

赤外線画像にニューラルネットワークを適用したICボードの故障診断

西野 聰 大嶋 建次

Fault Diagnosis for IC Board using Thermography applied Neural Network

Satoshi NISHINO and Kenji OHSHIMA

あらまし ボード上のIC間の温度関係をニューラルネットワークに学習させて、このネットのもつ大きな特徴である汎化性を用いて故障ICを指摘する（故障診断）手法を開発した。故障時は故障ICのみが異常発熱するだけでなく、故障ICの影響でこのICにファンイン、ファンアウトしているICも異常発熱することが多いことがわかっている。従って、この現象を基に、ボード上のICを信号線の入力本数により強い接続グループのICと、弱い接続のグループのICに類し、強い接続グループのICについては学習データを得るための故障実験を詳細に行う。また、弱い接続のグループのICについては簡単に行うことで、この二通りの実験データよりすべての学習データを生成した。その結果少ない学習データの採取で高診断率のニューラルネットワークを構築することができた。さらに、ニューラルネットワークの出力に処理を行うことで約4%診断率を向上させ、この結果、三種のボードに対して91%前後の診断結果を得た。

キーワード 故障診断、赤外線画像、ニューラルネットワーク、VLSI、ICパッケージ

1. まえがき

IC技術の発展によりVLSI, ULSI化が進展し、ICチップ内の論理回路も複雑になって集積度は膨大になってきている[12][13]。これに伴い、ボードを一つのチップ上に集積化するシステム・オンチップも現実化している[14]。従って、このような集積度の大きいICを搭載したボードでは、従来の故障検出・診断手法を適用することが困難になりつつある。この状況に対応するために、我々は赤外線画像を使用した、ボードレベルの故障検出手法を検討してきた[1], [2]。本論文では、この研究をさらに進め、ICレベルで故障を指摘する、すなわち故障診断手法[3], [4]を開発したので報告する。

集積度が大きくなるに従って、ICパッケージも大型になってきている[24]～[29]。近年このような大型パッケージを数個しか搭載していない形態のボードも多くなってきている。このような状況から、ユーザに出荷後の実用レベルのボードの故障診断では、ボード上のどのICが故障かを指摘できれば十分である。従って、本論文では、故障診断とはICレベルで故障を指摘することを示す。文献[1],

[2]での検討の結果、故障時は故障ICのみが異常発熱するだけでなく、故障ICの影響でこのICにファンイン、ファンアウトしているICも異常発熱することが多いことがわかっている。このため、単に異常発熱ICを故障と指摘するだけでは診断できない。まれに、故障ICの発熱温度は正常値範囲内でこのICにファンイン、ファンアウトしているICのみが異常発熱する場合もある。また故障ICの異常発熱が隣接ICの発熱へ影響することや、ボードへの熱伝導の影響が正常ICの温度値を変化させ、これらの現象は、診断を乱す要因となる。これに対応する手段として、故障実験を何通りも繰り返し、故障状態の温度値の組み合わせをテーブルに持ち、照合することが考えられるが、すべての組み合わせを故障実験を行い、テーブルを作ることは、現実的に不可能である。そこで、本論文ではボード上のIC間の温度関係をニューラルネットワークに学習させて、このネットのもつ大きな特徴である汎化性を用いる方法を探った。この際に、上述した診断を乱す熱的な要因を学習過程で含んで学習させる工夫をして診断の向上を図った。また、少ない学習デー

タの採取で高診断率のニューラルネットワークを構築する手法を開発し、さらに、このニューラルネットワークの出力に処理を行うことで診断率を向上させた。

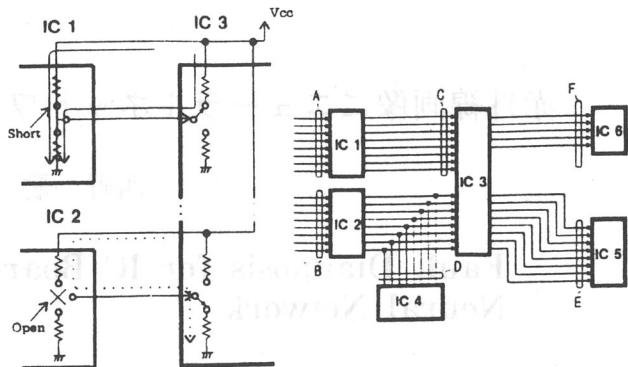
2.故障診断の考え方と学習アルゴリズム

2.1 学習の基本的な考え方

高集積化した最近のVLSI,ULSIでは内部素子や配線幅が微細化し、その結果電流密度が高くなり、出荷後ユーザ段階でエレクトロマイグレーションや、酸化膜ブレーク、ホットエレクトロン注入などの各種内部要因や、外部からの静電気やノイズによるラッチアップに起因する破壊や、熱的なストレスによるアルミ配線の断線などが多く発生し[15]～[20]、その結果が素子自身の異常発熱として入出力値に関係なく固定的に現れるので、この場合はテスト入力は不要である[1]。本論文では、文献[1]と同様に主として、このような出荷後ユーザで発生する内部故障を対象としている。学習データ採取用故障ICおよび、診断対象未学習故障ICは学生実験で発生した故障ICを用いた。

前述したように、実際の故障では、故障ICのみが異常発熱するとは限らず、故障ICの影響を受けて、このICにファンイン、ファンアウトしている正常ICも回路的に影響を受けて異常発熱をすることが多い[1]。図1(a)に入出力回路を簡約化し、IC1,2の出力トランジスタが共に固定的に短絡および開放した場合を示す。このような場合は、IC1,2と3共に正常時と異なった電源電流が流れる。ICパッケージの発熱は電源電流が基となっている[1]ので、このためにICが異常発熱することがある。これらの現象はトランジスタの破壊の度合いにより異なり、一意的に決まるらないが、故障IC自体と、ファンアウトの両方のICが異常発熱を呈することが多い。実際のボードでは例えば、Z-80チップが故障で高温発熱しているときに、これにファンアウトしているROMが正常にもかかわらず正常温度範囲よりも低温となるなどの例がある[1]。

最近のVLSIによる回路は図1(b)の様な構成が多く、この様な回路では、入力線数の多いICが互いにファンイン、ファンアウトしていることが多い。また、樹枝状回路も同様である。各ICの入出力端子が故障する確率が等しいと仮定すると、入力線数の多いICほど故障の影響を受ける確率が大きくなる。



(a) Influence of fault IC (b) LSI Circuits

図1 故障ICの影響と回路構成

Fig.1 Influence of fault IC.

