

## ニューラルネットワークを用いた肝癌肝 切除術の予後予測

香川医科大学第1外科

濱本 勲 岡田 節雄 若林 久男  
前場 隆志 前田 肇

肝癌肝切除術の予後をニューラルネットワークを用いて予測した。入力層、中間層および出力層にそれぞれ9, 14および1個のニューロンを持つ階層型ニューラルネットワークを構築し、これにあらかじめ予後のわかっている58例の肝切除症例(耐術49例, 非耐術9例)の予後を教師信号(1, 耐術; 0, 非耐術)を用いて学習させた。10万回の学習でニューラルネットワークは良好に収束し、1例を除いて正確に応答するようになった。この学習済みニューラルネットワークを用いて、11例の肝切除症例の耐術能を術前に prospective に予測した。その結果、10例の耐術例および1例の非耐術例を術前に正確に評価することができた。ニューラルネットワークは、肝癌肝切除後の予後を予測する上で、強力な手段となりうるということがわかった。

**Key words:** neural network, hepatocellular carcinoma, hepatectomy

### はじめに

肝切除は肝細胞癌治療において最も有効な治療法のひとつである。肝臓は本来大きな予備能を備えており、70%の切除が可能といわれている。しかし、わが国における肝細胞癌の大半は、BないしC型肝炎による肝硬変を合併しているために<sup>1)</sup>、肝切除率が制限されることが少なくない<sup>2)</sup>。そのために、術前に肝切除限界を正確に評価することが重要となる。現在までに、肝切除術後の予後予測に関して多くの方法が提案されている<sup>3)~5)</sup>。しかし、これらすべての方法は、線形モデルを用いており、肝切除術の耐術能のように、多くの要素が複雑に関係しあった系の挙動を予測するには、不十分であると思われる。

一方、ニューラルネットワークは天気予報<sup>6)</sup>、文字認識<sup>7)</sup>、株価予測<sup>8)</sup>などの複雑な系の予測に用いられて威力を発揮している。

本研究では階層型ニューラルネットワークを用いて肝癌肝切除術の耐術能評価を行った。

### 方 法

対象症例：学習に用いた症例：1984年10月から1994年10月までに当科で施行された肝細胞癌に対する肝切

除術159例のうち、データのそろっている58例をニューラルネットワークの学習に用いた。これらの症例のうち、いったん退院することのできた49例を耐術群、術後肝不全によって死亡した9例を非耐術群とした。対象症例の背景因子を示す (Table 1)。

Prospective analysis に用いた症例：1992年5月から1993年10月までに当科で施行された11例の肝細胞癌に対する肝切除症例を prospective に分析した。

**Table 1** Back grounds of the patients belonging to Group A and B

	Group A	Group B
n (female)	49 (11)	9 (2)
Age	63.0 ± 8.80	61.4 ± 2.79
AST (U/L)	51.0 ± 22.8*	70.8 ± 23.0
ALT (U/L)	43.6 ± 23.5	62.9 ± 33.1
ALP (U/L)	262 ± 95.4*	484 ± 439
HPT (%)	90.4 ± 16.0	85.3 ± 17.9
ICGR15 (%)	22.5 ± 12.6	24.6 ± 9.44
Plt (/μ <sup>3</sup> )	13.8 ± 6.54	15.9 ± 10.6
Bil (mg/dl)	0.759 ± 0.354*	1.11 ± 0.877
TVL (ml)	1,220 ± 370	968 ± 132
RLV (ml)	761 ± 299	598 ± 190

Mean ± S.D. TVL, total liver volume; RLV, residual liver volume. \*, vs. Group A (p < 0.05) by student t-test.

<1995年2月8日受理>別刷請求先：濱本 勲  
〒761-07 香川県木田郡三木町池戸1750-1 香川医  
科大学第1外科

肝体積の測定：1cm スライスの肝臓 CT 像上で肝切除線を引き、各スライスの肝臓の輪郭および残存肝の輪郭をディジタイザー（グラフィック、モデル KD4030B）を用いて、パーソナルコンピュータ（日本電気、PC9801 VX）に読み込んだ。各スライスの全肝および残存肝の面積を定積分によって求めた後、各スライスの面積に厚さ1cm を乗じて総和をとったものを全肝体積および残存肝体積として用いた<sup>9)</sup>。

