原著論文

ネットワークインバージョンを用いた ユーザの感性情報に適合するカクテル創出法

奥谷 勝行*, 塩谷 浩之**, 工藤 康生**, 沖井 廣宣**

* 室蘭工業大学大学院 工学研究科 情報工学専攻, ** 室蘭工業大学 しくみ情報系領域

Method for Creating a Suitable Cocktail based on User's Kansei Information by Network Inversion

Katsuyuki OKUYA*, Hiroyuki SHIOYA**, Yasuo KUDO** and Hironori OKII**

* Graduate school of Computer Science and Systems Engineering, Muroran Institute of Technology,
27-1 Mizumoto Muroran, Hokkaido, 050-8585, Japan.

** College of Information and Systems, Muroran Institute of Technology,
27-1 Mizumoto Muroran, Hokkaido, 050-8585, Japan.

Abstract : Data mining has been used for obtaining a typical structure of given data set in the field of information science, systems engineering and so on. In this paper, the cocktail-data quantification using the distance mapping learning network architecture is introduced as a kind of data mining for Kansei engineering. And moreover, the network inversion method is newly introduced into the cocktail-data quantification in order to obtain a suitable cocktail based on given user's Kansei information. A simple numerical example is presented with the usage of some typical cocktails and their questionnaire.

Keywords : Cocktail data, Distance mapping learning network, Network inversion.

1. は じ め に

データマイニングは対象の特性を知るための有効な手法とされる。一般的には、対象からのデータは常に定量的に表されるとは限らず、感性情報としてのデータは定性的に表されることが多い。定性的データの解析方法として、一般的な統計による分析にのみならず、ニューラルネットワークやファジィ理論を利用した感性情報分析など感性データ解析手法の研究が進められている [1]。感性工学においては、人が製品などに対して懐く感性情報を解析し、ユーザの感性に合う製品とはどのようなものかを解析することは、ユーザフレンドリな商品開発において重要である。

本研究においては、感性データとしてカクテルを対象とし、定性的特性から感性的違いが与えられる状況を想定し、様々な素材から作られる多様なカクテルの分類問題に、距離写像学習ネットワーク (Distance Mapping Learning Network : 以降DMLN) [2] による数量化の枠組みを応用する。データの数量化のみを目的とする場合は、例えば数量化第4類を適用することでデータの分類や空間配置を行うことができる。さらに、ニューラルネットの汎化能力によって、未学習データの出力予測ができる。このような情報処理を行えるアーキテクチャとして、ニューラルネット以外に求めることは難しい。

このDMLNの枠組みについて、数量化などのデータ配置に関する結果は、文献 [2] において既に得られている。配置問題については、入力から出力への対応の解析的处理であ

り、汎化性は別として、配置だけを求めるものであれば、他手法でも可能である。しかしながら、そのような結果解析だけではなく、感性的な表現空間において指定されるユーザの懐く対象をどのように求めるかが、感性情報処理を元にした商品化開発などにおいて重要となる。

本研究においてはDMLNに逆問題を導入する。まず、学習を通じて得られたDMLNを利用し、出力空間上に任意に指定された特徴点に対応する入力 (カクテル組成) を推定する、すなわち、感性的表現空間からのカクテル推定方式を新たに提案する。具体的には、ネットワークインバージョン (文献 [4, 5]) として、入力の定義域に制限がある場合にも対応可能なアルゴリズムを、距離写像学習ネットワークの学習法として新たに導入し、感性情報を表す出力空間の点に対応する入力推定を実現し、DMLNの出力空間上で指定された感性情報に対応する新たなカクテルの創出例を示す。

2. 感性的違いによる距離的情報分析

2.1 基 本 設 定

人が感じる感性的印象によってデータの類別をすることは、感性情報処理のひとつと考えられる。ここで、感性的違いに起因する感性情報を距離によって情報分析する枠組みについて、一般的な数理表現により整理する。

まず、感性情報の対象となる製品などを定義する空間を X とする。すなわち、 X を製品の物理的情報を表す定義域とみなし、その1点がある製品に相当する。 X の2点に対し、感

