

文書の論理構造を備えた日本語清書システム「浄書」の設計と実現†

里山元章†† 中川正樹††† 高橋延匡†††

本論文は、高品質な文書出力と高度な文書清書機能を持つインテリジェント清書マシン「浄書」(JOSHO: Japanese Output Server with HOspitality)の設計と実現について述べたものである。浄書は、レーザービームプリンタをインテリジェント化し、清書機能や文書交換機能を持たせている。このため、パソコンやワードプロセッサの清書マシンとして利用できる。浄書には、日本語フォーマッタや英文フォーマッタ、リステイングツールなどのソフトウェアが用意されているが、本論文ではそれらのうち、特に日本語フォーマッタについて述べている。浄書の持つ日本語フォーマッタは、章や節、見出し、図といった文章の内部構造を書式化に反映しており、それらの文書構造に対して書式を設定するようになっている。また、和欧混合組版規則に基づく行頭、行末、分離禁則処理やスペーシング処理を実現している。浄書はすでに研究室において実用され、論文や研究報告書、プログラムとそのドキュメント、議事録などの印刷に利用されている。

1. ま え が き

計算機を文書作成に利用し始めたのは、プログラム作成やその仕様書作成のためであった。計算機科学に従事する研究者は、マニュアルや仕様書を計算機で管理する目的や自らの論文や報告書を秘書にタイプしてもらうコストを軽減するためあるいは、印刷屋に頼めないような文書を作成することを目的として、さまざまな文書作成システムを作り上げた。troff/nroff¹⁾、TEX²⁾、Scribe³⁾などは有名な例である。それらのいくつかは、日本語化されている⁴⁾。

我々の研究の長期的な目的は、日本の文化に根ざした計算機による文書作成環境の実現にある。その環境では、論文もプログラムも仕様書も同一の環境下で扱われるべきであると考えている。このような文書作成環境の実現のためにオペレーティングシステムのレベルから研究を行っている。

その研究の一環として我々は、『文書を美しく仕上げることができるという喜びは我々の創作意欲をそそるものである』というモットーのもと、高度な日本語文書清書機能を持つインテリジェントプリンタの開発を1979年より始めた。これを「浄書」(JOSHO: Japanese Output Server with HOspitality)⁵⁾と呼ん

でいる。浄書は、単なる印字機能だけでなく、高度な組版処理を行うフォーマッタをプリンタ上に置くといった点で他のプリンタシステムや清書システムと異なる。

本研究の具体的な目的は、次のようなプリンタを開発することである。

(1) 文書の論理的な構造を反映した書式設定機能や和欧混合組版規則に基づく禁則処理機能を持つ日本語フォーマッタを備えたプリンタ

(2) プログラムやドキュメントを扱うソフトウェア工学的な研究など、文書出力を必要とする研究の出力システムとして利用できる柔軟性と、ソフトウェアによる高い付加価値を持つプリンタ

最近、電子出版システムが注目され、米国で開発された幾つかのシステムが日本語化されている。我々は、ソフトウェアの多くが、使われる国の文化に大きく依存すると考えている。浄書は、わが国の伝統的な組版処理を重視して設計したオリジナルなシステムである。

浄書の開発の経緯について次に述べる。

我々は、1983年10月にフォーマットマシンの基本構成を示し⁶⁾、1986年7月に、本論文で提示したシステムの基本仕様の実現を報じ¹⁰⁾、同年11月、和欧混合組版規則をインテリジェントソフトウェアとして組み込んだ¹¹⁾。

1983年における我々のフォーマットマシンの発表の方が、PostScript(1984年8月発表)やLaser-Writer(1985年1月発表)よりも早い¹²⁾。また、和欧混合組版規則を文書整形に組み込んだのも我々が最初

† Japanese Formatting System JOSHO and Its Formatting Strategy Based on the Logical Structure of a Document by MOTOAKI SATOYAMA (Systems Development Laboratory, Hitachi, Ltd.), MASAKI NAKAGAWA and NOBUMASA TAKAHASHI (Department of Computer Science, Faculty of Technology, Tokyo University of Agriculture and Technology).