このようなことから、ボード上の入力線数の多いICを選定することは、故障ICの影響を大きく受けるICを選定することになる。

ボード上のICが一つ故障した場合（以下单一IC故障と記す）以外に、数個のICが故障する場合（以下多重IC故障と記す）も発生し、この場合は故障ICの異常発熱の熱的影響が、隣接するICやボードを介して他のICに及びさらに診断を困難にする。そこで本研究では、被診断対象ボードのICの正常時と故障時の発熱の状態を上述した影響を含めてニューラルネットワークに学習させる。この観点から、入力線数の多いICは故障実験を行い、実際の故障時の発熱を学習データとして採取する。入力線数が少ないIC間では相互の影響も少ないので、これらのIC間では故障実験を少なくし、一部は模擬的に学習データを作成する。

以上のことから、次の手順で回路ファイルから、ボード上のICを2つのグループに分類する。

[接続によるICの分類手順]

1. 回路図を基に、各ICの入力線が何本各々のICに接続されているか数え上げる。この場合双方向性バスは1本に数える。
2. 1のようにして数え上げた入力線数を一覧表にして、差が大きくなっているICを境に、2つのグループに分け、入力線数の多いほうのICのグループを、接続関係の強い（以下強い接続と記す）ICグループ、残りのグループを接続関係の弱い（以下弱い接続と記す）ICグループとする。強い接続のICグループと、弱い接続のICグループの分類は次の考え方で行う。
 - (1) 搭載IC個数をnとすると、強い接続のICグループのIC個数が、 $[n/2]$ を越えないこと。
 - (2) ICの最高入力線数をNとすると、弱い接続

赤外線画像にニューラルネットワークを適用したICボードの故障診断

のICグループのに入る分類の境界本数を,
 $[N \times 0.2]$ 本を目安とする.

(3) 上記2つの条件を考慮して,全体の接続本数を見渡して,なるべく強い接続のグループのIC個数が少なくなるように決定する.

[] は内部の数値を四捨五入して整数とすることを表す.

二つのグループから得た測定データから2.3に述べるアルゴリズムで学習データを自動生成する.

2.2 故障実験による学習データの測定回数

故障診断対象のボード上のIC個数がn個の場合は,最低でも 2^n 通りの,さらに様々な故障モードを考えると, $2^n \cdot k$ 通りの学習データが必要となり,nが大きくなると,これらのデータをすべて故障実験より得ることは実用上は不可能である.また,学習データ採取の測定労力を考えると学習データは少ない方がよい.しかし,学習データが少ないとその結果として,構築されたニューラルネットワークの汎化性が得られず,良好な診断結果を得ることができない.そこで,いかに少ない学習データで良好な診断結果を得るかが課題となる.

ICが複数個壊れる場合は,最初に故障したICにファンイン,ファンアウトしているICが壊れことが多いことわかっている.例えば,近年マイクロコンピュータチップの普及で盛んに使用されているトライステートバスなどは,その信号制御を誤ると,このバスに入出力するICが破壊される恐れがある[30],などがあげられる.また,多くのICが一度に壊れるのは,ボードに供給する電源の極性を反対にしたり高い電圧を誤って供給した場合などに生じる人為的ミスのときのみで一般にはないと考えられる.以上の状況を基に,故障実験による学習データの測定回数を削減するために,故障ICはボード上に最大3個しか存在しないという仮定を置く.

ボード上の診断対象IC個数をn, 強い接続のグループのIC個数を n_1 , 弱い接続のグループのIC個数を n_2 とする($n = n_1 + n_2$)と, この場合の測定回数は次のようになる.

1. 強い接続のグループに対する測定回数は, 次式のようなる.

$$\sum_{i=0}^3 n_i C_i \quad (1)$$

このデータはすべて故障ICを用いた故障実験より得る.弱い接続のICグループはこのときは測定せずに,強い接続グループ単独で行う.

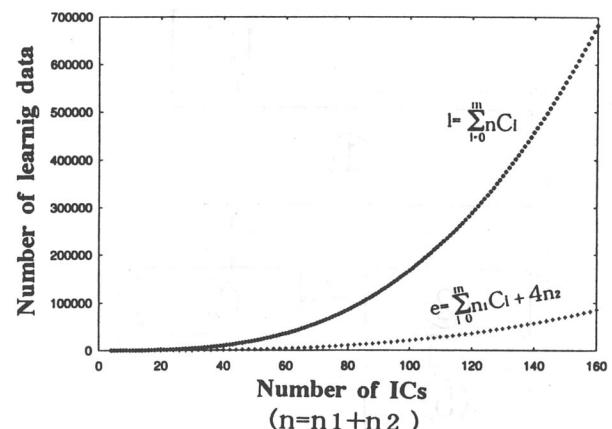


図2 学習データ数の比較
 Fig. 2 Comparison of learning data.

2. 弱い接続のICグループは,これらのICと接続関係にあるICの中で一番入力線数が多いIC 1つとのみ,故障-正常,正常-故障,故障-故障,正常-正常,の4通り故障の実験を行い発熱データを採取する.このとき次の2つの場合がある.

(1) 強い接続のICグループからの入力線数が一番多い場合.

この際に測定するのは,弱い接続側のICについてのみの4個の発熱温度である.

(2) 弱い接続のICグループの同士の入力線数が一番多い場合.

この場合はすべての組み合わせの4通りの両者の発熱データ8個を測定する.

