meat

Table4-4-2 Types of chemical components

◎Protein (1 species)
◎Lipid (1 species)
◎Inorganic components (8 species)
Sodium , Potassium , Calcium , Magunesium Phosphorus , Iron , Zinc , Copper
◎Vitamin components (6 species)
Vitamin B1 , Vitamin B2 , Vitamin B3 , Vitamin B6 Vitamin B12 , Pantothenic acid

4.4.1.3 分散分析による化学成分値の順位付け

量的データである化学成分含有量から牛肉製品を「製品種類」(赤肉、脂身つき、皮下脂肪なし、脂身、副生物、加工品、ひき肉)、「部位」(かた、かたロース、サーロイン、リブロース、そともも、もも、ばら、ヒレ、ランプ、副生物、加工品、ひき肉)、「牛の種類」(和牛肉、輸入牛肉、乳用肥育牛肉、交雑牛肉、子牛肉、副生物、加工品、ひき肉)、「牛の種類」(和牛肉、輸入牛肉、乳用肥育牛、交雑牛肉、子牛肉、副生物、加工品、ひき肉)の各分類に照合可能と考え、分類の決定に影響を与える化学成分値の順位付けはF値を算定することで実施した。

4.4.1.4 判別分析による「製品種類」、「部位」及び「牛の種類」の分類に寄与する化学成分値の特定

検証に用いる牛肉製品データ 396 種の「製品種類」「部位」「牛の種類」の各分類について、タンパク質、脂質、無機成分 8 種、ビタミン 6 種を対象に判別分析を行うことで分類に寄与する化学成分を特定した。

牛肉製品の「製品種類」「部位」「牛の種類」に含まれる分類項目をグループとし、それらを決定付けるデータを化学成分とした。それぞれの牛肉製品データに含まれている化学成分値により、各「製品種類」「部位」「牛の種類」に形成された多変量空間内において、その牛肉製品がどの「製品種類」「部位」「牛の種類」に判別されるかを算定した。また、本検討で用いた判別分析法は、線形判別分析法を用い、どの「製品種類」「部位」「牛の種類」に判定するかを Mahalanobis 距離により決定した。なお、評価指標は、(4.1)式に示す通り、既知の「製品種類」「部位」「牛の種類」に判別された牛肉製品データを正判別とし、その製品数を 396 製品で除することで正判別率を算定・評価した。なお、分散分析により算定した化学成分の F 値順位に応じ、1 つずつ成分数を追加して判別分析を実施し正判別率を算定した。その後、化学成分を追加する事による正判別率の推移を示した。これより、何種類の化学成分を用いる事で、牛肉製品データを「製品種類」「部位」「牛の種類」に分類が可能か評価した。

4.4.1.5 クラスタ分析に分類傾向の検証

クラスタ分析とは、多変量の直線的な距離からデータ、変量を複数のグループ(クラスタ)に分類する分析方法である。主な手法として、階層的分類法、非階層的分類法があり、階層的分類法のクラスタ分析では、最初にすべての観測対象1個ずつをそれぞれ独立したクラスタと考え、次にこれらの中で多変量空間において互いに最も近い2点を見つけ、これら2点間の多変量平均の1点で置き換えて新たなクラスタとする。この過程をクラスタの数が1個になるまで繰り返すと樹形図ができあがり、観測対象間の距離がわかるようになる。

本報告では、階層的分類法の1手法である、Ward法を用いた。Ward法は、2つのクラスタ間における分散分析の平方和全ての観測対象について合計した値をクラスタ間距離とする方法であり、長く伸びたクラスタが生成される鎖効果が生じにくい実用性の高い手法であるため採用した。(4.2)式にクラスタ距離の算定式を示す。

$$D_{KL} = \frac{\|\bar{x}_K - \bar{x}_L\|^2}{\frac{1}{N_K} - \frac{1}{N_L}} \quad (4.2)$$

D_{KL} はクラスタ間距離を示し、 N_K 、 N_L がそれぞれのクラスタ(式中では K と L のクラスタ)に含まれる観測試料の数、 \bar{x}_K 、 \bar{x}_L が各クラスタの平均ベクトルを示す。

クラスタ数は、クラスタ間距離により機械的に決定し樹形図として結果を表した。

樹形図は、視覚的に比較しやすい星座樹形図を採用し、それぞれのクラスタに含まれる「製品種類」「部位」「牛の種類」の各分類に含まれる牛肉製品データが何データあるかを整理し分類傾向を確認した。

4.4.2 牛肉製品を対象とした結果

4.4.2.1 分散分析による分類に寄与する化学成分値の順位付け

牛肉製品の「製品種類」「部位」「牛の種類」に対し化学成分値を用いた分散分析結果について説明する。

はじめに「製品種類」の結果について Table4-4-3 に示した。F 値が最も高い結果を示した化学成分はナトリウムであった。次点以降は、脂質、亜鉛、カルシウム、マグネシウム、タンパク質、カリウム、リンと続き、最後 16 番目は銅となった。傾向として無機成分はビタミン成分より F 値が高い。ビタミン成分の中で最も F 値が高い化学成分はビタミン B6 であり 16 成分中 9 位である。

次に「部位」の分散分析結果を Table4-4-4 に示した。最も高い F 値は「製品種類」同様、ナトリウムであった。次点以降は、カルシウム、マグネシウム、鉄、脂質、カリウム、ビタミン B6 と続き 16 番目は銅である。「製品種類」と比較し、脂質とビタミン B6 の順位が高い。しかし、全体的な傾向としては、無機成分の順位が高くビタミン成分低い F 値となった。

最後に Table4-4-5 に「牛の種類」の結果を示した。「製品種類」「部位」と同様にナトリウムが最も F 値が大きい。また、次点以降は、カルシウム、脂質、ビタミン B12、カリウム、マグネシウム、ビタミン B3 と続く。これは、「製品種類」「部位」とは異なる傾向であり、ビタミン B12、ビタミン B3 といったビタミン成分の F 値が大きいことが確認された。

(1) 「製品種類」に対する結果

「製品種類」の結果について Fig.4-4-1 に示した。F 値が最も高い結果を示した化学成分はナトリウムであった。次点以降は、脂質、亜鉛、カルシウム、マグネシウム、タンパク質、カリウム、リンと続き、最後 16 番目は銅となった。全体的に無機成分の F 値が高く、「製品種類」の分類に寄与する成分が多いことが確認できた。しかし、大まかな傾向として無機成分はビタミン成分より F 値が高い。ビタミン成分の中で最も F 値が高い化学成分はビタミン B6 であり 16 成分中 9 位であった。




Fig.4-4-1 F value ranking for chemical components (product type)

(2) 「部位」に対する結果

牛肉製品の「部位」に対する分散分析結果について説明する。

「部位」の分散分析結果を Fig.4-4-2 に示した。最も高いF 値は「製品種類」同様、ナトリウムであった。次点以降は、カルシウム、マグネシウム、鉄、脂質、カリウム、ビタミン B6 と続き 16 番目は銅である。「製品種類」と比較し、脂質とビタミン B6 の順位が高い。しかし、全体的な傾向としては、無機成分の順位が高くビタミン成分低い傾向となった。




Fig.4-4-2 F value ranking for chemical components (product part)

(3) 「牛の種類」に対する結果

牛肉製品の「牛の種類」に対する分散分析結果について説明する。

「牛の種類」の結果を Fig.4-4-3 に示した。「製品種類」「部位」と同様にナトリウムが最も F 値が大きい。また、次点以降は、カルシウム、脂質、ビタミン B12、カリウム、マグネシウム、ビタミン B3 と続いた。これは、「製品種類」「部位」とは異なる傾向であった。特にビタミン B12、ビタミン B3 が大きいことを確認した。




Fig.4-4-3 F value ranking for chemical components (kind of cattle)

4.4.2.2 判別分析による「製品種類」及び「部位」の分類に寄与する化学成分値の特定

前節では、牛肉製品の「製品種類」、「部位」、「牛の種類」に寄与する化学成分値を分散分析でF値を算定し、その多寡によって順位付けした。この結果を用い、判別分析による分類状況を確認した上で、これらに必要な化学成分の特定を試みた。

(1) 「製品種類」に対する結果

分散分析によって算定したF値の順位に応じ、化学成分を追加する操作を繰り返し実施した判別分析の結果を説明する。本節では、「製品種類」についての結果を示した。

Fig.4-4-4 に示した「製品種類」の判別分析結果は、F値最上位のナトリウム1成分では、正判別率38.4%と示した。脂質を追加した2成分では、正判別率は向上し42.9%となる。その後、鉄を加えた10成分、ビタミンB12を加えた12成分では、73.2%、75.0%と増加傾向に転じた。以降、銅までを追加した16成分では、正判別率70%代後半とほぼ横ばいに推移した。以上の結果より、16化学成分による牛肉製品の「製品種類」特定はF値上位12成分、ナトリウム、脂質、亜鉛、カルシウム、マグネシウム、タンパク質、カリウム、リン、ビタミンB6、鉄、ビタミンB3、ビタミンB12の含有量を把握すれば75.0%の精度で特定できることが確認できた。




Fig.4-4-4 Result of discriminant analysis using chemical component for product type.

(2) 「部位」に対する結果

分散分析によって算定したF値の順位に応じ、化学成分を追加する操作を繰り返し行い、「部位」に対する牛肉製品396種の判別率の推移を示し、何種類の化学成分を定量すれば正確に分類可能か評価した。その結果をFig.4-4-5に示した。

「部位」の判別分析結果は、F値最上位のナトリウム1成分で正判別率13.1%と「製品種類」と比較して低い値を示した。カルシウムを追加した2成分では、正判別率は向上したものの21.2%であった。その後、化学成分を追加するたびに正判別率は向上し、ビタミンB3を加えた12成分では66.4%となった。以降、銅までを追加した16成分を追加しても正判別率は減少傾向を示した。以上の結果より、16化学成分による牛肉製品の「部位」特定はF値上位12成分、ナトリウム、カルシウム、マグネシウム、鉄、脂質、カリウム、ビタミンB6、亜鉛、ビタミンB12、リン、タンパク質、ビタミンB3の含有量を把握すれば66.4%の精度で特定することが可能であった。




Fig.4-4-5 Result of discriminant analysis using chemical component for product type.

(3) 「牛の種類」に対する結果

分散分析によって算定したF値の順位に応じ、化学成分を追加する操作を繰り返し行い、「牛の種類」に対する牛肉製品 396 種の判別率の推移を示し、何種類の化学成分を定量すれば正確に分類可能となるか評価した。その結果を Fig.4-4-6 に示した。

F 値最上位のナトリウム 1 成分で正判別率 29.8%であった。カルシウムを追加した 2 成分では、正判別率は向上し 38.4%となった。その後、化学成分を追加するたびに正判別率は向上し、ビタミン B6 を加えた 10 成分では 61.6%、ビタミン B1 を加えた 15 成分では 69.2%となった。しかし、16 成分では正判別率がわずかに減少した。以上の結果より、16 化学成分による牛肉製品の「牛の種類」特定は F 値上位 15 成分、ナトリウム、カルシウム、脂質、ビタミン B12、カリウム、マグネシウム、ビタミン B3、亜鉛、鉄、ビタミン B6、タンパク質、リン、ビタミン B2、ビタミン B5、ビタミン B1 の含有量を把握すれば 69.2%の精度で特定可能であった。




Fig.4-4-6 Result of discriminant analysis using chemical component for kind of cattle.

4.4.2.3 クラスタ分析による分類傾向の検証

4.3.2 節における判別分析の結果より、牛肉製品の「製品種類」「部位」「牛の種類」を分類可能な化学成分値を用いてクラスタ分析による 2 次元的な分類傾向について検証した。その結果について、以下に述べる。

(1) 「製品種類」に対する結果

牛肉製品 396 種類に対する判別分析の結果により特定した化学成分値 12 種を用い、クラスター分析を実施、その分類結果と各クラスターに含まれる「製品種類」を示した。

Fig.4-4-7、Table4-4-5 に「製品種類」について、12 化学成分(ナトリウム、脂質、亜鉛、カルシウム、マグネシウム、タンパク質、カリウム、リン、ビタミン B6、鉄、ビタミン B3、ビタミン B12)の含有量を用いたクラスター分析結果を示した。この結果より、牛肉製品の「製品種類」はクラスター分析において 5 つのクラスターに分けられた。各クラスターの傾向として、No.1 は「赤肉」、「皮下脂肪なし」が半数以上を示した。No.2 は肝臓に限定された「副生物」、No.3 はビーフジャーキーに限定された「加工品」、No.4 は肝臓を除いた「副生物」、No.5 は「脂身つき」「脂身」と脂質が多い製品が優位のクラスターとなった。

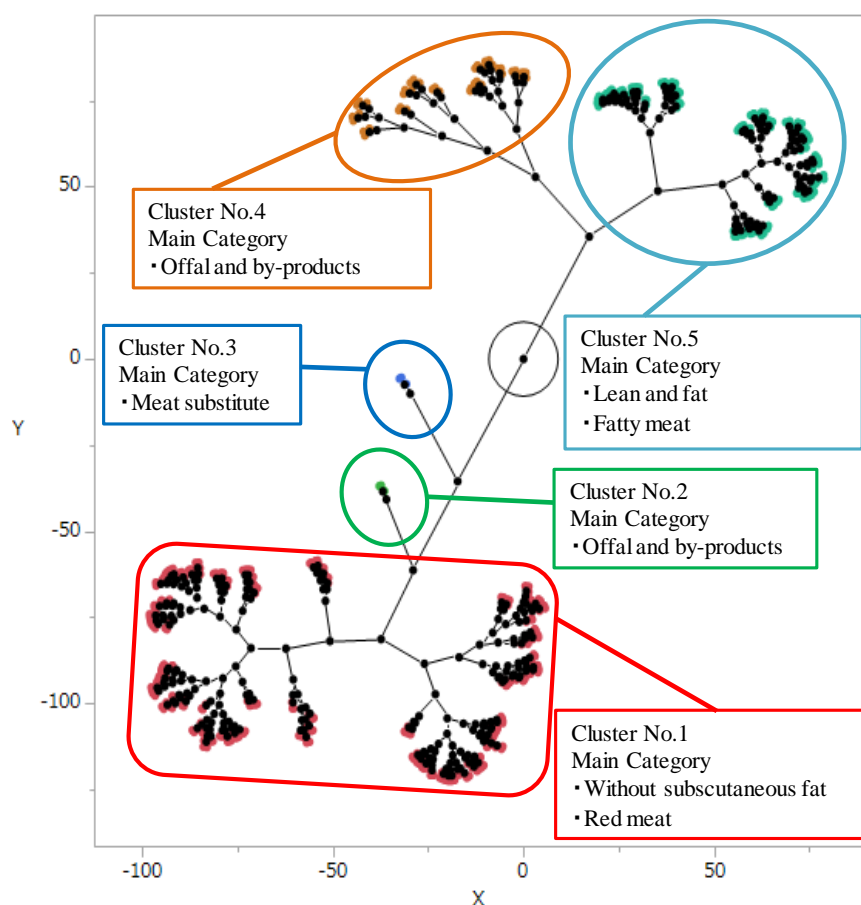


Fig.4-4-7 Result of cluster analysis using chemical component for product type.