性情報として製品2点の違いが与えられているとする。それに基づいて感性的空間配置を行うことで、感性的な特徴分類などが得られる。 X の2つの要素と感性的な関連性を示す非負の実数 $\mathbb{R}^+ \cup \{0\}$ の2つの要素と感性的な関連性を示す非負の実数との対応を関数として以下のように表記する。

$$F: X \times X \rightarrow \mathbb{R}^+ \cup \{0\}. \quad (1)$$

サンプルの製品に対して、2つの製品の感性的な違いがアンケートなどでデータが得られているとする。これを感性的な教師データとして用いることを想定する。具体的には、 n 個のサンプル集合を $S_n = \{S_1, \dots, S_n\} (\subset X)$ とし、その直積集合 $S_n \times S_n$ と非負の実数の集合 $\mathbb{R}^+ \cup \{0\}$ との対応関係が得られているものとする。インデックス $I = \{1, \dots, n\}$ を用い、2つのサンプルとそれらの感性的関連性の値の組を以下のように表す。

$$D_n = \left\{ (s_i, s_j | r_{ij}) \mid i, j \in I, i < j \right\}. \quad (2)$$

ただし、関連性の数値については対称とする。すなわち $r_{ij} = r_{ji}$ とする。

D_n に基づいて、データ $\{S_1, \dots, S_n\}$ を感性的特徴空間として用意した k 次元の実数空間 $\mathbb{R}^k$ に配置する。次元数については、その空間の利用法に依存する。文献[1]においては、例題として与えられた色の集合の中で、2つの色の違いをアンケートによって与え、複数回答から平均値を求め、それを2つのサンプルの感性的違いとしてデータを構成している。この場合、サンプル間の感性的な違いを距離値として正の実数値を与えることに相当する。データの直積空間から非負の実数への写像 F に対する定義域 S_n への制限写像を、以下のように表わす。

$$F_n: S_n \times S_n \rightarrow \mathbb{R}^+ \cup \{0\}. \quad (3)$$

つまり、この関数は、2サンプルの感性的特徴空間における距離を与える。感性的特徴空間上に、 S_n の要素を F_n に従って配置するには、定義域から感性的特徴空間への以下の(非線形)写像 M を用いる。

$$M: X \rightarrow \mathbb{R}^k \quad (4)$$

これに対し、特徴空間における2サンプルに対応する点の間のユークリッド距離 d について、以下を満たしていることが要求される。

$$d(M(s_i), M(s_j)) = r_{ij}. \quad (5)$$

定義域の離散点の入力と出力の組、すなわち教師データによって非線形写像を近似により構成するには、階層型ニューラルネットワークがよく用いられる。出力間の距離の関係を満たす非線形写像を構成するために、次の節において、文献[2]に従い距離写像学習ネットワークを導入する。

2.2 感性的空間配置のための非線形写像と学習

前節にて導入した写像 M を、教師データ D_n から構成するため、文献[1]に従ってDMLNを導入する。DMLNとは、2つのサンプル間の出力空間において与えられている距離を満

たすような配置を実現するニューラルネットワークである。

あらかじめデータ集合 S_n の2要素間の距離が与えられている。その空間的な配置付けを行うために、3層ニューラルネットワークを2つ用意する。2つのニューラルネットは同じ重みを持つものとする。便宜的に一方を NN_1 、もう一方を NN_2 と名づけることにする。ニューラルネットワークへの入力 $\mathbf{x}$ 、重みパラメータベクトルを $\mathbf{w}$ とすると、ニューラルネットワークの出力を $\mathbf{f}_w(\mathbf{x})$ とする。出力次元を K として、出力 $\mathbf{f}_w(\mathbf{x})$ は、 j 番目の出力素子の出力 $f_w^j(\mathbf{x})$ を用いて以下のようにベクトル表示される。

$$\mathbf{f}_w(\mathbf{x}) = \{f_w^1(\mathbf{x}), \dots, f_w^K(\mathbf{x})\}. \quad (6)$$

2つの入力点 A, B を階層型ニューラルネットワーク NN_1 および NN_2 に入力する。 A, B の入力ベクトルをそれぞれ $\mathbf{x}_A, \mathbf{x}_B$ とすると、出力はそれぞれ $\mathbf{f}_w(\mathbf{x}_A)$ および $\mathbf{f}_w(\mathbf{x}_B)$ となる。よって、出力間のユークリッド距離は以下のように与えられる。

$$d(\mathbf{f}_w(\mathbf{x}_A), \mathbf{f}_w(\mathbf{x}_B)) = \left\{ \sum_{k=1}^K \left(f_w^k(\mathbf{x}_A) - f_w^k(\mathbf{x}_B) \right)^2 \right\}^{\frac{1}{2}}. \quad (7)$$

