

〔生物工学会誌 第73巻 第5号 387-395, 1995〕

ニューラルネットワークと遺伝的アルゴリズムを用いた 吟醸酒の品質モデリング

各務 彰洋・花井 泰三・本多 裕之・小林 猛*

名古屋大学工学部生物機能工学科
〒464-01 名古屋市千種区不老町

(平成7年3月27日受付 平成7年6月5日受理)

Quality Modeling of *Ginjo* Sake Using a Neural Network and Genetic Algorithm

AKIHIRO KAKAMU, TAIZO HANAI, HIROYUKI HONDA, and TAKESHI KOBAYASHI* (*Department of Biotechnology, Faculty of Engineering, Nagoya University, Chikusa-ku, Nagoya 464-01*) *Seibutsu-kogaku* 73: 387-395, 1995.

This paper deals with the quality modeling of *Ginjo* sake using a neural network (NN) and genetic algorithm (GA). A NN model was constructed to estimate 7 sensory evaluations concerning the quality of *Ginjo* sake from 18 chemical component analytical values. The performance index, J , of the NN model was significantly small compared with that obtained using multiple regression analysis (MRA). Using the model, analytical data on the chemical components was estimated from the 7 given sensory evaluation values by means of a genetic algorithm, which was employed as an optimizing method. It was found that almost all the estimated values coincided with the actual values within an error range of less than 0.3.

[**Key words:** neural network, sensory evaluation, genetic algorithm, quality modeling, *Ginjo* sake]

最近、消費者の間で吟醸酒に対する関心が高まっており、その消費が増加しつつある。しかし、吟醸酒の製法は、いまだ手造りで現状の醗の工程は主にアルコールと日本酒度を指標として管理されている。これらを指標とした量的な制御は自動化しやすいが、質的な制御は熟練者の経験と勘に委ねられており、その制御ルール構築が望まれている。^{1,2)} 一般に清酒の品質は官能評価により測られており、品質を特徴づける原因となっている化学成分を特定したり、得られた情報を製造工程にフィードバックすることは難しい。したがって、目的品質の吟醸酒をつくるための製造管理を客観的指標を持って実施するためには、酒質と成分の関係を明らかにし、目的の品質の吟醸酒にはどのような成分がどのくらい入っているのかを決定しておく必要がある。

しかしながら、酒質と成分のあいまいな関係をモデリングするためには、化学成分の分析値と官能評価値の間に非線形な関係が存在する可能性があるため、従来の線形重回帰モデルで表現するには限界があると指摘されており、そのため NN (ニューラルネットワーク) やファジィ理論を応用した非線形モデリングが報告されている。^{3,4)} 我々も各官能評価値から総合評価値を推定するために、NN モデルを構築し、この手法の有効性を実証した。⁴⁾

一方、構築したモデルを用いて品質から成分を求めるためには、目的の官能評価値になるような最適な機器分析値の組み合わせを求める最適化問題を解けば良いと考えられる。しかし、NN のような非線形なモデルの場合、局所解が多く存在する可能性があり、従来の最適化手法では正確に解を求めることが難しく、膨大な時間と計算量がかかる。非線形最適化問題の解法としては、最近 GA (遺伝的アルゴリズム) が注目さ

* 連絡先, Corresponding author.

れており、プランニングやスケジューリング、制御、認識、モデリングなどの多くの応用が試みられている。^{3,5,6)}

そこで本論文では、NN を用いて機器分析値から官能評価値を推定する官能評価モデルを構築し、構築したモデルと GA を組み合わせて、目的の官能評価値を満足する吟醸酒の成分の推定を行うシステムの構築を試みた。

このシステムが実現されれば、目的品質の吟醸酒をつくるための製造管理への適用ができるだけでなく、ブレンディング工程への応用やマーケティングリサーチに基づいた種々の品質の吟醸酒づくりに関する方法論も展開できると考えられる。

解析方法

解析対象データ 前報⁴⁾と同様、1990年に愛知県食品工業技術センターで行われた市販吟醸酒61点に関する利き酒⁷⁾の結果を用いた。品質評価の項目および採点法は、国税庁市販吟醸酒利き酒の方法を基準にし、若干の変更を加えた。つまり、官能評価項目は、見た目の評価である色、香りに関する評価である立香・含香、味に関する評価である濃淡・甘辛・硬軟・熟度であり、1, 2, 3 点の三段階で15人の熟練者（パネリス

