論　文

PDF 中のテキスト情報を利用した視覚障害者のための英文 PDF 科学技術文書読み取りシステム

金堀　利洋[†a)]　　鈴木　昌和[††b)]

Scientific English PDF Document Reader for Visually Impaired People Utilizing Embedded Text Information

Toshihiro KANAHORI[†a)] and Masakazu SUZUKI[††b)]

あらまし　Web アクセシビリティの意識が浸透しつつある一方で，電子図書など情報が PDF として提供される流れが加速している．配布されている PDF には文字情報が、人が読む順序と異なる順番に埋め込まれていて、視覚障害者がその内容を読み取る事が困難であるといった問題が指摘されている [2]．また，数式の情報が読み取れる形で入っていることは少ない．更に，印刷文書を OCR を用いて認識し，その認識結果から PDF を生成した文書の場合，数式がその周辺に文字認識のエラーを引き起こし，数式中以外の文字を読むことも困難になる場合も多い．今回，特に数式を含んだ科学技術文書を対象とし，PDF から抽出した文字情報と，PDF を画像として認識した結果を統合することで，質の高い，アクセシブルな文書情報を PDF から取り出すシステムを示す．

キーワード　視覚障害者，Web アクセシビリティ，PDF アクセシビリティ，OCR，数式認識

1. はじめに

近年のインターネットを中心とした情報処理・通信技術の発達により，Web 上のコンテンツは，我々の重要な情報源の 1 つとなっている．視覚障害者にとっても，以前は印刷物として提供されていた情報の多くが，Web 上のコンテンツとして配信される様になり，スクリーンリーダ等でこれらの情報に独力でアクセス可能となった [1] [2]．しかしながら，かつては文字中心であった Web コンテンツは，画像や動画などを伴うインタラクティブなコンテンツが中心となり，視覚障害者にとって，Web ページ上にある情報を把握することが困難な状況になってしまった．そういった状況のなか，障害の有無に依らず Web コンテンツの情報が利用可能であること (Web アクセシビリティ) を確保するため，Web 技術の標準化団体 W3C からガイドラインが示された [3]．国内においても，日本工業規格により，「高齢者・障害者等配慮設計指針」(JIS X8341) が示され，その中で Web アクセシビリティについて定められている．こういった取り組みの結果，Web アクセシビリティの意識は，次第に浸透し，Web コンテンツ上の情報へのアクセスは，改善されてきている．

一方，Web コンテンツ内で，主に資料等の文書が PDF として提供される流れも加速している．最終的に必要な情報が PDF として提供されている事が非常に多くなっている．また，印刷文書を OCR によって認識し，文字情報を埋め込んだ PDF として文書を閲覧可能とした電子図書の提供も盛んになってきている．提供されている多くの PDF には以下の様な問題がある:

（1） 印刷文書をスキャンした画像のみで，文字情報が埋め込まれておらず，スクリーンリーダで読み上げることができない．

（2） 文字情報が埋め込まれていても，その順番が，人が読む順番に従って入っておらず，正確な情報を取り出せる状態になっていない．特に，図表の周辺ではキャプションが正しく入らない事が多い [2]．

† 筑波技術短期大学 障害者高等教育研究支援センター
〒 305–0821 茨城県つくば市春日 4–12–7
Tsukuba College of Technology, Research Center on Higher Education for the Hearing and Visually Impaired, Kasuga 4–12–7, Tsukuba-shi, Ibraki-ken, 305–0821 Japan
†† 九州大学大学院数理学研究院
〒 812–8581 福岡市東区箱崎 6–10–1
Faculty of Mathematics, Kyusyu University, Hakozaki 6–10–1, Higashi-ku, Fukuoka-shi, 812–8581 Japan
a) E-mail: kanahori@k.tsukuba-tech.ac.jp
b) E-mail: suzuki@math.kyushu-u.ac.jp

（3） 印刷文書をスキャンし，OCR で認識させ，文字情報を埋め込んでいても，数式など認識が困難な部分があると，その部分の文字情報だけでなく，周辺の情報が誤って入っている．また，多種多様な数学記号や数式構造の情報が入っていることはほとんど無い．この問題については後で詳しく述べる．

