LVQ法によるインターホンの良否識別

正員	紙本	伸明	(松下電工)
正員	阿部	敏郎	(松下電工)
非会員	林	鍵	(大阪府立大学)
正員	大松	繁	(大阪府立大学)

Quality Recognition of Interphones by the LVQ Method

Nobuaki Kamimoto, Member (Matsushita Electric Works), Toshiro Abe, Member (Matsushita Electric Works), Lin Ken, Non-member (Osaka Prefecture University), Sigeru Omatu, Member (Osaka Prefecture University)

Automatic quality recognition of interphones has been well developed and it is important that the classifier must be highly accurate. Generally, the accuracy is represented by a recognition rate for sample data. To evaluate it more strictly, we will introduce a reliability criterion. In the pattern recognition, neural networks (NNs) have been adopted. Among them a competitive NN has a simple structure and can explain the input/output relation more easily than a layered NN based on the error back-propagation method. Thus, we adopt a competitive NN for the recognition of good and no good interphones where the learning vector quantization (LVQ) method is used for training. Finally, we show the effectiveness of the proposed method by applying it to real interphone data.

キーワード：電子音識別、インターホンの良否判別、競合ニューラルネットワーク、学習ベクトル量子化 (LVQ)

1. まえがき

一般住宅分野のIT化が進み、住宅のセキュリティ商品としてインターホンが開発されてきた。このインターホンの報知音は電子的に作られており、この報知音に基づいた良否識別を熟練した検査員の官能評価で行っているのが現状である。この場合、下記のような問題点が生じている。

- (1) 複数の検査員の識別結果が異なることがある。
- (2) 検査員の熟練度や疲労等によって、判定結果が変動する。
- (3) 判定した結果が、定量的に把握できない。

近年、コンピュータの発達およびパターン認識技術の進歩により、音声認識分野で人間の声紋分析がコンピュータで自動的に行われている。その中で、ニューラルネットワーク (Neural Network、以後、NNと略記する) を用いたニューロパターン認識は、学習能力や汎化能力を有し、音声の官能評価に変わる識別手法として注目されている^{(1) - (5)}。

ニューロパターン認識手法としては、誤差逆伝播 (error back-propagation、以後、BPと略記する) 法という学習法に基づいた階層型 NN⁽¹⁾ や、学習ベクトル量子化 (learning vector quantization、以後、LVQと略記する) 法による競合型 NN⁽⁴⁾、⁽⁵⁾ などがある。しかし、階層型 NNは、1) 認識システムの構造がブラックボックスである、2) 誤認識の原因が解明しにくい、3) 学習に長時間を要する、4) 中間層のニューロン数の決定法があいまいである等の欠点がある。他方、競合型 NNは、入力

層と出力層からなる2層構造であり、入力の次元が高くなった場合にも、クラスタ分類を容易に行うことができ、入出力の因果関係の意味付けも容易である。そこで本論文では、良否の特徴を有する電子音のオクターブバンド波形を、競合型NNへ適用する新しい検査手法を提案し、従来から行われている官能検査の代替性について定量的に考察する。

まず、インターホン音響データの計測法と計測されたデータの前処理法について述べる。つぎに、その前処理によって選択された周波数帯域に対するオクターブバンド波形を求める。さらに、ここで用いるLVQ法による学習法について述べる。最後に、提案手法の有効性について定量的に検証する。

2. インターホン音響データの収録

図1は、本論文で使用する識別システムの概要を示している。

図1 処理システムのブロック図

Fig. 1. Block diagram of the processing system.