ト）により採点された。品質は通常パネリスト間の差をなくして平均的な評価値で判断されているので、解析にはすべてのパネリストの平均点を用いた。

機器分析値としては Table 1 に示すように、吟醸酒の品質に特に重要であると言われている各成分値に、原材料に関する数値を加え18種類を選択した。Table 1 には使用したデータの最小値、最大値、平均値を合わせて示す。品質全体に関わると思われる酸度、アミノ酸度、日本酒度、アルコール、香りに関するイソアミルアルコール (iAmOH)、酢酸イソアミル (iAmOAc)、カブロン酸エチル (EtCap)、熟度の指標になる 3-DG、色に関する着色度 (OD₄₃₀) および原料に関する粕歩合、精米歩合、その他として紫外外部吸収 (OD₂₆₀)、グルコース、ビルビン酸、アセトアルデヒドなどが含まれる。これら機器分析のうち香氣成分は吉沢の方法⁸⁾ 3-DG は岩野らの方法⁹⁾ により測定した。これら以外の13項目の機器分析は国税庁所定分析法¹⁰⁾ に従った。また甘辛の指標になる甘辛度、濃淡の指標になる濃淡度および E/A 比の3項目は以下の式に従って算出した。¹¹⁾

$$\begin{aligned} Amakarado = & 193593 / (1443 + (Nihonshudo)) \\ & - 1.16 (\text{Acidity}) - 132.57 \end{aligned} \quad (1)$$

$$\begin{aligned} Noutando = & 94545 / (1443 + (Nihonshudo)) \\ & + 1.88 (\text{Acidity}) - 68.54 \end{aligned} \quad (2)$$

$$E/A = 100 \times (iAmOAc / iAmOH) \quad (3)$$

これら成分値以外にも異臭成分などが吟醸酒品質に重要であると考えられる¹²⁾ が、本研究に使用したサンプルのうち「異臭あり」と評価されたサンプル数があまり多くなく、異臭成分の分析も困難であるため、本論文では異臭成分の解析については取り上げなかった。

NN の構造と評価方法 NN の構造を Fig. 1 に示




Fig. 1. Topology of three-layer NN for modeling the relation between chemical components and sensory evaluation.

Table 1. Input variables used in the study.

Component	Concentration		
	Low	High	Average
Acidity (ml)	0.95	1.65	0.95
Amino acidity (ml)	0.60	1.70	1.03
Nihonshudo (—)	+1.00	+9.50	+5.75
Alcohol (%)	15.2	17.9	16.4
OD ₄₃₀	0.006	0.072	0.014
OD ₂₆₀	0.084	0.282	0.182
Amakarado (—)	-0.80	0.001	-0.40
Noutando (—)	-1.62	-0.054	-0.922
Glucose (mg/ml)	5.60	14.0	9.10
Pyruvic acid (mg/l)	5.20	160	66.6
3-DG (OD ₅₃₀)	0.054	0.530	0.276
Acetaldehyde (ppm)	7.60	39.2	19.7
iAmOH (ppm)	95.6	161	119
iAmOAc (ppm)	0.60	18.1	4.47
E/A ratio (—)	0.50	13.2	3.71
EtCap (ppm)	0.00	2.90	1.22
Polishing ratio (%)	35.0	60.0	44.0
Cake ratio (%)	34.7	68.0	51.5

す。NN は入力層，中間層，出力層からなる3層構造で，機器分析値を入力して官能評価値を出力するように構成した。学習方法は一般に用いられているBPアルゴリズムに慣性項を導入した逐次修正法を用いた。¹³⁾ 初期の重みは乱数で与え，学習係数は0.002，慣性項の係数は0.9として学習を行い，ネットワークの構造を最適化するために中間層の数は必要に応じて変化させた。NNの入力値 (I_{ij}) および教師値 (T_i) は61個のデータセットの最大値と最小値の間で，0から1の間の値になるように式(4)，(5)に従い規格化した。

$$I_{ij} = \{ (j\text{-th chemical component of } i\text{-th Ginjo sake}) - (\text{minimum value of } j\text{-th chemical component}) \} / \{ (\text{maximum value of } j\text{-th chemical component}) - (\text{minimum value of } j\text{-th chemical component}) \} \quad (4)$$

$$T_i = \{ (\text{sensory evaluation of } i\text{-th Ginjo sake}) - 1 \} / 2 \quad (i=1 \sim 61, j=1 \sim 18) \quad (5)$$