ICG クリアランステスト：早朝空腹時、0.5mg/kg のインドシアニングリーン (ICG) を5ml の蒸留水に溶解した後、30秒以内に速やかに静脈内注入（静注）した。静注前と静注 5、10および15分後に末梢静脈血を採取し、血清 ICG 濃度を805nm の吸光度から計算した。これらの時系列データを

$$y = ae^{-kt}$$

y…ICG 血中濃度, t…静注後経過時間

に線形最小 2 乗法でフィッティングさせることによって a および k 値を求め、ICGR<sub>15</sub> (%) は  $100e^{-15k}$  によって求めた。

ニューラルネットワーク：構造：今回われわれは、1 層の中間層を持つ階層型ニューラルネットワークをパーソナルコンピュータ Macintosh Quadra 800 上で構築した (Fig. 1)。ニューラルネットワークのプログ

Fig. 1 A neural network used in this study. The neural network is consisted of 9 neurons of the input layer, 14 neurons of the middle layer and one neuron of the output layer.





Fig. 2 An artificial neuron. The neuron receives input signals ( $x_i$ ) and output was made by the transfer function,  $f$  which was a function of input signals,  $x_i$ , synaptic weights,  $w_i$  and threshold,  $\theta$ .



ラムは、プログラム言語 Think C (Symantec Corp.) を用いて記述した。ニューラルネットワークは、生物の神経系を模倣した並列処理系で、図のような単位ニューロンを網の目状に接続することによってノイマン型のコンピュータが苦手とするパターン認識や予測を行わせるものである<sup>6)13)14)</sup>。単位ニューロンは複数の入力を受ける (Fig. 2)。それらの値に個々の結合定数を乗じたものの総和に閾値を加えた値に対して、伝達関数によって決定される値を出力する。今回、われわれは伝達関数  $y(x)$  として、

$$y(x) = 1 / \{1 + e^{-x/\mu}\}$$

を用いた。ここで、

$$x = \sum (x_i w_i) + \theta$$

$x_1 \dots i$  番目の入力値,  $w_1 \dots i$  番目の入力に対する結合定数,

$\theta$  …… 閾値,  $\mu$  …… 伝達関数の傾きを決める正の定数。

これらの単位ニューロンを入力層に 9 個、中間層に 14 個、出力層に 1 個配し、階層状に接続したものを用いた (Fig. 1)。

学習：このようにして構成したニューラルネットワークは、このままでは役には立たず、予後が既知の症例を学習する必要がある。学習に際しては、まずニューラルネットワークの結合定数および閾値を乱数によって決定する。次にニューラルネットワークの入力層に、学習用の症例の aspartate aminotransferase (AST), alanine aminotransferase (ALT), alkaline phosphatase (ALP), total bilirubin (T. Bil), ヘパラスチンテスト (%), ICGR<sub>15</sub> (%), 全肝体積, 残存肝体積および血小板数を入力し、その出力値を得る。

Table 2 Parameters for supervised learning and output of the learned neural network