†† (株)日立製作所システム開発研究所

††† 東京農工大学工学部数値情報工学科

である。

2. フォーマットマシンアーキテクチャ

高印字品質を実現するため、高解像度で柔軟性の高いプリンタ上で高度な文書出力をユーザが行うには、多くのプログラム開発をする必要がある。

現在、幾つかの電子出版システムやワークステーションによって高品質な文書が得られるようになった。しかし、こういった高価なシステムを使わず、安価なワードプロセッサで作成した文書をユーザ自身の手で手軽に、なおかつ、写植のようにきれいに出力したいといった要求もある。我々はフォーマットをプリンタに持たせた。この機能分散により入力編集を行うシステムに依存しない清書機能の実現が可能になる。

また、プリンタの解像度を上げれば上げるほどデータの転送量の増大などからシステムの負荷が大きくなるといった問題もこの負荷分散により軽減される。

我々はこのようにインテリジェント化したプリンタに清書機能を持たせたものをフォーマットマシンと呼んでいる。次にフォーマットマシンの利点をあげる。

- (1) 高機能プリントサーバとして種々の計算機から利用可能であること
- (2) ホスト側に負担をかけずに高解像度プリンタの性能を生かせること
- (3) プリンタ上で資源を共有できること
- (4) データのコード化による転送量の減少と高い機種独立性を保てること
- (5) ソフトウェアによる高い付加価値をプリンタに持たせることができること

さらに、フォーマットマシン用の言語で表現された文書ファイルを中間ファイルとして会話的に生成できるソフトウェアの実現が望まれるが、本稿では先に実現したプリンタ側のソフトウェアについて述べる。なぜなら、日本において普及している日本語ワードプロセッサや、パーソナルコンピュータ上のワープロソフトなどから利用できるフォーマットマシンを実現することの方が現実的であり、まず手掛けるべきことであるからである。特に我々のプログラム開発環境をモデルに考えた場合には、この方式の利点は大きい。

3. 日本語フォーマットの設計目標

日本語フォーマットは、フォーマットマシンの中核をなすアプリケーションソフトウェアである。次に日本語フォーマットの設計目標をあげる。

(1) 文書構造を反映した書式化機能

一般に書式化の機能と言えばページのサイズ、上下左右の余白、段組数や行形式などといった用紙やページの物理的要素に対する機能であった。本日本語フォーマットでは、文書の論理構造に対する機能を加える。つまり、章、節、項、脚注、ノンプル、柱、見出し(タイトル)といった文書の要素に対しても書式の設定を行えるようにする。また、設定された書式に従って、章番号、図番号や目次の自動生成、索引、参考文献などの出力を可能にする。

(2) 文書のきりばり機能

文書の編集で、“きりばり”の対象(例えば図)の挿入削除を繰り返しているうちに、それを参照している文から遠く離れてしまうことがある。この“きりばり”の対象をできるかぎり自動的にレイアウトする機能を持たせる。

我々は“きりばり”の対象を“箱”と呼んでいる。図、表などのように他の部分を構成する文字列と区別され固定した領域を持つものや、新聞の見出しのように特殊な組み方(これを箱組という)をするものを箱として出力する図形整形言語などを実現する。

(3) 禁則処理

和欧混合組版に従ったスペーシング処理、行頭、行末、分離などの禁則処理、プロポーションルピッチ、右ぞろえ(right justification)を行う。

(4) 文書作成支援機能

作成した文書中に現れた各文字の頻出度、表記のゆれなどを調べる機能や、作成年月日、作成者名、文書ファイル名、その他コメントなどを出力する機能があると便利である。また、参考文献をデータベース化し、そこから引き出せるようにする。こういった文書の作成、管理を支援する機能を設ける。

4. システム構成

我々が開発用に実現したフォーマットマシンを特に浄書マシンと呼ぶことにする。

4.1 ハードウェアシステムの構成

浄書マシンは、レーザビームプリンタをマイクロプロセッサ MC 68000 によってインテリジェント化を

指定なのでフォーマット側で適当な位置に出力する(5.6 節参照).

(3) 実体部

実体部は段落か箱の実体部で構成される. 実体部指定の構造指定指令は, 例えば, 以下のように行う.

@和 段落を指定する.

また, 文字列は次のような文字列修飾指令で文字修飾も指定できる.

@下線/@級“10”/アンダラインを引く @/@/

段落は, 段落を構成する文字列が和文か英文か数式かを識別するコード, テキストバッファへのポインタ, 次の段落へのポインタで構成される. テキストバッファは, 文字列と各文字の属性を表す文字属性表へのポインタから構成される. 文字属性表は文字の書体コード, 修飾コード, 相対座標などで構成される.

箱の実体部は図や表などの識別コード, 座標やサイズ, カットネーム表へのポインタなどで構成される.