ここで i は61種の吟醸酒に対応し， j は18種類の各機器分析値に対応する。モデルを構築するために，61個のデータセット中，40個をNNの学習用データとして，残りの21個を評価用データとして用いた。

学習用データに対する出力値 (O_i) も0から1の間の値であり，以下のように O_i と教師値 (T_i) の自乗誤差の平均を J_1 とし，評価用データに対する自乗誤差の平均を J_2 とした。

$$J_1 = \frac{1}{40} \sum_{i=1}^{40} (O_i - T_i)^2 \quad (6)$$

$$J_2 = \frac{1}{21} \sum_{i=41}^{61} (O_i - T_i)^2 \quad (7)$$

NNの評価には次の評価関数 J を用いた。

$$J = (J_1 + J_2) / 2 \quad (8)$$

重回帰分析 重回帰分析 (MRA) は前報⁴⁾ 同様，ワークステーション SP-20 (新日本製鐵) 上で統計解析ソフト SAS (SAS Institute Inc.) を用いて行った。

遺伝的アルゴリズムによる機器分析値の探索 GAによる探索は Simple GA⁵⁾ により行った。

遺伝子へのコーディングは実値コード化法により規格化後の各機器分析値の少数点以下の数字の8桁目までをそのまま8個のビット列に変換することにより各遺伝子として表現した。甘辛度，濃淡度，E/Aの3つは前述のように他の機器分析値から計算して求められるので，これら3つを除いた15種類の機器分析値を遺伝子にコードし，これらの遺伝子を繋ぎ合わせて染

色体とした。初期の個体は乱数を用いて決定し，40個体生成することにした。

各個体の適応度は次式に示すように目的の官能評価値 (規格化後の値) と官能評価モデルの出力値の絶対誤差の平均値で評価し，誤差の小さいものほど高い適応度を与えた。

$$F(j) = \sum_{i=1}^N |y_i - y_i^*| / N \quad (9)$$

$$f_j = 1 - F(j) \quad (10)$$

ここで y_i は官能評価モデルの出力， y_i^* は設定した官能評価値， N は官能評価モデルの出力の数， $F(j)$ は j 番目の個体の絶対誤差の平均， f_j は j 番目の個体の適応度である。

各個体の適応度を計算した後，ルーレットモデルに基づいた適応度比例戦略を用いることにより適応度の高いものを選んだ。交差は2つの個体のペアを作り，各機器分析値ごとに0.9の交差率で一点交差を行った。突然変異は0.01の突然変異率で任意に突然変異を起こす場所 (ビット) を決定し，乱数で遺伝子 (数字) を入れ替えた。

探索後の機器分析値の評価 探索後に得られた各機器分析値は以下に示すように0から1の値に規格化した実際の値と機器分析値の絶対誤差の平均値 E により評価した。

$$E_1 = \sum_{i=1}^m |x_i - x_i^*| / m \quad (11)$$

$$E_2 = \sum_{j=1}^n |x_j - x_j^*| / n \quad (12)$$

$$E = (E_1 + E_2) / 2 \quad (13)$$

E_1 はNNの学習用データに対する平均絶対誤差， E_2 は学習後のNNの評価用データに対する平均絶対誤差を示す。 x_i および x_j は規格化された実際の分析値， x_i^* および x_j^* はGAにより得られた分析値 (規格化されている) である。実際には学習用データから8個 ($m=8$)，評価用データから7個 ($n=7$) をそれぞれ任意に選び総数の1/4にあたる15個を用いて E_1 ， E_2 ， E を算出し，GAによる探索能力の傾向を評価した。

解析装置 NNとGAの計算には，パーソナルコンピュータ PC-9821 Ap2 (NEC) を，プログラム言語にはC言語を用いた。

結果と考察

各官能評価値と機器分析値の間の相関分析 NN

Table 2. Correlations between all variables.