Sex	Age (y.o.)	AST (U/L)	ALT (U/L)	ALP (U/L)	T. Bil (mg/dl)	HPT (%)	ICGR15 (%)	TLV (ml)	RLV (ml)	Plt (/μl)	A	B	C
M	63	32	19	229	3.3	80	42.0	937	857	5.4	0	0.015	0.007
F	58	68	30	497	0.9	57	30.0	946	886	4.8	0	1.000	1.000
F	63	48	33	496	0.6	102	20.6	990	590	31.7	0	0.020	0.001
M	60	87	124	169	0.5	99	20.2	961	661	33.8	0	0.000	0.000
M	61	73	82	506	0.8	72	26.9	812	333	13.6	0	0.000	0.000
M	62	60	66	1,605	1.5	116	9.3	1,243	354	19.6	0	0.005	0.003
M	63	96	51	270	0.6	83	31.8	1,092	608	14.4	0	0.029	0.014
M	57	68	82	298	1.1	73	17.5	856	530	11.2	0	0.039	0.017
M	66	105	79	287	0.7	86	22.7	875	562	9.0	0	0.023	0.009
M	52	34	36	407	0.3	101	7.8	1,686	250	22.6	1	1.000	1.000
M	54	61	69	243	0.9	62	21.4	1,090	1,040	5.8	1	1.000	1.000
M	75	41	26	152	0.7	90	14.9	906	801	12.7	1	1.000	1.000
M	63	52	62	293	0.4	76	18.6	1,444	1,314	11.5	1	1.000	1.000
F	70	83	41	244	0.6	66	40.8	1,089	1,039	10.5	1	1.000	1.000
M	55	34	36	204	0.3	130	8.9	982	212	13.0	1	1.000	1.000
M	62	30	35	254	1.4	97	15.0	951	280	15.1	1	1.000	1.000
M	52	37	36	252	0.6	109	11.9	1,987	982	24.1	1	1.000	1.000
M	72	63	75	237	0.8	84	25.8	1,235	1,185	4.9	1	1.000	1.000
M	66	25	26	154	0.7	117	10.0	1,494	1,147	17.6	1	1.000	1.000
M	46	95	40	276	1.3	61	53.3	1,111	991	10.4	1	0.988	0.999
F	61	52	67	198	0.7	73	35.2	946	886	9.7	1	1.000	1.000
F	53	50	40	225	0.5	121	14.1	997	877	13.2	1	1.000	1.000
M	71	50	26	288	0.8	84	29.9	1,263	822	9.6	1	1.000	1.000
M	65	50	42	127	0.7	95	19.6	1,060	985	4.0	1	1.000	1.000
M	67	62	60	268	0.4	96	18.8	1,043	993	10.8	1	1.000	1.000
M	67	53	81	250	0.7	101	29.2	1,042	951	12.0	1	1.000	1.000
M	48	42	48	242	1.9	76	43.3	1,082	1,022	6.9	1	1.000	0.997
F	62	25	25	259	0.6	100	26.5	873	793	9.1	1	1.000	1.000
M	66	48	28	191	1.0	83	45.0	1,515	815	8.1	1	1.000	1.000
M	39	65	106	264	0.8	98	7.4	1,597	490	20.8	1	1.000	1.000
F	59	99	39	150	0.5	76	14.9	664	258	8.7	1	0.983	0.992
M	66	19	17	216	0.6	105	18.2	1,348	1,148	21.9	1	1.000	1.000
F	67	60	29	332	0.6	114	17.7	930	580	21.6	1	0.982	0.993
M	56	70	86	422	0.8	89	22.7	1,920	549	30.9	1	0.985	0.993
M	58	35	31	374	0.6	117	18.4	2,482	582	29.5	1	1.000	1.000
M	51	25	42	158	0.5	80	22.7	1,377	687	12.1	1	1.000	1.000
M	68	11	17	238	0.5	100	7.2	1,289	331	26.0	1	1.000	1.000
M	73	35	18	371	0.6	95	26.2	893	525	19.5	1	1.000	1.000
M	66	27	44	160	0.7	106	16.2	1,394	935	12.7	1	1.000	1.000
M	63	76	81	239	1.0	82	22.6	1,159	380	11.4	1	0.969	0.987
M	78	34	21	197	0.5	93	20.2	1,410	760	15.3	1	1.000	1.000
M	69	30	19	474	1.3	92	14.0	1,555	351	13.6	1	1.000	1.000
M	59	23	23	271	0.7	99	11.9	1,828	1,240	15.0	1	1.000	1.000
M	74	84	111	280	1.1	92	14.0	981	746	8.1	1	0.981	0.992
M	60	53	49	419	0.3	54	22.2	1,191	558	9.1	1	1.000	1.000
M	67	49	22	272	0.6	89	11.3	677	449	10.5	1	1.000	1.000
M	78	84	62	249	1.1	94	49.7	1,142	964	10.6	1	1.000	1.000
M	63	118	88	336	0.6	76	11.9	1,026	485	9.0	1	0.999	1.000
M	46	74	58	642	0.9	74	23.4	1,156	1,156	13.2	1	1.000	1.000
F	67	32	34	166	0.4	83	44.9	1,041	871	17.2	1	1.000	1.000
M	57	44	31	219	0.5	76	3.0	1,159	817	8.1	1	1.000	1.000
M	57	48	32	202	0.9	72	27.3	1,200	1,170	6.3	1	1.000	1.000
F	65	51	30	174	0.9	77	56.3	696	686	8.5	1	1.000	1.000
F	69	35	19	164	0.5	100	20.0	1,137	300	22.9	1	1.000	1.000
F	68	67	27	276	1.6	88	28	1,824	997	23	1	0.999	1.000
M	68	36	23	343	1.0	98	18	1,350	701	19	1	1.000	1.000
F	76	83	38	250	0.3	94	11	1,015	729	14	1	1.000	1.000
M	71	47	42	227	1.5	94	33	528	474	5	1	0.999	0.999

M, male; F, female. TLV, total liver volume; RLV, residual liver volume. A, actual patient outcome for teaching signal; B, output after supervised learning; C, output after reconstruction learning.