Web アクセシビリティの意識の向上により，欲しい情報に辿り着くことはある程度出来る様になったが，肝心の情報が PDF 化されているために結局その情報を得ることが出来ない．現在の PDF には用意されたアクセシビリティのための機能があるが，それを用いて作成された PDF は少なく，ただ単に，OCR や生成ソフトを用いて自動的に生成された PDF をそのまま使用していることがこの様な事態を生み出している．しかしながら，すでにある PDF に数式の情報を入力したり，数式によって引き起こされた文字情報の間違いを修正するのは，大変，手間と時間がかかると思われる．

今回，我々は，特に数式を含む，英文の科学技術 PDF 文書を対象とし，抽出した PDF 内に埋め込まれている文字情報と，一方で，PDF を画像として認識し，その認識結果を抽出した文字情報を用いて修正し，質の高い文書情報を PDF から取り出し，視覚障害者にとってアクセシブルな形式として出力する事を目的としたシステムを開発した．使用する文書認識システムは，九州大学鈴木研究室を中心に開発をしている科学技術文書処理システム *Infty* [4] を使用する．認識した結果は，*Infty* の機能を用いて，数式部分を LaTeX の書式で文字情報を埋め込んだ PDF 文書を生成することもできる．本論文では，このシステムの処理の流れ，特に PDF から抽出した文字情報と，PDF を画像として認識した認識結果のマッチングを用いた認識結果修正手法について詳しく述べ，この手法の評価実験の結果も示す．

2. 数式を含んだ PDF の問題

数式を含んだ PDF において，特に数式周辺で以下の様な問題が挙げられる．例えば，LaTeX を使用し，dvipdfm を使用して生成した PDF では，単純な数式:

$$H = \frac{h_1}{h_2} \times 1000, \quad D = \frac{c_1 - c_2}{h_1} \times 1000,$$

を変換した PDF から，Acrobat 7 を使用して「アクセシビリティ可能なテキスト」として出力した結果は，

```
h|.|c|1|..c|2|H=|?1000;D=?1000.|h|.|h|.|
```

となり (各 | は改行)，全く元の数式の情報を得ること

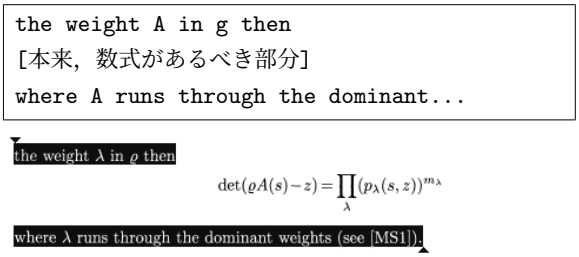

が出来なくなってしまう．また，OCR を用いて，印刷文書に文字情報を埋め込んだ PDF では，図 1 の様に数式部分に文字情報が入っておらず，その文字情報は，

図 1 黒く反転している部分には文字情報が入っているが，2 行目にある数式に文字情報が入っていない．
Fig. 1 The mathematical formula on the middle line is skipped and there is no hidden text for the formula.

の様に，数式部分が認識されずに，本来，数式の情報が入っているべき部分にまったく文字情報が入っていなかったり，図 2 の様に，数式部分に文字情報は入っているが，入っている情報は，

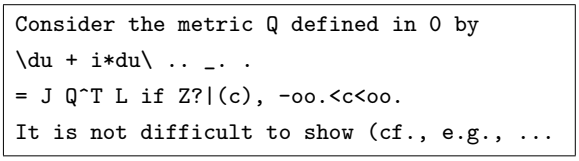

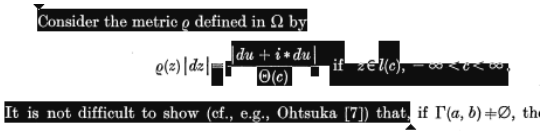

図 2 数式部分に文字情報は埋め込まれているが，数式の情報は入っていない．
Fig. 2 The hidden text for mathematical formulae do not have correct mathematical information.