Table4-4-5 Features of product type cluster analysis results.

Cluster No.	Total samples	Category	Samples	Sample rate
1	249	Red meat	81	32.5%
		Without subcutaneous fat	87	34.9%
		Lean and fat	63	25.3%
		Offal and by-products	9	3.6%
		Ground meat	6	2.4%
		Meat substitute	3	1.2%
2	3	Offal and by-products	3	100.0%
3	3	Meat substitute	3	100.0%
4	42	Offal and by-products	33	78.6%
		Meat substitute	9	21.4%
5	99	Red meat	3	3.0%
		Without subcutaneous fat	15	15.2%
		Lean and fat	45	45.5%
		Fatty meat	33	33.3%
		Offal and by-products	3	3.0%

(2) 「部位」に対する結果

牛肉製品 396 種類に対する判別分析の結果により特定した化学成分値 12 種を用い、クラスター分析を実施、その分類結果と各クラスターに含まれる「部位」を示した。

Fig.4-4-8、Table4-4-6 に「部位」について、12 化学成分(ナトリウム、カルシウム、マグネシウム、鉄、脂質、カリウム、ビタミン B6、亜鉛、ビタミン B12、リン、タンパク質、ビタミン B3)の含有量を用いたクラスター分析結果を示した。この結果より、牛肉製品の「部位」はクラスター分析において 5 つのクラスターに分けられた。各クラスターの傾向として、No.1 は「もも」、「かた」、「そともも」、「ランプ」等が含まれた。No.2 は肝臓に限定された「副生物」、No.3 はビーフジャーキーに限定された「加工品」、No.4 は肝臓を除いた「副生物」、No.5 は「リブローズ」の脂質が多い製品が優位のクラスターとなった。

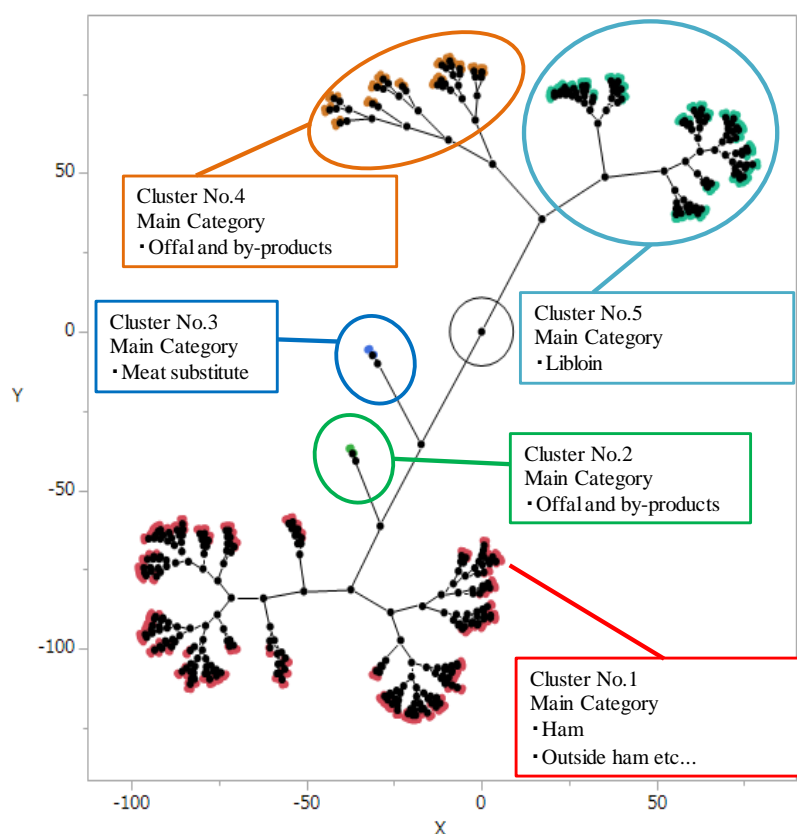


Fig.4-4-8 Result of neural cluster analysis using chemical component for product part.

Table4-4-6 Features of product part cluster analysis results.

Cluster No.	Total samples	Category	Samples	Sample rate
1	249	Chuck	27	10.8%
		Chuck roll	21	8.4%
		Sirloin	21	8.4%
		Libloin	27	10.8%
		Outside ham	27	10.8%
		Ham	63	25.3%
		Fillet	15	6.0%
		Belly	3	1.2%
		Rump	27	10.8%
		Offal and by-products	9	3.6%
		Ground meat	6	2.4%
		Meat substitute	3	1.2%
2	3	Offal and by-products	3	100.0%
3	3	Meat substitute	3	100.0%
4	42	Offal and by-products	33	78.6%
		Meat substitute	9	21.4%
5	99	Chuck	9	9.1%
		Chuck roll	6	6.1%
		Sirloin	6	6.1%
		Libloin	48	48.5%
		Ham	12	12.1%
		Belly	15	15.2%
		Offal and by-products	3	3.0%

(3) 「牛の種類」に対する結果

牛肉製品 396 種類に対する判別分析の結果により特定した化学成分値 15 種を用い、クラスター分析を実施、その分類結果と各クラスターに含まれる「牛の種類」を示した。

Fig.4-4-9、Table4-4-7に「牛の種類」について、15 化学成分(ナトリウム、カルシウム、脂質、ビタミン B12、カリウム、マグネシウム、ビタミン B3、亜鉛、鉄、ビタミン B6、タンパク質、リン、ビタミン B2、ビタミン B5、ビタミン B1)の含有量を用いたクラスター分析結果を示した。この結果より、牛肉製品の「牛の種類」はクラスター分析において 4 つのクラスターに分けられた。各クラスターの傾向として、No.1 は「和牛肉」、「輸入牛肉」、「乳用肥育牛肉」、「交雑牛肉」等様々製品が含まれた。No.2 はビーフジャーキーに限定された「加工品」、No.3 は肝臓に限定した「副生物」、No.4 も No.1 同様、様々「牛の種類」が含まれたクラスターとなった。

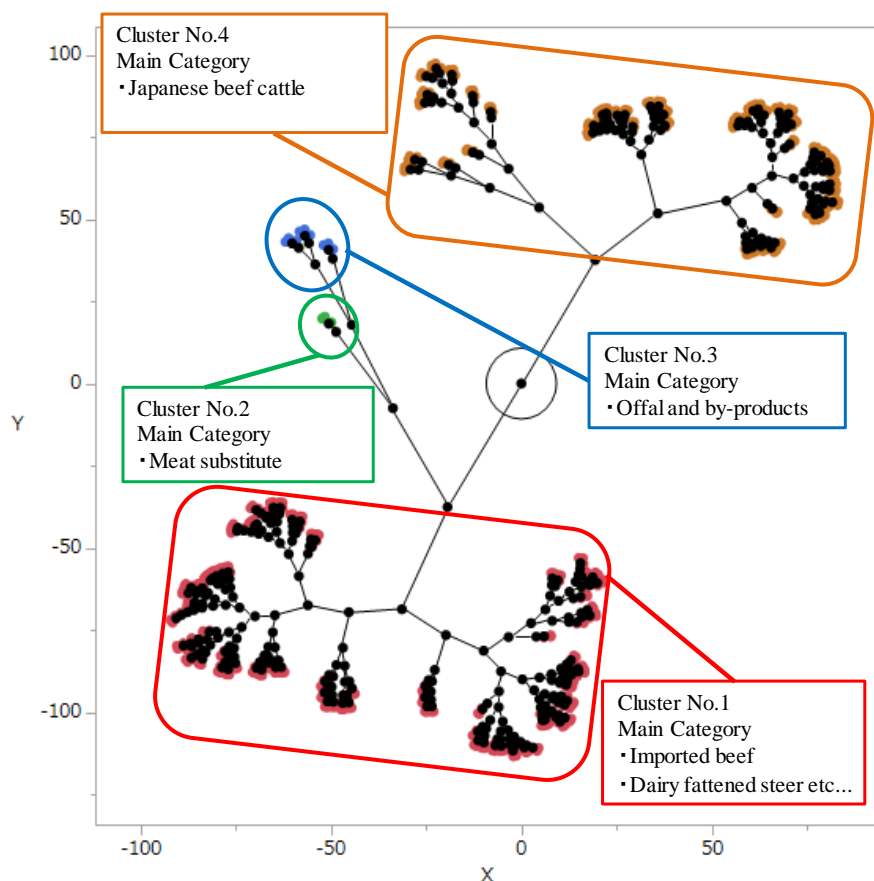


Fig.4-4-9 Result of cluster analysis using chemical component for kind of cattle.

Table4-4-7 Features of kind of cattle cluster analysis results.

Cluster No.	Total samples	Category	Samples	Sample rate
1	246	Japanese beef cattle	51	20.7%
		Imported beef	78	31.7%
		Dairy fattened steer	66	26.8%
		Crossbred steer	21	8.5%
		Veal	9	3.7%
		Offal and by-products	9	3.7%
		Meat substitute	6	2.4%
		Ground meat	6	2.4%
2	3	Meat substitute	3	100.0%
3	9	Offal and by-products	9	100.0%
5	138	Japanese beef cattle	39	28.3%
		Imported beef	12	8.7%
		Dairy fattened steer	30	21.7%
		Crossbred steer	21	15.2%
		Offal and by-products	30	21.7%
		Meat substitute	6	4.3%

4.4.3 結果の考察

本節では、牛肉製品に含まれる化学成分値を用いた分類の可能性について検討した考察を示す。

4.4.3.1 判別分析法による、牛肉製品の分類に寄与する化学成分の探索

化学成分 16 種類を用いた判別分析により、牛肉製品の「製品種類」「部位」「牛の種類」による判別状況を分析した結果を示す。

(1) 「製品種類」に対する結果

各「製品種類」における正判別率及び誤判別率を Table4-4-8 に示す。

「製品種類」の結果では全体の正判別率 75.0%に対し、「赤肉」：88.1%、「副生物」：81.3%、「加工品」：93.3%、「脂身」「ひき肉」：100.0%と高い正判別率を示した。これは、「赤肉」製品に含まれる脂質含有量、「副生物」のカルシウムを除いた化学成分含有量の低さ、「加工品」は添加物に用いられるナトリウム、マグネシウム等の無機成分含有量の高さが要因と考えた。また、正判別率 100.0%を示した「脂身」は脂質含有量の高さと他化学成分含有量の低さ、「ひき肉」は無機成分とビタミン B3 含有量の高さが要因と考える。「皮下脂肪なし」「脂身つき」は、それぞれ製品種類の違いとして皮下脂肪の有無だけであるため、相互に誤判別があることを確認した。

Table4-4-8 Discrimination analysis result by product types.

Product type	True	False	False rate	True rate
Red meat	74	10	11.9%	88.1%
Without subcutaneous fat	61	41	40.2%	59.8%
Lean and fat	70	38	35.2%	64.8%
fatty meat	33	0	0.0%	100.0%
Offal and by-products	39	9	18.8%	81.3%
Ground meat	6	0	0.0%	100.0%
Meat substitute	14	1	6.7%	93.3%
Total	297	99	25.0%	75.0%

(2) 「部位」に対する結果

各「部位」における正判別率及び誤判別率を Table4-4-9 に示す。

「部位」の結果では全体の正判別率 66.4%に対し、「かたロール」「ヒレ」「ひき肉」が 100.0%、「副生物」：77.1%、「加工品」：80.0%と高い正判別率を示した。「副生物」「加工品」は、「製品種類」同様の要因と考えられるが、「肩ロール」「ヒレ」といった一般的に加工されていない製品について、高い判別率を示した。これは、「かたロール」の亜鉛含有量が他の部位と比較し高く、一方でその他無機成分、ビタミン成分含有量が低い傾向にあることが挙げられる。また、「ヒレ」は高タンパク質であり、カリウム、マグネシウム、リン、鉄、ビタミン B6 の含有量がその他部位より高い値を示していることが要因として挙げられる。しかし、その他の部位については化学成分含有量の傾向が似通っており正しい部位に判別する際の障害になったと考える。

Table4-4-9 Discrimination analysis result by product part.

Product type	True	False	False rate	True rate
Chuck	24	12	33.3%	66.7%
Chuck roll	27	0	0.0%	100.0%
Sirloin	17	10	37.0%	63.0%
Libloin	38	37	49.3%	50.7%
Outside ham	18	9	33.3%	66.7%
Ham	39	36	48.0%	52.0%
Belly	11	7	38.9%	61.1%
Fillet	15	0	0.0%	100.0%
Rump	19	8	29.6%	70.4%
Offal and by-products	37	11	22.9%	77.1%
Ground meat	6	0	0.0%	100.0%
Meat substitute	12	3	20.0%	80.0%
Total	263	133	33.6%	66.4%

(3) 「牛の種類」に対する結果

各「牛の種類」における正判別率及び誤判別率を Table4-4-10 に示す。

「牛の種類」の結果は全体の正判別率 69.2%に対し、「子牛肉」「ひき肉」が 100.0%、「副生物」：81.3%、「加工品」：80.0%と高い正判別率を示した。「副生物」「加工品」「ひき肉」は、「製品種類」「部位」同様の要因が考えられる。「子牛肉」は他の牛の種類よりタンパク質、カリウム、マグネシウム、リン、ビタミン B3、ビタミン B6 の含有量が高く、脂質が低いいためこのような結果になった。しかし、「和牛肉」「輸入牛肉」「乳用肥育牛肉」「交雑牛肉」は正判別率が 56.7～71.4%と低い。この要因として、それぞれの「牛の種類」に含まれる化学成分含有量の傾向が近似していることが挙げられる。

Table4-4-10 Discrimination analysis result by kind of cattle.