その出力値と切際の予後(耐術群=1, 非耐術群=0)とを比較し, 出力値が実際の予後に近づくようにそれぞれの結合定数および閾値を調整する。これを繰り返すことによって, すべての学習に用いた患者のデータを入力すると, 正確にその予後を出力できるようになる。これを学習と呼び, 上記の方法で結合定数と閾値を決定する方法を逆伝搬法という<sup>10)</sup>。学習は, 各症例の出力値と実際の予後との差の絶対値の平均が0.02以下になるまで繰り返した。

再構築学習: 以上のようにして決定した結合定数や閾値は一意的なものではないために, 処理過程の解析結果は曖昧なものになる。ニューラルネットワーク内の情報の流れを一意的に求めるために, 上記の学習の後に, 忘却, 学習の過程を取り入れた再構築学習法を行った<sup>11)</sup>。すなわち逆伝搬学習の後に, 下記の条件に従って結合定数を一部消去(忘却)した。

$$W_{ij} \leftarrow W_{ij} - \text{sgn}(W_{ij}) \xi \{1 - \delta(W_{ij})\}$$

$W_{ij}$ : i 番目の入力層ニューロンと j 番目の中間層ニューロン間の結合定数。

ここで  $\delta(\ )$  は  $|W_{ij}| < \xi$  のとき 1,  $|W_{ij}| > \xi$  のとき 0 を与える関数である。こうして, 一部データを消去したあと, 再び逆伝搬法によって学習を行った。この忘却, 学習のサイクルを100回繰り返すことによって, 一意的に結合定数を決定することができた。

Prospective analysis: 学習済みのニューラルネットワークを用いて前述の11症例の耐術能を prospective に分析した。

**結 果**

学習に用いた全症例のデータと予後, およびニューラルネットワークの出力結果を示す (Table 2)。1 症例を除いて, すべての症例に対して, 誤差0.02の範囲で正確な応答をしていることがわかる。また, 同表の

**Table 3** Synaptic weights between middle and output layers before and after reconstruction

1	2	3	4	5	6	7	8	9	10	11	12	13	14	threshold
Before reconstruction learning														
4.20	2.77	0.31	-14.34	1.13	3.96	-0.20	7.01	4.16	-0.27	-0.36	-5.71	5.81	6.06	-0.50
After reconstruction learning														
4.32	2.79	0.10	-17.53	0.96	4.26	-0.42	8.28	4.63	-0.53	-0.50	-7.39	6.97	8.26	-0.01

Synaptic weights between input and middle layers before and after reconstruction learning