このときの最大測定回数は式(2)のように表される.

$$4n_2 \quad (2)$$

3. (1),(2)式から,測定データの最大測定回数は

$$\sum_{i=0}^3 n_i C_i + 4n_2 \quad (3)$$

となり,式(3)から作成することができる学習データ数はもっと多くなり

$$\sum_{i=0}^3 n_i C_i \quad (4)$$

である.

ここで,学習データ数について評価する.一般的な例を検討するために $n_1 = n_2$ の場合で故障IC数m=3とした場合の生成学習データ数 ℓ と,このデータを生成するために必要な実際の測定回数 e を比較した結果を図2に示す.この図2から,ボード上のIC個数が多くなるほど,学習データ生成アルゴリズムが測定回数軽減に大きく寄与していることがわかる.

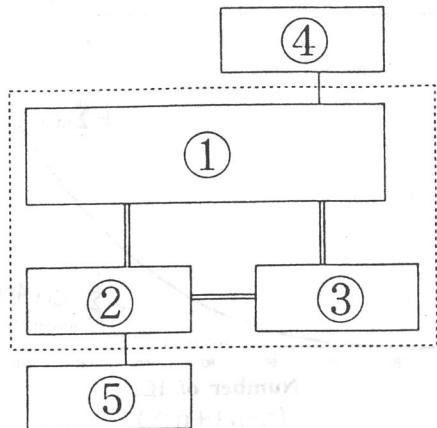


図3 モデル回路

Fig. 3 Model circuit.

2.3 学習データ生成手順

前述したようにして得た実験データより式(3)で表される数の学習データを生成するアルゴリズムについて図3に示す診断対象ICが5個のモデル回路の場合で、具体的に述べる。図3のIC1, 2, 3は強い接続のICグループであり、4, 5は弱い接続のICグループである。まず2.2で述べた2の手順で測定する。

1. 強い接続のICグループの故障実験データの測定。

ボード上の故障ICが1~3個の場合全てについて測定を行う。この様子を、図4の(a)に示す。測定したデータの各々を[1]~[8]とする。長方形はICを示し、■のものは故障ICを示す。また、中にTemperatureと記してあるものは、温度データが確定したことを示す。

2. 弱い接続のICグループの故障実験データの測定。

この場合の2個は2.2の2.(1)の弱い接続のICが、強い接続のICグループとの接続をもつ場合で、IC4はIC1と、IC5はIC2と一番多く入力線数が接続されている。これらの場合は強い接続のデータが優先するので、全ての組み合わせのデータの弱い接続のICグループの実験データのみを採取する。この様子を図4の(b)に示す。

3. 1, 2で採取した故障データから全てのIC中の1~3個が故障と、すべてのICが正常の場合の学習データを生成する。

例として図4の(c)に示す、IC2, 3, 4が故障、他のICが正常時のデータを生成する場合を説明する。この図4においてICを示す長方形の上に記した[]と■内の数字は図4(a), (b)の故障実験データの番号を示し、■はこのデータを学習データとして確定したことを示す。

Table (a) shows strong connection IC temperature data measurement. It has columns for IC1, IC2, and IC3. Rows [1] to [8] show various fault patterns. A legend indicates: Non fault (white box) and Fault (black box).

	IC1	IC2	IC3
[1]	Temperature	Temperature	Temperature
[2]	Temperature	Temperature	Temperature
[3]	Temperature	Temperature	Temperature
[4]	Temperature	Temperature	Temperature
[5]	Temperature	Temperature	Temperature
[6]	Temperature	Temperature	Temperature
[7]	Temperature	Temperature	Temperature
[8]	Temperature	Temperature	Temperature

Table (b) shows weak connection IC temperature data measurement. It has columns for IC1, IC4, IC2, and IC5. Rows [9] to [16] show various fault patterns.

	IC1	IC4	IC2	IC5
[9]		Temperature		Temperature
[10]			Temperature	Temperature
[11]			Temperature	Temperature
[12]			Temperature	Temperature
[13]				Temperature
[14]				Temperature
[15]			Temperature	Temperature
[16]			Temperature	Temperature

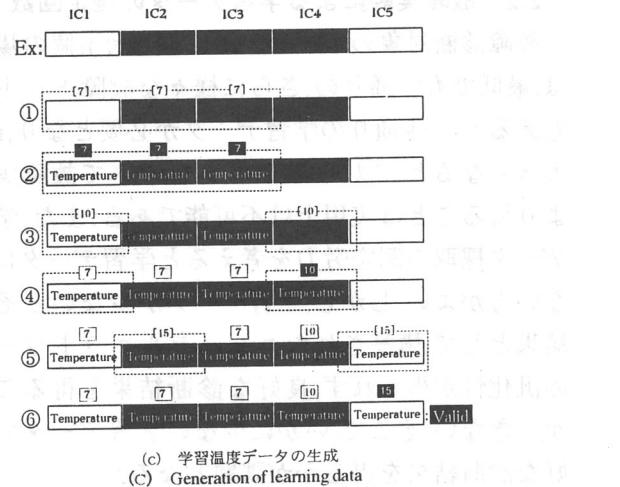
(a) 強い接続関係のIC温度データの測定
(a) Strong connection IC temperature data(b) 弱い接続関係のIC温度データの測定
(b) Weak connection IC temperature data

図4 学習データ生成アルゴリズム
Fig. 4 Algorithm of learning data generation.

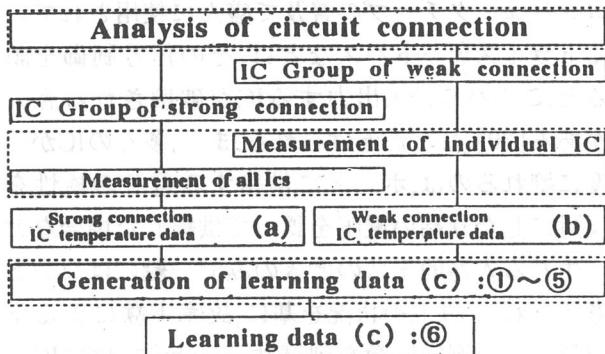


図5 ニューラルネットワーク構築手順
Fig. 5 Constitution process of neural network.

