ニューラル・ネットワークによる清酒の官能評価データの解析

佐藤和夫・蓼沼 誠*

<国税庁醸造研究所>

平成6年7月28日受理

An Analysis of Sensory Tested Data of Sake by a Neural Network

Kazuo SATO and Makoto TADENUMA

(National Research Institute of Brewing, 2-6-30, Takinogawa, Kita-ku, Tokyo 114)

Sensory tested data of sake were analyzed by a back-propagation method of a neural network, where the input data were trained for the output of sake-categories. To optimize the training condition, effects of the numbers of training iteration and the unit of hidden layer were examined. The accuracy of discrimination by the neural network was better than that by the discriminant analysis under these conditions. The characteristics of the categories were described from the weight coefficient analysis between input and output layers. These results show a new point of view to evaluate the qualities of sake, which is derived from the non-linearity of the neural network.

Key words: ニューラルネットワーク・清酒カテゴリー・判別分析・非線形解析

緒 言

人間の感性の応答は複雑で非線形な要素が大きい。嗜好品である酒類の評価についても、人間の味覚や嗅覚を主体とした多くの感覚的要素によって判断が行われるが、さらに飲酒の経験の程度や評価パネルの性別や年齢などの肉体的、心理的あるいは社会的要素も影響すると思われる。したがって、一般的に官能評価の結果は評価パネルの個人差が大きいので、評価結果の客観性を持たせるために、多くの評価パネルによる平均的評価を行うことが通例である¹⁾。このように、酒類の官能評価は人間の高度な感性構造に基づくことから、その応答結果は複雑で、例えば、酒類の官能評価データを多次元の線形モデルでシミュレーションした場合においても、十分な精度が得られないことが多く見受けられる。

一方、コンピューターによるシミュレーションモデルとしてのニューラル・ネットワークは、もともと脳の神経細胞のネットワークを模したものであり、学習のうちに得られる応答モデルはいわゆる非線形多変量モデルに類せられる²⁻⁴⁾。したがって、多変量データを取り扱う場合には、一般に線形モデルを用いた場合よりも高い精

度を期待できる。また、高度な数学的知識を必要とする非線形多変量解析に比べると、データの反復学習によるモデル生成・認識過程は取り扱いがきわめて容易である。しかし、ニューラル・ネットワークにより生成されるモデルは中間層の数やそのユニット数、また、入力パターンの学習回数などの学習条件により連続的に変化するため、最終的な収束モデルの同定が難しい。また、学習打ち切り回数や中間層の条件などをあらかじめ設定することが困難、といった問題がある。

そこで、市販清酒のきき酒結果を入力とし、清酒カテゴリーを出力とするニューラル・ネットワーク学習に際して、中間層のユニット数と学習回数の違いによる入力パターンの認識率の変化を調べ、これらの学習条件によりネットワーク構造の変化とカテゴリー認識成績の変化を調べた。さらに、学習後のネットワークの入出力の応答を調べることで清酒カテゴリーの特徴を抽出した。

実 験 方 法

1. 官能評価データ

59点の市販清酒についてプロファイル法によりきき酒を行った結果を入力データ^{5,6)}として用いた。この内訳は吟醸酒 23点、古酒 10点、純米酒 12点、生酒 14

酒類評価に関する感性情報処理 (第1報)

* 現在、(財)日本醸造協会

Table 1 Sensory tested items for sake.

Item		Note
Appearance	1 color	(1. colorless 2. pale 3. light yellow 4. yellow brown)*)
Odor	2 top note	(1. weak 2. medium 3. strong)*)
	3 fragrant	(1. weak 2. medium 3. strong)*)
	4 impression	(1. not agreeable 2. normal 3. agreeable)*)
	5 fruity	
	6 floral	
	7 sherry aroma	
	8 aged sake odor	
	9 amasake odor	
	10 pleasant	
	11 esteric	
	12 fresh	
	13 light	
	14 heavy	
Taste	15 soft	(1. not agreeable 2. normal 3. agreeable)*)
	16 impression	(1. atin 2. light 3. medium 4. thick 5. heavy)*)
	17 boody	(1. dry 2. light dry 3. medium 4. sweet 5. heavy sweet)*)
	18 sweet	
	19 light	
	20 clean	
	21 fresh	
	22 smooth	
	23 aftertaste	
	24 heavy	
	25 elegant	
	26 harmonious bitter	

*) Checked according to the degree of intensity.