本論文では、データの収録時間を6 secとし、A/D変換のサンプリング周波数を44kHzとした。ただし、人間の可聴周波数の限界は20kHzであり、サンプリング周波数は40kHzで充分であ

る。しかし、一般の人間の耳で識別できない高周波成分が識別に有効なことが多いので、余裕を持って 22kHz までのデータを取り扱えるように、44kHz のサンプリング周波数とした。実際に得られた音響データを図 2 に示す。ただし、図 2 (a) は全体の波形を示し、図 2 (b) はそれを拡大したときの部分波形を示している。上述のサンプリング周波数 44kHz の場合には、サンプリング間隔は約 $22.7 \mu\text{sec}$ となり、計測した信号は 264,000 個のデータとなる。その中で、インターホンの音響データは後半部分の 3 sec とし、132,000 個のデータである。

図2 音響信号波形 (a)全体の波形、(b)一部を拡大した波形

Fig.2. Acoustic signal waves.

- (a) Total wave form of an acoustic signal.
- (b) Zooming wave form of the acoustic signal.

3. データの前処理

〈3・1〉 離散フーリエ変換 計測した 132,000 個のインターホン音響データを NN に直接入力すると、入力層のニューロン数が多いため、NN の学習が収束しないとか、良否識別のための計算時間がかかりすぎるなどの問題が生じている。そこで、学習や良否識別の時間を短縮するために、識別すべき音響データの特徴ができるだけ明確になるような周波数帯域を抽出する。そのために、インターホン音響信号の時系列データに対して、離散フーリエ変換 (discrete Fourier transform、以後、DFT と略記する) を行い、時間領域での信号を周波数領域で考察する。計測されたデータを x_i ($i=1, \dots, L-1$) とするとき、DFT は次式で与えられる。

$$X_k = \sum_{i=0}^{L-1} x_i e^{-j2\pi k i / L}, \quad k = 0, 1, \dots, L-1 \quad (1)$$

しかし、上式の計算には L^2 個の乗算が必要であり、本論文では計算時間を短縮するために、次節の高速フーリエ変換を用いる。

〈3・2〉 高速フーリエ変換 高速フーリエ変換 (fast Fourier transform、以後、FFT と略記する) は、データ数 L の場合、乗算回数は $L \log_2 L$ 回に減少できることが知られている⁽⁶⁾。

図3 1,024 個の幅をもつ窓関数を用いた FFT スペクトル

Fig.3. FFT spectrum of acoustic signals using the window of 1,024 width.

以下では、FFT を用いたデータ解析を行う。そこで、図3のようなインターホン音響データに対して、時間軸に沿って移動しながら、1,024 個のデータについて順次 FFT を行う。このとき、132,000 個のデータに対しては、129 回の FFT が必要である。ただし、129 回目のデータには 96 個の計測データをすべて 0 と仮定した。

4. スペクトルデータとオクターブバンドの抽出

〈4・1〉 スペクトルデータ 図2(a)の音響信号波形に〈3・2〉の FFT で求めたスペクトルデータを図4に示す。

図4 FFT 処理された信号波形

Fig.4. Acoustic signal waves by FFT.

ただし、図3のように与えられた 1,024 個のデータに対して、FFT を施したときの周波数を横軸とし、1,024 個ごとの時間軸を縦軸とする。このスペクトル波形から、良否の特徴が顕著にで

でているスペクトル部分を抽出することを次節で述べる。

＜4・2＞ オクターブバンドの抽出 図4から分かるように、スペクトル波形は特定の周波数帯域内で、類似した挙動をしている。そこで、この特徴を表現するために、図4からJISで決められた周波数帯域でのスペクトルの平均値をとった時間波形を、オクターブバンド波形と呼ぶ。図5、6は、音圧を電圧に変換した値を時間の推移に従って変化する、オクターブバンド波形を表している。良品の場合のオクターブバンド波形は、図5に示すように、殆ど同じ形をしている。良品とならない異音品のオクターブバンド波形を図6に示すが、図5と異なり、 $n=45$ から $n=80$ までの範囲で、レベルが急激に変化している。このように、選ばれた周波数帯域においては、良品は類似な振舞の波形であるが、異音品はさまざまな振舞の波形となっている。

図5 良品のオクターブバンド波形

Fig.5. Octave band waves for good cases.