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
Before reconstruction learning														
AST	-1.01	0.27	-0.19	8.92	-0.01	-1.73	-0.01	-0.51	0.24	-0.07	-0.02	0.30	-0.22	0.38
ALT	-1.01	0.61	-0.05	2.87	0.37	-1.12	-0.13	0.91	0.54	-0.10	-0.18	-1.02	0.96	0.79
ALP	-1.02	-0.50	-0.19	-1.44	-0.26	-0.32	-0.06	-0.92	-0.99	-0.09	0.00	0.50	-0.47	-1.23
HPT	0.94	0.13	-0.20	-0.64	-0.23	0.13	-0.08	-0.22	0.54	-0.04	0.04	-0.66	0.49	0.93
ICGR15	-1.21	-1.12	-0.07	-2.62	-0.16	0.32	-0.09	0.69	-1.81	0.01	-0.11	1.58	-1.67	-2.72
TLV	0.76	1.02	-0.04	-4.09	0.34	0.35	-0.20	2.96	1.73	-0.18	-0.22	-3.24	3.35	3.04
RLV	-2.07	-0.32	-0.10	-1.90	-0.03	0.16	-0.13	0.19	-1.38	-0.10	-0.04	0.05	0.36	-1.38
Plt	-0.63	-0.35	-0.13	0.91	-0.22	-1.23	-0.07	-2.94	-0.45	0.02	-0.17	0.77	-0.82	-0.73
Bil	-0.78	-1.16	-0.19	0.98	-0.49	-1.82	0.10	-1.25	-0.96	0.12	0.18	1.35	-1.40	-0.51
threshold	1.28	0.03	-0.13	0.30	-0.01	1.17	-0.18	1.23	0.59	-0.17	-0.21	0.04	-0.06	0.36
After reconstruction learning														
AST	-0.28	0.00	0.00	7.38	0.01	-0.01	0.00	0.01	-0.01	0.00	-0.06	-0.27	0.29	1.12
ALT	-0.92	0.00	-0.01	3.33	-0.01	-0.01	0.01	-0.01	-0.01	0.00	-0.15	-0.98	0.92	0.36
ALP	-0.27	0.01	-0.01	-0.21	0.00	0.00	0.00	0.00	-0.01	0.00	0.01	0.82	-0.70	-1.82
HPT	0.49	0.00	-0.01	-0.01	-0.01	0.01	0.00	0.01	-0.01	0.00	0.04	-1.35	1.10	2.01
ICGR15	-0.51	-0.01	0.00	-1.83	-0.01	-0.01	0.00	0.01	-0.47	0.01	-0.06	2.03	-2.00	-3.42
TLV	0.01	0.18	0.00	-4.27	0.00	0.00	0.00	2.15	1.06	-0.20	-0.23	-4.04	4.10	4.10
RLV	-1.88	-0.01	-0.01	-2.48	0.00	0.00	0.00	0.01	-0.94	-0.06	-0.01	0.38	0.21	-2.41
Plt	-0.07	-0.01	0.00	-0.42	-0.01	-1.22	0.00	-2.83	-0.01	0.12	-0.07	0.88	-0.95	-0.76
Bil	0.00	-0.07	0.00	1.75	0.00	-0.68	0.01	-0.64	-0.01	0.13	0.20	1.31	-1.37	-0.35
threshold	0.50	-0.20	-0.16	0.04	-0.13	0.84	-0.14	1.50	0.13	-0.11	-0.16	0.57	-0.67	0.11

TLV, total liver volume; residual liver volume.

最右列に再構築学習後のニューラルネットワークの出力を併記しているが、逆伝搬学習後と同様、1症例を除いて、すべての症例に対して良好な応答を示した。

逆伝搬学習後と再構築学習後の結合定数と閾値を示す (Table 3)。再構築学習後には、一部の結合定数が大きくなり、他の定数が減少し、ニューロンの結合が強調されていることがわかる。

Prospective analysis に用いた症例のデータと予後、およびニューラルネットワークの出力結果を示す (Table 4)。症例11以外は耐術症例であるが、ニューラルネットワークの出力も0.7558–1.0000となり、実際

の予後と一致した。また、症例11は非耐術症例であるが、ニューラルネットワークの出力は0.0024となり、非耐術症例となった。

Prospective analysis に用いた11症例に対するニューラルネットワークの出力を、x軸に残存肝体積をとって示した (Fig. 3)。非耐術例の症例11以外は、すべて0.5以上の出力を示したが、症例11は、約680mlの残存肝体積の時に出力が0.5以下となり、これより小さい残存肝体積では耐術不可能と判断された。実際、この症例の残存肝体積は606mlであり、非耐術症例となった。

### 考 察

われわれ外科医が、手術前に患者の耐術能を評価し、手術の可否を決定する時には、無意識のうちにさまざまな情報が加味されている。これらの要素の中で、どれが重要であり、どのように予後に反映しているかということを知ることが、すなわち耐術能評価の客観化に他ならない。これまでに肝切除の予後予測の方法として、ICGRmaxを用いた Mizumoto ら<sup>4)</sup>の報告や、重回帰分析による Okamoto らの予後得点<sup>3)5)</sup>などが考案されており、高く評価されているが、必ずしも耐術症例と非耐術症例を完全に分離できるところまでは至っていない。その理由のひとつに、これらの評価法は術前因子を入力とし、手術の予後を出力として与えるブラックボックスの中身を線形モデルで記述したことがあげられる。前述のように、耐術能のような、多くの要素によって決定される複雑な系の挙動を線形モデルで記述するのは、解析の容易さという面で致し方

Fig. 3 Outputs of the learned neural network to the 11 cases used for prospective analysis as a function of residual liver volume.