点、の合計4カテゴリー59点である。きき酒試験は13名のきき酒エキスパートを主体とする審査員グループにより、清酒カテゴリーおよび銘柄を表示せずに行われた。きき酒項目は、色調、香り、味に関する26項目で、それぞれの評価項目にチェックする方式により行われた(Table 1)。

データの解析に際して、きき酒データは各サンプルごとに審査得点を集計し、それぞれの項目について合計得点を0～1に正規化した。

2. ニューラル・ネットワーク

きき酒項目を入力層とし、清酒カテゴリーを出力層として、1つの中間層を設定した合計3層のネットワーク構成により、バック・プロパゲーション・モデルによる入力データのパターン反復学習と認識を行った。このときのネットワーク構成は、入力層のユニット数はきき酒項目数に対応する26ユニット、また、出力層ユニット数は清酒カテゴリー数に対応する4ユニットである。中間層のユニット数は、ユニット数を変化させた場合のパターン認識精度の変化を調べるために大小さまざまな数に設定した。Fig. 1にネットワーク構成の模式図を示し

Fig. 1 An outline of a 3l-ayer neural network.

Symbols, VI, VH and VO mean the values of the units in the input, hidden and output layers, respectively: v and w mean the weight coefficients of input-hidden and hidden-output layers, respectively.

た(ただし簡略化のため、各層のユニット数は実際とは異なる)。

ニューラル・ネットワークのソフトウェアには日本電気インフォメーション・テクノロジー(株)製のパッ

ク・プロパゲーション・モデル（道真）を用い、パーソナル・コンピュータを用いて計算した。

実験結果および考察

1. 学習条件によるカテゴリー認識率の変化

ニューラル・ネットワークによる入力データのパターン学習では、学習の繰返しにより入力パターンの認識モデルが連続的に変化する。この入力パターンの学習・認識過程では設定されたネットワークの中間層の層数と中間層に含まれるユニット数により、パターン誤認識率が収束するに至るまでの学習回数が異なる。一般的には中間層の層数やそのユニット数を大きくするとモデルの非線形性が増して学習パターンの認識精度が増すが、一方では誤認識率の収束に要する学習回数が大きくなる。また、いわゆるデータのオーバー・フィッティング（過学習）により、認識精度が低下することがあるといわれる⁴⁾。

このようにニューラル・ネットワークによる学習条件の設定には中間層の層数やユニット数などについて、あらかじめ適当な条件を決めることが重要であるが、現在のところこのような問題を解決できるような方策は見だされていない。このため、個々の入力データについて学習過程における認識精度の変化から経験的に学習条件を設定することが行われているが、このような手法の一つにクロス・バリデーションがある⁷⁾。これは入力データを学習データグループと認識データグループとに2分して、前者によりいろいろなニューラル・ネットワークでの学習を行い、学習後の認識モデルにより後者のパターン認識を行い、これら結果から最適な学習条件を設定する方法である。

そこでこの方法により、清酒カテゴリー判別のための最適な学習条件を決定することとした。ニューラル・ネットワークの学習データには全サンプル（59点）から各清酒カテゴリーのサンプル数に比例するように無作為にとりだした40点（吟醸酒17点、純米酒8点、古酒7点、生酒8点）のきき酒データを学習データとして用い、清酒カテゴリーを教師信号とする学習を行った。さらに、残りの19点のデータを認識データとして清酒カテゴリーの判別を行った。このとき、ネットワークの入力ユニット数と出力ユニット数は、それぞれ26ユニットおよび4ユニットで、きき酒項目と清酒カテゴリーの数に相当する。中間層のユニット数については、異なるユニット数のネットワークを作成して学習を行い、それぞれについて学習回数による認識精度の変化を調べた。なお、中間層の層数を増すとモデルの非線形性が増すが、学習後のネットワークの解析が複雑になる。また、

Fig. 2 A Changes in the training error by the numbers of the training iteration and the unit of hidden layer of a neural network.