図6 異音品のオクターブバンド波形

Fig.6. Octave band waves for no good cases.

5. LVQ法の概要

本論文では、競合型NNの学習アルゴリズムとしてLVQ法を用いる。この方法は、競合学習における教師なし分類と異なり、競合層ユニットの属するカテゴリが予め決められた教師付き学習を行う方法で、入力の次元が高い場合にも適用可能な方法である⁽⁴⁾。

LVQ法を採用した理由は、以下の(1)～(5)の要求によるためである。

- (1) 本システムで計測されたデータには、人の話し声、機械の回転音や動作音、他のサンプル音などが含まれることが多い。したがって、本良否識別法は、これらの周囲環境にロバストな識別手法であることが望ましい。
- (2) 本良否識別法では、識別結果の信頼度が定量的に把握できることが求められている。
- (3) 本良否識別法では、対象とする商品を変更しても、容易に対応できることが望ましい。
- (4) 本良否識別法では、学習や識別の計算過程が分かり易く、定量的に表された数値に基づいて、教師データやシステムを改良できることが望ましい。
- (5) 本良否識別法では、人間の官能による評価結果を、忠実に識別システムに反映でき、学習や識別結果に基づいたシステムの改良が容易であることが求められている。

以下では、競合型NNの構造を＜5・1＞で述べ、LVQ法の概要を＜5・2＞に、本論文で用いるLVQ1法⁽⁴⁾の概要については＜5・3＞で述べる。

＜5・1＞ 競合型NNの構造 競合型NNは図7に示されるような2層構造になっている。第1層は入力層と呼ばれ、パターンを受け取り次の層へ受け渡す処理を行う。第2層は、競合層と呼ばれ、入力パターンの分類を行う。これらを構成するユニットは、それぞれ、入力層のユニットと結合されている。それぞれの結合には、結合荷重が与えられている。ここで、入力層のユニット i から競合層のユニット j への結合荷重を w_{ij} と表すことにする。また、図7に示すように入力層のユニット数を N 個、競合層のユニット数を M 個とし、 d_i ($i=1, 2, \dots, M$) は入力ベクトル $\mathbf{x} = (x_1, x_2, \dots, x_N)$ と結合荷重ベクトル $\mathbf{w}_i = (w_{i1}, \dots, w_{iN})$ とのユークリッド距離を表している。

図7 競合型NNの基本構造

Fig.7. Basic structure of a competitive NN.

＜5・2＞ 学習ベクトル量子化法 (LVQ法) 競合層のユニットでは、入力された入力ベクトル $\mathbf{x}$ とその競合層のユニットが持つ結合荷重ベクトル $\mathbf{w}_i$ とのユークリッド距離 d_i を次式で計算する。

$$d_j = \|\mathbf{x} - \mathbf{w}_j\| = \sqrt{\sum_{i=1}^N (x_i - w_{ji})^2} \quad (3)$$

競合層すべてのユニットの中で、 d_j が最も小さくなるユニット c を選び、それを勝者ユニットと呼ぶ。その勝者ユニットが正しいクラスターに属しているか否かによって、その勝者ユニットの結合係数を好ましいクラスターに属するように修正するのが LVQ 法である。

まず、競合層の各ユニットは、いずれのカテゴリを表現するかを予め決めておく。LVQ 法は、これらの教師パターンベクトルと競合層ユニットのカテゴリ情報を用いて学習を行う教師付き学習である。この NN の LVQ 法による構造を図 8 に示す。

図8 LVQ法を用いた競合型NN

Fig.8. A competitive neural network by the LVQ method.