No.	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
1 Color	1.00																								
2 Flavor top	0.05	1.00																							
3 Flavor base	0.16	0.91	1.00																						
4 Heavy-thin	0.55	0.30	0.35	1.00																					
5 Sweet-dry	0.19	0.03	0.05	0.44	1.00																				
6 Hard-soft	0.41	0.23	0.35	0.61	0.66	1.00																			
7 Aging	0.60	0.37	0.54	0.69	0.47	0.74	1.00																		
8 Acidity	0.13	0.11	0.20	0.22	-0.08	0.00	0.16	1.00																	
9 Amino acidity	0.09	0.28	0.29	0.36	0.12	0.21	0.27	0.43	1.00																
10 <i>Nihenshudo</i>	-0.02	-0.01	-0.02	-0.29	-0.17	-0.20	-0.16	-0.50	-0.58	1.00															
11 Alcohol	0.19	-0.41	-0.38	0.12	0.04	-0.03	-0.02	0.02	-0.07	0.00	1.00														
12 OD ₂₀₀	0.50	-0.24	-0.05	0.27	0.22	0.30	0.29	-0.03	-0.01	-0.04	0.10	1.00													
13 OD ₂₆₀	0.36	-0.19	-0.12	0.15	-0.23	-0.09	0.06	0.42	0.58	-0.32	0.21	0.13	1.00												
14 <i>Amakurado</i>	-0.09	-0.09	-0.18	0.10	0.27	0.21	0.02	-0.46	0.19	-0.54	0.00	0.09	-0.07	1.00											
15 <i>Noutando</i>	0.09	0.07	0.17	0.22	-0.05	0.04	0.15	0.97	0.49	-0.67	-0.01	-0.03	0.43	-0.26	1.00										
16 Glucose	0.15	-0.16	-0.16	0.34	0.37	0.37	0.16	0.07	0.34	-0.54	0.28	0.31	0.14	0.50	0.16	1.00									
17 Pyruvic acid	0.02	-0.16	-0.17	-0.12	0.06	0.03	-0.14	-0.09	-0.18	0.04	0.17	-0.08	-0.18	0.06	-0.07	0.12	1.00								
18 3-DG	0.02	-0.07	-0.08	-0.09	0.08	0.05	-0.09	-0.06	-0.12	0.03	0.13	-0.10	-0.21	0.03	-0.05	0.14	0.98	1.00							
19 Acetaldehyde	-0.04	0.10	-0.01	-0.06	-0.02	-0.25	-0.12	-0.08	-0.20	0.02	-0.02	-0.11	-0.25	0.07	-0.09	0.15	0.29	0.35	1.00						
20 iAmOH	0.13	-0.21	-0.14	-0.01	-0.14	-0.06	0.03	0.42	0.27	-0.25	0.14	0.12	0.52	-0.14	0.41	-0.02	-0.28	-0.33	-0.25	1.00					
21 iAmOAc	-0.13	-0.31	-0.26	-0.30	-0.22	-0.26	-0.21	0.10	-0.02	0.13	0.11	-0.09	0.12	-0.23	0.70	-0.09	-0.06	-0.06	-0.07	0.41	1.00				
22 E/A ratio	-0.16	-0.27	-0.23	-0.30	-0.19	-0.23	-0.21	0.02	-0.06	0.18	0.08	-0.11	0.02	-0.21	-0.01	-0.07	-0.01	0.01	-0.04	0.22	0.97	1.00			
23 EtCap	0.23	-0.78	-0.75	-0.16	-0.04	-0.16	-0.26	-0.17	-0.20	0.20	0.58	0.26	0.31	-0.04	-0.20	0.16	0.19	0.11	-0.17	0.25	0.33	0.29	1.00		
24 Polishing ratio	0.13	0.37	0.41	0.34	0.17	0.28	0.41	0.06	0.39	-0.20	-0.24	-0.06	0.17	0.16	0.07	0.00	-0.34	-0.29	-0.17	0.08	-0.32	-0.35	-0.31	1.00	
25 Cake ratio	0.02	-0.29	-0.35	-0.18	0.10	-0.04	-0.29	-0.32	-0.25	0.16	0.09	0.02	-0.20	0.15	-0.28	0.13	0.37	0.32	0.23	-0.32	-0.05	0.01	0.27	-0.52	1.00

によるモデリングに先立ち、各官能評価値と機器分析値の間で相関分析を行った。結果を Table 2 に示す。各官能評価値と相関が強い機器分析値を調べて見ると、以下のような結果となり、立香、含香に与する EtCap を除いて強い相関を示すものはないことがわかった。一般酒に対しての解析では官能評価値である甘辛、濃淡と成分値である甘辛度、濃淡度の間には、0.9 近い相関係数が報告されている¹¹⁾が、本研究ではかなり低い相関係数 (0.2~0.3) となった。これは一般酒では品質的にある程度ばらつきがあるが、吟醸酒では品質がかなり似かよっており、その評価には甘辛度、濃淡度以外の成分が関与しているためと考えられる。他の相関係数があまり高くないのは、官能評価値と成分値の間に高い非線形関係が存在するためと予想される。