Input : sensory tested data of 40 samples.

Output : 4 sake-categories.

N_H : unit number of hidden layer.

Fig. 2 B Changes in the validation error by the training condition of a neural network.

Input : sensory tested data of 19 samples.

Output : 4 sake-categories.

N_H : unit number of hidden layer.

オーバー・フィッティングとならないためには中間層のユニット数は必要最小限にすることが望ましいといわれ⁸⁾、データがそれほど複雑でない場合には中間層数を1とした3層構成が一般に用いられる。

そこで、ニューラル・ネットワークの中間層数は1とし、バック・プロパゲーションの入力パラメータには、シグモイド関数の傾き係数 $\mu_0=0.75$ 、荷重およびしきい値に対する修正係数 $\alpha=0.1$ 、忘却係数 $\gamma=1.0$ 、として学習を行った。

Table 2 Comparison of the validation errors on sake-categories between discriminant analyses and a neural network.

Sake-category	The number of samples	Discriminant analysis		Neural network ¹⁾
		<i>Mahalanobis'</i> generalized distance	1st order discriminant function	
<i>Ginjo-shu</i>	7	0.43	0.29	0.14
<i>Junmai-shu</i>	4	0.25	0.50	0.25
<i>Ko-shu</i>	3	1.00	1.00	0.67
<i>Nama-shu</i>	5	0.80	1.00	0.60
Total	19	0.58	0.63	0.37

1) Training condition ; the numbers of hidden layer and the training iteration were 30 and 50,000, respectively.

Fig. 2 A は、40 点の学習データについて所定回数学習後の誤学習率を示した。また、Fig. 2 B は学習後のネットワークにより 19 点の未学習データの 카테고리判別を行ったときの誤認識率を示した。

Fig. 2 A にみられるように、いずれの中間層数においても数百回程度の学習で誤学習率は急速に減少し、さらに学習が進むと誤学習率は 0 に近い値となった。このとき、中間層のユニット数が少ない ($N_H < 10$) と、学習が収束しにくい傾向がみられたが、中間層のユニット数が大きくなる ($N_H \geq 10$) と収束傾向に大きな違いはみられなかった。

一方、Fig. 2 B によれば、未学習データの誤認識率も数百回程度の学習により急速に減少した。100,000 回までの学習による誤認識率の変化を調べると、学習が数千回以上となると中間層のユニット数による違いは少なく、誤認識率はほぼ一定となった。ただし、中間層の数が大きい場合 ($N_H = 120$) には、誤認識率が減少するための学習回数が多く必要であった。

したがって、今回の入出力データおよび学習条件に関しては、学習回数を大きくした場合や、中間層の数や中間層のユニット数を大きくした場合にみられるというオーバー・フィッティング現象は観察されなかった。また、ある程度学習が進んだ段階では生成したパターン認識モデルの認識精度はそれほど大きな違いがないと結論づけられる。

バック・プロパゲーションによるパターン学習に際して、中間層の各ユニットは、入力層の各ユニット値の要約的機能を果たすと見なすことができる。今回の計算結果で、中間層のユニット数が入力層のユニット数に比べて極端に少ない場合でも、学習によってユニット数が多い場合とあまり変わらない認識率を示した。このことは、少なくとも今回の官能評価データについては、清酒のカテゴリ認識を目的とした場合、それほど複雑な特徴抽出を行う必要がないことを示すと思われる。

2. カテゴリ判別精度の比較

バック・プロパゲーション法による学習では教師信号に対する入力信号の誤差の 2 乗和を最小にするようにネットワークの重みが形成される。また、未学習パターンのカテゴリ認識に際しては教師信号パターンに対する誤差の 2 乗和を比較することにより判別が行われる。このようにして得られたカテゴリ認識モデルは、マハラノビスの汎距離による判別分析などの線形分離手法と対比するとアナロジーな概念をもつが、線形判別分析モデルでは入力項目間に相関性がないことを前提として判別関数を作成するのに対して、ニューラル・ネットワークでは中間層の各ユニット間に独立性がなく、非線形な動作特性をもつという点で違いがある。