Product type	True	False	False rate	True rate
Japanese beef cattle	51	39	43.3%	56.7%
Imported beef	69	21	23.3%	76.7%
Dairy fattened steer	58	38	39.6%	60.4%
Crossbred steer	30	12	28.6%	71.4%
Veal	9	0	0.0%	100.0%
Offal and by-products	39	9	18.8%	81.3%
Ground meat	6	0	0.0%	100.0%
Meat substitute	12	3	20.0%	80.0%
Total	274	122	30.8%	69.2%

(4) まとめ

「製品種類」「部位」「牛の種類」と判別分析による分類に資する化学成分値の検証結果より、それぞれのカテゴリーにおいて分類が難しい製品もあるが、「副生物」「加工品」「ひき肉」製品、特長的な製品については 7 割程度の精度で判別可能となることが確認できた。

4.4.3.2 クラスタ分析による分類傾向の確認

クラスタ分析で確認した分類傾向の確認結果について、各クラスタの化学成分含有量の傾向から特徴を考察した。

(1) 「製品種類」に対する結果

Fig.4-4-12 に「製品種類」の各クラスタにおける化学成分含有量の傾向を示す。No.1 はカルシウム、鉄、ビタミン B12 含有量が低く、亜鉛が他のクラスタより若干高い結果の試料が集合した。No.2 は肝臓に限定した「副生物」であるため、リン、鉄、ビタミン B3、ビタミン B6、ビタミン B12 が豊富に含まれていることが確認できた。No.3 は「加工品」が分類されていることから、食塩由来であるナトリウム、マグネシウムを含む無機成分含有量が高い。No.4 は肝臓を除く「副生物」試料が含まれているクラスタであるため胃、腱等に含まれるカルシウム含有量のみ高く、他の成分は多く含まれていない。No.5 は脂質を多く含む製品が分類されており、その他化学成分は他のクラスタと比較し低い。

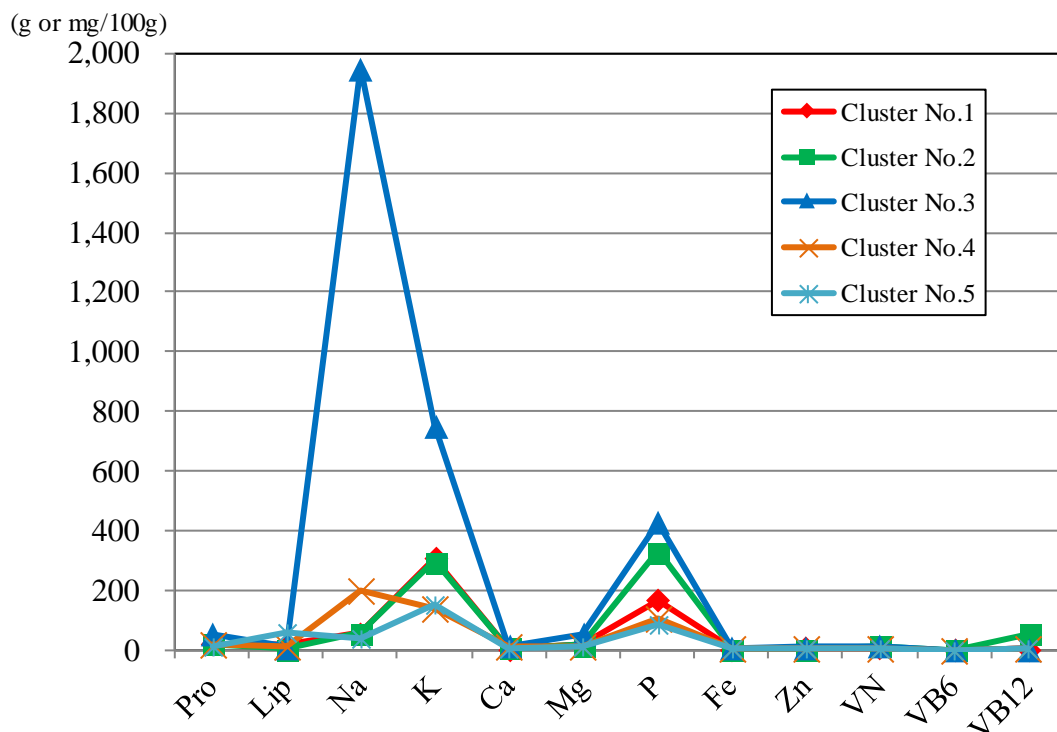


Fig.4-4-12 Characteristics of chemical component values by cluster analysis of product type.

(2) 「部位」に対する結果

Fig.4-4-13 に「部位」の各クラスターにおける化学成分含有量の傾向を示す。No.1 はカルシウム、鉄、ビタミン B12 含有量が低く、亜鉛が他のクラスターより若干高い結果の試料が集合した。No.2 は肝臓に限定した「副生物」であるため、リン、鉄、ビタミン B3、ビタミン B6、ビタミン B12 が豊富に含まれていることが確認できた。No.3 は「加工品」が分類されていることから、食塩由来であるナトリウム、マグネシウムを含む無機成分含有量が高い。No.4 は肝臓を除く「副生物」試料が含まれているクラスターであるため胃、腱等に含まれるカルシウム含有量のみ高く、他の成分は多く含まれていない。No.5 は脂質を多く含む部位が分類されていることが確認された。




Fig.4-4-13 Characteristics of chemical component values by cluster analysis of product part.

(3) 「牛の種類」に対する結果

Fig.4-4-14に「牛の種類」の各クラスターにおける化学成分含有量の傾向を示す。No.1は脂質、マグネシウム、亜鉛含有量が高く、ビタミン成分含有量が他のクラスターより低い傾向にあった。No.2は「加工品」が分類されていることから、食塩由来であるナトリウム、マグネシウムを含む無機成分含有量が高い。No.3は肝臓を除く「副生物」試料が含まれているクラスターであり、ビタミン成分含有量が他のクラスターと比較し高い試料が含まれている。No.4は脂質を多く含む製品が分類されており、その他化学成分は他のクラスターと比較し低い。




Fig.4-4-14 Characteristics of chemical component values by cluster analysis of kind of cattle.

(4) まとめ

以上より、牛肉製品に対する「製品種類」「部位」「牛の種類」別の分類傾向は概略ではあるが把握することが可能であった。しかし、判別分析と異なる教師なしの多変量解析手法であるためそれぞれのクラスターに様々な製品が混在し、特徴的な製品以外はこの手法では分類が困難であることを確認した。

4.4.4 牛肉製品に対する検討結果のまとめ

以上より、牛肉製品 132 種を対象データとし、分析機器測定誤差、産地、製造工場による環境誤差として $\pm 10\%$ 誤差をランダムで付与したダミーデータを作成した上で、このダミーデータ(+10%:132 種類、-10%:132 種類)を加えた合計 396 種類のデータについて、「製品種類」「部位」「牛の種類」への分類に繋がる可能性のある化学成分を分散分析、判別分析の傾向により特定し、クラスター分析を実施した上で分類傾向について視覚的に整理した。

これより、化学成分値 12~15 種類を定量することで牛肉製品の「製品種類」「部位」「牛の種類」への分類可能性を見出した。

判別分析では、「製品種類」「部位」「牛の種類」について 7 割程度の精度で分類可能であったが、筋間脂肪有無、つまり「製品種類」で指す「皮下脂肪なし」「脂身つき」等の製品については誤判別率が高くなった。

クラスター分析、判別分析は教師なし分析として分類を試みたが化学成分値の傾向が特異的な製品を除き明確な分類が難しかった。

4.5 本章のまとめ

本章における結果のまとめを行う。

豚肉製品 88 種類に含まれる化学成分値の中から、原子吸光分析装置等で定量可能な無機成分 13 種(ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅、マンガン、ヨウ素、セリン、クロム、モリブデン)、高速液体クロマトグラフィーで定量可能なビタミン成分 12 種(レチノール、 β カロテン、ビタミンD、ビタミンK、ビタミンB1、ビタミンB2、ナイアシン、ビタミンB6、ビタミンB12、葉酸、パントテン酸、ビタミンC)の含有量データを抽出、最適化し、その後、各種計量化学的手法(分散分析、判別分析)を用いる事で「製品種類」「部位」による分類可能性が高い化学成分を評価した。

豚肉製品の「製品種類」(赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身)の判別は、分散分析と判別分析の評価結果より、無機成分であれば、ナトリウム、マグネシウム、カリウム、リンの含有量を特定することで、7割以上の精度で識別・分類が可能であることを示した。また、ビタミン成分であればビタミンB1、ビタミンB6、ビタミンC、ビタミンD、ナイアシン、ビタミンK、ビタミンB12の7成分を定量することで約7割の判別が可能であることを示した。

同様に豚肉製品の「部位」(かた、かたロース、そともも、ばら、ひれ、もも、ロース、肝臓、豚足、内臓、軟骨、ゼラチン、ひき肉、加工品)は、無機成分であれば全13成分で7割以上、ビタミン成分では、ビタミンC、ビタミンB1、ビタミンD、ビタミンB6、ビタミンK、ビタミンB12、ナイアシン、 β カロテン、葉酸、パントテン酸の10成分を定量すれば約7割の精度で識別可能なことを示した。

これら結果は、製品の産地差、化学成分含有量の測定現場における分析誤差を考慮していないため、今後は、誤差を含めた分析を行い本結果を再度検証する必要がある。また、本検討で対象とした化学成分値である無機成分、ビタミン成分を全て対象とし、「製品種類」「部位」について、より正しく分類可能となる化学成分の抽出を検討する必要がある。「部位」については、脂質含有量、不飽和脂肪酸、一価不飽和脂肪酸等の成分を無機成分やビタミン成分に追加することで、正判別率の向上に寄与する可能性について検証する必要がある。

また、牛肉製品 132 種を対象データとし、分析機器測定誤差、産地、製造工場による環境誤差として $\pm 10\%$ 誤差をランダムで付与したダミーデータを作成した上で、このダミーデータ(+10%:132種類、-10%:132種類)を加えた合計 396 種類のデータについて、「製品種類」「部位」「牛の種類」への分類に繋がる可能性のある化学成分を分散分析、

判別分析の傾向により特定し、クラスター分析を実施した上で分類傾向について視覚的に整理した。これより、化学成分値 12~15 種類を定量することで牛肉製品の「製品種類」「部位」「牛の種類」への分類可能性を見出した。

判別分析では、「製品種類」「部位」「牛の種類」について 7 割程度の精度で分類可能であったが、筋間脂肪有無、つまり「製品種類」で指す「皮下脂肪なし」「脂身つき」等の製品については誤判別率が高くなった。

クラスター分析は教師なし分析として分類を試みたが化学成分値の傾向が特異的な製品を除き明確な分類評価が難しかった。

上記結果を踏まえ、豚肉・牛肉製品の分類・照合に向けた栄養成分の抽出が可能であることが確認できた。この検討を深化させた上で、栄養成分を測定可能な化学センサや物理センサ等を応用し、簡易分類評価に繋げる事への応用が可能である。

参考文献

1. Aleixos.N, ほか. Multispectral inspection of citrus in real-time using vision and digital signal processors. : Computers and Electronics in Agriculture.Vol.33,No.2, 2002.
2. Amamcharla.K.J, ほか. Fourier transform infrared spectroscopy (FTIR) as a tool for discriminating Salmonella typhimurium contaminated beef. : Food Qual.Vol.4, 2010.
3. Ampuero.S, Bosset.O.J. The electronic nose applied to dairy products: a review. : Sensors and Actuators.Vol.94, 2003.
4. Andres.S, ほか. Prediction of sensory characteristics of lamb meat samples by near infrared reflectance spectroscopy.: Meat Science.Vol.7, 2007.
5. Ariana.P.D, Lu.R. Evaluation of internal defect and surface color of whole pickles using hyperspectral imaging. : Journal of Food Engineering.Vol.96, 2010.
6. Barbin.D, ほか. Near-infrared hyperspectral imaging for grading and classification of pork. : Meat Science.Vol.90, 2012.
7. Dobrin.S, ほか. Quality control of some traditional meat products. : Scientific study & reseach .Vol.14, 2013.
8. Guidetti.R, Beghi.R , Giovezana.V. Chemometrics in food thchnology. : Intechopen, 2011.
9. 合田元清, 小島洋一郎. 物理化学分析と多次元データ解析による食品分類手法の検討. : 日本味と匂学会誌,Vol.21,No.3, 2014.
10. 中島広基, ほか. 栄養成分データとケモメトリクスを用いた食品の識別方法. : 日本味と匂学会誌,Vol.20,No.3, 2013.
11. 合田元清, 小島洋一郎. 計量化学的手法を用いた豚肉製品分類・照合可能性の検討. : 産業応用工学会論文誌,Vol.6,No.1, 2018.
12. 合田元清, ほか. 無機成分の化学分析値とクラスター分析を用いた豚肉製品分類法に関する基礎的検討. 日本味と匂学会誌,Vol.18,No.3 : 日本味と匂学会論文誌, 2011.
13. 合田元清, ほか. 無機成分含有量と多変解析による豚肉製品の分類. : 日本味と匂学会誌,Vol.19,No.3, 2012.
14. 文部科学省. 食品成分データベース. (オンライン) 2018年7月. <https://fooddb.mext.go.jp/>.
15. 鐵健司. 新板 品質管理のための統計的方法入門. : 日科技連, 2000, ページ: 182-192.
16. 廣野元久, 林俊克. JMP による多変量データ活用術. : 海文堂出版, 2004, ページ: 76-78,155-220.
17. JMP Ver.11 多変量解析法. SAS 社. 2014, ページ: 76-78.
18. McCulloch.S.W, Pitts.W. A logical calculus of the ideas immanent in neurons activity. : Bull.Math.Biophys.Vol.5, 1943.
19. Zhang.Ling, Zhang.Bo. A geometrical representation of McCulloch-Pitts neural model and its applications. : IEEE transactions on neural networks.Vol.10, No.4, 1999.