色：着色度 (0.50)、紫外外部吸収 (0.36)

立香：EtCap (-0.78)、アルコール (-0.41)、精米歩合 (0.37)

含香：EtCap (-0.75)、精米歩合 (0.41)、アルコール (-0.38)、粕歩合 (-0.35)

濃淡：アミノ酸度 (0.36)、精米歩合 (0.34)、グルコース (0.34)

甘辛：グルコース (0.37)、甘辛度 (0.27)

硬軟：グルコース (0.37)、着色度 (0.30)、精米歩合 (0.28)

熟度：精米歩合 (0.41)、粕歩合 (-0.29)、着色度 (0.29)、アミノ酸度 (0.27)、EtCap (-0.26)

また、機器分析値の間で相関の強いものは、酸度と濃淡度 (0.97)、3-DG とピルビン酸 (0.98) が挙げられる。

NN による官能評価モデルの構築 18種類の機器分析値から各官能評価値を推定する NN の構築を行った。中間層のユニットの数を変えて何回か学習を行い、誤差 J の値が最小になるような中間層のユニットの数を用いた。また、BP 法により NN を学習させた場合、学習しすぎると汎化が悪くなるという問題点があるので、NN が過剰学習しないように誤差 J が最小値となったところで学習を終了させた。

学習後の NN を用いて 18種類の機器分析値から各官能評価値を推定した結果を Fig. 2 に示す。横軸を各官能評価値の実際の値、縦軸を NN による推定値としているので、対角線上に点が集まるほどモデルの精度が良いといえる。立香、含香ではかなり対角線上に点が集まっている。それぞれのモデルの誤差 J と相関係数を Table 3 に示す。NN の結果は色を除いて J 値は 0.014 以下になった。これは誤差が学習用、評価用を含めて平均して 12% 以下に抑えられていることを示す。濃淡、熟度は MRA と比較して誤差は小さいものの相関係数がやや劣った。甘辛、硬軟では誤差はかなり小さくなったが相関係数が小さい。これは評価値自体があまりばらついていないためである。色に関しては相関係数は高いものの、誤差も 20% と大きくなった。しかし、3 点法の評価値を 0~1 に規格化した場合、最大 25% の誤差を含むと見積もられるので、こ




Fig. 2. Modeling of sensory evaluation using the trained NN. Symbols: ×, data for learning; ●, data for evaluation.

Table 3. NN model and MRA estimation results.

Sensory evaluation	NN		MRA	
	<i>J</i> value	Correlation coefficient	<i>J</i> value	Correlation coefficient
Color	0.0374	0.70	0.0440	0.61
Flavor top	0.0090	0.86	0.0098	0.85
Flavor base	0.0071	0.86	0.0071	0.86
Heavy-thin	0.0132	0.59	0.0264	0.37
Sweet-dry	0.0059	0.45	0.0097	0.32
Hard-soft	0.0070	0.62	0.0096	0.54
Aging	0.0138	0.56	0.0197	0.56

これらの結果を考慮に入れると NN により, ある程度官能評価値を推定することができたといえる。

NN モデルの精度を明らかにするため, 従来の重回帰モデルを構築して精度を算出した。使用した重回帰モデルは変数減少法などの最適化を行っていないため, 冗長な変数も取り込んでおり, 結果として十分な精度が得られていない。しかしこれは NN モデルでも同様であるため本論文は両者の精度と相関係数を直接比較することとした。結果を Table 3 に示す。ほとんどの官能評価値に関して, NN モデルは重回帰モデルと同等あるいはそれ以上の精度が得られたことがわかる。含香と立香といった香りに関する官能評価値に対しては, 吟醸酒の香りの主成分である EtCap が加えられていることに起因して, 両方のモデルで精度が良かった。硬軟, 濃淡, 甘辛のような味に関する官能評価値に対しては重回帰モデルよりも NN モデルの方が精度が良かった。しかし相関係数は立香, 含香に比べて小さいことから, これらの官能評価値と機器分析値の間に非線形な関係があると推測できた。