そこで次に、両者の判別精度を比較するために、さきにニューラル・ネットワークの学習条件の検討に用いた 40 点のデータを学習データとして、マハラノビスの汎距離による判別関数を作成し、19 点の未学習データのカテゴリ判別を行い、ニューラル・ネットワークによる認識結果と比較した結果を Table 2 に示した。また同様に、1 次の線形判別関数を作成してカテゴリ判別分析を行ったうちで、判別成績がもっともよかったものの結果も示した。

これらの結果によると、マハラノビスの汎距離による判別分析結果では、カテゴリの誤認識率は 58% であった。また、1 次の線形判別関数による判別分析結果では 63% に及び、これらは清酒カテゴリの判別を行うためには、ほとんど有効とは思われない精度であった。一方、ニューラル・ネットワークの場合では誤認識の極小値は 37% であったことから、判別分析法よりも高い精度でカテゴリ判別が可能と評価できた。

このように、今回のき酒データのように判別分析法では十分なカテゴリ判別ができないデータについても、ニューラル・ネットワークによれば精度良く判別できる可能性が示された。ただし、これまでに述べたよう

に個々のデータについて中間層の設定や学習回数などの最適条件を設定することが困難であるため、クロス・バリデーションなどの手法によりあらかじめ見当をつけておく必要がある。

3. ネットワークの構造解析とカテゴリーの特徴抽出

Fig. 1 に示されたような3層のニューラル・ネットワークによるバック・プロパゲーション学習では、学習により入力層-中間層間および中間層-出力層間の各ユニットを結ぶネットワーク結合荷重が形成される。入力層の各ユニットにデータが入力されたとき、これに応答する中間層と出力層の各ユニットの値は次のように計算される。

$$\text{中間層} \quad VH_k = f\left(\sum_k v_{kl} \cdot VI_l + \theta H_k\right) \quad (1)$$

$$\text{出力層} \quad VO_j = f\left(\sum_k w_{jk} \cdot VH_k + \theta O_j\right) \quad (2)$$

ただし、 VI_l , VH_k , VO_j はそれぞれ入力層、中間層、出力層の各ユニット値、 v_{kl} , w_{jk} はそれぞれ入力層-中間層間および中間層-出力層間のネットワーク荷重である。 θH_k , θO_j はそれぞれ中間層と出力層の各ユニットのしきい値である。また、関数 f は入出力特性を決定するシグモイド関数で、今回の計算には $f(x) = \{1 + \tanh(x/\mu_0)\}/2$ を用いた。ただし、 μ_0 はシグモイド関数の傾きを決めるパラメータである。

入力パターンの学習によりこれらの荷重は変化するが、ある程度学習が進んで誤差が収束した状態では、その後の学習による荷重の変化はわずかとなる。そこでこのような状態において、ネットワーク荷重を解析することにより、入出力間のネットワークの構造を解析できる。

(1) 入力層-中間層間のネットワーク荷重の解析

Table 3 Weight coefficient analysis between input and hidden layers of a neural network on the discrimination of sake-categories.