最初に、強い接続の実験データ[7]を使用する。原則は、強い接続のICグループの実験データを優先して使用するので図(c)の②のように強い関係のICの生成学習データの温度値は決まる。次にIC4が故障の場合は、IC4は弱い接続に属するICであり、IC1の間に一番多く入力線の接続があるので、弱い接続の実験データ図(b)の中から、図(c)の一番上に示したEXのIC1が正常でIC4が故障に相当するデータ[10]を図(c)の③のように当てはめる。この場合に当てはめるのは、強い接続のデータを優先する

赤外線画像にニューラルネットワークを適用したICボードの故障診断

原則からIC1の正常時のデータは②で当てはめたデータをそのまま残し、④のようにIC4には[10]の故障データを当てはめる。IC5のデータは、IC2と5に接続があるので、図(b)の[15]の関係を使い、図(c)の⑤のように当てはめて、最終的に、⑥のように決まる。

以上1~5のようにして、強い接続と弱い接続の実験データをその特性を生かして使用し、少ない実験データから学習データを生成する。

以上の手順をまとめたものを、図5に示す。図5の(a),(b),(c)は、図4の(a),(b),(c)に対応する。

2.4 生成学習データの検討

ここで具体的にZ-80ボードの場合の学習データを対象に評価する。このボードはZ-80CPUを中心に、RAM, ROM, I/O-LSI8255, 各種MSI,SSIを計21個搭載したワンボードマイコンである。このボードを図6に、接続表を表1に示す。IC13と19を境に上側の9個が強い接続、下の12個が弱い接続のICグループである。学習データ数は、式(4)から

$$\sum_{i=0}^3 2^i C_i = 1562 \quad (5)$$

必要であるが、式(3)により、測定回数は

$$\sum_{i=0}^3 9^i C_i + 4 \cdot 12 = 178 \quad (6)$$

に減少する。従って、この場合の測定回数の削減率は約89%になる。

生成した学習データは、次の性質をもつ。

- 測定データは一度に測定は不可能なので、測定する時間的なずれがある。従って、周囲温度の変動などがあり、測定されるIC温度値にはばらつきが生じる。
- 弱い接続のICデータの測定で、強い接続のICとの接続がある場合は、強い接続のICの測定データ

表1 Z-80ボードの接続表
Table 1 Connection table of the Z-80 board.

IC No.	Name	1	2	5	6	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	入力端子	
22	74LS45 (Bus Transceiver)	8	8	8				1								x							34	
5	Intel ITC-2740/2708/TMS2716		x						2		1						8	3	8				22	
6	PD8255C-E		x		x				8	1	2				1		2	8					22	
1	Z80 CPU		x							1	2						2		8				13	
2	nMOS UV-EPROM 2716		x									1						x					13	
20	74LS541 (Buffer)	8										1							x				9	
21	74LS541 (Buffer)	8										1							x				9	
10	74LS03 (NAND)							3		x	3									2		8	8	
13	74LS03 (OR)											x						8					8	
19	74LS07 (Bus Buffer)	5										1						x					7	
9	74LS00 (NAND)							1	x			3			1				1				6	
11	74LS04 (NOT)	1										1			1			1					6	
17	74LS138 (selector)											1			x			5					6	
8	74LS00 (NAND)							x	1	1		1						2					5	
16	74LS138 (selector)											x							5					5
18	74LS244 (Bus Buffer)	4																x					4	
12	74LS14 (NOT (Trigger Inverters))							2		x													3	
14	74LS42 (Decoder)											3											3	
24	74LS293 (Binary Counter)	1										2								x			3	
23	MC4049UB (NOT)																			x			2	
15	74LS107 (JK-FF)												1		x								1	

(ただし、IC No. 3, 4, 7について、ワンボードマイコン上で用いてない(任意増設である)ため、省略。)

タは、強い接続のIC同士で測定したデータを使用し、弱い接続のデータのみを採取する。このために、採取した時間がさらに大きく異なり、両者のグループのIC温度値にはばらつきが生じる。文献[1]で、ボード上の各ICの温度は正規分布をすることが確認されている。ICの発熱を x として、平均値を μ 、標準偏差を σ とすると、その分布は次式(5)のごとく表される。

$$y = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (7)$$

この温度分布のICの正常時のICの発熱温度は

$$\mu \pm 3\sigma \quad (8)$$

の範囲に含まれる。

また、文献[21], [22], [23]より、ニューラルネットワークの能力を高める、すなわち、汎化能力を高めるには、学習データに診断対象に適合した適切な乱数を印可することが効果的であることが知ら

表2 生成学習データ例

Table 2 Example of generation learning data.