教師データとして与えられている入力点 A, B の出力空間における距離を $T(A, B)$ とする。 S_n の異なる2点の組合せの全体集合を X とする。 A, B を入力としたときの、それぞれのネットワーク出力間の距離 $d(\mathbf{f}_w(\mathbf{x}_A), \mathbf{f}_w(\mathbf{x}_B))$ と教師データ $T(A, B)$ との2乗誤差は、以下のように与えられる。

$$E_{\text{DMLN}}(\mathbf{w}) = \frac{1}{|X|} \sum_{(A, B) \in X} \left(d(\mathbf{f}_w(\mathbf{x}_A), \mathbf{f}_w(\mathbf{x}_B)) - T(A, B) \right)^2. \quad (8)$$

ただし $|X|$ を集合 X の要素数とする。誤差関数が最小になる重みを推定することが、DMLNの学習の目標となる。更新前後の重みパラメータベクトルをそれぞれ $\mathbf{w}^{\text{old}}, \mathbf{w}^{\text{new}}$ とすると、更新規則は次のように表される。

$$\mathbf{w}^{\text{new}} = \mathbf{w}^{\text{old}} - \varepsilon \frac{\partial E_{\text{DMLN}}(\mathbf{w}^{\text{old}})}{\partial \mathbf{w}^{\text{old}}}. \quad (9)$$

ただし、 ε は学習係数である。 i 番目の入力素子から j 番目の隠れ素子への結合重みを w_{ij} 、 j 番目の隠れ素子から k 番目の出力素子への結合重みを v_{jk} とすると、具体的な更新式は以下のように表される。

$$\begin{aligned} w_{ij}^{\text{new}} = & w_{ij}^{\text{old}} + \frac{\varepsilon}{|X|} \sum_{(A, B) \in X} \sum_{k=1}^K \frac{1}{d(\mathbf{f}_w(\mathbf{x}_A), \mathbf{f}_w(\mathbf{x}_B))} \cdot \\ & (T(A, B) - d(\mathbf{f}_w(\mathbf{x}_A), \mathbf{f}_w(\mathbf{x}_B))) \cdot \\ & (z_{k'}^A - z_{k'}^B) \left\{ z_{k'}^A (1 - z_{k'}^A) v_{jk'} y_j (1 - y_j) x_i^A - \right. \\ & \left. z_{k'}^B (1 - z_{k'}^B) v_{jk'} y_j (1 - y_j) x_i^B \right\}, \end{aligned} \quad (10)$$

$$v_{jk}^{\text{new}} = v_{jk}^{\text{old}} + \frac{\varepsilon}{|X|} \sum_{(A,B) \in X} \sum_{k'=1}^K \frac{1}{d(f_w(x_A), f_w(x_B))} \cdot (T(A,B) - d(f_w(x_A), f_w(x_B))) \cdot (z_{k'}^A - z_{k'}^B) \left\{ z_{k'}^A (1 - z_{k'}^A) y_j - z_{k'}^B (1 - z_{k'}^B) y_j \right\}. \quad (11)$$

ただし、各出力 z_k^A および z_k^B は、入力 x に対し、 w_{ij}^{old} および v_{jk}^{old} をパラメータとする。

文献 [2] においては、学習の効率を向上させるために、慣性項が加えられた学習方式を採用しているが、本研究では通常の誤差最小化アルゴリズムを利用している。各点間の距離を満たす限り点の配置は自由であるので、誤差がゼロであっても、配置された点全体の回転・反転・平行移動により出力空間の配置は複数存在する。学習で得られた（非線形）写像 M_F を用いて、未学習の入力データのシステム出力を得ることができる。出力次元は、システムの利用者が定めるものであるが、感性情報を視覚的に捉える目的においては2次元が一般的である。

以上のまとめとして、DLMLの構造と学習法の概略図を図1に示す。2つの入力 A 、 B に対する階層型ニューラルネットワークの出力間の距離と、教師データとして与えられた2入力に対する距離の誤差を最小化するようにニューラルネットワークの重みを変更する。つまり、通常の階層型ニューラルネットワークにおける入力と教師出力の組のデータが与えられるのではなく、2入力に対する2出力について、その間の距離が教師データとして与えられている。よって、そのような教師データを学習済みの階層型ニューラルネットワークにおいては、教師データとして与えられる出力空間の2点間の距離制約を満たすような、 X から $\mathbb{R}^k$ への非線形写像が構成される。

