

## インピーダンスによる食品の識別と混合比の推定 Recognition and Blend Ratio Estimation of Foods Based on their Impedance

佐藤仁樹

Hideki Satoh

公立はこだて未来大学

Future University Hakodate

### 1. まえがき

クロマトグラフィー，分光光度計，味覚センサ等の測定機器の発達により，食品の品質管理や評価を客観的な基準に基づいて実施できるようになった。しかし，これらの機器を利用するためには高い代価（機器本体やセンサの購入，試料の液状化や色抜き等の前処理，専門の技術の習得）が必要となる。

一方，食品のインピーダンスにより食品の特性を調べる方法[1]には，特別な技術や前処理はほとんど必要なく，測定機器（LCRメータ）も安価である。しかし，測定されたインピーダンスと食品の特性との関係が必ずしも明確でないため，食品の品質管理や評価にはほとんど利用されていない。

そこで，インピーダンスと食品の特性（銘柄および混合比）の関係を解析し[2]，LCRメータが食品の品質管理や評価に利用できることを示す。

### 2. インピーダンス測定

白金メッキのチタン製の電極2本（直径2mm，長さ20mm，電極間距離7mm）をセンサとして，試料 $\omega_1, \dots, \omega_K$ のインピーダンスを同一試料に対して日時を変えて $M$ 回測定する。試料 $\omega_k (1 \leq k \leq K)$ の $m$ 回目の測定結果から得られた周波数 $f_i$  [Hz] ( $1 \leq i \leq N_f$ )のコンダクタンス $G_i(k, m)$ およびサセプタンス $B_i(k, m)$ を以下の手順で編集し，データベクトル $\tilde{\mathbf{u}}(k, m)$ を設定する。

#### (1) 正規化

$$\tilde{G}_i(k, m) \equiv G_i(k, m) / \sigma [G_i(k, m)] \quad (1)$$

$$\tilde{B}_i(k, m) \equiv B_i(k, m) / \sigma [B_i(k, m)] \quad (2)$$

#### (2) データベクトルの設定

$$\tilde{\mathbf{u}}(k, m) \equiv (\tilde{G}_1(k, m), \dots, \tilde{G}_{N_f}(k, m), \tilde{B}_1(k, m), \dots, \tilde{B}_{N_f}(k, m))^T \quad (3)$$

ここで， $\sigma[\cdot]$ は $m$ に関する標準偏差， $T$ は転置である。また， $f_1=10\text{Hz}$ ， $f_{N_f}=5\text{MHz}$ ， $N_f=80$ とした。

### 3. 解析

#### 3.1. 清酒の銘柄の識別

清酒の銘柄をクラスとして，試料のインピーダン

スから試料が属するクラスを判定する。

#### (1) 学習データと評価データ

64銘柄の清酒（アル添，純米，普通，吟醸，大吟醸，古酒，生酛，山廃，速醸を含む）の測定データ ( $K=64$ ， $M=5$ ) を，学習データ $\mathbf{D}_{\text{uL}} \equiv \{\tilde{\mathbf{u}}(k, m) \mid \forall k, m=1, 2, 3, 4\}$ と評価データ $\mathbf{D}_{\text{uE}} \equiv \{\tilde{\mathbf{u}}(k, m) \mid \forall k, m=5\}$ に分割する。

#### (2) 正準判別分析による次元圧縮

正準判別分析[3]はデータを低次元空間に射影する際に，クラス内の標本点の分布ができるだけ重ならないように射影行列を構築する手法である。そのため全標本の分散が最大となるように射影行列を構築する主成分分析と比べて，低次元空間に射影してもクラス構造を保存しやすいという特徴ある。

そこで，正準判別分析により $2N_f$ 次元のデータベクトル $\tilde{\mathbf{u}}(k, m)$ を $N_x$ 次元のベクトル $\tilde{\mathbf{x}}(k, m)$ に圧縮する ( $N_x < 2N_f$ )。  $\tilde{\mathbf{u}}(k, m)$ を $\tilde{\mathbf{x}}(k, m)$ に圧縮するための射影行列の計算には $\mathbf{D}_{\text{uL}}$ を用いた。また， $\tilde{\mathbf{u}}(k, m)$ の次元 $2N_f$ に対してデータ数が少ないため射影行列の計算の際に必要な逆行列の計算が不安定になる。この問題を回避するために，各クラス毎に標本点をランダムに追加した。

#### (3) 多群線形判別による識別

$\tilde{\mathbf{x}}(k, m)$ を説明変数，学習データを $\mathbf{D}_{\text{xL}} \equiv \{\tilde{\mathbf{x}}(k, m) \mid \forall k, m=1, 2, 3, 4\}$ ，評価データを $\mathbf{D}_{\text{xE}} \equiv \{\tilde{\mathbf{x}}(k, m) \mid \forall k, m=5\}$ として， $\tilde{\mathbf{x}}(k, m)$ の共分散行列に基づくマハラノビス距離を用いて，多群線形判別（各クラスの説明変数の平均と試料の説明変数の距離が最小となるクラスに判別する）により試料が属するクラスを判定する[3]。ここで，共分散行列および各クラスの説明変数の平均の計算には $\mathbf{D}_{\text{xL}}$ を用いた。その結果を表1に示す。

表1 清酒の銘柄の識別誤り率[%]