ここでは LVQ 法として、多少バラツキがあるデータ系列に対しても識別がロバストであり、しかも構造が簡単で収束性が速い、次節に示すような LVQ1 法を採用する。

＜5・3＞ LVQ1 法 ここでは、LVQ 法の基本的なアルゴリズムである LVQ1 法について述べる。結合荷重ベクトルの初期値は、一般に乱数で与えられることが多い。LVQ 法では学習に用いる教師パターンベクトルが属するカテゴリは、既知であるとしている。それぞれのカテゴリに属する教師パターンベクトルの平均ベクトルを計算し、これらの平均値を結合荷重ベクトルの初期値として用いる。これによって、結合荷重ベクトルの初期値に乱数を用いた場合よりも、学習速度の向上が期待できる。

結合荷重ベクトルの初期値を $\mathbf{w}_i(0)$ ($i=1, \dots, M$) とし、教師パターンベクトルの入力回数が t 回のときの結合荷重ベクトルを $\mathbf{w}_i(t)$ とする。 t 回目の教師パターンベクトル $\mathbf{x}(t)$ が入力された後、式(3)で競合を生じ、勝者ユニット c が決定される。このとき、結合荷重ベクトルは式(4)のように更新される。

$$\mathbf{w}_c(t+1) = \begin{cases} \mathbf{w}_c(t) + \alpha(t)(\mathbf{x}(t) - \mathbf{w}_c(t)) & (\mathbf{x}(t) \text{ と 競合勝者 } c \text{ のカテゴリが等しい場合}) \\ \mathbf{w}_c(t) - \alpha(t)(\mathbf{x}(t) - \mathbf{w}_c(t)) & (\mathbf{x}(t) \text{ と 競合勝者 } c \text{ のカテゴリが異なる場合}) \end{cases}$$

$$\mathbf{w}_i(t+1) = \mathbf{w}_i(t), \quad (i \neq c) \quad (4)$$

$\alpha(t)$ は $0 < \alpha(t) < 1$, $t \rightarrow \infty$ のとき、 $\alpha(t) \rightarrow 0$ を満足する関数であり、学習率と呼ばれている。ここでは、

$$\alpha(t) = \alpha_0 \left(1 - \frac{t}{T}\right) \quad (5)$$

を用いる。ただし、 T は最大学習回数、 α_0 は学習率の初期値 ($0 < \alpha_0 < 1$) を示す。

式(4)から分かるように、勝者ユニット c と教師パターンベクトル $\mathbf{x}(t)$ のカテゴリが一致した場合、結合荷重ベクトルは、教師パターンベクトルに近づくように更新される。しかし、勝者ユニット c が教師パターンベクトル $\mathbf{x}(t)$ のカテゴリと一致しなかった場合、結合荷重ベクトルは教師パターンベクトルから遠ざかるように更新される。図9は、LVQ1 法の学習過程を示している。以後、記述を簡単にするために LVQ1 法を LVQ 法とする。

$\mathbf{w}_c(t)$: t 回目の学習での勝者ユニットの結合荷重ベクトル
 $\mathbf{x}(t)$: t 回目の学習での教師パターンベクトル

図9 結合荷重ベクトルの更新

Fig.9. Adjustment of a connection weight vector.

6. 実験および考察

この章では、インターホンの音色である教師データに対して、NNを用いて学習した後に、それを用いてチェック用データを識別し、提案手法の有効性を評価する。

＜6・1＞ 学習用データ 以下では、図5に示すような8個の良品データのサンプルおよび図6に示すような8個の異音品データのサンプルを学習データとする。図4のFFT処理された信号波形の時間軸から分かるように、図7では $N=129$ である。

＜6・2＞ 異音品3ユニットでの学習 前節＜6・1＞で述べた学習データに対して、各カテゴリのユニットを、良品については2個、異音品については3個とし、NNを学習させたときの結果を表1に示す。ただし、表1の中の各記号は、C0: 異音品カテゴリ、

C1：良品カテゴリ、d0, d1, d2, g0, g1は、カテゴリC0およびC1のコードベクトルであり、標本データ（入カベクトル）との距離を示している。

最小距離は、d0, d1, d2, g0, g1の中で最小になる距離を示す。識別結果であるカテゴリ（m, n）は、mがカテゴリCmであり、nはそのカテゴリのユニットnを表している。