の様に，数学記号や，数式の構造に関する情報を得ることが出来ない．また，数式はその前後の文字認識にエラーを生じさせる．

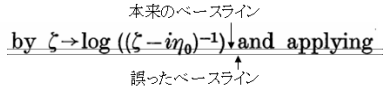

図 3 数式 $\zeta \to \log((\zeta - i\eta_0)^{-1})$ が後のテキスト部分の文字認識のエラーを引き起こしている．
Fig. 3 The mathematical formula $\zeta \to \log((\zeta - i\eta_0)^{-1})$ causes recognition errors of next characters.

例えば，図 3 の，数式 $\zeta \to \log((\zeta - i\eta_0)^{-1})$ が行のベースラインの推定を誤らせ，その後の d を (と i に

認識させたり，p を P と認識させるという認識エラーを引き起こし，結果，その文字情報は以下の様になってしまっている．

```
by ?-^l? g ((?-^o)"1) a n ( i aPPtying ...
```

この様に，特に理系の文書において，数式の情報を得ることが出来ないということは，視覚障害者が理系学問を学ぶにあたって，大変致命的なことである．

3. PDF 認識の流れ

このシステムは，PDF からテキスト情報とページ画像を抽出するために *Ghostscript* [5] を用いて，以下の流れで PDF の認識を行う (図 4)．各プロセスの詳細な説明は後の節で行う:

（1） PDF からテキスト情報をテキストファイルの形で抽出する．

（2） PDF からページ画像をマルチ TIFF 形式の画像ファイルとして生成する．

（3） 生成したページ画像を *Infty* で認識する．

（4） PDF から抽出したテキスト情報を，*Infty* の認識結果を用いて数式や欠落しているテキスト追加して修正を加えていく．

（5） 修正結果を最終的な認識結果として出力する．

この手法で利用するのは，PDF に埋め込まれた単純なテキスト情報のみである．よって，PDF のバージョンや，生成方法を考慮する必要はないし，更には，何らかの方法でテキスト情報さえ取り出せれば，対象は PDF でなくても構わない．その反面，PDF が持っている文字の位置や大きさといった有用な情報を利用することはできない．本手法の特徴的な部分は，後に述べる *Word Matching Method* によって，単語毎にテキスト情報と *Infty* の認識結果とのマッチングを行い，対応する *Infty* の認識結果の文字矩形座標を PDF のテキストに割り当てていくことにより，テキスト情報の修正に必要な情報を復元するところにある．また，読み上げの順番に影響するレイアウトに関しては，PDF でのレイアウト (読み上げ順番) は関係なく，全て *Infty* の結果を用いる．*Infty* のレイアウト解析は，基本的にページの左上から右下に向かって，2 カラムであればカラム毎に，順番をつけていく．これによって，PDF の読み上げ順を改善する事を狙っている．

4. PDF からの情報抽出

PDF から抽出する情報は，テキスト情報とページ画像の 2 つである．これらは PostScript インタプリタとしてよく用いられる *Ghostscript* をバッチファイルから呼び出して行われる．

4.1 テキスト情報の抽出

Ghostscript を呼び出し，PDF からテキスト情報を ASCII テキストファイルとして抽出する．抽出したテキストファイル中の文字列をスペースで切り分ける．切り分けた各部分文字列を “単語” と呼び，テキストファイルから得られる全ての “単語” をリストとして保持する．このリストの単語と *Infty* の認識結果内の単語のマッチングを行う．

4.2 ページ画像の生成

Ghostscript を用いて PDF から全てのページ画像を持った 1 つの 600dpi 白黒 2 値マルチ TIFF 画像ファイルを生成する．この生成した画像ファイルを *Infty* で認識を行う．

5. *Infty* の認識結果と PDF のテキスト情報を用いた最終認識結果の生成

PDF から生成された画像に対して，*Infty* はレイアウト解析，文字認識，表認識，数式認識を行う．文字認識結果後，各単語がテキスト部であるか，そうでないかを後に説明する *Geometric Position Checking* という手法を用いて判断し，テキスト部でない単語を数式部として数式構造解析する．この解析部では，文字認識結果が変更されることもあるため [6]，解析後もう一度，テキスト/数式の判定を行う．この認識結果と，PDF からのテキスト情報を用いて最終的な認識結果を生成する．基本的には，テキスト部に対しては PDF のテキストを用い，数式部に対しては，*Infty* の認識結果を用いるが，PDF 中のテキスト情報の誤り，*Infty* の誤認識を考慮して，以下の手順で生成を行う．