	Item	Neural network ¹⁾			Discriminant analysis ²⁾		
		Unit 1	Unit 2	Unit 3	Function 1	Function 2	Function 3
Appearance	1 color	-2.000△	1.998○	2.002○	0.263	0.165	0.136
Odor	2 top note	-0.003	0.997	-0.360	-0.217	0.187	0.267
	3 fragrant	0.264	0.006	-1.409	0.034	-0.586△	-0.234
	4 impression	0.096	-1.995△	-1.781△	-0.009	0.201	-0.142
	5 fruity	1.209○	0.047	-1.994△	-0.512△	0.124	-0.551△
	6 floral	1.589○	1.000	1.006	-0.177	0.051	0.009
	7 sherry aroma	-0.905	-1.544△	1.157	0.696○	0.015	-0.206
	8 aged sake odor	0.558	1.998○	-1.997△	-0.279	0.956○	0.306
	9 amatake odor	-0.601	-1.144△	0.670	0.352○	-0.239	0.109
	10 pleasant	1.743○	0.068	0.188	-0.351	-0.071	-0.039
	11 esteric	-2.000△	-0.489	-0.391	0.325○	0.253	0.059
	12 fresh	1.440○	-0.754	1.000	0.109	-0.212	-0.193
	13 light	0.649	-1.997△	0.064	-0.343	0.099	-0.300△
	14 heavy	-1.536△	0.239	0.836	-0.290	-0.750△	0.094
	15 soft	-0.910	0.277	-1.993△	-0.163	0.224	0.010
Taste	16 impression	-0.003	1.736○	-1.257	-0.485△	0.127	0.579○
	17 body	0.998	-0.710	-0.540	-0.847△	-0.533△	-0.625△
	18 sweet	-0.428	1.999○	3.463○	0.537○	-0.169	0.770○
	19 light	-0.730	0.702	-0.664	0.019	-0.397△	-0.037
	20 clean	-1.007	-1.695△	2.026○	0.380○	0.022	-0.079
	21 fresh	1.547○	1.155	1.845○	-0.154	-0.266	0.191
	22 smooth	0.999	0.643	0.763	-0.135	-0.243	0.042
	23 aftertaste	-0.152	0.531	-0.175	-0.092	0.036	-0.194
	24 heavy	-0.602	-1.270△	-2.320△	0.175	0.463○	0.210
	25 elegant	-0.950	2.343○	0.300	0.178	-0.066	0.631○
	26 harmonious bitter	0.014	0.005	-0.586	-0.262	0.354○	0.189
	Variance	1.141	1.613	2.083	0.118	0.120	0.100

1) Training condition; the numbers of the training iteration and the unit of hidden layer were 3 and 50,000, respectively.

2) Three functions were effective on the discriminant analysis of sake-categories.

Symbols, ○ and △, mean the relative great and small values calculated by standard deviation, respectively.

3層構成のニューラル・ネットワークでは入力パターンの学習時における中間層は、概念的には入力層の各ユニットの値に重みづけによる要約を行う機能をもつと理解でき、先に述べたようにこのような機能は線形判別関数とアナロジーである。したがって、入力層と中間層の各ユニットを結ぶネットワーク荷重の大小と線形判別関数の重み係数の大小とを比較すると両者の特徴抽出の違いを理解することができると思われた。

ただし、当然のことながらニューラル・ネットワークの中間層のユニットの数によりそれぞれのユニットの意味づけが異なる。今回の59点の官能評価データについて、1次の線形判別関数により清酒カテゴリーの判別を行ったところ、有意な合成変数の数は3つであった。そこで、中間層のユニット数を3とするニューラル・ネットワーク構成でこのデータのカテゴリー学習を行い、誤学習率がほとんど変化しなくなったことを確認し、入力層-中間層の各ユニット間の結合荷重を調べた。なお、学習終了時までの学習回数は50,000回とし、このときの誤学習率は2/59であった(Table 3)。

Table 3において荷重の絶対値が大きい項目を抽出することにより、各ユニットの特徴抽出の概略を知ることができる。例えば、第1ユニットでは香りに関して「果実様」、「花様」、「はなやか」、「エステル様」、「新鮮」、「重い」といった項目が、また味では「新鮮」という項目が抽出できることから、第1ユニットは「上槽後間もない新酒の、いわゆる吟醸香」を軸とした特徴抽出を行うと見なすことができる。同様に第2ユニットは「香味の熟成」、第3ユニットは「十分に熟成がすすんでいない荒々しさ」を軸とした評価基準と見なすことができる。

一方、線形判別関数の合成変数の重み係数を調べると、第1合成変数は「上槽後間もない新酒の特徴」と性格づけられ、これはニューラル・ネットワークの第3ユニットとよく似たイメージである。第2合成変数は「かなり熟成の進んだ古酒の特徴」、第3合成変数は「味の調和」を基準とした評価基準と見なすことができる。