標本データは、B01～B08が異音品でカテゴリ0であり、G01～G08が良品でカテゴリ1であることを表す。例えば、B0i（i=1, 2, ..., 8）は異音品で第i番目のサンプルを示している。

表1で網かけ欄（標本データB02）は、学習結果が正しくないことを示している。*印は発火ユニットと異なるカテゴリの距離が「1」以内のものが存在していることを示す。ここでは、本来カテゴリとして異音品となるべきB07が、他の異音品と大きく異なり、むしろ良品のユニット0に近くなっていると考えられる。さらに、良品で学習させた標本データの中でG08は、<4・2>に示した他の良品標本データと比べて、大きくずれており、教師データとして学習させるには不相当であると判断した。そこで、表2に示すように、B07に近い異音品を追加し、逆にばらつきが少ない良品の教師データを4個に減らして再度学習させた。表2の中の各記号は、表1と同様である。標本データは、B01～B11がカテゴリ0であり、G01～G04がカテゴリ1であることを表す。

表1 異音品3ユニットでの学習結果
Table 1. Learning results for 3units of no good samples.

標本データ	C0			C1		最小距離	カテゴリ (m, n)	
	d0	d1	d2	g0	g1			
B01	9	36	44	39	30	8.52	0	0
B02	40	22	22	20	20	19.79	1	0
B03	38	28	0	24	26	0	0	2
B04	8	27	33	29	19	8.41	0	0
B05	27	12	34	18	17	11.99	0	1
B06	25	10	30	16	16	10.26	0	1
B07 *	39	11	30	12	23	11.11	0	1
B08	37	11	28	13	21	10.85	0	1
G01	23	21	25	23	10	10.16	1	1
G02	47	26	25	20	28	20.02	1	0
G03	25	19	27	19	7	6.92	1	1
G04	29	13	26	9	18	9.37	1	0
G05	40	14	28	12	23	11.53	1	0
G06	30	13	27	15	10	9.84	1	1
G07	29	13	26	9	18	9.37	1	0
G08 *	33	10	25	10	18	9.62	1	0

この結果、表2に示すように、表1で異音品として与えた標本「B02」が、異音品として学習され、すべての標本データが目的としたカテゴリに分類できるようになった。しかし、網かけ欄で示したB09とB11の最小距離が他の標本データに比べて大きく、与えられた教師データに対して、離れた距離にあると考えられる。このような教師データで、未知のサンプルを認識させた場合、本来、異音品となるべきサンプルが良品となる可能性が高いと思われる。

表2 異音品3ユニットでの学習結果
Table 2. Learning results for 3units of no good samples.

標本データ	C0			C1		最小距離	カテゴリ (m, n)	
	d0	d1	d2	g0	g1			
B01	10	40	36	31	34	10.42	0	0
B02	38	11	28	25	26	11.20	0	1
B04	23	27	12	18	15	12.00	0	2
B05	21	25	10	17	15	10.26	0	2
B06	36	24	11	22	19	11.11	0	2
B07	34	22	11	21	18	10.85	0	2
B08	12	35	23	22	24	11.56	0	0
B09	45	19	28	30	28	18.53	0	1
B10	36	10	22	20	21	9.98	0	1
B11	29	21	29	28	25	20.79	0	1
G01	22	23	21	10	22	9.93	1	0
G02	23	23	19	7	20	7.00	1	0
G03	26	19	13	18	0	0.00	1	1
G04	27	22	13	9	17	9.46	1	0