5.4 書式表・印刷指定表

書式指定指令によって書式表が生成される. 書式表は, 要旨, 章, 節といったすべての文書の階層クラスや頭書, 脚書, 脚注, ノンブル, 図, 表といった実体属性, 章や節のタイトル, 図や表のカットネームといった見出しなど, それらにあった書式が(例えば, タイトルは前後の行あきの指定など)別個に生成される.

5.5 行の書式化処理

行の書式化処理とは, 段落を禁則処理を施しながら行に分割していく処理である. 次に述べる処理により, 和欧混合組版規則に基づく行の書式化を実現した.

5.5.1 行の印字領域の管理

段落を行に分割するまえに, 図表がページ上に配置されていたり, 2段組みが指定されている場合などの条件を考慮し, 行のサイズと位置が計算される. このとき, 袋閉じや見開き印刷のために2ページ分の印字領域を管理している. 例えば, 図3のようなページが構成された場合, 図の数字の順序で行を展開する. この展開アルゴリズムを図4にPADで示す.

5.5.2 スペース処理

行の長さや位置が決まると, 段落を行に分割する. この分割は段落を構成する文字の幅を計算し, その合計が行長より長くなる前の文字で行われる. 文字幅とその合計の計算をスペース処理という.

スペース処理は, ひとつ前に印字した文字とこれから印字しようとする文字の組合せによって決まる. ここで, 文字を幾つかのカテゴリに分類し, カテゴリの組合せでスペース処理を決める行列を考えた. これをスペース処理行列と呼ぶ. スペース処理行列のカテゴリは〈漢字〉, 〈英数字〉, 〈空白〉, 〈記号〉, 〈句読点〉, 〈起こしの括弧〉, 〈受けの括弧〉, 〈行頭記号〉の8種類に分類される. 行頭記号は, 行バッファの先頭に置かれる特別な記号で, 行の先頭であることを示す. 例えば〈英数字〉と〈英数字〉の組合せはプロポーションナルピッチを施し, 〈受けの括弧〉と〈句読点〉は, 半角詰めるなど, スペース処理を分類するのに使う. プロポーションナルピッチが必要な場合は, プロポーションナルピッチが格納された英数字と英数字の組合せによる2次元配列から得る.

表1にスペース処理行列を示した. 表1の〈半〉では, 例えば“)”に“.”が続くとき, ベタ詰めにす. 〈頭〉では, 例えば“[”が行頭にきても, 左端




図3 ページ構成の例 Fig. 3 An example of page layout.

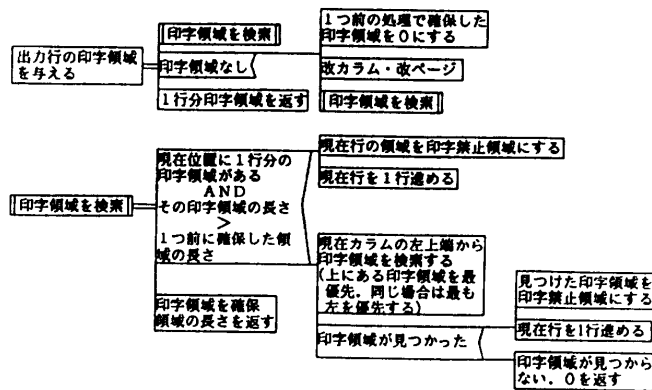


図4 印字行の決定アルゴリズム Fig. 4 Algorithm to determine next line position.

に余分なアキがでないようになる。

5.5.3 禁則処理と右そろえ

段落を行に分割するためには、さらに禁則処理と右そろえの処理が必要である。ここでは、和欧混合組版規則に基づく禁則処理とその実現方法について述べる。

禁則処理は、行頭禁則処理、行末禁則処理、分離禁則処理の三つに分けられる。

本日本語フォーマッタでは、行頭禁則文字として、前節で分類したカテゴリの中の〈受けの括弧〉と〈句読点〉、および、〈記号〉のカテゴリから、促音記号、コロン、セミコロン、疑問符、中黒、感嘆符 (JIS コード 16 進で、2126~2145) など合計 47 種類を設定している。また、行末禁則文字として前節で分類したカテゴリの中から、〈起しの括弧〉を設定した。

分離禁則は、リーダー (…) ダッシュ (—) どちらの場合や組合せ数字の場合 (03 や 0423 など)、連数字 (86,000 や 9 億 7,000 万など) の場合、小数点の前後 (96.58, 3.14 など) の場合、記号 (kg, mm, sec, No, \$, ¥, %, @ など) と数字の組合せの場合などに適用される。