5章 ニューラルネットワークを用いた 食肉製品分類評価の検討

5.1 緒言 [1]

ニューラルネットワークは、第2章にて整理した通り、生物の神経回路網を模擬し、脳の情報処理を人工的に実現する解析手法の1つである。

心理学者である Rosenblatt [2] [3]より、パーセプトロンと呼ぶパターン認識のための機械学習モデルの提案があり、そのパーセプトロンは、脳の情報処理を実現するものと期待され、研究が活発化した。しかし、1969年に Minsky [4]らによる限界(線形分離可能問題しか解答不可)が示されたことにより、研究ブームの終わりを見せた。その後、Hopfield [5]らがホップフィールドネットワークを提案、巡回セールスマン問題を解答可能との見解を示している。1986年には Rumelhart [6]らが多層パーセプトロンとバックプロパゲーション学習法を提案し、パーセプトロンの限界を解決した。これにより、ニューラルネットワーク研究の第二次ブームと呼ばれる現象が起き、活発な研究が行われている。

多層パーセプトロンは、様々な分野(音声処理、パターン認識、運動予測・制御等)に応用され、医療分野ではコンピュータ支援診断、長時間心電図の情報圧縮、放射線画像の画質改善等へ応用されている。食品の分野においても、ニューラルネットワークを採用した家畜飼養管理支援システムの構築を目的に、肥育豚の仕上がり日令に対する成長予測因子ベクトルを基に予測するモデルの作成や映像記録装置とニューラルネットワークを用いた物体認証技術を食品工場の生産ライン管理システム等、多くの事例を有する [7] [8]。

しかし、ニューラルネットワークと食肉製品中に含まれる化学成分含有量データに注目し活用した製品の分類技術は報告されていない。そこで本章では、食肉製品の主要動物種である豚肉及び牛肉製品を対象に、化学分析機器から得られる化学成分含有量データとニューラルネットワークを用い「製品種類」「部位」等への分類の可能性について検証した [9] [10] [11]。

5.2 本研究における検証手法

本章における、化学成分値を用いた豚肉製品、牛肉製品の分類可能性の検証手法について、以下に述べる。

5.2.1 使用する豚肉、牛肉製品データの取得

本検討に用いる、豚肉、牛肉製品データは、4.3.1.1 節、4.4.1.2 節 [12]と同一とした。

5.2.2 ニューラルネットワークによる分類可能性の検討(豚肉製品)

4.1 節では、無機成分 13 種類、ビタミン成分 12 種類について、豚肉製品の分類に必要な化学成分を評価した。

本節では、豚肉製品に対し、誘導結合プラズマ質量分析計(以下、ICP-MS)で測定可能な無機成分に限定し、分類可能性をニューラルネットワークで検証した。また、第 3 章の牛肉製品に対する検証と同様に豚肉製品 88 種を対象に分析機器測定誤差、産地、製造工場による環境誤差として±10%誤差をランダムで付与したダミーデータを作成した。このダミーデータ(+10%:88 種類、-10%:88 種類)を加えた合計 264 種類のデータについて、「製品種類」「部位」「調理方法」への分類を試みた。

ニューラルネットワークは、先にも述べた通り、人間の脳における神経細胞を表現する数学的モデルである。このモデルは、入力層、出力層、隠れ層から構成される。入力層で受けた情報は出力層にて判定され、各カテゴリー(製品種類、部位、調理法)の中で適した情報に出力される。その際、出力時の出力データを規定するため、隠れ層では微分可能な活性化関数を用いた(Fig.5-2-1)。

計算は、統計分析ソフトウェア Weka(Waikato 大学) [13] [14] [15] [16]、OS Windows10、メモリ 8GB、プロセッサは Intel Core i5-8500 を使用した。判別率は以下の式(5.1)により決定され、ニューラルネットワークにより定義された各カテゴリーについて正確に予測された試料数を全試料数 264 で除することで評価した。本検討では、中間層 5、学習回数 0~90,000 回で実施した。

$$\text{Determination rate}(\%) = \frac{\text{Positive discrim samples}}{\text{All samples}} \times 100 \quad (5.1)$$

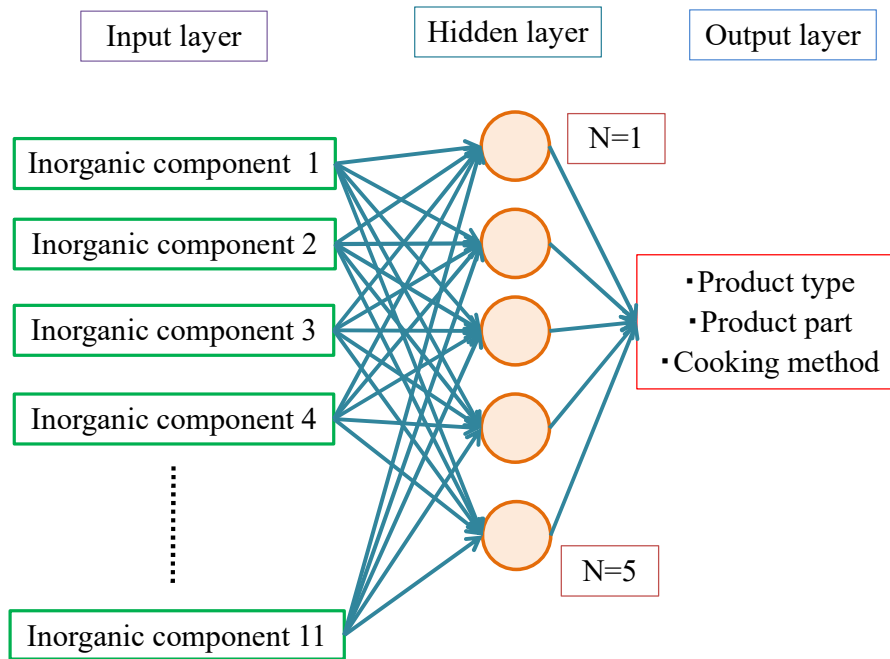


Fig.5-2-1 Image of neural network using inorganic components. [11]

5.2.3 ニューラルネットワークによる分類可能性の検討(牛肉製品)

第4章では牛肉製品に対し無機成分、ビタミン成分を混合した状態で、「製品種類」、「部位」、「牛の種類」への分類が可能であるか検討した。

その結果、「製品種類」であればナトリウム、脂質、亜鉛、カルシウム等の12成分、「部位」ではナトリウム、カルシウム、マグネシウム、鉄等の16成分、「牛の種類」では、ナトリウム、カルシウム、脂質、ビタミンB12等16成分の含有量により7割程度照合可能であることが確認された。

本章では、これら特定された化学成分を用い、牛肉製品の「製品種類」、「部位」、「牛の種類」に対しての分類可能性をニューラルネットワークにて確認した。用いる試料数は4.4.1.2節と同様、ニューラルネットワークの構成は入力層、出力層、隠れ層とし、入力層で受けた情報は出力層にて判定され、各カテゴリー(製品種類、部位、牛の種類)の中で適した情報に出力される。その際、出力時の出力データを規定するため、隠れ層では微分可能な活性化関数を用いた(Fig.5-2-2)。

計算は、統計分析ソフトウェア Weka(Waikato 大学)、OS Windows10、メモリ 8GB、プロセッサは Intel Core i5-8500 を使用した。なお、計算条件は、隠れ層 13、学習回数 100,000 回、学習率 0.01 と固定して実施した。判別率は豚肉製品同様に決定し、ニューラルネットワークにより定義された各カテゴリーについて正確に予測された試料数を全試料数で除することで表した [11] [13]。

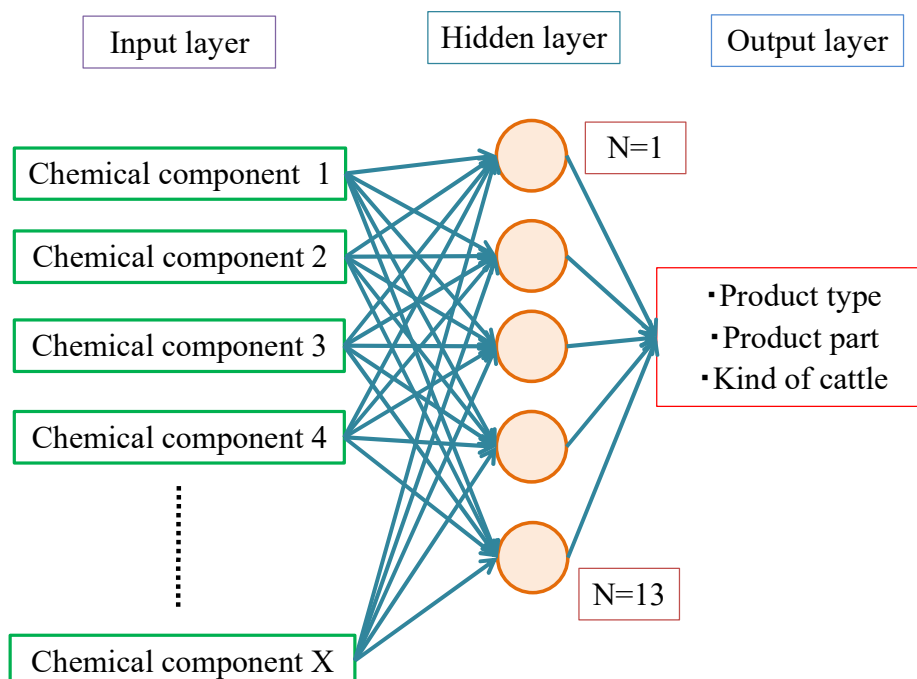


Fig.5-2-2 Image of neural network using chemical components.

5.3 本章における結果

本章における検討結果を示す。

5.3.1 ニューラルネットワークによる分類可能性の検討(豚肉製品)

本節では、ICP-MS で測定可能な無機成分 11 種類の含有量を用い、非線形回帰分析の 1 つであるニューラルネットワークによって、豚肉製品が「製品種類」「部位」「調理法」への分類可能性の評価結果を示した。

Fig.5-3-1、5-3-2 に豚肉製品 264 種類中に含まれる 11 種類の無機成分含有量を用いたニューラルネットワークによる各カテゴリー(「製品種類」、「部位」、「調理法」)への分析結果を示した。

Fig.5-3-1 に示すように、264 種類の豚肉製品を製品種類に分類した結果、学習回数が増加するに従い、正判別率が向上した。学習回数 55,000 回の場合、「製品種類」にて最も高い正判別率は 89.4%であった。以降、学習回数を増加したとしても正判別率は変化せず定常状態であった。同様に「部位」と「調理法」についても正判別率が学習回数 55,000 ~75,000 回まで増加することが確認された。学習回数が 75,000 回の時、部位の最大正判別率は 86.7%、調理法は 55,000 回の際に 92.8%であった。分類項目が多い部位については、製品種類、調理法と比較し、正判別率が低い傾向が確認された。




Fig.5-3-1 Result of neural network analysis using inorganic component for pork products.

Determination rate and learning iteration plot. [11]

Fig.5-3-2 に示すように、計算時間と学習回数間では正の相関があることが確認され、学習回数が増加するに従い計算時間が比例して増加した。各カテゴリーの学習回数に対する計算時間の関係では、製品種類と調理法では同程度の計算時間を示すが、部位はこれらカテゴリーと比較し、計算時間を要することが確認できた。




Fig.5-3-2 Result of neural network analysis using inorganic component for pork products.
Calculation time of neural network by learning iteration. [11]

5.3.2 ニューラルネットワークによる分類可能性の検討(牛肉製品)

非線形回帰分析であるニューラルネットワークを用いた牛肉製品の分類可能性について評価した。

検証条件は、5.3.3 節の通りであり、正判別率を確認することで検証を行った。なお、選択する化学成分は、第 4 章の判別分析結果より確認し、クラスター分析で用いた成分を使用した。

以上条件による計算結果より、「製品種類」は正判別率：84.6%、「部位」：91.2%、「牛の種類」：93.9%となった。これより、非線形回帰分析の 1 つであるニューラルネットワークでは牛肉製品の化学成分値を 12～15 種類定量すれば、「製品種類」では 8 割、「部位」「牛の種類」では 9 割の精度で分類可能であることを示した。

5.4 本章における結果の考察 [11]

本章における検討結果に対する考察を行う。

5.4.1 ニューラルネットワークによる分類可能性の検討(豚肉製品)

5.3.1 節で実施した、無機成分 11 種類を用いたニューラルネットワークによる分類結果に対する考察を行った。

Table5-4-1 は、「製品種類」別の正判別率を示している。その結果、「脂身」「副生物」「加工品」の正判別率は 100%であり、「皮下脂肪なし」は 58.3%と低い値を示した。「脂身つき」や「ひき肉」は 80.0%以上を示すが、約 20%の誤判別が確認された。これは、「皮下脂肪なし」「脂身つき」「ひき肉」に脂身が含まれているため、製品 100g 当たりの無機成分組成が類似していることから誤判別があると考えられる。

Table5-4-1 Neural network analysis result by product type.

Product type	True	False	False rate	True rate
Red meat	36	3	7.7%	92.3%
Without subcutaneous fat	21	15	41.7%	58.3%
Lean and fat	36	9	20.0%	80.0%
Fatty meat	30	0	0.0%	100.0%
Offal and by-products	33	0	0.0%	100.0%
Ground meat	5	1	16.7%	83.3%
Meat substitute	75	0	0.0%	100.0%
Total	236	28	10.6%	89.4%

Table5-4-2 は、部位別の正判別率を示している。

「ロース」、「ヒレ」、「ばら」、「ひき肉」、「豚足」、「副生物」、「軟骨」、「加工品」は正判別率 91.7~100%と高い値を示し、11 無機成分含有量によるニューラルネットワークの学習により、高精度で分類が可能であることを示した。

一方、「ロース」、「かたロース」、「そともも」、「もも」は、互いに近接している部位であるため、正判別率はその他部位より低く、50.0~87.5%である。

「ゼラチン」は 66.7%の正判別率であり、これはゼラチンを含む豚足に誤判別されることが要因である。

Table5-4-2 Neural network analysis result by product part.

Product part	True	False	False rate	True rate
Picnic shoulder	15	9	37.5%	62.5%
Picnic shoulder loin	21	3	12.5%	87.5%
Outside ham	12	12	50.0%	50.0%
Ham	22	8	26.7%	73.3%
Loin	32	1	3.0%	97.0%
Fillet	11	1	8.3%	91.7%
Belly	9	0	0.0%	100.0%
Ground meat	6	0	0.0%	100.0%
Pig's feet	3	0	0.0%	100.0%
Visceral meat	24	0	0.0%	100.0%
Cartilage	3	0	0.0%	100.0%
Gelatin	2	1	33.3%	66.7%
Meat substitute	69	0	0.0%	100.0%
Total	229	35	13.3%	86.7%

Table5-4-3 に調理法別の正判別率を示した。

「ゆで」、「生」、「ソーセージ」、「ハム」、「揚げ」は、95.2~100.0%の高い正判別率を示した。しかし、「焼き」、「燻製」、「ペースト」は 61.1~66.7%と低く、「ベーコン」は 22.2%であった。

以上の結果から、隣接部位の正判別率向上が問題であることが示されたが、明らかに異なる部位の分類は高精度で可能であることを示した。

上記結果から、豚肉製品に含まれる ICP-MS で測定可能な無機成分を用いることで各カテゴリーへ分類が可能であることを示した。しかし、調理法以外は、90%以上の正判別率が得られないため、更なる分類精度向上を検討する必要がある。

Table5-4-3 Neural network analysis result by cooking method.

Cooking method	True	False	False rate	True rate
Roasted	11	7	38.9%	61.1%
Boild	20	1	4.8%	95.2%
Raw	153	0	0.0%	100.0%
Smoking	2	1	33.3%	66.7%
Paste	2	1	33.3%	66.7%
Sausage	27	0	0.0%	100.0%
Ham	24	0	0.0%	100.0%
Becon	2	7	77.8%	22.2%
Breaded and fried pork	6	0	0.0%	100.0%
Total	247	17	6.4%	93.6%

5.4.2 ニューラルネットワークによる分類可能性の検討(牛肉製品)

5.3.6節で実施した、ニューラルネットワークによる分類結果に対する考察を行った。

Table 5-4-4 に「製品種類」の詳細な正判別率を示した。この結果より化学成分 12 種類（ナトリウム、脂質、亜鉛、カルシウム、マグネシウム、タンパク質、カリウム、リン、ビタミン B6、鉄、ビタミン B3、ビタミン B12）を定量することにより牛肉製品の「製品種類」について 8 割以上の精度で分類が可能であることを確認した。各カテゴリーで見れば「赤肉」「脂身」「副生物」「ひき肉」「加工品」は 92.9～100.0%の正判別率であり、化学成分含有量を把握することで正確に分類可能である。一方、「皮下脂肪なし」「脂身つき」については 75.0%をわずかに下回りそれぞれで誤判別を示すことが確認できた。これは、2つの製品種類において皮下脂肪の有無のみが違いとなるため、化学成分含有量の傾向に大きな変化がないことが要因である。

Table5-4-4 Neural network analysis result by product type.