Table 4 Prospective prediction of the prognosis of the patients with hepatocellular carcinoma with the learned neural network

Case	Age	Sex	AST (U/L)	ALT (U/L)	ALP (U/L)	TBil (mg/dl)	HPT (%)	ICGR15 (%)	TLV (ml)	RLV (ml)	Plt (/μl)	A	B
1	49	M	36	39	197	0.9	110	7.15	1,334	364	18.1	1	1.0000
2	55	M	45	50	212	0.7	92	17.8	1,337	696	7.8	1	1.0000
3	60	M	23	29	304	0.7	100	19.0	1,356	312	8.2	1	1.0000
4	68	F	56	29	479	1.2	65	40.5	910	870	7.0	1	0.9999
5	38	F	371	354	312	1.7	79	15.7	832	672	8.4	1	0.9992
6	60	M	84	74	433	1.0	80	32.6	972	892	9.1	1	0.9880
7	59	M	114	99	262	0.8	7.5	33.0	1,627	1,563	6.7	1	1.0000
8	73	M	71	56	203	0.8	93	25.0	828	780	10.3	1	0.9991
9	65	M	30	19	271	1.6	93	16.0	1,627	1,531	15.7	1	1.0000
10	47	M	24	32	323	0.9	72	24.4	580	522	18.5	1	0.9883
11	70	M	160	97	246	0.9	82	28.2	837	606	6.6	0	0.0000

M, male; F, female; TLV, total liver volume; RLV, residual liver volume. A, actual prognosis (1=discharged; 0=hospital death); B, output of the neural network.

ないものとは思われるが、原理的矛盾をはらんでいる。

ニューラルネットワークは、既述のように非線形の応答をする並列処理系であり、系の内部構造が複雑すぎてモデル化できないような事象の予測に利用されて威力を発揮している<sup>6)~8)</sup>。その最大の特徴は、入力データの種類をあらかじめ選択する必要がないこと、非線形の応答および学習にある。多変量解析においては、説明変数をあらかじめ決定しておく必要があるが、ニューラルネットワークは、必要と思われるすべてのデータを入力してもかまわない。学習を繰り返すうちに、出力に大きな影響をおよぼさないデータのシナプス結合は弱くなり（結合定数が小さくなることに相当）、重要なデータに対応するシナプス結合のみが強くなるために、重要でない変数は淘汰されてしまうためである。本研究では9つのデータを用いた。これらのデータは、あらかじめ20のデータを用いたニューラルネットワークを同様に学習させた結果、他の11のデータは、出力に影響を及ぼさなかったために省略した。20データをそのまま用いなかった理由はその計算時間にある。本研究に用いたニューラルネットワークによる1,000回の学習には、約80秒の時間を要する。入力が20項目になり、中間層が30ニューロンになると、結合数は前者の140から630へと増加するために、計算時間が5倍以上に延長し、実用性を失う。今後、より広範囲の手術リスクの判定にニューラルネットワークを用いる上で、計算時間の短縮が大きな課題となろう。ニューラルネットワークの非線形応答については、3層以上の階層型ニューラルネットワークで確認されている<sup>12)</sup>。ニューラルネットワークの特徴のひとつである学習は、他の解析にみられない大きな特徴といえる。通常のノイマン型デジタルコンピュータを用いて問題を処理する上で、あらかじめその問題を解析し、すべての場合に対処できる処理方法（プログラム）を、コンピュータに指示しておかなければならない。このプログラムの作成において、あらかじめすべての場合を想定することは、人間にとって非常に困難な作業である。ニューラルネットワークにおいては、学習がデジタルコンピュータのプログラム作成過程に相当する。学習によるプログラミングの特徴のひとつとして、デジタルコンピュータにおけるプログラムの作成の場合のように問題を解析する必要がないことがあげられる。このように、入力データの特徴が、学習によってニューラルネットワーク内に自動的に記録されるといふ特徴は、因果関係の解析が困難なデータを処理する