本日本語フォーマッタでは、分離禁則処理を拡張し、行末禁則文字は、その次の文字と分離禁止とし、行頭禁則文字はその前に印字する文字と分離禁止とすることで、行頭、行末禁則処理を実現した。

図 5 に行の禁則処理と右そろえ処理を PAD で示す。

5.6 箱の処理

図や表といったものは箱として処理される。例えば図の場合、まず、ページ上のどの位置に配置するか計算する。次にカットネームに番号を振って出力し、最後に図の内容を処理する。図形の処理は現在、開発を進めている。

箱を配置する座標が指定されていない場合、自動的に適当な領域に展開する。この場合、箱は指定指令が現れた位置の最も近くで、展開するのに十分な広さを持つ領域にレイアウトされる。ただし、箱の横幅がカラム幅より狭い場合、カラムの右端にそろえ、逆の場合

表 1 スペース行行列
Table 1 Matrix for spacing.

	行頭	起括弧	受括弧	句読点	英数字	記号	漢字	空白
行頭	ERR	頭	ERR	ERR	0	0	0	0
起括弧	ERR	半	全	全	プ	全	全	全
受括弧	ERR	半	半	半	プ	半	全	全
句読点	ERR	半	半	半	全	全	全	半
英数字	ERR	プ	プ	プ	全	全	全	全
記号	ERR	全	全	全	全	全	全	全
漢字	ERR	全	全	全	全	全	全	全
空白	ERR	半	全	全	全	全	全	全

(一つ前に印字したカテゴリを縦に、これから印字するカテゴリを横に並べている)

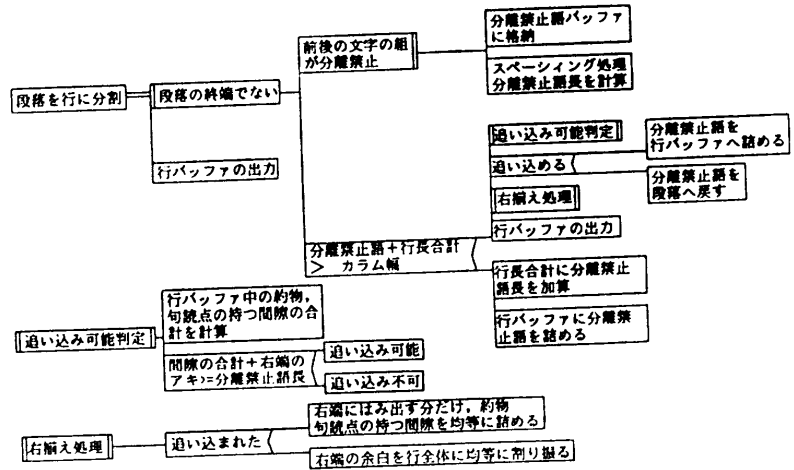


図 5 禁則処理と右そろえ
Fig. 5 Japanese typesetting and right-justification.

$$\sum_{n=1}^{\infty} \frac{n}{\sqrt{n+1}}$$

図 6 数式の出力例

Fig. 6 An example of arithmetic expression formatting.

合、カラムの左端にそろえる。

5.7 数式の処理

数式は次のような数式整形言語によって記述する。

@数 \sum from $n=1$ to ∞ [n over $\sqrt{n+1}$]

このように指定すると、図 6 のような出力が得られる。

5.8 組版処理に関する問題

実現した組版処理で問題になった点を次にあげる。

- (1) 文字だけで分離禁則が判定できない場合
- (2) 大きな箱が連続して何個も指定され、次々に後ろのページに追い出された場合

(1)の問題は、例えば円周率「3.14」の点、小数

点なのかピリオドなのかといった判定である。たまたま、前のセンテンスが数字で終わり、次のセンテンスが数字で始まる場合と判定できない。また、「ROM 8個で構成する。」という文の場合、ROM と 8 は分離禁止にする必要はなく、逆に ROM と 8 の間はアキをとるのが普通である。ところが、ROM を 8 個なのか、ROM 8 という単語なのか判別できない。これらを判別するには、文脈や単語の意味を情報として持っている必要がある。これは、今後の研究課題となる。

(2)の問題は、人間がレイアウト処理を行っても生じる問題である。箱の外の部分にあたる文字列を移動して、箱の再配置処理を行うと、例えば図の場合、図が存在するページより後方のページに図を参照する文がきてしまう可能性がある。また、図と図を参照する文の最適な位置関係を計算する処理の自動化は不可能に近い。このため(2)の問題については、自動的なレイアウトは目安として使い、利用者がレイアウトを考え、箱の印字座標を指定するようにした。そして、自