このように、ニューラル・ネットワークは判別関数とは異なるカテゴリー特徴抽出の切り口をもつことが確認できた。

(2) 入出力層間のネットワーク荷重積和の解析

学習後のニューラル・ネットワークの構造において、それぞれの出力ユニットに対してどの入力ユニットが強く(正または負の)結合をしているかをみるためには(1)、(2)式にみられる VI_i と VO_j の関係から、中間層を介する入力層と出力層の各ユニット間のネットワークの荷重積和 p_{ij} を比較すればよい。

$$p_{ij} = \sum_k v_{ik} \cdot w_{kj} \quad (3)$$

(3)式により、ニューラル・ネットワークの出力層の各カテゴリーがどの入力項目と結びつきが深いかを知らることができる。

そこで、今回のきき酒データの全データ(59点)について、これまでと同様に26項目のきき酒結果を入力データとし、4つの清酒カテゴリーを教師信号として学習を行い、学習後の入力層-出力層間のネットワークの荷重の積和を計算し、-1~+1の範囲に正規化した。学習に際して、中間層のユニット数 N_H は3~60の5段階、最大学習回数は50,000回とし、各カテゴリーごとに中間層のユニット数と学習回数による荷重積和の変化を調べた。

この結果によれば、中間層のユニット数が少ないものほど誤学習率の収束に要する学習回数は少なかったが、いずれの学習条件においても学習回数が1万回を越えるとこれ以降の学習によるネットワーク荷重の変化はわずかであった。学習回数5万回までの最終誤学習率は中間層のユニット数が3のとき2/59、ユニット数が60のとき1/59、これら以外の場合0/59であった。これらの結果のうちから、吟醸酒について中間層のユニット数を変えた場合の学習回数による荷重積和の変化を調べた結果をFig. 3に示した。

Fig. 3にみられるように、学習回数による荷重積和の変化は小さかった。これは誤学習率が収束した状態では、ニューラル・ネットワークによるパターン認識モデルの変化はほとんどないことを意味する。一方、中間層のユニット数の大小によって荷重積和のパターンにはやや違いが見られた。このことは、中間層のユニット数によりパターン認識モデルに違いが生じることを意味する。すなわち、中間層のユニット数を増すことによりその非線形性が増大した結果と思われた。

(3) 荷重積和の解析によるカテゴリー特徴の抽出

これまでの結果から、ニューラル・ネットワークによるパターン認識モデルは学習回数や中間層のユニット数を変えることにより連続的に変化する特徴をもっているが、ある程度学習が進んだ状態では、ネットワークの荷重積和を調べることでカテゴリーの特徴抽出の「切り口」とすることができると思われる。ただし、Fig. 3にみられるように、入出力間の結合の強さを示す荷重の積和は中間層のユニット数によりそのパターンに違いが生じ、ニューラル・ネットワークは中間層のユニット数を変化させることにより、切り口の異なる判別モデルを生成する。

しかし、いずれのモデルにおいても、荷重積和の大小のパターンはカテゴリーによって大きな違いがあり、それぞれの出力ユニット(清酒カテゴリー)によって正ま

Fig. 3 Changes in the sum of the products of the weight coefficients between the units of input and output layers during the training of a neural network.

Data on *Ginjo-shu* were shown.

Input : sensory tested data of 59 samples.

Output : 4 sake-categories.

N_H : unit number of hidden layer.

item : 26 sensory tested items shown in Table 1.

たは負に強く結合する入力ユニット(評価項目)に違いがあった。そこで、各カテゴリーごとにネットワーク荷重積和の絶対値が大きい入力項目をとりだして、これらを比較した。このとき、荷重積和が正の大きな値をもつ項目はカテゴリーに固有な特徴を表し、負の大きな値をもつ項目はカテゴリーに含まれない特徴を表わすと思われる。

このような特徴抽出法の有効性を確認するためには、学習後の入出力間荷重積和に基づいて新たに入力パターンデータを作成し、学習済みネットワークによりこのデ

ータのカテゴリー再認識を行い、その認識精度を調べればよい。このとき中間層のユニット数による認識精度の違いを調べるために、中間層ユニット数を3~60とする5つのネットワーク構成で、入力をきき酒データ、出力を清酒カテゴリーとして50,000回学習を行い、それぞれ学習後の入出力間荷重積和を計算して各カテゴリーごとの入力パターンデータを作成した。