Product type	True	False	False rate	True rate
Red meat	78	6	7.1%	92.9%
Without subcutaneous fat	76	26	25.5%	74.5%
Lean and fat	80	28	25.9%	74.1%
fatty meat	33	0	0.0%	100.0%
Offal and by-products	48	0	0.0%	100.0%
Ground meat	6	0	0.0%	100.0%
Meat substitute	14	1	6.7%	93.3%
Total	335	61	15.4%	84.6%

Table 5-4-5 に「部位」の詳細な正判別率を示した。この結果より化学成分 12 種類（ナトリウム、脂質、亜鉛、カルシウム、マグネシウム、タンパク質、カリウム、リン、ビタミン B6、鉄、ビタミン B3、ビタミン B12）を定量することにより牛肉製品の「部位」について 9 割以上の精度で分類が可能である。各カテゴリーで見れば「かたロース」「サーロイン」「そともも」「副生物」「加工品」等の 10 カテゴリーにおいて 83.3～100.0%の正判別率を示し、これらの 12 化学成分含有量を把握することで正確に分類可能であることを示唆した。一方、「かた」「ヒレ」については正判別率が 72.2～75.0%であり、脂質含有量が低いことからそれぞれ誤判別が確認された。

Table5-4-5 Neural network analysis result by product part.

Product type	True	False	False rate	True rate
Chuck	27	9	25.0%	75.0%
Chuck roll	27	0	0.0%	100.0%
Sirloin	26	1	3.7%	96.3%
Libloin	66	9	12.0%	88.0%
Outside ham	26	1	3.7%	96.3%
Ham	70	5	6.7%	93.3%
Belly	13	5	27.8%	72.2%
Fillet	14	1	6.7%	93.3%
Rump	24	3	11.1%	88.9%
Offal and by-products	48	0	0.0%	100.0%
Ground meat	5	1	16.7%	83.3%
Meat substitute	15	0	0.0%	100.0%
Total	361	35	8.8%	91.2%

Table 5-4-6 に「牛の種類」の詳細な正判別率を示した。この結果より化学成分 15 種類（ナトリウム、カルシウム、脂質、ビタミン B12、カリウム、マグネシウム、ビタミン B3、亜鉛、鉄、ビタミン B6、タンパク質、リン、ビタミン B2、ビタミン B5、ビタミン B1）を定量することにより牛肉製品の「牛の種類」について 9 割以上の精度で分類が可能である。全 8 カテゴリーにおいて 87.8~100.0%の正判別率を示し、これらの 15 化学成分含有量を把握することで正確に分類可能であることを示唆した。

Table5-4-6 Neural network analysis result by kind of cattle.

Product type	True	False	False rate	True rate
Japanese beef cattle	88	2	2.2%	97.8%
Imported beef	79	11	12.2%	87.8%
Dairy fattened steer	88	8	8.3%	91.7%
Crossbred steer	40	2	4.8%	95.2%
Veal	9	0	0.0%	100.0%
Offal and by-products	47	1	2.1%	97.9%
Ground meat	6	0	0.0%	100.0%
Meat substitute	15	0	0.0%	100.0%
Total	372	24	6.1%	93.9%

5.5 本章のまとめ

本章により実施した結果のまとめを行う。

豚肉製品 88 種類を対象に ICP-MS を用いて計測できる無機成分を用いた分類の検討では、測定誤差を考慮した上で実施した。検討手法はニューラルネットワークを用いて実施し、「製品種類」「部位」「調理法」の各項目に対する分類を試みた。

その結果、「製品種類」については正判別率 89.4%、「部位」が 86.7%、「調理法」が 92.8%となった。これより、豚肉製品に対しては、ICP-MS で測定可能となる 11 無機成分を定量すれば上記 3 項目の分類がニューラルネットワークにて可能であることを示唆された。しかし、「製品種類」では「皮下脂肪なし」「脂身つき」「ひき肉」、「部位」の「ロース」「肩ロース」「そともも」「もも」、「調理法」の「焼き」「燻製」「ペースト」等は誤判別率が高い傾向にあるため、これらの分類精度の向上も必要である。今後は、各カテゴリーの分類精度向上を目的とした隠れ層や学習時間等の増減を検討し、実際に分類が不明となる製品を用いた分類について検証を試みる。

また、牛肉製品 132 種類を対象に主要化学成分値を用いた分類の検討では、測定誤差を考慮した上で実施した。検討手法は豚肉製品同様、ニューラルネットワークを用いて実施し、「製品種類」「部位」「牛の種類」の各項目に対する分類を試みた。その結果、「製品種類」については正判別率 84.6%、「部位」が 91.2%、「調理法」が 93.9%となった。これより、牛肉製品は、食品中の主要化学成分を定量すれば上記 3 項目の分類がニューラルネットワークにて可能であることを示唆した。しかし、「製品種類」では「皮下脂肪なし」「脂身つき」、「部位」の「ロース」「ヒレ」は、正判別率が 7 割前後と低いため、これらの分類精度の向上が課題であることを併せて確認した。豚肉製品同様、今後は、各カテゴリーの分類精度向上を目的として隠れ層や学習時間等の増減等、計算条件設定、化学成分の絞り込みを検討し、実際に分類が不明となる製品を用いた分類について検証する必要がある。

上記結果を踏まえ、ニューラルネットワークによる豚肉・牛肉製品の分類・照合に向けた栄養成分の抽出が可能であることを確認できた。この検討を深化させた上で、栄養成分を測定可能な化学センサや電気センサ等、また、機械学習を応用し、食品の簡易分類評価に繋がる応用研究が期待される。

参考文献

1. Block.H.D. The Perceptron: A Model for Brain Functioning. I. : Rev. Mod. Phys. 34, 1962.
2. Rosenblatt.F. The Perceptron--a perceiving and recognizing automaton. : Cornel Aeronautical Laboratory, 1957.
3. Rosenblatt.F. The perceptron: a probabilistic model for information storage and organization in the brain. : Psychological Review, 65, 1958.
4. Minsky.M, Papert.S. Perceptrons: An Introduction to Computational Geometry. : MIT Press, 1969.
5. Hopfield.J.J. Neural networks and physical systems with emergent collective computational abilities. : Proceedings of the National Academy of Sciences of the United States of America 79, 1982.
6. Rumelhart.E.David, Hinton.E.Geoffrey , Williams.J.Ronald. Learning representations by back-propagating errors. : Nature volume 323, 1986.
7. 井岡良太, ほか. ニューラルネットワークによる物体認識技術の食品生産管理システムへの応用. : 第 34 回ファジィシステムシンポジウム講演論文集, 2018.
8. 佐竹隆顕, ほか. 家畜飼養管理システムへのニューラルネットワークの適用に関する研究(1)-肥育豚の成長予測-. : 農業施設, 1994.
9. Mcculloch.S.W , Pitts.W. A logical calculus of the ideas immanent in neurons activity. : Bull.Math.Biophys.Vol.5, 1943.
10. Zhang.Ling , Zhang.Bo. A geometrical representation of McCulloch-Pitts neural model and its applications. : IEEE transactions on neural networks.Vol.10, No.4, 1999.
11. Goda.Motoki , Kojima.Yohichiro. Possible classification of pork products by ICP-MS . : Journal of the Institute of Industrial Applications Engineers, 2020.
12. 文部科学省. 食品成分データベース. (オンライン) 2018 年 7 月. <https://fooddb.mext.go.jp/>.
13. The University of Waikato. WEKA The workbench for machine learning. (オンライン) <https://www.cs.waikato.ac.nz/ml/weka/>.
14. 山本章博. 機械学習統合環境 Weka とベンチマークデータ. (オンライン) 京都大学 情報学研究科, 2012 年 12 月 25 日. <http://www.iip.ist.i.kyoto-u.ac.jp/member/akihiro/Weka12.pdf>.
15. 荒木雅弘. フリーソフトではじめる機械学習入門. : 森北出版株式会社, 2014.
16. 合田元清, 小島洋一郎. ニューラルネットワークと判別分析による水産食品分類条件の検討. : 産業応用工学会論文誌, Vol.7, No.1, 2019.

6章 水産食品の分類に寄与する 化学成分の評価

(多変量解析的手法・ニューラルネットワーク)

6.1 緒言

本章では、第4章、第5章及び先行研究 [1] [2] [3] [4] [5] [6] [7]で実施した豚肉製品、牛肉製品等といった食肉製品とは異なる、水産食品を対象とした化学成分値を用いる分類の評価を行った。

本報告では、無機成分含有量が既知である水産食品 419 種類を対象に、「製品種類」6 種類(魚類、貝類、いか・たこ類、えび・かに類、水産練り製品、水性生物類)への分類が可能であるか検討した。水産食品を対象とした理由は以下に述べる。

昨今の食の安全・安心に対する消費者の関心が高まると共に、より高品質な食品への要望も挙がっている。この傾向は、日本国内のみならず外国人旅行者を中心とした日本食へのブームもあいまって顕著に表れている。以上の背景を発端とし、日本政府は2015年に改訂された「日本再興戦略」 [8]において、我が国の農水産物・食品の海外市場開拓と拡大を目標にしており、北海道も同様に各農水産物生産団体にて、ブランド製品の開発と販路拡大に邁進している。加えて、輸出先国の高度衛生管理認証 [9]を含めた、製品種類、調理法などの特定や区別、それらに関連した含有化学物質の検出といった安全性の確保を課題としている。これより、食肉製品以外の分類検討として北海道の食品輸移出の主力である水産食品を対象とした。

本検討は、豚肉製品、牛肉製品に適用した分散分析及び判別分析を用いた手法の他、非線形回帰分析の1つであるニューラルネットワークによる分類に資する無機成分の特定と評価を実施した。

6.2 本研究における検証手法

本研究における実験概要を説明する。無機成分値が既知である水産食品 419 種を対象に無機成分含有量を用いる事により「製品種類」6 種類 (魚類、貝類、いか・たこ類、えび・かに類、水産練り製品、水性生物類) [10]への分類が可能であるかを検討した。

はじめに、分類を決定しうる無機成分値の順位付けを分散分析により実施し、その結果を持ってニューラルネット及び判別分析による分類の検証を行った。次節より、その詳細について説明を行う。

6.2.1 使用する水産食品データの取得

文部科学省 科学技術・資源調査分科会報告 7 訂増補日本食品成分表 2015 [10]における代表的な水産食品 419 種類を抽出し、これらを試料として解析対象とした(Table6-2-1)。

取得した水産食品に含まれる、無機成分 13 種(ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅、マンガン、ヨウ素、セレン、クロム、モリブデン)の含有量も併せて取得した(Table6-2-2)。なお、「Tr」「-」「0」と記載のある場合、該当する化学成分の含有量が著しく低い、または、皆無であることを示しているため、一律「0」とした。

本検討における分類項目である、製品種類を下表に示す。

Table6-2-1 Description of aquatic product types. [10]







		
Fish	Shellfish	Sleeve fish & Devil fish
A group of animals excluding limbs from the vertebrates. It refers to an organism called a fish.	It is a generic term for molluscs, generic name of things with clear shells.	It refers to sleeve fish & Devil fish which is an animal belonging to molluscan portal foot group.
		
Shrimp & Crab	Fishery paste products	Aqueous living things
It refers to shrimp and crab in crustaceans. Classified as an arthropod.	Food made from fish paste as the main ingredient, formed by adding salt and then gelled.	Organisms to be covered by other marine products such as sea shoots.

Table6-2-2 Types of inorganic components [10]

◎Inorganic components (13 species)
Sodium , Potassium , Calcium , Magnesium
Phosphorus , Iron , Zinc , Copper , Manganese
Iodate , Selenium , Chrome , Molybdenum

6.2.2 分散分析による無機成分の順位付け

量的データである無機成分含有量から水産食品の「製品種類」(魚類、貝類、いか・たこ類、えび・かに類、水産練り製品、水性生物類)に分類可能と考え、分類の決定に影響を与える化学成分値の順位付けを F 値算定 [11] [12]により行った。

6.2.3 判別分析による「製品種類」の分類に寄与する無機成分の特定と評価

検証に用いる水産食品データ 419 種の「製品種類」について、無機成分 13 種類を対象に判別分析を行うことで分類に寄与する化学成分を特定した。

水産食品の「製品種類」に含まれる分類項目をグループとし、それらを決定付けるデータを無機成分とした。それぞれの水産食品データに含まれている無機成分値により、各「製品種類」に形成された多変量空間内において、その水産食品がどの「製品種類」に判別されるかを算定した。また、本検討で用いた判別分析法は、線形判別分析法を用い、どの「製品種類」に判定するかを Mahalanobis 距離 [11] [12]により決定した。なお、評価指標は、(6.1)式に示す通り、既知の「製品種類」に判別された水産食品データを正判別とし、その製品数を 419 製品で除することで正判別率を算定・評価した。なお、分散分析により算定した化学成分の F 値順位に応じ、1 つずつ成分数を追加して判別分析を実施し正判別率を算定した。その後、化学成分を追加する事による正判別率の推移を示した。これより、何種類の無機成分を用いる事で、水産食品データを「製品種類」に分類が可能となるか評価した。

$$Determination\ rate(\%) = \frac{Positive\ discrim\ samples}{All\ samples} \times 100 \quad (6.1)$$

6.2.4 ニューラルネットワークを用いた判別率算定による検証

水産食品データ 419 種の「製品種類」について、分類に必要な無機成分含有量をニューラルネットワークによって算定した正判別率により検証した。なお検証は、正判別率が向上する無機成分の種類、隠れ層の数、学習回数の設定に留意した上で実施した。

本論文では、入力層を無機成分含有量とし、出力層を水産食品の「製品種類」、隠れ層に用いる活性化関数を双曲線正接関数である TanH を用いた [13] [14] [15]。なお、計算は、統計解析ソフトウェア Weka (The University of Waikato) を用い、使用 OS は Windows7、実装メモリ 4GB、プロセッサは Intel Core i3 inside 560 とした。無機成分は、分散分析の F 値順位に習い追加し、隠れ層は 5~13、学習回数は 50~5、000 回の間に変化させた。また、学習後は判別率を算定し、「製品種類」への分類の可能性を評価した。なお、判別率は、6.2.3 節と同様、(6.1)式により決定した。




Fig.6-2-1 Image of neural network using inorganic components.