IC	ICNo	22	5	6	1	2	20	21	10	13	19	9	11	17	8	16	18	12	14	24	23	15	
[°C]	$\mu - 3\sigma$	26.9	5.0	20.1	27.1	8.7	15.0	15.5	6.4	8.8	9.4	7.7	9.0	10.2	12.3	9.9	14.1	12.2	9.0	8.5	6.6	9.7	
	μ																						
	$\mu + 3\sigma$	28.8	9.2	23.7	31.0	12.9	17.8	19.8	11.0	12.6	11.9	11.9	12.2	12.7	17.7	15.9	11.9	16.9	15.9	13.8	11.8	10.7	
1	作成データ	29.6	8.1	29.4	12.2	17.7	18.4	8.2	12.5	12	10.2	12	16.7	15.7	11.7	16.5	15.1	12.1	11.1	10.5	11.8		
1	実測値	27.9	5.9	27.3	10.9	15.4	16.8	6.4	10.2	21.2	9	9.7	15.1	10.4	14.1	12.5	9.2	9.3	7.9	10.6			
2	作成データ	28.1	7.9	23.4	12.9	17.8	18.7	7.9	11.4	16.1	17.2	11.5	16.5	15.1	13.6	11.1	10.5	12.8					
2	実測値	25.5	5.0	20.4	28.2	16.3	17.8	6.6	8.9	9.5	9.3	11.1	11.5	12.9	9.5	15.3	13.4	12	8.5	8.1	10.4		
3	作成データ	28.4	9.1	23.5	10.6	19.6	18.7	8	12.1	11.1	10.2	12	17.7	17.8	11.7	17.5	14.6	13.6	8.9	10.5	11.8		
3	実測値	27.5	7.6	22.3	21.0	11.0	14.8	19.9	5.6	10	9.6	9.1	10.6	15.4	10.3	15.5	13.5	11.1	8.4	7.5	12.9		
4	作成データ	28.5	8.6	23.5	29.2	10.4	16.7	18.2	7.0	5	11.1	12	16.7	15.7	11.7	16.5	12.1	13.6	11	10.5	12.5		
4	実測値	25.5	6.8	20.6	27.8	8.8	15.1	17.6	7.6	22.9	10.1	10	10.0	9	13.9	13.2	9.2	21.9	9	12.7	9	9.4	8.1
5	作成データ	28.1	8.6	23.5	19.2	10.8	17.1	18.2	7.9	9.5	16.6	17.1	11.4	17.4	7.7	15.7	11.7	16.5	15.1	11.3	11.1	7.4	
5	実測値	27.3	6.6	22.9	27.6	11.8	15.1	17.6	5.8	7.3	13.1	20	10.4	20.9	16.1	14.2	10	14.4	13.6	10.9	9.1	6.7	
6	作成データ	28.1	8.6	23.5	29.2	10.8	17.1	18.2	7.9	9.5	16.5	11.5	11.4	17.6	14.5	17.2	15.1	13.6	11.1	10.5	11.8		
6	実測値	27.1	7.4	21.9	26.3	8.7	16.3	18.2	7.3	7.4	11.4	9.5	9.1	11.4	5.1	12.4	17.8	14.4	12.4	11.3	8.7	8.2	
7	作成データ	28.5	9.1	23.4	11.1	17.3	19.7	11.6	12	12	10.2	12	16.7	15.7	11.7	16.5	15.1	13.6	12.5	11.7	12.8		
7	実測値	25.6	6.4	22.5	29.1	9.1	15.7	17.7	8.9	9.4	11.4	9.4	9.1	11.4	14.8	13	10.1	5.6	10.9	9.5	8.6	10.8	
8	作成データ	28.5	9.1	23.4	30.9	12.1	17.3	19.7	11.6	12	12	10.2	12	10.3	15.7	11.7	16.5	15.1	13.6	12.5	10.5	11.8	
8	実測値	27.7	6.8	22.5	29.1	10.8	15.5	19.1	11.0	9.7	11.4	7.4	7.1	11.2	12.5	15	10.9	15.3	13	11.6	9.5	10.3	

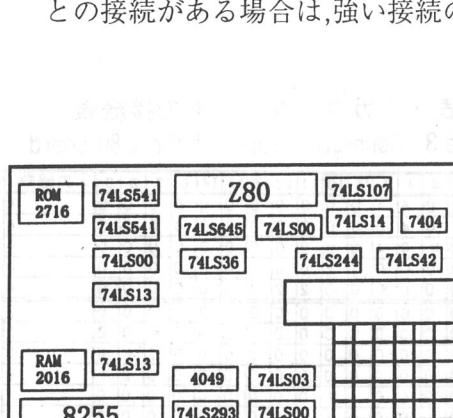


図6 Z-80ボード

Fig. 6 Z-80 board.

れている。このようなことから、採取時間の大きく異なる実測データから、学習データを生成することは、式(7)のように正規分布する各ICに、式(8)の正常温度範囲内の正規分布乱数を与えていていることに相当する。

表2の作成データは図4,5のアルゴリズムで作成した学習データであり、実測値はかなり時間を経てから作成データに対応した故障ICと正常ICの温度を実測したものである。なお、温度値は室温を引いた値であり、灰色部は故障ICであることを示す。これから生成データと実測データの違いがほとんどの場合 $\mu \pm 3\sigma$ 以内であることが分かる。このことから本論文のアルゴリズムで学習データを自動生成することは、正規分布乱数を付加することに相当し、構築したニューラルネットワークの汎化性を助長させることになる。

また、学習データを量的に拡大すれば、汎化能力は向上すると考えられるが、これに代わる方法としてすでにある学習データを質的に改良することが考えられる。具体的には既存の学習データの変動サンプルを生成することでカテゴリーの分布を広げることである[22]。例えば表2のNo.3の行のIC20の実測値の温度は17.8°Cであり、故障であるにもかかわらず $\mu \pm 3\sigma$ の範囲に入っている。しかし、IC1とこの20は強い接続にあり、IC1の故障により故障IC20が回路的な影響を受けて、故障にもかかわらず異常発熱しない例となっている。しかし、このような場合でもニューラルネットワークでは学習データにあわせて教師信号を与えて、故障と学習させるので、全体のICの組み合わせで診断可能である。このようにすることは、故障ICの影響、すなわち正常ICが異常発熱したり、また故障にも関わらず故障ICが正常温度範囲内になるなどの、故障診断を乱す要因をあらかじめ学習に取り込むことと、学習データの変動サンプルを与えることに相

当する。

以上のことから、本論文のアルゴリズムで生成された学習データは、ニューラルネットワークの汎化能力を助長することになる。

3. 故障診断実験とその評価

学習データ生成アルゴリズムに基づいて学習データの生成を行い、4層のニューラルネットワークをバックプロパゲーション法の逐次修正法でPC9821 V16(Pentium 166MHz)上にC++で、図6に示したZ-80ボードと、図7(a)のカウンタボードと(b)のMSIボードの2種に対応して各々構築し、故障診断実験を行った。表3にカウンタボードの接続表を示す。