2.3 人工データによる予備実験

2つのカクテルの違いに関する感性的評価を人工的に設定し、DMLNによって学習可能であるかを確認するための予備的な数値実験を行う。学習による出力空間への配置を確認するだけであれば、カクテルのデータである必要はないが、本稿においては、示す実際のカクテルの物理的特長による数値実験を行うために、このような予備実験を行う。なお、4節の数値実験においては、実際のカクテルの試飲によるアン

図1 DMLNと学習方法に関する模式図

ケートに基づいたカクテルデータを用いる。

入力となる素材入力ベクトルと2つのカクテルの違いに対応する数値を人工的に設定する。まず、適当に15種類のカクテルを文献 [3] より選出する。カクテルの物理特徴として、アルコール度数や使用果実などを数値化し、ニューラルネットワークへの入力とする。

カクテルの素材としては、ベースとなるお酒、および果物類が用いられている。入力設定として、カクテルの液量、アルコール度数、ベースリキュールの種類、果実の種類、炭酸の有無、作成技法を用いる。それぞれの具体的な設定を表1に示す。入力には定量的な入力とそのように表現されない要素がある。アルコールの種類や果物の種類については互いの順序関係がないので、 $[0, 1]$ の定義域において、例えば2種類であれば、それぞれ0と1とするなど、なるべく互いに離し、定性的データに対応しやすい設定としている。

設定に用いたカクテルの名称を表2に示す。15種類のカクテル（No.1～No.15）について、飲みやすさと親しみやすさの2次元座標 (k_1, k_2) の点とし、2つのカクテルの感性的違いを距離によって与える。DMLNの点の配置能力を確認

表1 カクテル素材・作成技法に関するDMLNの入力設定

入力内容	設定と利用素子数
カクテル液量	ショート（値0）・ロング（値1）、（1素子）
アルコール度数	1～100%を $[0, 1]$ で正規化、（1素子）
ベース酒	ジン・ライム・ウオッカ・リキュール（2素子、00, 01, 10, 11で指定）
果実類	15種の果実類から2種類まで指定（10素子、果実類1種につき4素子、液量全体での割合に1素子で指定）
炭酸	あり（値1）、なし（値0）（1素子で指定）
作成技法	シェーク・ステア・ビルド・ブレンドのいずれか（2素子、00, 01, 10, 11で指定）

表2 数値実験に用いた15種類のカクテル

No.	カクテル名
1	マティーニ
2	ギムレット
3	ジン・リッキー
4	オレンジ・ Blossam
5	ダイキリ
6	フローズン・バナナ・ダイキリ
7	サンチャゴ
8	バラライカ
9	ソルティー・ドック
10	スクリュー・ドライバー
11	モスコミュール
12	神風
13	バレンシア
14	アプリコット・クーラー
15	ファジィ・ネーブル

するために、15点間の距離全てについて誤差 E_{DMLN} が0.01以下となるようにDMLNのパラメータを学習させた。教師データについては、誤差 E_{DMLN} が基準以下となり学習を達成したことから、出力空間における2点間の距離は、教師データとほぼ一致している（図2(a)）。よって、この人工データを用いた実験では、データは各2点間の関係として適切に配置されたと言える。

次に、汎化能力を調べるために、データNo.4を除いた14個のデータ（No.1～13, 15）を教師データとして学習させた。結果、この14個の教師データに対しては、配置を表現できるDMLNが得られた。図2(b)に、学習後のニューラルネットによって配置されたデータ（No.1～13, 15）を示す。図2(b)を反時計回りに回転させると、データ（No.1～13, 15）について、図2(a)とほぼ同じ配置関係になることが分かる。そして、No.4のデータに対応する入力を、その学習後のDMLNの入力としたときの出力空間における出力点を、他よりも少し大きな数字にて図2(b)にて示す。ニューラルネットワークとしては、14個と少ない学習データ数であるにも関わらず、未学習データのNo.4は、図2(a)に示されるのと同様にデータNo.5, 6, 8, 9付近に配置されていることが分かる。よって、DMLNは未知データの配置に対して一定の汎化能力を持つ。