6.3 本章における結果

本章における検討結果を示す。

6.3.1 分散分析による分類に寄与する無機成分の順位付け

水産食品の「製品種類」に対し無機成分含有量を用いた分散分析結果について説明する。

分散分析による F 値算定結果について Fig.6-3-1 に示した。F 値が最も高い結果を示した無機成分は、銅であった。次点以降は、マグネシウム、亜鉛、セレン、カリウム、カルシウムと続き、最後 13 番目はヨウ素となった。これより、水産食品の「製品種類」6 種類（魚類、貝類、いか・たこ類、えび・かに類、水産練り製品、水性生物類）の分類を考えた場合の無機成分の重要度を Fig.6-3-1 に示すように決定した [16] [17]。




Fig.6-3-1 Inorganic component of aquatic product types F value ranking. [17]

6.3.2 判別分析による「製品種類」分類に寄与する無機成分の特定

6.3.1 節では、分散分析による水産食品の「製品種類」に寄与する無機成分を分散分析により F 値を算定し、その多寡によってそれぞれの分類に寄与する無機成分を順位付けした。この結果を用い、判別分析による分類状況を確認した上で、これらに必要な無機成分の特定を試みた。その結果を以下に示す。

分散分析によって算定した F 値の順位に応じ、化学成分含有量を追加する操作を繰り返し実施した判別分析の結果を示した。

Fig.6-3-2 は、水産食品の「製品種類」に対する正判別率の推移を示している。「製品種類」の判別分析結果は、F 値最上位の銅 1 成分では、正判別率 11.0%を示した。マグネシウムを追加した 2 成分では、正判別率は向上し 54.4%となった。その後、セレンまで追加した 4 成分では、一時的に正判別率の低下が見られたが、カリウムを加えた 5 成分、カルシウムを加えた 6 成分では、67.5%、70.2%と増加傾向に転じた。以降、リンを追加した 10 成分では、正判別率 7 割前後とほぼ横ばいに推移した。ナトリウムを加えた 11 成分より多くの成分を追加した場合、正判別率は 75%前後と再び増加した。以上の結果より、無機成分による水産食品の「製品種類」の特定は F 値上位 6 成分、銅、マグネシウム、亜鉛、セレン、カリウム、銅の含有量を把握すれば 7 割程度の精度で特定できることが示唆された。 [17]




Fig.6-3-2 Result of discriminant analysis using inorganic component for aquatic product types. [17]

6.3.3 ニューラルネットワークを用いた判別率算定による検証

6.3.1 節では、分散分析による水産食品の「製品種類」に寄与する無機成分を分散分析により F 値を算定し、その多寡によってそれぞれの分類に寄与する無機成分を順位付けした。この F 値の順位に応じ、無機成分を 1~13 種類、隠れ層数 5~13、学習回数 50~5,000 の間で条件を設定し、ニューラルネットワークにて学習を行った。これより、水産食品 419 種類に対する分類を試みた。また、学習後は、正判別率を算定し、「製品種類」への分類の可能性を評価した。

その結果の一部を Fig.6-3-3 に示す。




Fig.6-3-3 Result of neural network analysis using inorganic component for aquatic product types.(Determination rate – Learning time plot)

ニューラルネットワークによる計算条件は多岐にわたるため、Fig.6-3-3 に示した結果で説明を行う。上記計算条件は、無機成分を 8 種類（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン）、隠れ層数 5~13、学習回数 50~5、000 と変化させた結果である。これらの計算結果について、Fig.6-3-3、Fig.6-3-4 に示す。Fig.6-3-3 は隠れ層数 5~13 別の学習回数を変化させた正判別率の推移、Fig.6-3-4 は、学習回数による計算時間の変化である。

Fig.6-3-3 より、隠れ層数が 10、13、学習回数 5,000 回で正判別率 80%を上回る結果となった。Fig.6-3-4 に示す計算時間の変化は隠れ層数、学習回数と正の相関を示し、学習回数が増加することで計算時間も増大することが確認できた。 [17]




Fig.6-3-4 Calculation time of neural network by learning time. [17]

詳細な学習時間、隠れ層数毎の判別率及び計算時間については、Table6-3-1～6-3-2に示した。

Table6-3-1 Result of neural network analysis using inorganic component for aquatic product types.

Learning time	Node5	Node6	Node7	Node8	Node9	Node10	Node11	Node12	Node13
50	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%
100	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%
200	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%	72.1%
300	72.3%	72.3%	72.3%	72.3%	72.3%	72.3%	72.1%	72.1%	72.1%
400	72.3%	72.3%	72.3%	72.3%	72.1%	72.3%	72.3%	72.3%	72.3%
500	72.3%	72.1%	72.1%	72.1%	72.3%	72.6%	72.3%	72.3%	71.8%
600	72.3%	72.6%	72.6%	72.6%	72.6%	72.3%	72.3%	72.6%	72.3%
700	73.0%	73.0%	72.6%	72.6%	73.0%	72.8%	73.3%	73.7%	73.0%
800	73.7%	73.7%	73.5%	73.7%	74.0%	73.7%	73.7%	74.0%	74.0%
900	74.0%	73.7%	73.7%	74.0%	74.5%	74.2%	74.0%	74.5%	74.7%
1000	74.2%	74.0%	74.0%	74.0%	74.7%	74.9%	74.2%	74.7%	74.7%
1500	74.9%	75.7%	75.9%	75.4%	75.7%	77.1%	76.1%	77.1%	76.8%
2000	76.4%	75.2%	75.9%	76.8%	77.3%	77.6%	77.8%	78.0%	77.8%
2500	77.6%	76.8%	77.3%	78.0%	78.3%	78.5%	78.3%	78.3%	78.3%
3000	78.5%	78.0%	78.3%	79.0%	78.5%	79.5%	78.8%	78.5%	79.0%
3500	78.8%	77.8%	79.0%	79.0%	78.8%	80.0%	78.5%	78.8%	79.2%
4000	78.5%	78.0%	78.3%	79.0%	79.0%	80.0%	78.8%	79.0%	79.5%
4500	79.0%	78.5%	78.8%	78.8%	80.0%	80.4%	79.0%	79.0%	79.5%
5000	79.0%	79.5%	79.0%	79.5%	80.4%	80.4%	79.7%	79.5%	80.4%

Table6-3-2 Calculation time of neural network by learning time.

Learning time	Node5	Node6	Node7	Node8	Node9	Node10	Node11	Node12	Node13
50	0.11	0.19	0.14	0.15	0.16	0.19	0.18	0.20	0.22
100	0.24	0.27	0.26	0.29	0.31	0.34	0.40	0.44	0.44
200	0.44	0.50	0.52	0.60	0.62	0.66	0.77	0.80	0.85
300	0.70	0.76	0.76	0.88	0.93	1.09	1.12	1.21	1.27
400	0.96	1.03	1.08	1.16	1.33	1.36	1.49	1.55	1.71
500	1.24	1.26	1.34	1.49	1.68	1.68	1.93	1.98	2.09
600	1.42	1.49	1.57	1.74	1.97	2.11	2.34	2.33	2.48
700	1.65	1.79	1.85	2.03	2.26	2.33	2.60	2.72	2.94
800	1.91	1.97	2.11	2.38	2.65	2.57	3.04	3.10	3.34
900	2.22	2.21	2.36	2.57	2.92	3.03	3.30	3.47	3.82
1000	2.36	2.45	2.64	2.87	3.35	3.61	3.89	4.47	4.18
1500	3.45	3.77	4.11	4.43	4.92	5.08	5.36	5.84	6.20
2000	4.56	4.96	5.18	5.78	6.52	7.20	7.14	8.04	8.62
2500	5.88	6.15	7.25	7.28	9.29	8.59	9.14	10.04	10.60
3000	6.69	7.40	7.89	8.70	11.00	10.61	12.36	11.77	12.84
3500	8.38	8.87	9.27	10.38	11.41	11.94	12.61	13.94	14.59
4000	9.70	10.15	10.57	11.32	12.17	14.80	14.82	15.83	17.02
4500	9.97	11.35	11.65	13.21	13.78	15.70	18.02	20.07	18.65
5000	10.55	11.19	13.23	14.17	15.48	16.85	18.79	19.19	22.09

上記のような正判別率、計算時間に関わる傾向は、いずれの無機成分数（1～13種類）、隠れ層数、学習回数においても確認された。

以上より、水産食品の無機成分含有量を情報として与え、ニューラルネットワークによる「製品種類」の分類に最適な計算条件を正判別率、学習時間、使用する無機成分数の観点から条件を取り纏め、必要な最小無機成分数を確認した。正判別率が8割を越えた代表的な計算条件をTable6-3-3に示す。示した条件は以下の特徴が見られた。

- ① 無機成分数が最も少ない。
- ② 計算時間が最も少ない。
- ③ 正判別率が最も高い。

Table6-3-3 Optimal calculation condition of neural network for aquatic product types classification.

No.	Number of inorganic components	Determination rate (%)	Learning time	Node	Calculation time (s)
①	Cu, Mg, Zn, Se, K, Ca, Fe, Mn	80.4	5000	9	15.48
②	Cu, Mg, Zn, Se, K, Ca, Fe, Mn, Mo, P, Na	80.2	2000	6	5.58
③	Cu, Mg, Zn, Se, K, Ca, Fe, Mn, Mo, P, Na, Cr, I	81.9	4500	11	19.95

この3計算条件より、分類に必要な無機成分含有量の種類が最も少ない8種類（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン）を用いることで水産食品の「製品種類」について分類することが可能であることを示した。

[17]

6.4 結果の考察

本節では、水産食品に含まれる無機成分を用いた分類の可能性について評価した結果の考察を示す。

6.4.1 判別分析による、水産食品「製品種類」の分類に寄与する無機成分の探索

無機成分含有量を用いた判別分析により、水産食品の「製品種類」による判別状況を分析した場合（Table6-4-1）、「水産練り製品」の正判別率 90%以上と高い結果となった。これは、練り製品の主原料となる「すけとうだら」、「いとよりだい」の無機成分含有量が他の魚類名に属する試料より低いことが要因である。一方、「いか・たこ類」が正判別率 32.0%となった。これは、「いか・たこ類」、「えび・かに類」双方に属する一部の試料（「するめいか」、「ずわいがに」等）のセレン含有量が特異的に高く、同じく豊富に含まれる試料が多い「魚類」に誤判別されたことが要因として考えられる。同じく正判別率が低い傾向にあった「水性生物類」は、属する生物がそれぞれ特異的な生体を有し、化学成分値も大きな差異があった。

以上より、「えび・かに類」、「水性生物類」は、無機成分 6 成分の含有量を特定しただけでは、正確に判別が難しいことがわかった。しかし、無機成分 6 成分では、「魚類」、「水産練り製品」の判別が可能となることを示唆した。 [17]

Table6-4-1 Discrimination analysis result by aquatic product types. [17]

Product type	True	False	False rate	True rate
Fish	241	61	20.2%	79.8%
Shellfish	22	19	46.3%	53.7%
Sleeve fish & Devil fish	8	17	68.0%	32.0%
Shrimp & Crab	6	19	76.0%	24.0%
Fishery paste products	12	1	7.7%	92.3%
Aqueous living things	5	8	61.5%	38.5%
Total	294	125	29.8%	70.2%

6.4.2 無機成分とニューラルネットワークを用いた分類条件の探索

水産食品の「製品種類」に含まれる無機成分を対象に分散分析による順位付け後、入力層として含まれる無機成分8種（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン）を選択し、出力層を「製品種類」、隠れ層数を9として構築したニューラルネットワークによる学習より確認できた「製品種類」への分類結果を検証した。

上記条件による学習結果に対する「製品種類」別の正判別率について Table6-4-2 に示す。これより、「魚類」は95.7%、「貝類」は75.6%と高い割合で分類できることを確認した。しかし、「いか・たこ類」であれば52.0%まで減少し、「えび・かに類」は16.0%、「水生生物」及び「水産練り製品」は正しく判別できた製品が存在しなかった。 [17]

Table6-4-2 Neural network analysis result by aquatic product types. [17]

Product type	True	False	False rate	True rate
Fish	289	13	4.3%	95.7%
Shellfish	31	10	24.4%	75.6%
Sleeve fish & Devil fish	13	12	48.0%	52.0%
Shrimp & Crab	4	21	84.0%	16.0%
Fishery paste products	0	13	100.0%	0.0%
Aqueous living things	0	13	100.0%	0.0%
Total	337	82	19.6%	80.4%

この要因は、「魚類」が製品として302種類と全体の72%を占めており、ニューラルネットワークにて学習するデータが多いため判別において、高精度となったことが考えられる。一方で、「貝類」は41種類、「いか・たこ類」、「えび・かに類」は25種類、「水生生物」及び「水産練り製品」は13種類と学習に用いる食品数が不足しているため、正判別率が低下したことが考えられる。

上記考察の検証を実施するため、本検討で設定した同一条件（無機成分8種類：銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン、隠れ層数9、学習回数5,000回）にて、「いか・たこ類」、「えび・かに類」、「水生生物」、「水産練り製品」それぞれの製品についてコピーしたデータをダミーデータとして追加した全水産食品536種類のデータベース（「貝類」：41種類→82種類、「いか・たこ類」：25種類→50種類、「えび・かに類」：25種類→50種類、「水生生物」：13種類→26種類、「水産練り製品」：13種類→26種類、「魚類」：302種

類)を作成し、ニューラルネットワークによる解析を行った。その結果を Table.6-4-3 に示す。 [17]

Table6-4-3 Neural network analysis with dummy data added result by aquatic product types. [17]

Product type	True	False	False rate	True rate
Fish	282	20	6.6%	93.4%
Shellfish	67	15	18.3%	81.7%
Sleeve fish & Devil fish	34	16	32.0%	68.0%
Shrimp & Crab	22	28	56.0%	44.0%
Fishery paste products	12	14	53.8%	46.2%
Aqueous living things	2	24	92.3%	7.7%
Total	419	117	27.9%	72.1%

結果より、「貝類」81.7%、「いか・たこ類」68.0%、「えび・かに類」44.0%、「水産練り製品」46.2%、「水生生物」7.7%と正判別率が向上した。

これより、無機成分8種類（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン）を定量することで、水産食品の「製品種類」を分類が可能であることを見出した。

6.4.3 判別分析とニューラルネットワークによる結果の比較と分類への利用性について

ニューラルネットワークによる検証結果では、無機成分を8種類（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン）を定量することにより水産食品の分類が8割可能となることを示した。一方で、判別分析では、無機成分を最低6種類（銅、マンガン、亜鉛、セレン、カリウム、カルシウム）定量することで7割の精度で分類が可能であった。