学習後の各ネットワークを用いて、新たに作成した入力データのカテゴリー再認識を行った結果をTable 4に示した。この結果によれば、5つのネットワーク条件

Table 4 Re-validation of sake-categories by the weight coefficient analysis of neural networks.¹⁾

Unit number of hidden layer	Category	Intensity of recognition			
		<i>Ginjo-shu</i>	<i>Junmai-shu</i>	<i>Ko-shu</i>	<i>Nama-shu</i>
3	<i>Ginjo-shu</i>	0.998	0.005	0.026	0.001
	<i>Junmai-shu</i>	0.089	0.993	0.001	0.000
	<i>Ko-shu</i>	0.206	0.011	0.953	0.032
	<i>Nama-shu</i>	0.000	0.000	0.007	0.999
5	<i>Ginjo-shu</i>	0.827	0.002	0.837	0.001
	<i>Junmai-shu</i>	0.000	0.999	0.367	0.006
	<i>Ko-shu</i>	0.342	0.001	0.991	0.000
	<i>Nama-shu</i>	0.000	0.002	0.012	1.000
10	<i>Ginjo-shu</i>	1.000	0.000	0.000	0.000
	<i>Junmai-shu</i>	0.000	1.000	0.008	0.002
	<i>Ko-shu</i>	0.535	0.126	1.000	0.000
	<i>Nama-shu</i>	0.000	0.037	0.000	1.000
30	<i>Ginjo-shu</i>	1.000	0.000	0.006	0.000
	<i>Junmai-shu</i>	0.005	1.000	0.000	0.001
	<i>Ko-shu</i>	0.922	0.000	0.993	0.000
	<i>Nama-shu</i>	0.000	0.000	0.000	1.000
60	<i>Ginjo-shu</i>	1.000	0.000	0.826	0.000
	<i>Junmai-shu</i>	0.000	1.000	0.022	0.000
	<i>Ko-shu</i>	0.839	0.000	1.000	0.000
	<i>Nama-shu</i>	0.000	0.000	0.000	1.000

- 1) Input data were the sum of the products (p_{ij}) of two weight coefficients (v_{ik} and w_{jk}).
The Number of training iteration was 50,000 at each neural network.
The bold letters are the greatest values in the group of intensity.

Table 5 Characteristics of sake-categories evaluated by the weight coefficient analysis of a neural network.¹⁾

Category	Appearance/Odor		Tastes		Summary
	Positive	Negative	Positive	Negative	
<i>Ginjo-shu</i>	floral aged sake odor	sherry aroma amasake odor	impression		Odors are floral, and have an aged sake-odor, without sherry aroma and amasake odor. The impression of the tastes is agreeable.
<i>Junmai-shu</i>	sherry aroma light	color		elegant	Appearance is pale. Odors are light, and have a sherry aroma. Tastes are not elegant.
<i>Ko-shu</i>	aged sake odor		harmonious bitter	clean, fresh	Odors have an aged sake odor. Tastes are not clean and fresh, and have a harmonious bitterness.
<i>Nama-shu</i>	amasake odor heavy	aged sake odor soft	sweet, fresh		Odors are heavy and not soft, and have an amasake odor without aged sake odor. Tastes are sweet and fresh.

- 1) Extraction of sensory tested items was done by the intensity of the connection between input and output layers of a neural network.

でカテゴリーの誤認識は1点だけ（中間層ユニット数5のネットワーク、吟醸酒）で、全体の誤認識率は1/20であった。したがって、入出力間荷重積和をもとにして作成した清酒カテゴリーの入力パターンデータは、それぞれのカテゴリーの特徴をほぼ表現したものとみなすこ

とができる。

このように、入出力間荷重積和によりそれぞれのカテゴリーに固有な特徴を抽出できることが確認できた。ただし、中間層のユニット数の違いにより特徴抽出に多少の違いがあるため、入力項目の抽出は中間層のユニット