3. 感性的配置からの入力推定

前節において、2つのカクテルの違いについて得られた感性的情報から、DMLNによって配置する方針を示した。しかしながら、DMLNによる配置は、未知データの汎化を除いては数量化第IV類によっても可能である。本研究においては、以上の順方向の情報処理から逆に、感性的違いから配置された空間における任意の出力点に対応する入力（すなわち、カクテルの入力ベクトルで表される素材）を推定する方式を提案する。入力の推定方式として、ネットワークインバージョンをDMLNに導入する。この機能をDMLNによるカクテルデータマイニングに導入することで、ユーザが求める新メニューがニューラルネットワークの逆問題を解くことで得

図2 (a) 15個の教師データ（No.1～15）を学習したDMLNによる出力点の配置。(b) 14個の教師データ（No.1～13, 15）を学習したDMLNによる出力点（No.1～13, 15）および未学習データNo.4の出力点の配置

られ、ユーザの感性を直接商品に生かせる枠組みの一つとなることが期待される。以下、ネットワークインバージョンのDMLNへの導入と、本研究で新たに導入する改良型入力推定手法について述べる。

3.1 ネットワークインバージョン

ネットワークインバージョン [4, 5] とは、学習済みのニューラルネットワークを用いて出力から入力を推定する方法である [2]。入力 $\mathbf{x} = (x_1, \dots, x_L)$ に対するDMLNにおける階層型NNの出力を $\mathbf{z}(\mathbf{x}) = (z^1(\mathbf{x}), \dots, z^k(\mathbf{x}))$ とする。出力 $\mathbf{z}(\mathbf{x})$ と指定された出力点 $\mathbf{z}_* = (z_*^1, \dots, z_*^k)$ との自乗誤差 E は、以下のように与えられる。

$$E_{\mathbf{z}_*} = \frac{1}{2} \|\mathbf{z}(\mathbf{x}) - \mathbf{z}_*\|^2. \quad (12)$$

出力 $\mathbf{z}(\mathbf{x})$ は、入力 $\mathbf{x}$ と階層型ニューラルネットワークの重み $\mathbf{w}$ に依存する。DMLNが学習済みであることから、重みパラメータ $\mathbf{w}$ は固定されている。よって、誤差 E は入力 $\mathbf{x}$ に原因があるものとして、誤差 E を最小化する入力ベクトルを求める。階層型ニューラルネットワークにおける重みベクトル $\mathbf{w}$ について、入力素子、中間素子および出力素子のインデックス集合をそれぞれ $\mathbf{L} = \{1, \dots, L\}$, $\mathbf{M} = \{1, \dots, M\}$ および $\mathbf{N} = \{1, \dots, N\}$ とし、入力層と中間層の間の重みを w_{ij} 、中間層と出力層の間の重みを v_{jk} と置く。更新前後の入力ベクトルをそれぞれ $\mathbf{x}^{\text{old}}$ および $\mathbf{x}^{\text{new}}$ とすると、入力ベクトルの更新規則は学習係数 η を用いて以下のように表される。

$$\mathbf{x}^{\text{new}} = \mathbf{x}^{\text{old}} - \eta \frac{\partial E_{\mathbf{z}_*}(\mathbf{x}^{\text{old}})}{\partial \mathbf{x}^{\text{old}}}. \quad (13)$$

ただし、

$$\frac{\partial E_{\mathbf{z}_*}(\mathbf{x}^{\text{old}})}{\partial \mathbf{x}^{\text{old}}} = \left(\frac{\partial E_{\mathbf{z}_*}(\mathbf{x}^{\text{old}})}{\partial x_1^{\text{old}}}, \dots, \frac{\partial E_{\mathbf{z}_*}(\mathbf{x}^{\text{old}})}{\partial x_L^{\text{old}}} \right), \quad (14)$$

$$\frac{\partial E_{\mathbf{z}_*}(\mathbf{x})}{\partial x_i} = \sum_{(j,k) \in \mathbf{M} \times \mathbf{N}} \delta_k(\mathbf{x}) v_{jk} y_j(\mathbf{x}) \times (1 - y_j(\mathbf{x})) w_{ij}, \quad (15)$$

$$\delta_k(\mathbf{x}) = (z^k(\mathbf{x}) - z_*^k) z^k(\mathbf{x}) (1 - z^k(\mathbf{x})). \quad (16)$$