これら2種類の検証方法における分類の利用性について、ニューラルネットワークであれば、水産食品に含まれる8種類の無機成分含有量を学習することにより、分類が必要な「製品種類」が未知の水産食品サンプルの無機成分含有量を定量後、ニューラルネットワークに学習させることにより適切な「製品種類」への判別が可能となる。一方、判別分析においては、判別可能となる無機成分の検証は実施できたが、「製品種類」自体が未知の水産食品を検証する場合、本報告で検討した既知の水産食品に対し、「製品種類」別の無機成分含有量の特徴を比較する必要性が生じる。したがって、正判別率、学習による判別が可能となる観点から、無機成分含有量定量後の「製品種類」判別は、ニューラルネットワークを用いることが最も簡易的であると考えられる。

6.5 本章のまとめ

本章では、水産食品 419 種類に含まれる化学成分値の中から、原子吸光分析装置等を用いる分析法で定量可能な無機成分 13 種類（ナトリウム、カリウム、カルシウム、マグネシウム、リン、鉄、亜鉛、銅、マンガン、ヨウ素、セレン、クロム、モリブデン）の含有量データを抽出、最適化し、その後、分散分析、ニューラルネットワーク、判別分析を用いる事で「製品種類」への分類可能性を評価・検討した。

ニューラルネットワークでは、分散分析により順位化した無機成分を入力層として設定し、隠れ層を経て出力層にて判別された「製品種類」が水産食品本来の「製品種類」となるかを検討し、正判別率、計算時間、使用する無機成分数を総合的に勘案した上で、最適な計算条件を設定した。この設定した計算条件では、無機成分 8 種類（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム、鉄、マンガン）の定量値を用いることで「魚類」は 95%以上、「貝類」は 75%以上判別することができる。

判別分析では、無機成分 6 種類（銅、マグネシウム、亜鉛、セレン、カリウム、カルシウム）の含有量を特定することで約 7 割判別可能であった。しかし、「製品種類」別に正判別率の差が大きく、これら無機成分含有量の特定で判別可能な「製品種類」は、「魚類」、「水産練り製品」であった。

以上、これら 2 種類の手法による比較と利用性の検討により、無機成分含有量を用いた水産食品の「製品種類」分類は、無機成分 8 種類の定量後、ニューラルネットワークによる手法を用いることが有用と考える。

しかしながら、これら結果は、魚類名や化学分析の測定現場における分析誤差を考慮していないため、今後は、産地や測定場所等の誤差を用いた分析を実施し、本報告の結果を再度検証する必要がある。また、先行研究によって行われた豚肉製品の分類に寄与する成分との比較を行い、それぞれの製品に対して分類を行う際の最適な化学成分定量値の特定が重要となる。加えて、ニューラルネットワークでは、学習に必要な既知となる水産食品のデータを増やすことで正判別率が高くなることが示唆されたことから、データの蓄積による学習結果向上の検討が必須である。

今後の展望として、深層学習等を加えた検討を実施し、さらに分類精度向上を試み、実験系においても応用可能であるか検討を進める。

上記結果を踏まえ、ニューラルネットワーク、判別分析による水産食品の分類・照合に向けた栄養成分の抽出が可能であることを確認できた。これは、食肉製品以外の食品でも応用可能であることを示す。これら検討をもとに、栄養成分を測定可能な化学センサや電気センサ等、また、機械学習を応用し、様々な食品の簡易分類評価に繋がる応用

研究を進める。

参考文献

1. 木村祐太, ほか. 食品成分データと判別分析による牛肉識別の検討. : 日本味と匂学会誌, Vol. 18, No. 2, 2011.
2. 合田元清, ほか. 無機成分の化学分析値とクラスター分析を用いた豚肉製品分類法に関する基礎的検討. 日本味と匂学会誌, Vol. 18, No. 3 : 日本味と匂学会論文誌, 2011.
3. 合田元清, ほか. 無機成分含有量と多変解析による豚肉製品の分類. : 日本味と匂学会誌, Vol. 19, No. 3, 2012.
4. 合田元清, 小島洋一郎. 物理化学分析と多次元データ解析による食品分類手法の検討. : 日本味と匂学会誌, Vol. 21, No. 3, 2014.
5. 中島広基, ほか. 栄養成分データとケモメトリクスを用いた食品の識別方法. : 日本味と匂学会誌, Vol. 20, No. 3, 2013.
6. 合田元清, 小島洋一郎. 計量化学的手法を用いた豚肉製品分類・照合可能性の検討. : 産業応用工学会論文誌, Vol. 6, No. 1, 2018.
7. 合田元清, 小島洋一郎, 岩波俊介. 化学成分値を用いた牛肉製品の分類・照合に向けた基礎的検討. : 産業応用工学会論文誌, Vol. 8, No. 1, 2020.
8. 内閣府. 『日本再興戦略』改訂 2015. (オンライン) 2018年5月. <https://www.kantei.go.jp/jp/singi/keizaisaisei/kettei.html#saikou2015>.
9. 田口博人. 対EU輸出水産食品の現状と課題. : 大日本水産会 品質管理部, 2013.
10. 文部科学省. 食品成分データベース. (オンライン) 2018年7月. <https://fooddb.mext.go.jp/>.
11. 鐵健司. 新板 品質管理のための統計的方法入門. : 日科技連, 2000, ページ: 182-192.
12. 廣野元久, 林俊克. JMPによる多変量データ活用術. : 海文堂出版, 2004, ページ: 76-78, 155-220.
13. 荒木雅弘. フリーソフトではじめる機械学習入門. : 森北出版, 2014.
14. McCulloch.S.W, Pitts.W. A logical calculus of the ideas immanent in neurons activity. : Bull.Math.Biophys.Vol. 5, 1943.
15. Zhang.Ling, Zhang.Bo. A geometrical representation of McCulloch-Pitts neural model and its applications. : IEEE transactions on neural networks.Vol.10, No. 4, 1999.
16. 合田元清, 小島洋一郎. 水産食品の化学成分値を用いた美味しさ決定要因特定に向けた基礎的検討. : 日本味と匂学会誌, Vol. 24, No. 3, 2018.
17. 合田元清, 小島洋一郎. ニューラルネットワークと判別分析による水産食品分類条件の検討. : 産業応用工学会論文誌, Vol. 7, No. 1, 2019.
18. JMP Ver. 11 多変量解析法. SAS社. 2014, ページ: 76-78.

19. Guidetti.R, Beghi.R, Giovezana.V. Chemometrics in food thchnology. :
Intechopen, 2011.

7章 結論と今後の課題

本論文の結論を整理し、今後の研究への課題を述べる。

はじめに本論文にて実施した各種検討の整理を行う。

第4章は、代表的な食肉製品である豚肉製品及び牛肉製品に対し多変量解析により分類を検討・評価した結果を整理・考察した。第4章では、豚肉製品、牛肉製品それぞれの化学成分データを文部科学省のデータベースから取得し検討を実施した。豚肉製品では、88種類の食品に対し無機成分13種類、ビタミン製品12種類の含有量を取得し、「製品種類」(赤肉、脂身つき、皮下脂肪なし、ひき肉、副生物、加工品、脂身)、「部位」(かた、かたロース、そともも、ばら、ひれ、もも、ロース、肝臓、豚足、内臓、軟骨、ゼラチン、ひき肉、加工品)に分類可能となる化学成分の特定を行なった。検討は、無機成分、ビタミン成分それぞれで実施し、最初に各項目の決定に影響を与えると考えられる化学成分を対象に各分類項目同士の群間分散と各分類項目間に属する食品間の郡内分散の比であるF値を算定する分散分析によって、影響度合いの順位付けを行った。その後、その順位に応じ化学成分を1つずつ選択し、都度、判別分析を実施、各分類項目へ正しく判別されているか正判別率を算定することで確認を行った。これより、化学成分を加えた際の正判別率の変化を確認し、分類に必要な化学成分の選択・評価した。豚肉製品の「製品種類」に対する結果は、無機成分で4成分、ビタミン成分で12成分の定量値を用いればそれぞれ76.1%、85.2%の正判別率を示し、高確率で分類できることが確認した。同様に「部位」に対する結果は、無機成分13種類全ての定量値を用いて72.7%、ビタミン成分は10成分を用いた65.9%が最も高い正判別率となり、「製品種類」と比較しても分類が難しいことが確認できた。牛肉製品への検討は無機成分、ビタミン成分と区別せずに検討を行い、「製品種類」「部位」「牛の種類」について分散分析後、判別分析による分類を検討、クラスター分析による分類傾向を確認した。加えて、豚肉製品では実施していない、測定誤差等を考慮したダミーデータを用いて検証した。結果は、「製品種類」では12成分で75.0%、「部位」は12成分で66.4%、「牛の種類」は15成分で69.2%との正判別率であった。豚肉製品と比較し、正判別率は低く、無機成分、ビタミン成分の定量値による分類は難しいことを評価した。その中で、「副生物」等の特定の製品には正確に分類可能と考察した。 [1][2]

第5章は、豚肉製品及び牛肉製品の化学成分値を用いた分類の可能性について、非線形回帰分析であるニューラルネットワークにて検討した。豚肉製品では、ICP-MS(誘導結合プラズマ質量分析)により定量される11の無機成分を対象に「製品種類」「部位」「調理法」への分類可能か検討した。また、第4章の牛肉製品に行った測定誤差を考慮したダミーデータを用い、ニューラルネットワークを実施した。計算条件は、中間層5、学習率0.01と固定し、

学習回数 0~90,000 回と変化させ実施した。結果、学習回数が増加するに従い、正判別率が向上した。学習回数 55,000 回の場合、製品種類の最高正判別率率は 89.4%であった。これより、学習回数を増加したとしても正判別率は変化せず定常状態であった。同様に、学習回数が多いほど、部位と調理法についても正判別率が向上することを確認した。学習回数が 75,000 回の時、部位の最大正判別率は 86.7%、調理法は 55,000 回の際に 92.8%であった。牛肉製品は、第 4 章の判別分析により絞り込んだ化学成分を用いて「製品種類」「部位」「牛の種類」について検討した。計算条件は、隠れ層 13、学習回数 100,000 回、学習率 0.01 と固定した。その結果、「製品種類」は正判別率：84.6%、「部位」：91.2%、「牛の種類」：93.9%となった。以上の結果より、非線形回帰分析の 1 つであるニューラルネットワークによる処理を行えば、豚肉製品、牛肉製品ともに化学成分による分類が高精度に行うことが可能であること示した。 [2] [3]

第 6 章は、第 4 章、5 章で検討対象とした食肉製品と異なる食品を対象に化学成分値と多変量解析、ニューラルネットワークを用いた分類の検討を目的に水産食品を対象とした検討を実施した。検討は無機成分を用い、「製品種類」(魚類、貝類、いか・たこ類、えび・かに類、水産練り製品、水性生物類)への分類可能性を検討した。手法は、13 種類の無機成分を分散分析により F 値の順位付けし、その後、順位に応じ判別分析によって正判別率を算定した。同様にニューラルネットワークにおいても順位に応じ無機成分を追加、計算条件である学習回数、中間層を変化させ、正判別率を算定した。これより、判別分析では、「製品種類」の特定に 6 成分の含有量を把握すれば 7 割程度の精度で特定できることが確認された。ニューラルネットワークは、無機成分 8 種類、中間層 9、学習回数 5,000 回で正判別率 80.4%という結果を示した。以上より、食肉製品以外においても判別分析とニューラルネットワーク、化学成分値を用いた分類は可能であることを確認できた。 [4]

以上結論より、各章における今後の課題を述べる。

第 4 章で述べた豚肉・牛肉製品では「製品種類」「部位」「牛の種類」を 4~15 の無機成分、ビタミン成分、脂質等、主要化学成分を定量することで 7~8 割の精度で分類が可能であることを示した。これは従来 of 物性的な品質管理手法とはことなり、化学成分の多寡で分類を目指す点で新規性のある結果となった。しかし、これら結果はダミーデータとして測定誤差を考慮しているものの、真の製品産地差、化学成分含有量の測定誤差を考慮していない。したがって、今後はこれらを考慮可能となるデータの取得、実験による測定検証が必要である。

第 5 章で述べた豚肉・牛肉製品の分類に関わるニューラルネットワークを用いた検討は、

豚肉製品に含まれる ICP-MS で測定可能な 11 の無機成分で「製品種類」「部位」「調理法」へ 8 割の精度にて分類が可能であることを示した。しかし、計算条件において学習回数は変化させているものの、隠れ層の数、学習率を固定しており、学習回数を増加させても 89.4% 以上の正判別率を算定することに至らなかった。したがって、今後は、これら計算条件を変化させ、更なる正判別率向上を検討する必要がある。牛肉製品は、計算条件を隠れ層 13、学習回数 100,000 回、学習率 0.01 と固定した。その結果、「製品種類」は正判別率：84.6%、「部位」：91.2%、「牛の種類」：93.9%となったが、その他計算条件について検証が不足しており、今後は学習回数、隠れ層、学習率を変化させることによる正判別率の向上を検討、最適な計算条件の探索が必要である。しかし、本論文の結果では、化学成分含有量を測定、単純なニューラルネットワークを用いる事による食肉製品分類法確立に優位になると評価した。

第 6 章は水産食品に対し、無機成分を測定することで「製品種類」に分類が可能であることを判別分析とニューラルネットワークはで示した。その中でもニューラルネットワークは有効な手法であり、上記の食肉製品以外の食品においても化学成分含有量測定による分類可能性を見出すことができた。しかしながら、食肉製品同様、魚類名や化学分析の測定現場における分析誤差を考慮していないため、今後は、産地や測定場所等の誤差を用いた分析を実施し、本報告の結果を再度検証する必要がある。加えて、ニューラルネットワークでは、学習に必要な既知となる水産食品のデータを増やすことで正判別率が高くなることが示唆されたことから、データの蓄積による学習結果向上の検討が必須である。

上記全体の食品に対する化学成分含有量による分類研究の展望として、それぞれの製品でミンチ・ペースト状に加工され偽装された場合を想定し、これら防止のため、製品毎の無機成分、ビタミン成分の含有量指標を設定し多種機器計測による化学成分測定により化学分析の側面から簡易識別法を確立することを目標とする。また 無機成分含有量、ビタミン成分含有量を定量する数多くの試薬技術 [5]をはじめとする化学センサ、物性等を測定可能な物理・電気センサが発達しているため、これらの利用を念頭においた簡易分類が可能となるプロセスを構築する一助になる。

参考文献

1. 合田元清 , 小島洋一郎. 計量化学的手法を用いた豚肉製品分類・照合可能性の検討. : 産業応用工学会, 2018.
2. 合田元清, 小島洋一郎 , 岩波俊介. 化学成分値を用いた牛肉製品の分類・照合に向けた基礎的検討. : 産業応用工学会論文誌, Vol.8, No.1, 2020.
3. Goda.Motoki , Kojima.Yohichiro. Possible classification of pork products by ICP-MS . : Journal of the Institute of Industrial Applications Engineers, 2020.
4. 合田元清 , 小島洋一郎. 水産食品の化学成分値を用いた美味しさ決定要因特定に向けた基礎的検討. : 日本味と匂学会誌, Vol.24, No.3, 2018.
5. Oka.Y, ほか. TrotonX-100 selective chemosensor based on β -cyclodextrin modified by anthracence derivative. : Talanta, 2010.