数が入力層と出力層のユニット数の和に近いもの($N_H=10\sim60$)として、これらに共通する入力項目をとりだすこととした(Table 5)。

この結果によれば、吟醸酒の特徴は、「花様の香りと老酒様の香りがあり、シェリー様の香りと甘酒の香りが無い。味の印象は良い。」と要約できた。一般的には吟醸酒は新酒の段階では果実様の香りをもつことが特徴であるが、市販の吟醸酒は保存条件によってはいわゆる老ね香が強くあらわれることがある。このような結果は、今回の試料の吟醸酒の一部がこのような特徴をもっていたことによると思われた。

純米酒の特徴は、「色が薄い。香りは軽快でシェリー様の香りがある。味は上品さが無い。」と要約できた。これは、純米酒は原料米の精米歩合を低くしたり、発酵温度を低くする、あるいは粕歩合を高めるなど、仕込み段階での措置や出荷時の活性炭の使用量を増すなどの措置がとられることが多いことによると思われた。

古酒の特徴は、「老酒様の香りがある。味はほど良い苦みがあるがきれいさ、新鮮さが無い。」と要約できた。老酒様の香り(老ね香)と味の新鮮さを感じないことはもちろん一般的な古酒の特徴を示しているが、何らかの苦みを感じることは、他のカテゴリーにはない特徴と思われ、興味深い。

生酒の特徴は「甘酒の香りがあり、老酒の香りはなく、重い印象の香りでソフトな感じはない。味は甘く、新鮮である。」と要約できた。これは生酒が上層後間もない清酒のような、未熟な酒質をもつことを示すと理解できる。

このような手法により、ニューラル・ネットワークの特徴を利用して新しい清酒の官能評価項目の設定、あるいはきき酒表現・用語の検討など、清酒の品質評価や品質設計の指標を考える際の参考とすることができると思われた。

以上の結果をまとめると、ニューラル・ネットワークによればプロファイル法などの多くの項目からなるきき酒データを精度よく分類できることがわかった。また、学習後のネットワークの荷重を調べることにより、酒類のカテゴリーの特徴を抽出することができたが、これらはニューラル・ネットワークの非線形的特徴により、多変量解析法とは異なる評価基準がもたらされた結果とみ

ることができる。これらの特徴を利用して、きき酒データのほか、人間の感性計測データなど、複雑な現象の解析のための新しい手法として用いることができると思われた。

なお、本研究は(社)日本酒造組合中央会との共同研究の一環である。データの提供をいただいた(社)日本酒造組合中央会ならびに国税庁醸造研究所の関係各位に深謝申し上げる。

要 約

(1) バック・プロパゲーション法によるニューラル・ネットワークにより市販清酒のきき酒データから清酒カテゴリーの学習・認識を行い、ネットワークの中間層のユニット数や学習回数による誤差の変化を調べ、収束条件を検討した。

(2) カテゴリー学習後のネットワークにより未学習データの Kategorii の判別を行ったところ、判別分析法よりも精度よく Kategorii の判別ができた。

(3) 学習後のネットワークの入力層-中間層-出力層の各層間の荷重やその積和を調べることにより、Kategorii の評価基準や Kategorii に特徴的な項目の抽出を行うことができた。これらの結果を利用して、清酒の品質設計やきき酒方法の検討に利用することができると思われた。

文 献

- 1) 佐藤 信：官能検査入門, p.1-17, 日科技連(1978)
- 2) 平藤雅之：バイオエキスパートシステムズ, p.105-144, コロナ社 (1990)
- 3) 市川 紘：階層型ニューラル・ネットワーク, p.35-56, 共立出版 (1993)
- 4) P.D. WASSERMAN: Advanced Methods in Neural Computing, p.1-12, p.214-244, Van Nostrand Reinhold, New York (1993)
- 5) 日本酒造組合中央会：日本酒と料理の組み合わせに関する調査研究, (株)日本アプライドリサーチ研究所 (1989)
- 6) 小林信也：日本酒の官能評価, 醸協, 84, (12), 818-822 (1989)
- 7) M.SMITH: Neural Networks for Statistical Modeling, p.111-115, p.117-129, Van Nostrand Reinhold, New York (1993)