ここで、 $y_i(\mathbf{x})$ は入力 $\mathbf{x}$ に対する中間層の j 番目の素子の出力を表す。

3.2 逆推定と入力空間

DMLNにおいて、1つのニューラルネットワークの出力は、ある入力の物理的特長に対応する出力空間における配置を表している。よって、ネットワークインバージョンを適用する際には、ニューラルネットワークにネットワークインバージョンによる入力の推定を施す。しかしながら、入力が離散値として設定されているなど、入力空間に拘束条件が用いられている。本研究において、入力としてカクテル素材を

想定していることから、入力空間には制限が伴う。ネットワークインバージョンによって入力推定を行った場合には、拘束条件を満たさない入力が入力推定されることがあるので、条件に適合する入力を推定する方策が必要となる。

カクテルに対応する入力 x_i については、全て $[0, 1]$ の区間の値としている。しかしながら、ネットワークインバージョンの学習によって、この定義域外に x_i が推定される場合がある。この場合、推定入力を得られてもカクテルの入力データとして定義されていない為、推定された入力の各要素に対して、想定される素材がないこととなる。よって、それに対応するカクテルを指定することができない。そこで、連続値として入力要素を設定している場合に、定義域 $[0, 1]$ の範囲に入力値を推定させる方法、および離散値として設定されている入力要素に対して適用する方法として、次に示す方策1、および方策2を導入する。

[方策1] ($[0, 1]$ 区間の連続値への対応)

入力の拘束条件を満たさない場合に、更新方向の逆をペナルティとして与え、さらに全体を縮小する方策を採用する。具体的には、 x_i^{new} が更新式 (13) によって区間 $[0, 1]$ 外に更新された場合に、以下の変更式を用いる、

$$x_i^{\text{new}} = \begin{cases} x_i^{\text{old}} - \eta \frac{\partial E}{\partial x_i^{\text{old}}}, & \text{if } 0 \leq x_i^{\text{new}} \leq 1, \\ \beta \left(x_i^{\text{old}} - \eta \frac{\partial E}{\partial x_i^{\text{old}}} \right), & \text{otherwise.} \end{cases} \quad (17)$$

ただし、 β は正の係数。

[方策2] (離散値入力への対応)

入力データにおいては、全入力要素のうち、18種類の入力を離散値 (0 or 1 および 0 or 0.5 or 1) で定義している。しかしながら、逆推定によって得られる推定入力は設定した離散値と一致するとは限らない。そこで、学習過程において方策1を用いつつ、更新幅 $|\eta \partial E / \partial x_i|$ が一定以下になった離散値設定の入力ベクトルの要素について、学習が終了したものとみなし、取り得る離散値のうちの最も近いものに変換する。以後、その入力要素については固定して、学習による更新を行わないものとする、ただし η は係数。

4. 数 値 実 験

4.1 アンケート調査

アルコールが伴うアンケート調査においては、被験者が一度に試飲できる量を考慮しつつ、感性空間に広くカクテルが分布することを想定するために、有名なカクテルを含む10種類を表2から選定した。表2に示す15種類の中でモスコミュールとジン・リッキーとは素材について共通部分が多いことから、モスコミュールとジン・リッキーについては片方(本実験ではジン・リッキー)を選択した。インデックスについては、2.3節の予備実験との混同を避けるためにアルファ

ベットで表記している。それらのカクテルについて実際に試飲し、「飲みやすさ」と「見た目の華やかさ」の2つの指標について、11段階で評価するアンケート調査を行った。被験者は、お酒が飲める20歳以上の健康な男性15名である。カクテルの量としてショート・ロングがあるが、それぞれについて30ccと50ccとした。

アンケート調査に用いた10種類のカクテル、および試飲アンケートで得られた「飲みやすさ」「見た目(派手さ)」の評価を平均した値を表3に示す。これらの平均値から、各カクテルを2次元の感性空間に配置し、2つカクテルの距離を、それらの感性的違いのデータとする。

4.2 ネットワークインバージョンによるカクテルの推定

出力空間である感性空間の指定によるカクテルの創出には、まず、アンケートデータから得られた2カクテル間の感性的違いに関する教師データとして、DMLNの学習を行う。そして、出力空間から物理特徴の推定を行う。出力空間上の点1(マティーニ)と同じ座標を指定座標とし逆推定を行う。実験条件として、方策1および方策2において、学習率を0.60、許容誤差を 10^{-5} 、矯正対象更新幅を 10^{-2} 、 $\beta = 0.4$ とする。