動レイアウトの結果をディスプレイで確認できるようなプレビューの機能(箱と行のページ上での位置関係が分かる程度)を本日本語フォーマッタでは備えた。

6. 研究室における実用とその効果

高品質な文書出力環境は、ソフトウェア作成者にプログラムやドキュメントを良くしようとする気を起こさせ、我々のモラルと士気を高めることになった。特に日本語によるコメントと高印字品質により、読みやすくなった。プログラムは完成したものから、浄書マシンで印刷し製本している(図7参照)。このようなソフトウェア開発環境の実現も一つの成果である⁹⁾。

研究室で作成される学会の予稿や修士論文など、日本語ワードプロセッサやパーソナルコンピュータで作成した文書を、本日本語フォーマッタで出力できるようになった。また、英文フォーマッタでは図8のような出力を得ることができる⁹⁾。

7. むすび

フォーマットマシンのアーキテクチャをとることにより、浄書マシンにおいて、以下の利点を得られた。

(1) 清書用プリントサーバとしてパーソナルコンピュータやワードプロセッサなどで作成した文書をフロッピディスクを介して清書印刷することができる。

(2) 高解像度プリンタの高品質な文書出力を提供するうえで、パーソナルコンピュータや日本語ワードプロセッサなどのホスト側に負担を掛けない。

(3) 日本語フォーマッタ、英文フォーマッタ、リステイングツールなどのソフトウェアにより高い付加価値を付与できた。また、必要な出力ツールが浄書マシン上でプログラミングできるように、印刷に必要な機能をライブラリ化した。このため、柔軟性の高い利用形態が可能となった。

```

ファイル名:      a:demo.lst                               1989年 4月 8日 19時 51分
.....
/*      ファイル名:demo.c      */
/*      作成者   :大島      */
/*      作成日   :1987/04/30 14:00      */
/* (モジュールの仕組) : 文書ファイル中の文字をクラス      */
/*                  ごとに分類するプログラム:      */
.....
/**** ヘッダファイル      ****/
#include      "type.h"
#include      "stdio.h"
#include      "ismacro.h"

/**** 外部参照関数の宣言      ****/
FDCL_GLBL      INT      printf();
FDCL_GLBL      FILE      *fopenc();
FDCL_GLBL      INT      fclose();

/**** 外部定義関数の宣言      ****/
FDCL_GLBL      INT      main();

/**** 静的関数の宣言      ****/
FLOCAL      AVOID      分類処理関数();
FLOCAL      AVOID      表示処理関数();

/**** 外部静的データの定義      ****/
DLOCAL      FILE      *fp;
DLOCAL      INT      漢字文字数;
DLOCAL      INT      片仮名文字数;
DLOCAL      INT      平仮名文字数;
DLOCAL      INT      英文字数;
DLOCAL      INT      数字文字数;
DLOCAL      INT      キリシヤ文字数;
DLOCAL      INT      その他;

/**** 外部関数の定義      ****/
/* (関数名) : main :
/* (引数) INT      argc;      : コマンド行の引数の数;
/*      CHAR      *argv[];    : 引数を含む文字列の配列を
/*                  指すポインタ;
/* (機能) : プログラムの制御を行う。
.....
ENTRY      main(argc, argv)
INT      argc;
CHAR      *argv[];
{
    if (argc != 2) {
        puts("使用方法 : [demo] [入力ファイル名]");
        exit(0);
    }
}

```

図7 プログラムの出力例

Fig. 7 An example of program listing.

日本語フォーマッタで実現した特徴的な機能を次にまとめる。

(1) 章や章題, 節, 脚書といった文書の論理構造に対して書式設定が行える書式化機能。

(2) 図形等の固定した領域をページ上に確保する箱の指定機能と箱の自動レイアウト機能。

(3) 和欧混合組版規則に基づく, 行頭, 行末, 分離禁則処理およびスペーシング処理機能。

浄書の研究グループは日本語オペレーティングシステムの研究グループと密接な関係を保ちつつ, 日本語フォーマッタの改良や拡張のほか, 図形作成言語, 参考文献データベースの開発を進めている。これらのほかに表作成言語や会話的な環境を実現するための浄書用エディタの開発などは今後の課題である。