上で非常に有効となる。

以上のように、ニューラルネットワークを肝癌肝切除の耐術能の評価に用い、その有用性について検討したが、これまでの線形多変量解析では得られなかった優れた特性が示され、また prospective な分析においてもその有用性が示された。今後、ニューラルネットワークのニューロン数を増やすことによって、他の疾患に対する肝切除や、さらには他の手術の耐術能評価を総合的に判定する大きなシステムを構築できる可能性が示された。その際最も大きな障壁となるのが、その計算時間である。今回われわれはデジタルコンピュータを用いてソフトウェア的にニューラルネットワークを実現したために、膨大な計算時間を要した。今後、計算時間の問題を解決するためには、専用ハードウェアの導入を検討する必要があると思われる。

本論文の要旨は、第43回日本消化器外科学会総会(1994年2月、東京)、第44回日本消化器外科学会総会(1994年7月、富山)で発表した。

#### 文 献

- 1) Shikata T: Primary liver carcinoma and liver cirrhosis. Edited by Okuda K, Peter RL. Hepatocellular carcinoma. John Wiley and Sons, New York, 1876, p53-71
- 2) Lin TY: Results in 107 hepatic lobectomies with a preliminary report on the use of a clamp to reduce blood loss. *Ann Surg* 177:413-421, 1973
- 3) Okamoto E, Kyo A, Yamanaka N et al: Prediction of the safe limit of hepatectomy by combined volumetric and functional measurements in patients with impaired hepatic function. *Surgery* 95: 586-592, 1984
- 4) Mizumoto R, Kawarada Y, Noguchi T: Preoperative estimation of operative risk in liver surgery, with special reference to functional reserve of the remnant liver following major hepatic resection. *Jpn J Surg* 9: 343-349, 1979
- 5) Yamanaka N, Okamoto E, Kuwata K et al: A multiple regression equation for prediction of posthepatectomy liver failure. *Ann Surg* 200: 658-663, 1984
- 6) McCann DW: A neural network short-term forecast of significant thunderstorms. *Forecasting Techniques* 7: 525-534, 1992
- 7) 桐谷 滋, ニューロネットグループ: 入門と実習 ニューロコンピューター. 技術評論社, 東京, 1989, p231-241

- 8) Matsuba I: "Neural sequential associator and its application to stock price prediction", IECON '91, Kobe, 1991.
- 9) 濱本 勲, 因藤春秋, 前場隆志ほか: パーソナルコンピュータを用いた肝臓に対する集学的治療の効果判定. 医と薬学 21: 74-75, 1989
- 10) Rumelhart DE, Hinton GE, Williams RJ: Learning representations by back-propagating errors. Nature 323: 533-536, 1986
- 11) Aoyama T, Ichikawa H: Reconstruction of weight matrices in neural networks—A method of correlating outputs with inputs. Chem Pharm Bull 39: 1222-1228, 1991
- 12) 市川 紘: 階層型ニューラルネットワーク, 非線型問題解析への応用. 共立出版, 東京, 1993, p29-30

### Predicting the Prognosis of the Hepatectomized Patient with Hepatocellular Carcinoma with a Neural Network

Isao Hamamoto, Setsuo Okada, Hisao wakabayashi, Takashi Maeba and Hajime Maeta  
First Department of Surgery, Kagawa Medical School

The prognosis of the hepatectomized patients with hepatocellular carcinoma was predicted with a neural network. A neural network with 9 neurons for the input layer, 14 neurons for the middle layer and 1 neuron for the output layer was constructed. Preoperative data (AST, ALT, ALP, hepaplastine test, ICGR 1.5, total liver volume, residual liver volume, platelet and total bilirubin) of 58 hepatectomized patients (49 and 9 patients were discharge from and died at hospital, respectively) whose prognoses were already known, were learned by the neural network with teaching signals (1 for discharged, 0 for hospital death). After 100,000 times of learning, the output of the neural network converged satisfactorily and gave the correct answer in all except one case. With the learned neural network, the prognoses of 11 patients with hepatocellular carcinoma were estimated prospectively. The prognoses of these patients, 10 of them were discharged and one of whom died of hepatic dysfunction, were predicted correctly. It was concluded that the neural network was a powerful tool for predicting the prognosis of hepatectomized patients with hepatocellular carcinoma.

**Reprint requests:** Isao Hamamoto First Department of Surgery, Kagawa Medical School  
1750-1 Ikenobe, Miki-cho, Kita-gun, Kagawa, 761-07 JAPAN