測定した温度データは、正常温度を0として1までの値に変換して正規化を行い、ニューラルネットワークの学習および判定入力としている。また、学習係数は0.1、シグモイド関数の傾きは0.5および、慣性項の数は01とした。2.3で故障ICは3個と仮定し、作成した学習データを使用してニューラルネットワークを構築したが、出力は故障ICの数を3個に制限するようになつてない。

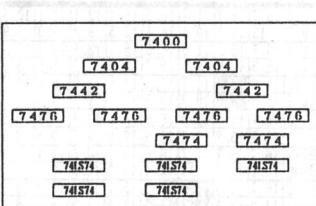
3.1 Z-80ボード

このボード上のすべてのIC21個に対して故障診断実験を行った。最初に、試行的に、全てのICが正常な場合と、全てのICが故障の場合を学習させて故障実験を行ったが、診断率が約20%と悪く、全く診断できない状態であった。従って、ある程度の学習データを与えて、ニューラルネットワークを構築する必要があることがわかった。

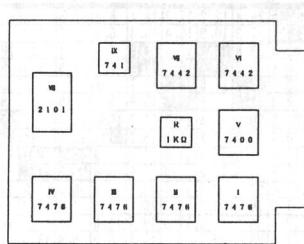
单一IC故障診断結果の一部を表4(a)に、(b)は故障を2個から3個挿入した多重IC故障診断結果の一部である。

表3 カウンタボードの接続表
Table 3 Connection table of the Z-80 board.

No	IC Name	1	2	3	4	5	15	10	11	12	16	13	14	6	7	8	9	入力線数
1	7400	x	0	0	4	4	0	0	0	0	0	0	0	0	0	0	0	8
2	7404A	0	x	0	4	0	0	0	0	0	0	0	0	0	0	0	0	4
3	7404B	0	0	x	0	4	0	0	0	0	0	0	0	0	0	0	0	4
4	7442A	0	0	0	x	0	2	0	0	0	0	0	0	0	0	0	0	4
5	7442B	0	0	0	0	x	0	0	2	0	0	0	0	0	0	0	0	4
6	74LS74B	0	0	0	0	0	0	0	0	0	0	0	2	x	0	0	0	2
7	74LS74C	0	0	0	0	0	0	0	0	0	0	0	0	2	x	0	0	2
8	74LS74D	0	0	0	0	0	0	0	0	0	0	0	0	0	2	x	0	2
9	74LS74E	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2	x	2
10	7476B	0	0	0	0	0	1	x	0	0	0	0	0	0	0	0	0	1
11	7476C	0	0	0	0	0	0	1	x	0	0	0	0	0	0	0	0	1
12	7476D	0	0	0	0	0	0	0	1	x	0	0	0	0	0	0	0	1
13	SN7474B	0	0	0	0	0	0	0	0	0	1	x	0	0	0	0	0	1
14	74LS74A	0	0	0	0	0	0	0	0	0	0	1	x	0	0	0	0	1
15	7476A	0	0	0	0	0	x	0	0	0	0	0	0	0	0	0	0	0
16	SN7474A	0	0	0	0	0	0	0	0	0	x	0	0	0	0	0	0	0



(a) Counter board



(b) MSI board

図7 故障診断実験対象ボード

Fig. 7 Fault diagnosis experiment board.

赤外線画像にニューラルネットワークを適用したICボードの故障診断

表4 Z-80ボードの診断結果の一部
Table 4 Part of fault diagnosis results on the Z-80 board

(a) Single IC fault

表4において、出力の欄の数字が0.5以上の場合は診断結果が故障（●と表示）であることを示し、0.5未満の場合は正常（×と表示）であることを示す。以下の表の場合も同様である。表4の灰色部はニューラルネットワークの出力が故障と指摘した故障候補ICを示す。

表6 Z-80ボードの診断結果の詳細
Table 6 Detail of fault diagnosis results
on the Z-80 board

(b) Multiple JC faults

表5 カウンタボードの診断結果の一部
Table 5 Part of fault diagnosis results on the Z-80 board.

Table 5 Part of fault diagnosis results on the Z-80 board.

表5(a)では19行目のICNo.16の故障の場合にこのICを正常と誤って診断している。しかし他の場合は灰色で囲った故障と診断した部分に必ず実際の故障ICが含まれている。これは表(b)についても同じである。最大3個の多重IC故障に関する故障診断実験も含めて、約87.5%の診断率を得ている。

完全に故障診断が失敗した2例について調べてみると、表5の(a)では、No.12行のIC10(74LS03)とNo.19行のIC16(74LS138)が故障にもかかわらず、正常と判定している。この理由として、表2でIC10, IC16とともに故障での学習温度が一部のみであるが正常範囲内で学習していることにも原因があると思われる。(b)では、No.4, 10, 11行のいずれもIC6(8255)が誤って、正常と診断されている。これらのICは学習データの正常時の発熱温度と、故障時の発熱温度にはあまり差がなく、このために故障を指摘できなかつたと考えられる。

3.2 カウンタボード

Z-80ボードはLSI, MSI, SSIの混在したボードであったので、この対局にあるSSIとMSIのみを搭載した図7(a)に示すカウンタボードを対象として取りあげた。このボードはJK・FFとD・FFにより非同期カウンタを構成し、このカウンタからMSI(7442)によりデコードしている回路である。Z-80ボードのようにLSIからSSIの各種ICを搭載していないので、正常時のICの発熱のばらつきも少なく、故障時の発熱も大きく各IC間では違わない。また、表3に示すように、各IC間の接続も少ないとから、故障時の発熱変化は不規則になると考えられる。このために、故障ICの影響が他のICに及ぶことを含んだ学習があまりできないので、ニューラルネットワークにとってはZ-80ボードよりも扱いにくいくらいと思われる。このボードの故障診断結果を表5に示す。

この表5の5, 7, 8, 9, 10, 13, 14のようにZ-80ボードに比べると、故障候補に実際の故障が含まれずに診断を誤ることが多く、診断率も85.2%と落ちている。