謝辞

本論文は、著者が平成 23 年に国立苫小牧工業高等専門学校専攻科 環境システム工学専攻に入学してから、北海道大学大学院環境科学院 環境物質科学専攻修士課程、北日本港湾コンサルタント株式会社、北海道科学大学附属研究所 寒地未来生活環境研究所 学外研究員として行なった研究結果を整理したものです。

本研究において苫小牧工業高等専門学校専攻科より今日まで終始暖かい激励と御指導御鞭撻を賜りました北海道科学大学 工学部 電気電子工学科 学科長 教授 小島洋一郎博士には、心より感謝の意を表します。言葉には表現できぬ程の多大な御尽力、愛情をかけて育てて頂きました。もう 10 年のお付き合いになります。これからもよろしくお願い致します。

本論文をご多忙の中、審査を御快諾頂きました北海道科学大学 工学部長及び工学研究科長 機械工学科 教授 竹澤聡博士、工学部 電気電子工学科 教授 三橋龍一博士、工学部 機械工学科 教授 堀内寿晃博士には、大変お世話になりました。ありがとうございます。

本論文の基礎となる様々な研究論文及び発表について、共同研究者として御指導頂きました、苫小牧工業高等専門学校 物質工学科 教授 岩波俊介博士、同情報工学科 教授 三上剛博士においても深謝致します。

また、博士論文として整理するため、北海道科学大学附属研究所 寒地未来生活環境研究所学外研究員として快く送り出して頂きました、北日本港湾コンサルタント株式会社 第 1 技術部次長 石川浩希技術士をはじめ、代表取締役社長 上原泰正技術士、専務取締役 当間功一技術士、常務取締役 岸哲也技術士、取締役兼第 1 技術部長 西浩吾樹技術士、参事 多田英彦技術士には、社業との両立を認めて貰い、研究発表の社内的意義にも御理解頂きました。両立の際には、私の社業における師匠に当たります第 1 技術部計画チーム 山本浩技師や終始サポートをして頂いた、市川(旧姓 岡井)利沙 2 級建築士(現:ケイアイスター不動産株式会社)、調整に御理解頂いた第 2 技術部計画チームサブリーダー 石黒一郎技術士、第 1 技術部計画チーム 松下圭吾技術士、楊彩嘉技師、白鳥夏生技師には大変お世話になりました。ありがとうございます。加えて、博士論文研究に情報及び統計学的知見を頂きました調査解析部解析チーム主任 野村明弘技師にも御礼を申し上げます。

長い研究生活を思い返すと、筆者が国立旭川工業高等専門学校物質化学工学科在学中、挫折を経験した際に当時の指導教員でありました、物質化学工学科 准教授 杉本敬祐博士、同期の中野源紀氏(現:フリーランス、投資事業家)には立ち直る機会を与えて頂き

ました。現在の私が存在するのはお二人のおかげです。月並みな言葉になりますがありがとうございます。その後、苫小牧工業高等専門学校専攻科進学後は、研究室配属当初から同期である三宅悠氏、本学専攻科 電子・生産システム工学専攻卒業生である、むかわ町役場総務企画課の木村祐太主事には多くの手法をご指導いただきました。この教えが今も研究に繋がっております。

北海道大学大学院環境科学院 環境物質科学専攻修士課程に進学後は、大気化学研究を専攻し、海洋境界面の不均一反応について研究を行いました。これまでやってきた分野とは全くの畑違いではございますが、そんな私に根気よく御指導してくださいました北海道大学大学院地球環境科学研究院 物質機能科学部門 准教授 廣川淳博士、京都大学大学院 地球環境学堂・地球環境学舎・三才学林 助教 坂本陽介博士には、研究者としての心得を一から学びました。この教えは進む分野が異なるとしても一生の糧と考えております。また、在学中も本研究を並行して取り組ませて頂いたことは大変感謝しております。今後も工学者、技術者としての人生が続く限り御指導を頂ければ幸いです。

博士論文を纏めるにあたり、私生活の面で根気よく支えて頂きました菅ひとみ氏、本当に感謝しております。

北海道大学大学院修了までの長きに渡る学生生活を支えて頂きました旭川の両親、祖父母、兄弟には大変お世話になりました。気が付いたら、博士号取得に向けた目標と一緒に追いかけていたように感じます。ここで一区切りになることをお伝え致します。また、本論文を志し半ば 26 歳で急逝した愚弟に捧げます。

最後に、博士論文の取り纏め及び研究生生活を続けるにあたり、御支援、御協力を賜りながら、ここに御名前を記していない、多くの方々に心より感謝を申し上げます。

本研究の遂行に当たり、北海道科学大学寒地未来生活環境研究所、北日本港湾コンサルタント株式会社、高専機構苫小牧工業高等専門学校地域共同研究センターによる支援を受けました。

また、研究費の一部は、科学研究費補助金(基盤研究(C)22500194,15K00806,18K02210)の助成により行われたことを記し、ここに深く感謝の意を表します。

北日本港湾コンサルタント株式会社 第1技術部
北海道科学大学附属研究所 寒地未来生活環境研究所
合田 元清

関連研究業績及びその他の研究業績

1 本論文の関連研究業績

1.1 査読付き学術論文(国内)

1. 合田 元清, 小島 洋一郎, 岩波 俊介, 化学成分値を用いた牛肉製品の分類・照合に向けた基礎的検討, 産業応用工学会 vol. 8, No. 1, pp53-57 (2020)
2. 合田 元清, 小島 洋一郎, ニューラルネットワークと判別分析による水産食品分類条件の検討, 産業応用工学会 vol. 7, No. 1, pp25-31 (2019)
3. 合田 元清, 小島 洋一郎, 計量化学的手法を用いた豚肉製品分類・照合可能性の検討, 産業応用工学会 vol. 6, No. 1, pp33-43 (2018)

1.2 査読付き学術論文(国際)

1. Motoki Goda, Yohichiro Kojima, Possible classification of pork products by ICP-MS, Journal of the Institute of Industrial Applications Engineers vol. 8, No. 1, pp53-57 (2020)

1.3 査読なし学術論文(国内)

1. 合田 元清, 小島 洋一郎, 水産食品の化学成分値を用いた美味しさ決定要因特定に向けた基礎的検討, 第 51 回日本味と匂学会年次会 Proceeding (2017)

1.4 学会発表(国内)

1. 合田 元清, 小島 洋一郎, 岩波 俊介, 化学成分値と多変量解析を用いた牛肉製品分類の基礎的検討, 日本食品工学会第 20 回年次大会, 2019. 8
2. 合田 元清, 小島 洋一郎, 情報工学的手法を用いた化学成分による食肉製品簡易分類の検討, 農業環境工学関連 5 学会 2018 年合同大会, 2018. 9
3. 合田 元清, 小島 洋一郎, 無機成分含有量で水産食品の分類は可能か? ~ニューラルネットワークによる検討~, 日本食品工学会第 19 回年次大会, 2018. 8
4. 合田 元清, 小島 洋一郎, 食肉製品分類に寄与するアミノ酸含有量の探索, 日本食品工学会第 18 回年次大会, 2017. 8

2 その他の研究業績

2.1 査読付き学術論文(国内)

1. 合田 元清, 小島 洋一郎, 三上 剛, 岩波 俊介, 味覚認識装置と官能検査によるデータを活用した果汁飲料製品の評価, 日本味と匂学会誌 vol. 22, No. 3, pp397-400 (2015)
2. 小島 洋一郎, 渡邊 駿, 三上剛, 岩波俊介, 合田 元清, 異種センサとデータ分析の融合による風味調味料の分類評価, 日本味と匂学会誌 vol. 22, No. 3, pp401-404 (2015)
3. 合田 元清, 小島 洋一郎, 物理化学分析と多次元データ解析による食品分類手法の検討, 日本味と匂学会誌 vol. 21, No. 3, pp399-402 (2014)
4. 小島 洋一郎, 合田 元清, 多糖類の簡易分析機器による果実飲料の分類に向けた検討, 日本味と匂学会誌 vol. 21, No. 3, pp407-410 (2014)
5. 中島 広基, 合田 元清, 小島 洋一郎, 三上 剛, 岩波 俊介, 栄養成分データとケモメトリクスを用いた食品の識別方法, 日本味と匂学会誌 vol. 20, No. 3, pp347-350 (2013)
6. 合田 元清, 小島 洋一郎, 三上 剛, 宇津野 国治, 岩波 俊介, 無機成分含有量と多変量解析による豚肉製品の分類, 日本味と匂学会誌 vol. 19, No. 3, pp417-420 (2012)
7. 合田 元清, 小島 洋一郎, 三上 剛, 宇津野 国治, 無機物の化学分析値とクラスター分析を用いた豚肉製品分類法に関する基礎的検討, 日本味と匂学会誌 vol. 18, No. 3, pp447-450 (2011)

2.2 査読付き学術論文(国際)

1. Yosuke Sakamoto, Motoki Goda, Jun Hirokawa, Kinetics Study of Heterogeneous Bromine Release from the Reaction between Gaseous Ozone and Aqueous Bromide Solution, The Journal of Physical Chemistry A vol.122, No.12, pp2723-2731 (2018)

2.3 学会発表(国内)

1. 三浦 公平, 合田 元清, 小島 洋一郎, 岩波 俊介, 赤紫系果実の退色抑制を考慮した発酵条件の検討, 日本食品工学会第 20 回年次大会, 2019. 8
2. 合田 元清, 小島 洋一郎, 情報工学的手法を用いた化学成分による食肉製品簡易分類の検討, 農業環境工学関連 5 学会 2018 年合同大会, 2018. 9
3. 小島 洋一郎, 合田 元清, 色情報による菓子の簡易品質評価に向けた検討, 農業環境工学関連 5 学会 2018 年合同大会, 2018. 9
4. 小島 洋一郎, 合田 元清, 小島 伊織, 小島 汐織, 三上 剛, 岩波 俊介, 渡部 知希, 色画像データによる食品の簡易品種評価, 日本食品工学会第 19 回年次大会, 2018. 8
5. 合田 元清, 小島 洋一郎, 情報工学的手法を用いた化学成分による食肉製品簡易分類の検討, 農業環境工学関連 5 学会 2018 年合同大会, 2018. 9
6. 小島 洋一郎, 合田 元清, 色情報による菓子の簡易品質評価に向けた検討, 農業環境工学関連 5 学会 2018 年合同大会, 2018. 9
7. 合田 元清, 安部 智香, 小島 洋一郎 岩波 俊介, 味覚認識装置を用いた果汁飲料製品分類手法の検討, 日本食品工学会 16 年次大会, 2015. 8
8. 小島 洋一郎, 岩波 俊介, 藤本 周, 合田 元清, 紅茶飲料の簡易機器分析とデータ解析による評価・分類, 日本食品工学会 16 年次大会, 2015. 8 (受賞有)
9. 合田 元清, 坂本 陽介, 廣川 淳, オゾン-臭素イオンの気相-液相不均一反応による臭素分子生成(2), 第 20 回大気化学討論会, 2014. 10
10. 小島 洋一郎, 安部 智香, 合田 元清, 岩波 俊介, 味覚認識装置と分析機器による果実飲料の分類, 日本食品工学会 15 年次大会, 2014. 8
11. 小島 洋一郎, 藤本 周, 合田 元清, 岩波 俊介, 紅茶の機器分析データと情報処理手法による評価と分類, 日本食品工学会 15 年次大会, 2014. 8
12. 合田 元清, 坂本 陽介, 廣川 淳, オゾン-臭素イオンの気相-液相不均一反応による臭素分子生成, 第 19 回大気化学討論会, 2013. 11

13. 小島 洋一郎, 合田 元清, 豚肉製品に含まれる無機成分データと感性データ解析による分類の検討, 第 15 回日本感性工学大会, 2013. 9
14. 小島 洋一郎, 合田 元清, 岩波 俊介, 三上 剛, 宇津野 国治, 食品の化学成分値とデータ解析による食品分類に向けた基礎的検討, 日本食品工学会 14 年次大会, 2013. 8
15. 小島 洋一郎, 合田 元清, 岩波 俊介, 三上 剛, 宇津野 国治, 食品の化学成分値とデータ解析による食品分類に向けた基礎的検討, 日本食品工学会 14 年次大会, 2013. 8
16. 合田 元清, 小島 洋一郎, 三上 剛, 宇津野 国治, 岩波 俊介, 山口 和美, 川上 光博, 木村 裕太, 無機成分含有量によるクラスター分析を用いた牛肉・豚肉製品分類法の基礎的研究, 第 14 回日本感性工学大会, 2012. 8
17. 合田 元清, 小島 洋一郎, 三上 剛, 宇津野 国治, 岩波 俊介, 山口 和美, 川上 光博, 無機成分含有量を利用した多変量解析による豚肉製品分類法の検討, 日本食品工学会 13 年次大会, 2012. 8
18. 合田 元清, 小島 洋一郎, 原子吸光分析装置と多変量解析を用いた豚肉製品分類の検討, 日本農芸化学会 2012 年度全国大会, 2012. 3
19. 合田 元清, 小島 洋一郎, 三上 剛, 宇津野 国治, 土居 茂雄, 山口 和美, 川上 博, ミネラル成分値による多変量解析を用いた豚肉分類法の検討, 第 13 回日本感性工学大会, 2011. 9

2.4 学会発表(国際)

- 1 . GODA Motoki, KOJIMA Yohichiro, Classification evaluation of tea-based beverages using image sensor , 18th Asian Pacific Confederation of Chemical Engineering Congress (APCChE 2019), 2019. 9
- 2 . GODA Motoki, KOJIMA Yohichiro, Evaluation of drinks by taste sensor, The 26th International Congress on Nutrition and Integrative Medicine. (Prospective New Technologies developed in Hokkaido) , 2018. 7
- 3 . SAKAMOTO Yosike , GODA Motoki, HIROKAWA Jun, A kinetics study of the gaseous bromine release via the heterogeneous reaction between gaseous ozone and aqueous bromide solution, 31st Symposium on Chemical Kinetics and Dynamics, 2015. 6
- 4 . SAKAMOTO Yosike , GODA Motoki, HIROKAWA Jun, Kinetic study of bromine release from heterogeneous reactions of gaseous ozone with aqueous bromine solution, 13th iCACGP/IGAC, 2014. 9