感性出力空間の点A(マティーニ)に対応する入力をネットワークインバージョンによって推定し、得られた推定カクテルの特徴と、マティーニとを比較した結果を表4に示す。DMLNによって、カクテルの集合から感性的特徴空間 $\mathbb{R}^2$ への非線形写像 M_F が構成されている。 M_F が関数であることから、同じ出力点を持つ別の入力が存在し、その出力点となる別の入力が推定されていることがわかる。推定されたカクテルにおいては、マティーニの果実成分であるハーブの部分がミルクと杏子となった。ハーブと比較して杏子の方が甘いので、飲みやすい新たなカクテルが得られていることがわかる。ネットワークインバージョンにおいては、解が一意とは限らない。よって、本結果においては、得られたカクテル組成データを元に、マティーニとの関連性についてシステム利用者が判断した結果である。見た目については色が入ったことで試飲における印象はマティーニと異なるが、推定して得られたカクテルの組成から、果実が多く含む(例えばファジィ・ネーブル)カクテルの組成とはなっていない、少しアルコール分がきついクラスのカクテルである。このことから、DMLNにネットワークインバージョンを適用した本提案手法の妥当性を示唆する事例の一つと考えられる。

次に、既知の2つのカクテルに対し、それらの出力点の中間点に相当するカクテルを推定する。例として点A(マティーニ)と点E(ファジィ・ネーブル)を選び、2点の中間の座標を指定出力の座標とし入力推定を行う。推定されたカクテルの特徴を、マティーニおよびファジィ・ネーブルと比較した結果を表5に示す。

得られたカクテルについて、指定した感性空間の点に相当するかどうかを検証することが必要となる。本研究では、ネットワークインバージョンで、任意の出力点に対応する入力を指定できる枠組みを提示している。すなわち指定した出力空

間の点に対応する入力の変換により、DMLNの入出力が得られる。この入力に対応するカクテルと、このカクテルの試飲によるアンケート（教師出力）の組みは、学習で用いていない未知の教師データとなる。DMLNの出力（出力空間で指定した点）と教師出力（試飲アンケートによって得られる出力空間上の点）との違い、すなわち汎化性の検証を通じて、ネットワークインバージョンによって得られる新たなカクテルを提示する本システムの有効性を検証する。図3に、表4と表5の推定されたカクテルについての試飲アンケートで得られた感性情報を、出力空間に配置した図を示す。推定されたカクテルに対して、試飲アンケートで得られた感性空間の点は、飲みやすさについては、マティーニとファジィ・ネーブルのほぼ中間の位置にあり、見た目についても大きくは外れていない。得られた推定カクテルの果実成分の含有割合については、飲みやすさについて同様の変化を示しており、推

表3 アンケート結果の平均値

No.	カクテル名	飲み易さ	見た目
A	マティーニ	2.87	2.80
B	神風	6.53	3.07
C	オレンジ・ブロッサム	5.13	6.07
D	アブリコット・クーラー	8.47	6.00
E	ファジィ・ネーブル	9.47	7.60
F	スクリュー・ドライバー	8.00	7.40
G	ダイキリ	4.47	1.87
H	サンチャゴ	2.87	7.60
I	ジン・リッキー	5.20	3.87
J	フロズン・バナナ・ダイキリ	9.00	7.67

表4 学習済みDMNLを用い、マティーニの出力点にネットワークインバージョンを施して得られた推定カクテル

カクテル名	マティーニ	推定カクテル
量	ショート	ロング
度数	30.0度	31.7度
ベース	ジン	ジン
果実成分1	ハーブ16.6%	オレンジ10.0%
果実成分2	なし	メロン1.5%
炭酸	なし	なし
技法	ステア	ステア

表5 学習済みDMLNを用い、マティーニとファジィ・ネーブルの中間点にネットワークインバージョンを施して得られた推定カクテル

マティーニ	ファジィ・ネーブル	推定カクテル
ショート	ロング	ロング
30.0度	5.4度	22.1度
ジン	リキュール	ウオッカ
ハーブ16.6%	オレンジ70.0%	メロン7.5%
なし	ピーチ15.0%	杏26.0%
なし	なし	あり
ステア	ビルド	ブレンド