また両方のモデルの精度を向上させるためには, ①ファジィニューラルネットワーク (FNN) などのモデリング手法の改良¹⁹⁾および②現在は固定されている 18 入力変数を変数減少法などを用いた入力変数の選択, について検討する必要がある。

学習後に得られたモデルの解析 学習後の NN の重みには何らかの知識が習得されていると考えられる。そこで, 重みの解析を行い, 以下に詳細を示す。また NN による推定の過程で特に重要になっているものを重要度の順に Table 4 に示す。

[色を推定するモデル] 色を推定する NN では着色度, 紫外外部吸収, 濃淡度など見た目や味の濃淡が重要となっているが, 重回帰モデルでは色よりも味の方

Table 4. Input variables contributing highly in the NN model and MRA.

Sensory evaluation	NN				MRA			
	Color	Flavor top	Flavor base	Heavy-thin	Sweet-dry	Hard-soft	Aging	
	OD ₄₃₀ EtCap EtCap Alcohol Nihonshudo Glucose OD ₄₃₀	Glucose Amino acidity Amino acidity EtCap Amino acidity Amino acidity 3-DG	OD ₂₆₀ iAmOH Polishing ratio iAmOAc Acetaldehyde Acetaldehyde Noutando	E/A Nihonshudo Cake ratio OD ₂₆₀	Noutando E/A E/A E/A Nihonshudo Amakarado 3-DG	Acidity iAmOAc iAmOAc iAmOAc Amakarado Nihonshudo Pyruvic acid	iAmOAc Acidity Acidity Pyruvic acid Amakarado	OD ₄₃₀ E/A iAmOH 3-DG Nihonshudo




Fig. 3. Generation dependency of value of fitness.

が重要となっていた。よって、NNの方が精度が良くなったのは色を重視する構造になったためであると考えられる。

〔立香を推定するモデル〕 立香を推定するNNでは吟醸香の主成分と考えられているEtCapがもっとも重要となっていたが、重回帰モデルではEtCapではなくiAmOAc, E/Aが重要になっていた。また、NNではアミノ酸度も重要となっており、香り成分の生成にアミノ酸が重要な役割を果たしていることが考慮されている。

〔含香を推定するモデル〕 含香を推定するNNでは立香の場合と同様にEtCap, アミノ酸度が重要となっており、重回帰モデルにおいても立香と同様な分析値が重要となっていた。しかし、NNにおいては精米歩合、粕歩合といった項目が重要となっている点が注目される。

立香, 含香について重回帰モデルでEtCapが選択されなかった理由は明確ではないが、入力値として18項目すべて取り込まれており、冗長な変数が入力されることによる相互作用も1つの原因と考えられる。

〔濃淡を推定するモデル〕 濃淡を推定するNNではアルコール, EtCap, iAmOH, 紫外外部吸収といったものが重要となっていた。味の濃淡に対してはアルコールと紫外外部吸収が大きく影響し、またEtCapのような香りの高低も味の濃淡に影響していることがこれより読みとれる。重回帰モデルでは香りを推定するモデルの場合と同様にiAmOAc, E/A, つまり、味ではなく香りの高低が重要となっており、この違いが精度の違いに影響している一つの要因であると考えられる。

〔甘辛を推定するモデル〕 甘辛を推定するNNで

Table 5. Example of outputs from NN model.

Sensory evaluation	Estimated value	Objective value
Color	1.83	1.79
Flavor top	1.51	1.53
Flavor base	1.33	1.33
Heavy-thin	1.93	1.93
Sweet-dry	1.99	2.07
Hard-soft	2.04	1.80
Aging	1.76	1.67
Fitness f_j	0.97	

は日本酒度, アミノ酸度のような味に関する分析値が重要となっていた。特に日本酒度は糖の量に関係しており、妥当なものが重要となっていると考えられる。また、重回帰モデルでも、甘辛度, 日本酒度, 酸度が重要となっており、従来の経験的な知識と一致していた。

〔硬軟を推定するモデル〕 硬軟を推定するNNではグルコース, アミノ酸度のような味に関する分析値が重要となっていた。また、重回帰モデルでも、日本酒度, 甘辛度のような味に関するものが重要となっており、従来の経験的な知識と一致していた。