多くの未知のサンプルを識別するシステムをつくる場合、あらゆる種類のパターンを有するサンプルが、識別するべき入力として与えられる。そこで、システムとしては、できるだけ他のカテゴリと離れていること。また、容易に収束するべきカテゴリのユニットを有していることが望ましい。逆に、NNを適用する場合、できるだけ小規模なシステムであることが望ましい。そこで、カテゴリを良品と異音品の2種類とし、<6・2>の結果を考慮して、ユニットは良品が2ユニット、異音品は4ユニットとした。学習データは<6・2>の表2と同じ標本データを使用した。

<6・3> 異音品4ユニットでの学習 異音品4ユニットの学習結果を表3に示す。表2で示したB09, B11が再学習され、誤認識がなく、しかも別カテゴリとの最小距離差が大きくなっている。また、最小距離は小さくなり、未知のサンプルの認識が容易にできることが表3から分かる。

この学習の結果が正しいかどうかを調べるために、各ユニット別に計算されたベクトル距離が、どの程度小さくなるかを検討した。ただし、LVQ1法での学習率初期値は、<6・2>と同様

に $\alpha_0=0.2$ 、学習回数は1,000回に設定した。
表3の記号は、表1、表2と同様であり、ここでは異音品カテゴリ（C0）に新たにユニットd3を追加した。

表3 異音品4ユニットでの学習結果
Table 3. Learning results for 4units of
no good samples.

標本 データ	C0				C1		最小 距離	カテゴリ (m, n)
	d0	d1	d2	d3	g0	g1		
B01	10	45	36	32	31	34	10.42	0
B02	38	12	28	26	25	26	11.78	0
B03	10	34	27	28	20	26	10.18	0
B04	23	30	12	29	18	15	12.00	0
B05	21	28	10	28	17	15	10.26	0
B06	36	23	11	35	22	19	11.11	0
B07	34	23	11	31	21	18	10.85	0
B08	12	39	23	31	22	24	11.56	0
B09	45	14	28	36	30	28	14.32	0
B10	36	9	22	27	20	21	8.68	0
B11	29	28	29	0	28	25	0.00	0
G01	22	25	21	28	10	22	9.93	1
G02	23	24	19	30	7	20	7.00	1
G03	26	22	13	25	18	0	0.00	1
G04	27	23	13	31	9	17	9.46	1

表3では最小距離のすべてが小さくなり、未知の識別すべきデータが与えられても、十分に余裕を持って識別できることが分かる。また、結合荷重ベクトルが示す最小距離は、図8、図9で示すように異なったカテゴリの隣接したベクトルとは、充分大きな距離を有しており、学習が正しく行われたことを示している。

◀6・4▶ 未学習データに対する識別結果 熟練の検査員により識別されたサンプル合計100個を、◀6・3▶の学習結果をもとに識別した。表4に、識別したサンプル100個のうちで、代表的な20個の評価結果を示す。

チェック用の標本データとしては表2と同様のサンプルを使用した。その結果、識別を行ったすべてのサンプルで、100%の精度で正しく識別された。すべての未知サンプルの識別結果をみると、最小距離を有するカテゴリとそれ以外のカテゴリとの最小距離の差は充分にあり、図9に表した「正しいカテゴリ」に識別されている。識別結果が正しいかどうかを調べるために、LVQ法により識別した解析結果と熟練した検査員による結果を比較した。その結果、検査員の識別と比較して、遜色ない状態で識別できていることが分かった。さらに、識別結果が数値とグラフによって視覚で考察できるため、限られた人による主観的な耳による識別能力に委ねることなく、誰でも容易に識別ができる「音質評価システム」を構成することができた。

表4 生産品の評価結果

Table 4. The classification of recognition results
for produced samples.