謝辞 1987年夏のプログラミングシンポジウム「ヒューマンフレンドリーなシステム」において, システム構成の問題点, 高品質出力がもたらす効用などについて, 貴重な御意見を頂いた木村泉教授, 大岩元教授に深謝する。日立製作所多賀工場の佐々木道甫氏, 榎本順一氏, 堀内雄一氏には, ハードウェア作成において御協力頂いた。ここに感謝の意を表す。

参 考 文 献

- 1) Kernighan, B. W. et al.: UNIX Time-Sharing System: Document Preparation, *Bell Syst. Tech. J.*, Vol. 57, No. 6, pp. 2115-2135 (1978).
- 2) Knuth, D. E.: *The TEXbook*, Addison-Wesley (1983).
- 3) Reid, B. K.: A High-Level Approach to Computer Document Formatting, *7th ACM Symposium of Principles of Programming Languages*, pp. 24-31 (1980).
- 4) 長谷部紀元ほか: 和欧混合文書組み版システムの試作と組み版規則の検討, 情報処理学会日本語文書処理研究会資料, 21-4 (1985).
- 5) Takahashi, N. et al.: 浄書: Japanese Output Server with HOspitality (JOSHO), *ICTP '83*, pp. 29-34 (1983).
- 6) 高橋延匡ほか: OS/o のアーキテクチャと第一版の実現, 情報処理学会オペレーティングシステム研究会資料, 24-11 (1984).
- 7) 写研・写植ルール委員会: 組み NOW, (株)写研 (1975).

6. Exponential and logarithmic functions

Two types of programs have been implemented for $\exp(x)$ and $\log(x)$ by Dr. Hamada and STL[6].

The STL program is based on the following principle:

$$e^x = \prod_k (1 + q_k 2^{-2^k}) \quad (6.1)$$

where

$$x = \sum_k q_k \log(1 + 2^{-k}), \quad q_k = 0 \text{ or } 1 \quad (6.2)$$

and

$$\log x = \log 2 - \sum_k r_k \log(1 + 2^{-k}) \quad (6.3)$$

where

$$x = \frac{2}{\prod_k (1 + r_k 2^{-k})}, \quad r_k = 0 \text{ or } 1 \quad (6.4)$$

図 8 英文の出力例

Fig. 8 An example of English text formatting.

- 8) 並木美太郎ほか: 日本語ワードプロセッサのソフトウェア生産への応用, 情報処理学会ソフトウェア工学研究会資料, 47-1 (1986).
- 9) Oxford University Press: *Hart's Rule for Composition and Readers*, 182 p., The University Press Oxford, Oxford (1983).
- 10) 里山元章ほか: 日本語文書出力システム「浄書」の基本設計と開発システムの実現, 情報処理学会ヒューマンフレンドリーなシステムシンポジウム報告書, pp. 181-191 (1986).
- 11) 関口 治ほか: 和欧混合組版機能を持つインテリジェントプリンタ第1版の実現, 情報処理学会日本語文書処理研究会資料, 9-1 (1986).
- 12) 石田晴久: PostScript インタプリタの開発とその日本語化の問題点, 情報処理学会マイクロコンピュータの現状と将来シンポジウム論文集, pp. 95-104 (1987).

(昭和 62 年 11 月 10 日受付)

(平成 元年 7 月 18 日採録)




里山 元章 (正会員)

昭和 37 年生。昭和 62 年東京農工大学大学院修士課程 (数理情報工学) 修了。同年 (株)日立製作所に入社。現在, 同社システム開発研究所においてオフィスオートメーション, マンマシン・インタフェースなどの研究に従事。電子情報通信学会会員。

**中川 正樹 (正会員)**

昭和 52 年東京大学理学部物理卒業。昭和 54 年同大学院修士課程修了。同大学院在学中英国 Essex 大学留学 (M. Sc. in Computer Studies)。昭和 54 年東京農工大学工学部数理情報助手。平成 1 年同助教授。同年 4 月より電子情報助教授。オンライン手書き日本語入力、日本語計算機システム、文書処理の研究に従事。理学博士。

**高橋 延匡 (正会員)**

昭和 32 年早稲田大学第一理工学部数学卒業。同年 4 月(株)日立製作所中央研究所入社、HITAC 5020 モニタ、TSS の開発などに従事。昭和 52 年東京農工大学工学部数理情報教授。平成 1 年同大工学部電子情報教授。オペレーティング・システム (OS/omicon), 日本語情報処理 (JOLIS, JOSHO) などの研究、教育に従事。理学博士。ACM, 電子情報通信学会, ソフトウェア科学会, 計量国語学会各会員。