図3 ネットワークインバージョンによって得られた推定カクテル（表3 および表4）の試飲アンケート結果（平均値）を配置した出力空間

定されたカクテルにおいて、2つのカクテルの中程度の飲みやすさが表現されていると考えられる。“●”は、表2におけるマティーニとファジィ・ネーブル以外のカクテルの感性空間上の点を示している。

5. ま と め

本研究においては、感性データとしてカクテルを取り上げ、距離画像学習ネットワーク（DMLN）による数量化を行い、汎化能力による配置に対して一定の性能を確認した。さらに、ユーザの感性情報を基にした逆問題解法として、出力空間の任意の点に対応する入力推定のためのネットワークインバージョンを導入し、感性関連性データに基づくカクテル創出法としての新カクテル組成導出法を提案した。

本研究は、2つの情報空間の関係において構造化され、入力空間と出力空間の関係から全体を把握できる。まず、カクテルの組成や製法などの要素上で定義される全てのカクテルから成る空間を入力空間とし、商品などのアイテムの関係を表す空間を出力空間とする。入力から出力への情報の流れについては、階層型ニューラルネットワークと教師あり学習が対応し、感性空間からそれに対応する入力への情報の流れに対しては、学習済みの階層型ニューラルネットワークを利用したネットワークインバージョンによる入力推定が対応する。このように2つの情報空間とその関係に基づく数理モデルによって、カクテルデータマイニングに関する感性情報処理系が構成されている。特に新カクテル創出においてDMLNに対しては、逆問題解法としてネットワークインバージョンの導入が適切であり、入力推定として、それ以外の手法での簡便な解法はない。

今後の課題として、多くのカクテルデータを用いたDMLNの精度の向上、ネットワークインバージョンにより逆推定されたデータと、得られたカクテルの試飲で得られる感性データとの不整合性の解消、さらには、他の商品における多様な感性に基づいたアンケート調査によるデータ蓄積とユーザ感性情報に対応する商品組成の解析などが挙げられる。

参 考 文 献

- [1] 徳丸正孝, 村中徳明: 感性情報の分析を目的としたファジー決定木の構成, 電子情報通信学会論文誌D, Vol.J90-D, No.5, pp.1305-1317, 2007.
- [2] 鈴木健嗣, 橋本周司: ニューラルネットワークを用いた感性情報の数量化, 電子情報通信学会論文誌D-II, Vol.J82-D2, No.4, pp.677-684, 1999.
- [3] 桑名伸佐: カクテル・パーフェクトブック, 日本文芸社, 2007.
- [4] A. Linden, J. Kindermann: Inversion of multilayer network, Proc. International Joint Conference on Neural Networks, Vol.3, pp.188-193, 1993.
- [5] 小杉幸夫, 橋本尚子, 小川毅彦: ネットワークインバージョンにおける動的正則化, 電子情報通信学会論文誌D-II, Vol.J81-D2, No.7, pp.1639-1646, 1998.

奥谷 勝行 (非会員)

2007年3月室蘭工業大学工学部情報工学科卒, 2009年3月同大学院工学研究科博士前期課程修了, 感性情報処理に関する研究に従事。現在, ほくでん情報テクノロジー株式会社。

塩谷 浩之 (非会員)

1990年3月北海道大学理学部数学科卒, 1992年3月同大学大学院工学研究科情報工学専攻修士課程修了, 1995年3月同大学大学院工学研究科博士後期課程修了。1995年4月同大学大学院工学研究科助手, 2001年8月室蘭工業大学情報工学科助教授, 現在, 室蘭工業大学しくみ情報系領域准教授。知能情報工学に関する研究に従事。電子情報通信学会, 計測自動制御学会などの会員。博士 (工学)。

工藤 康生 (正会員)

2000年北海道大学大学院工学研究科博士後期課程修了。室蘭工業大学情報工学科助手を経て, 現在, 同大しくみ情報系領域助教。博士 (工学)。ラフ集合理論, 非古典論理, データマイニングに関する研究に従事。第9回日本感性工学会大会優秀発表賞受賞。日本知能情報ファジィ学会, 人工知能学会各会員。

沖井 廣宣 (正会員)

1987年慶應義塾大学大学院工学研究科博士課程単位取得退学。1990年室蘭工業大学情報工学科助手。1994年室蘭工業大学情報工学科助教授を経て, 現在, 室蘭工業大学しくみ情報系領域教授。感性工学, 医用画像などの研究に従事。日本感性工学会, 電子情報通信学会などの会員。博士 (工学)。