サンプル	d0	d1	d2	d3	g0	g1	最小距離
1	30	21	16	28	16	12	12.08
2	49	27	40	49	17	33	16.67
3	54	46	31	53	24	37	24.02
4	37	27	20	37	16	19	15.65
5	29	23	31	36	24	18	18.21
6	54	42	33	55	16	36	16.05
7	28	13	20	29	13	12	11.75
8	28	23	26	29	25	20	19.66
9	32	16	21	34	13	15	12.71
10	41	30	17	30	15	22	15.04
11	30	20	18	31	13	14	12.59
12	42	27	33	43	12	23	12.14
13	48	42	31	50	20	35	20.56
14	22	20	29	29	27	18	18.16
15	25	21	25	30	34	19	18.91
16	47	39	27	48	23	31	22.95
17	39	27	21	40	12	21	11.92
18	52	42	28	50	21	34	21.31
19	32	17	21	29	14	15	14.19
20	31	15	22	30	16	14	14.07

7. まとめ

本論文では、LVQ法に基づいた競合型NNを用いた電子音音質評価法を提案し、人間の官能評価に代わる定量的な手法を確立した。それを実際に生産品に対して評価を行い、提案手法の有効性を定量的に検証した。

その結果、提案手法が人間の電子音の音質官能評価に変わり得るものであることを実証できた。この手法は、図5、図6に示す音波形の中で、極めて小さな異常も解析できるようになっている。そのため、人間の耳では決して識別できないほどの小さな「異音」を識別できるようになっている。この手法によって、音の官能評価の定量化に有効であることが実証できたことにより、関連した多くの商品に応用し、音に関する官能評価の定量化をさらに進める予定である。

(平成13年6月6日受付、同13年12月5日再受付)

文 献

(1) J. Dayhoff: "Neural Network Architectures : An Introduction", International Thomson Computer Press, Boston, USA (1996)
(2) 福田 重明, 小坂 利寿, 大松 繁: "時系列データを用いた日本円紙幣の識別", 電気学会論文誌C, Vol. 115-C, No. 3, pp. 354-360 (1995)
(3) 麻生 英樹: "ニューラルネットワーク情報処理", 産業図書,

(1988)

(4) T. Kohonen: "Self-Organizing Maps", Springer, Berlin, Germany (1995)

(5) 小坂 利寿, 竹谷 紀和, 大松 繁, 漁 邦広:
"信頼性評価規範を用いた LVQ による米国ドル紙幣識別",
電気学会論文誌, C Vol. 115-C, No. 11, pp1359-1364
(1999)

(6) 添田 喬, 太田 光雄, 大松 繁: "数理統計の基礎と応用",
日新出版(1979)

紙本 伸明

(正員) 1970 年 3 月金沢大学大学院電気工学研究科修士課程修了。同年松下電工株式会社入社。総合技術研究所を経て、現在、品質 R&D センターに勤務。製造工程の自動化、小型モータの設計及び小型モータ応用商品の開発業務に従事。1998 年に一般計量士、1999 年に環境計量士(騒音・振動)を取得し、現在は主として、官能評価の自動化研究に従事。電気学会会員。

阿部 敏郎

(正員)。1967 年 3 月大阪府立大学大学院電子工学修士課程修了。同年 4 月松下電工株式会社入社。半導体研究所所長を経て、現在、品質 R&D センター技監。パワー半導体素子、MOSIC、半導体リレー、照明点灯装置、ニューラルネットワークの応用等の研究に従事。1991 年科学技術庁長官賞受賞。工学博士。応用物理学会会員、電気学会会員。

林 鍵

(非会員) 1986 年中国電子科技大学卒業。1999 年大阪府立大学総合科学数理情報コース卒業。1999 年大阪府立大学工学研究科情報工学修了。

大松 繁

(正員) 1974 年大阪府立大学大学院博士課程修了。同年徳島大学工学部情報工学科助手。1988 年同知能情報工学科教授。1995 年大阪府立大学工学部情報工学科教授となり、現在に至る。1991 年電気学会論文賞, 1995 年計測自動制御学会論文賞, 1996 年市村賞受賞。ニューラルネットワークの研究に従事。IEEE Trans. on Neural Networks の Associate Editor。システム制御情報学会, 計測自動制御学会, IEEE 会員。工学博士