〔熟度を推定するモデル〕 熟度を推定するNNでは色, 3-DGが重要となっていた。色が濃いものは製造してから時間が経ち品質が劣化しているものと考えられ、3-DGは熟度の指標になると言われているので、これらが熟度の推定の過程で重要となっているのは経験的な知識と一致する。重回帰モデルではビルビン酸も重要となっていたが、これは相関分析の結果よりビルビン酸と3-DGはかなり相関があったためである。

以上のように構築した色, 立香, 含香, 濃淡, 甘辛, 硬軟, 熟度を推定するNNモデルを7個並列に並べ、18種類の機器分析値を使う官能評価モデルとした。このモデルを使って、逆に目的の官能評価値(品質)を得るような機器分析値を推定するためには、18種類の機器分析値を設定し、NNに入力し、出力値を実値と比較して入力値の適応度を判断することになる。これは組み合わせ最適化問題であり、本研究ではこの解法として収束性が良く、計算時間も少ないGAを使用した。

GAのパラメータの検討 GAには交差率, 突然変異率, 個体数などいろいろなパラメータがある。今回は交差率, 突然変異率のみ検討し、残りのパラメータは固定して行った。ある吟醸酒のデータを用いて、

Table 6. Component values of a *Ginjo* sake estimated by GA.

Component	Estimated value	Actual value
Acidity (ml)	1.28	1.15
Amino acidity (ml)	0.61	0.90
<i>Nihonshudo</i> (—)	3.51	8.00
Alcohol (%)	17.3	17.4
OD ₄₃₀	0.023	0.012
OD ₂₆₀	0.132	0.157
<i>Amakarado</i> (—)	-0.226	-0.484
<i>Noutando</i> (—)	-0.764	-1.22
Glucose (g/l)	13.9	9.90
Pyruvic acid (ppm)	112	160
3-DG (OD ₅₃₀)	0.284	0.53
Acetaldehyde (ppm)	32.5	31.5
iAmOH (ppm)	126	110
iAmOAc (ppm)	2.23	5.20
E/A ratio (—)	1.76	4.70
EtCap (ppm)	1.89	2.90
Polishing ratio (%)	35.4	40.0
Cake ratio (%)	63.0	57.5

交差率と突然変異率をいろいろな値に設定して収束の様子を観察したところ、交差率が小さすぎると収束しにくく、突然変異率が小さすぎると局所解に陥ることがあり、突然変異率が大きすぎると逆に収束しにくくなるのが観察された。そこで、細かく二つの値を変化させて何回か計算を行ったところ、交差率0.9、突然変異率0.01という値が最適であることがわかった。これらの値を用いて計算を行った場合の収束の様子の一例を Fig. 3 に示す。各世代の適応度は400世代から600世代の間に最大に達したが、その後突然変異の影響で適応度が下がるということも観察されたので、世代数は600世代を最大とし、その間で適応度が最大になった個体を収束値とすることにした。

GA による機器分析値の探索 ある吟醸酒に対する計算結果の一例を Table 5 および 6 に示す。目的品質としては、それぞれの官能評価値として NN 構築時と同様、有効数字 3 桁の値を用いた。600世代の計算後、最大の適応度は0.97となり、Table 5 に示すように目的の品質（官能評価値）によく一致していることがわかった。この場合のコーディング遺伝子を解析したところ、Table 6 に示すように機器分析値をある程度推定できていた。さらに、他のいくつかの吟醸酒に関して GA による探索を行い、その結果を Table 7

Table 7. Average E values of components estimated by GA.

Component	E_1	E_2	E
Acidity (ml)	0.287	0.237	0.262
Amino acidity (ml)	0.307	0.228	0.268
<i>Nihonshudo</i> (—)	0.317	0.218	0.268
Alcohol (%)	0.174	0.382	0.278
OD ₄₃₀	0.120	0.075	0.098
OD ₂₆₀	0.227	0.314	0.271
<i>Amakarado</i> (—)	0.508	0.379	0.443
<i>Noutando</i> (—)	0.245	0.195	0.220
Glucose (g/l)	0.226	0.256	0.241
Pyruvic acid (ppm)	0.211	0.224	0.218
3-DG (OD ₅₃₀)	0.384	0.307	0.346
Acetaldehyde (ppm)	0.185	0.373	0.279
iAmOH (ppm)	0.468	0.349	0.409
iAmOAc (ppm)	0.333	0.357	0.345
E/A ratio (—)	0.374	0.383	0.379
EtCap (ppm)	0.137	0.165	0.151
Polishing ratio (%)	0.332	0.294	0.313
Cake ratio (%)	0.226	0.294	0.260
Average of f_j	0.98	0.98	0.98