3.3 MSIボード

このボードは、小容量のRAM、デコーダMSI、またSSIなどを搭載しZ-80ボードとカウンタボードの中間に位置するボードである。このボードの故障診断率は、86.5%となっている。

3.4 故障診断実験の評価

3種の種々の形態のボードに対して故障ICを実装して故障診断実験を行った結果、すべてのボードで85%以上の診断率を得た。このようなことから、どのような回路構成のボードに対しても本研究での手法を適用することが可能であると考えられる。

Z-80ボードの診断結果の詳細を表6に示す。この表での診断率は21個の診断対象ICから「正常なのに故障」と「故障なのに正常」と誤って診断されたものを除いて、21で割ったものである。この表を見ると次のことが言える。

1. 実際の故障ICの個数に関係なく、故障と指摘される個数が1~4個であり、故障と指摘される個数が実際に故障している数よりも多い傾向を持つ。
2. 故障診断率は故障ICの数に関係なく80%~95%の間にある。
3. 誤って、正常を故障と指摘する場合は少ない。

ニューラルネットの診断結果で、故障を正常と危険側に判定した割合を見逃し率として、下記で定義すると

$$\text{見逃し率} = (\text{故障を誤って正常と診断したIC個数} / \text{診断対象IC総個数} \times \text{回数}) \times 100\%$$

Z-80ボードの場合は、8/(21個×45回)=0.85%と非常に小さく良好であり、診断結果は安全側に働くとみなせる。

故障と指摘されたICの温度は明らかに故障状態の発熱温度を呈しているのにも関わらず、誤って正常と判定された場合もある。これらはニューラルネットワークが全体のICの温度との組み合わせで判断するために生じる欠点であり、ニューラルネットワークのもつ長所の汎化能力の対局に相当する短所と考えられる。

4. 診断率を向上させるための工夫

3種のボードについて故障診断実験を行った結果、3種のボードすべてのニューラルネットワークの診断出力は、実際の故障数よりも多く故障を指摘する傾向がある。この診断結果に対して、今までの実験結果から、故障ICの発熱温度は式(8)からさらに大きく外れることが多いのでこれと、ボード上に故障ICは3個以内しか存在しないとの仮定を利用して、正常ICの発熱温度からの距離を以下

赤外線画像にニューラルネットワークを適用したICボードの故障診断

の手順で取り、故障候補ICを絞りこむことで診断率がさらに向上すると考えられる。

正常ICの温度値集合を $N = \{n_1, n_2, \dots, n_n\}$, ニューラルネットワークの出力の故障候補ICの温度値集合を $F = \{f_1, f_2, \dots, f_m\}$, ($m < n$) とする。

・ $m > 3$ の場合は

$$d_v = \max_{1 \leq i \leq m} |f_i - n_i| \quad (9)$$

式(9)により、最初に実故障候補温度 d_v を求め、次に、この候補を除いて d_2 、同様にして、 d_3 を求め、これらを持つIC3個のみを故障ICとする。すなわち、正常温度値から距離が一番大きいICから三番までのICを故障とする。

・ $m \leq 3$ の場合は

故障候補IC温度を持つICをそのまま故障とする。以上の処理をZ-80ボードのニューラルネットワークの出力に対して適用する前と、適用後の詳細を表6に示す。Z-80ボードでは、上述の処理を行った結果、診断率87.5%が91.4%に向上した。また、同様な処理を行うことで、カウンタボードでは85.2%が90.4%に、MSIボードでは86.9%が、90.8%に向上した。

5. 汎化能力の検討

2.4で生成学習データについて検討したが、ここではさらにそれを確認するために、Z-80ボードに対して、表2に示したようなばらつきは与えずに、意図的に正常ICの温度データ、故障ICの温度データ共に、一意的に学習データを与えて、ニューラルネットワークを構築して、すでに使用した同じ未学習故障ICに対して診断実験を行った結果、82.6%の診断率を得た。

また、強い接続のICグループの個数を9個から4個に減らし、弱い接続のICグループの個数を17個にして学習データを生成してニューラルネットワーク構築し、同様に故障診断実験を行った結果84.1%の診断率を得た。これらは本論文で提案した学習データ生成のアルゴリズムで構築したニューラルネットワークの診断率87.5%より劣り、本論文の学習データ生成アルゴリズムの汎化能力の助長に対する有効性が確認できた。

ニューラルネットワーク出力に対して、4.の診断率向上の手法を各々故障IC個数を4~7個に仮定して処理した結果を図8に示す。図8の□のプロットは、一括修正法で構築したニューラルネットワークで診断した出力を処理した結果で、○は逐次修

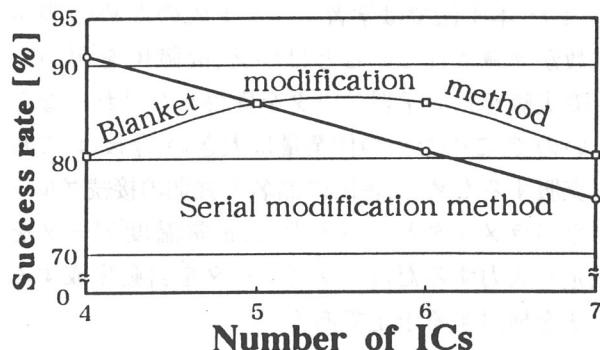


図8 故障IC個数を増やした場合の診断結果
(汎化能力の検討結果)

Fig. 8 Fault diagnosis result with increasing fault IC

正法で構築したニューラルネットワークで診断した出力を処理した結果である。

図8から、故障個数を増やすにつれて、診断率は減少しているが、6個のときに約81%の診断率である。これは故障の場合、異常発熱値は正常値と大きく異なる温度になることが多いので3個で構築したニューラルネットでもかなりの診断が可能であると考えられる。