$N_x$	2	4	8
学習データ	9.6	1.6	0.0
評価データ	38.8	16.4	14.9

学習データのデータ数が少ないため評価データの識別誤り率が学習データのそれと比較して大きい、少ないデータ数で単純な多群線形判別を用いていることを考慮すれば十分な精度である。測定回数を増やし非線形の識別手法を用いることにより、精度の改善が可能である。

### 3.2. コーヒーの混合比の推定

3種類のコーヒー（イルガチエフェ、コロンビアスプレモ、レッドマウンテン）を混合して試料を作成し、試料のインピーダンスから試料に含まれる3種類のコーヒーの混合比  $(r_1, r_2, r_3)$  を推定する。ここで、 $k$ 番目の試料のコーヒーの混合比を  $r_j(k)$  ( $0 \leq r_j(k) \leq 1 \mid j=1, 2, 3$ ),  $r_1(k) + r_2(k) + r_3(k) = 1$ , 混合比ベクトルを  $\mathbf{r}(k) \equiv (r_1(k), r_2(k), r_3(k))^T$  とする。

#### (1) 学習データと評価データ

データベクトル  $\tilde{\mathbf{u}}(k, m)$  の  $m$ に関する平均値ベクトル  $\bar{\mathbf{u}}(k) \equiv E[\tilde{\mathbf{u}}(k, m)]$  および混合比ベクトル  $\mathbf{r}(k)$  を、学習データ  $\mathbf{D}_{uL} \equiv \{\mathbf{r}(k), \bar{\mathbf{u}}(k) \mid 1 \leq k \leq 10\}$  と評価データ  $\mathbf{D}_{uE} \equiv \{\mathbf{r}(k), \bar{\mathbf{u}}(k) \mid 11 \leq k \leq 19\}$  に分割する。ここで、 $K=19, M=3$  (学習データ),  $M=2$  (評価データ) である。各々の試料の混合比ベクトル  $\mathbf{r}(k)$  を図1に示す。ここで、 $r_1(k) + r_2(k) + r_3(k) = 1$ なる制約のため、 $\mathbf{r}(k)$ は、 $r_1, r_2, r_3$ を座標軸とする3次元空間の平面上に分布する。学習データを●、評価データを○で図示した。図中の●および○の右横の番号が試料  $\omega_k$ の番号  $k$ を表す。例えば、 $\mathbf{r}(1) = (1, 0, 0)^T$ ,  $\mathbf{r}(2) = (0, 1, 0)^T$ ,  $\mathbf{r}(3) = (0, 0, 1)^T$ ,  $\mathbf{r}(4) = (0.5, 0.5, 0)^T$  である。




図1 混合比ベクトル  $\mathbf{r}(k)$

#### (2) 正準判別分析による次元圧縮

3.1節と同様に、正準判別分析により  $2N_f$ 次元のデータベクトル  $\bar{\mathbf{u}}(k)$  を  $N_x$ 次元のベクトル  $\bar{\mathbf{x}}(k)$  に圧縮する ( $N_x=8$ )。

#### (3) 混合比の重回帰分析

混合比  $\mathbf{r}(k)$  を目的変数、 $\bar{\mathbf{x}}(k)$  を説明変数として、

重回帰分析[3]により説明変数から目的変数を推定する。重回帰モデルの係数行列の計算には、学習データ  $\mathbf{D}_{XL} \equiv \{\mathbf{r}(k), \bar{\mathbf{x}}(k) \mid 1 \leq k \leq 10\}$  を用いた。

学習データと評価データ  $\mathbf{D}_{XE} \equiv \{\mathbf{r}(k), \bar{\mathbf{x}}(k) \mid 11 \leq k \leq 19\}$  の混合比の平均推定誤差(目的変数の推定値の平均二乗誤差の平方根)を表2に示す。

表2 コーヒーの混合比の平均推定誤差

	$r_1$	$r_2$	$r_3$
学習データ	0.029	0.109	0.088
評価データ	0.067	0.142	0.116

表2より平均推定誤差は1割程度であり、コーヒーの混合比を重回帰分析で推定できることが分かる。

### 3.3. ジュースの混合比の推定

3種類のジュース（アップルジュース、オレンジジュース、トマトジュース）の混合比を3.2節と同様な手法により推定した。その結果を表3に示す。

表3 ジュースの混合比の平均推定誤差

	$r_1$	$r_2$	$r_3$
学習データ	0.014	0.024	0.044
評価データ	0.057	0.067	0.014

表3より平均推定誤差は1割以下であり、ジュースの混合比を重回帰分析で推定できることが分かる。

## 4. まとめ

インピーダンスにより、清酒の銘柄を識別できることを示した。また、コーヒーの混合比およびジュースの混合比を重回帰分析により推定できることを示した。これにより、LCRメータが食品の品質管理や評価に利用できることが分かった。

## 謝辞

データの測定に尽力してくれた、本学卒業生の落合航平氏、金澤朋也氏、および染川眞輝氏に感謝します。

## 参考文献

- [1] 加藤宏郎, 坂口守彦, 大井康之, 丸尾信, 豊田薫, "インピーダンス特性による魚肉の鮮度判定 (第1報)," 農業機械学会誌, Vol. 62, No. 3, pp. 76-83 (2000).
- [2] 佐藤仁樹, "インピーダンスによる食品の識別と味覚表現," 平成31年電気学会大会論文集, vol. 3-200, pp. 281 (2019).
- [3] 小西貞則, 多変量解析入門, 岩波書店 (2010).