にまとめて示した。平均の適応度は0.98と高かった。分析値のうちでは EtCap、着色度に関して特に誤差が小さくなった。これらは NN モデルの重み解析 (Table 4) で重要度が高かったため、精度も高くなったものと思われる。重み解析で次に重要度が高かったアミノ酸度の収束はそれほど良くなかった。また、誤差がもっとも大きかった項目は甘辛度であり、次いで iAmOH、E/A 比となった。E/A 比が高いのは iAmOH が推定できていないことによる。これらを除いた他の項目の誤差は30%以下であった。さらに精度を上げたいところだが、もともとの利き酒の結果（官能評価値）に含まれる誤差および構築した NN モデルの推定精度（最大誤差20%）を考えるとこれ以上は困難であろうと予想される。推定精度の悪い機器分析値に関しては、FNN などの新たなモデリング手法の導入¹⁴⁾や機器分析データを増やすことおよび入力変数の選択により NN モデルの精度を向上させることで対処できると考えられる。

要 約

本研究ではまず、NN を用いて機器分析値から官能

評価値を推定するモデルを構築した。構築した NN を官能評価モデルとして用い、これと GA を組み合わせることにより、逆に品質（官能評価値）から成分（機器分析値）の値を求めるシステムの構築を行った。GA を用いることによりある程度機器分析値を決定することが可能であることが明らかになった。さらに評価関数の改良により成分の異なる組み合わせを同じ官能評価値の値から探索でき、品質モデリングが可能であることを示した。

本研究は愛知県食品工業技術センターの協力の下で行われた。官能評価値の収集および化学成分分析法に関し、多くのご助言を賜った同センターの深谷伊和男氏、西田淑男氏に感謝致します。また本研究の一部は文部省科学研究費試験研究 B(No. 07555257) および内藤科学技術研究助成金の援助を受けました。

文 献

- 1) 西田淑男, 深谷伊和男, 高橋伸幸, 花井泰三, 本多裕之, 小林 猛: 生物工学, **72**, 267-274 (1994).
- 2) 花井泰三, 本多裕之, 高橋伸幸, 西田淑男, 深谷伊和男, 小林 猛: 生物工学, **72**, 275-281 (1994).
- 3) Matsuura, K., Hirotsune, M., Hamachi, M., and Nunokawa, Y.: *J. Ferment. Bioeng.*, **79**, 45-53 (1995).
- 4) 各務彰洋, 花井泰三, 本多裕之, 西田淑男, 深谷伊和男, 小林 猛: 生物工学, **73**, 199-205 (1995).
- 5) 北野宏明: 遺伝的アルゴリズム, p. 3-41, 産業図書 (1993).
- 6) Furuhashi, T., Nakaoka, K., Morikawa, K., Uchikawa, Y.: *Proceedings of 9th FUZZY System Symposium* (Sapporo), p. 101-104 (1993).
- 7) 深谷伊和男, 幅 靖志, 久野敦史, 遠山久男, 森下浩伸, 金田富士彦, 服部伸重, 青木敏浩, 大倉鎮夫, 山田鐘美: 愛知県食品工業技術センター年報, **12**, 1-9 (1990).
- 8) 吉沢 淑: 醸協, **68**, 59-61 (1974).
- 9) 岩野君夫, 来間健次, 衣山陽三, 中村伝市, 河地元彦: 醸協, **65**, 59-62 (1970).
- 10) 日本醸造協会: 第4回改正国税庁所定分析法注解, p. 229-231 (1990).
- 11) 佐藤 信, 川島 宏, 丸山良光: 醸協, **69**, 774-777 (1974).
- 12) 西村 顕, 近藤恭一, 中沢英五郎, 三島秀夫, 竹村成三: 醸酵工学, **67**, 237-244 (1989).
- 13) Rumelhart, D. E., Hinton, G. E., and Williams, R. J.: *Nature*, **323**, 533-536 (1986).
- 14) 長谷川貴史, 堀川慎一, 古橋 武, 内川嘉樹, 島村 滋, 山田稔久, 國武意智, 大塚 晋: 日本フュージ学会誌, **5**, 409-419 (1993).