6. むすび

ボード上のICを入力信号線の接続本数により強い接続のICグループと、弱い接続のICグループに分類し、強い接続のICグループに対しては故障実験をすべて行い、弱い接続のICグループに関しては、一番入力線数の多いIC1つとのみ実験を行い学習データを得る。この際に、故障ICは3個以内であると仮定する。以上の二通りの実験データより学習データを生成し、この考え方で3種のボードに対して各々ニューラルネットワークを構築してICレベルで故障診断を行い、ニューラルネットワークの出力を、故障ICは3個までであるという仮定を生かして、処理を行うことで約90~91%の診断率を得た。この結果から少ない実験データから学習データを生成し、高診断率のニューラルネットワークを構築する本手法の有効性を確認することができた。

最近はボードの実装密度を上げるために、ペアチップでの実装[25]や、チップ内の多層配線化により、チップ内に故障が発生すると固定的に異常発熱が発生し、これが外部から観測しやすい状況になってきている。従って、ICの発熱を観測することを基本にした本手法がさらに有効になると考えられる。しかし、本手法は、ICの発熱を利用して故障でICに、学習時の状況を上回る大きな異常発熱が発生した場合は対応できず、診断を誤

る。また、本手法では学習データ生成のための測定回数が削減されているとはいえ、故障ICを用いて故障実験を行い学習データを獲得しなければならないので、このための作業量は大きい。今後は、これを克服するために、各ICの品名と強弱の接続グループをパラメータとして入力し、正常温度データを測定し入力するだけで学習データを自動生成する手法を検討する予定である。

文 献

- [1] 西野 聰, 大嶋建次, “赤外線画像によるICボードの故障検出,” 信学論(D-I), vol.J80-D-I,no.6,p p.514-526, June.1997.
- [2] 西野 聰, 大嶋建次, “赤外線画像のヒストグラムによるICボードの故障検出の検討,” 信学技報FT S93-62, Feb .1994.
- [3] 西野 聰, 大嶋建次, “赤外線画像にニューラルネットワークを適用したボードの故障診断の一試み,” 1996年信ソ大会,C-489.Septem.1996.
- [4] 西野 聰, 大嶋建次, “赤外線画像にニューラルネットワークを適用したボードの故障診断の一試み-II,” 1997年信学春季全会,C-12-12.May.1997.
- [5] 安居院猛, 長橋宏, 高橋裕樹, “ニューラルプログラム,” 昭晃堂, 1993.
- [6] 馬場則男, 小島史男, 小澤誠一, “ニューラルネットの基礎と応用,” 共立出版, 1994.
- [7] 臼井支朗, 岩田彰, 久間和生, 浅川和雄 “基礎と実践 ニューラルネットワーク,” コロナ社, 1995.
- [8] 坂和正敏, 田中雅博, “ニューロコンピューティング入門,” 森北出版, 1997.
- [9] 上坂吉則, “ニューロコンピューティングの数学的基礎,” 近代科学社, 1993.
- [10] 上坂吉則, “ニューラルネットと学習可能性,” 信学会誌, vol74,no.9,pp.943-948, 1991.
- [11] Jacek. M. Zurada, “Artificial Neural Systems,” West publishing co.1992.
- [12] 渡辺久恒, 福間雅夫, 山品正勝, “シリコンテクノロジの展望,” 信学論(C-II), vol.J81-C-II,no.6, pp 524-533, June.1998.
- [13] 久保脩治, “超LSIの展開,” オーム社, 1996.
- [14] 的場司, 富安雄一, 西出弘一, “システム オンチップ技術,” 東芝レビュー, vol.53,no.5pp.53-56, May.1998.
- [15] E. A. Amerasekera and D.S Campbell, “Failure mechanisms in semiconductor device,” Jhon Wiley & Sons, 1987.
- [16] 武石喜幸, 原央, “MOS集積回路の基礎,” 近代科学社, 1992.

- [17] 中前正彦, “最先端ULSIプロセス技術の現状と今後の動向,” NECDEVICE THECNOLOGY, 1997.no60.Dec.
- [18] Sung-Mo Kang , Yusuf Leblebici, “CMOS digital integrated circuits,” The McGraw-Hill, 1996.
- [19] Masakazu Shoji, “Theory of CMOS Digital Circuits and Circuit Failures,” Princeton University Press, 1992
- [20] “半導体特集,” 日本信頼性学会誌, vol.19, no.4, 1997.June.
- [21] 今井勝次, 郷原一寿, 内川嘉樹, “ニューラルネットワークを用いたチップ抵抗器の捺印数字列の認識,” 信学論(D-II), vol.J77-D-II,no.1, pp41-50.1994. Junua.
- [22] 田中直樹, 是枝稔明, 井上健, 梶谷浩二, “カテゴリーの分布を考慮したバックプロパゲーションネットワークの学習法,” 信学論(D-II), vol.J81-(D-II), no2, pp293-300, Feb.1998.
- [23] 藤吉弘亘, 梅崎太造, 今村友彦, 金出武雄, “ニューラルネットワークによるナンバープレートの位置検出,” 信学論(D-II), vol.J80,(D-II), no6, pp162 7-1634, June.1997.
- [24] 春日壽夫, 門間美和, “VLSIパッケージの最新技術動向と新パッケージ開発状況について,” NCE DEVICE THECNOLOGY, 1998.no62.June.
- [25] 日本経済新聞社, “日本経済新聞,” 1997.12.9, 13面.
- [26] 塚田 祐, “ビルドアップ配線リツ入門,” 日刊工業新聞社, 1998.
- [27] 大城一徳, “ソルダリング実装,” 日刊工業新聞社, 1998.
- [28] 春日壽夫, “CSP/BGA技術,” 日刊工業新聞社, 1998.
- [29] 土肥俊郎, 河西敏雄, 中川威雄, “半導体平坦化CMP技術,” 工業調査会, 1998.
- [30] 村井真一, 小迫靖志, 平峰千恵, 室井克信, 萩原拓治, “3値バス衝突チェック機能をもつルールベース設計規則チェック手法,” 信学論(D-I), vol.J79-D-I, no.12, Dec.1996. pp.1072-1082.

小山工業高等専門学校 電子制御工学科

E-mail: nishino@oyama-ct.ac.jp

(受理年月日 1998年9月30日)