（1） 誤認識により，本来テキスト部であるにも関わらず，数式部として切り分けられた場合も考慮して，一旦全てテキスト部とみなす．この時，数式構造解析の結果，分数や $\sum$，$\sqrt{\ }$ の様に，上下の構造を持つ数式部は，誤って数式部として切り分けられた部分ではないとして，最終的な認識結果として採用する．

（2） テキスト部の各単語 w に対して，対応する PDF 中の単語 W を，生成した単語リストの中から *Word Matching Method* を用いて決定する．この時，PDF 中に対応する単語が見つからなかった認識結果内の単語については，PDF 中で欠落した単語であるとし，最終的な認識結果に加える．

（3） 対応する単語 W が見つかった認識結果中の単語 w の各文字 c の外接矩形座標を，単語 W の各文字 C に対して割り当てていく．

（4） 座標が割り当てられた PDF 中の単語 W に対して，*Geometric Position Checking* を用いてテキスト部であるか判定する．W がテキスト部であると判定された場合，W を最終的な認識結果として採用する．テキスト部ではないと判定された場合，W に対応する *Infty* の認識結果 w を最終的な認識結果として採用し，再度，テキスト部/数式部の切り分けと，数式構造解析を行う．

以上の様にして，PDF のテキストに対して *Word Matching Method* を用いて *Infty* の認識結果と対応させ，外接矩形座標を復元して，PDF 中の単語が適切なテキスト情報であるかどうか判定する．単語に対するテキスト情報が適切でないと判定された場合は，*Infty* の認識結果を用い，PDF のテキスト情報の修正と，数式情報の埋め込みを行う．

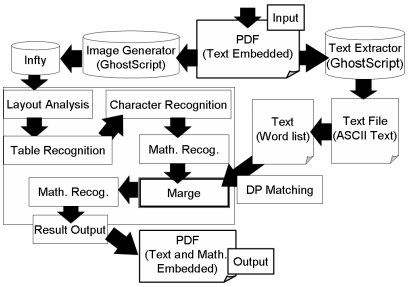

図 4 PDF の認識プロセス
Fig. 4 Outline of PDF recognition process.

5.1 Geometric Position Checking

文字認識後，各文字は外接矩形座標を持つ．各文字に対して，その位置特徴，*top line*，*center line*，*base line*，*bottom line* が推定される．特別に，小文字の ‘t’ に対しては，*t-top line* が求められる (図 5 参照)．これらの特徴量は文字種毎に採取した，文字の高さに対する特徴量の比を用いて推定し，数式構造解析でも使用される [6]．更に，各行中の文字の位置特徴から多数決で，その行全体の位置特徴が推定される．*Infty* の認識率が高いことから，行中の文字がある程度あれば，その位置特徴は信頼できる値となる．

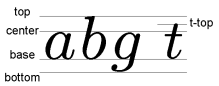

図 5 文字の位置特徴
Fig. 5 Position features of a character.

これらの位置特徴の内，*base line* を用いて，各単語がテキストであるか，そうでないかを調べる．単語中の各文字 c に対して，その外接矩形の下部の y 座標を $b(c)$ とし，行 L 全体の *base line* を $base(L)$ とすると，$|b(c) - base(L)| > T_G$ なる文字 c が単語中に存在した場合，その単語はテキストではない，と判定する．ここで T_G は閾値で，行 L の位置特徴 *top line*，*bottom line* をそれぞれ $top(L)$，$bottom(L)$ とすると，

$$T_G := \frac{|bottom(L) - top(L)| + 16}{16}$$

と経験的に定義された値である．なお，600dpi の画像において，$|bottom(L) - top(L)|$ の値は 100 程度である．すなわち，単語内の各文字が行のベースライン上に並んでいるかを調べ，そうであるならば，その単語はテキストであると判断する．そうでないならば，添え字といった数式構造を持つと思われるので，テキストではないと判断する．この手法を *Geometric Position Checking* と呼ぶ．

5.2 Word Matching Method

各行において，文字認識結果の列を，空白や，テキスト部と数式部の境目で区切って “単語” とする．この認識結果内の単語に対応した単語を，PDF から抽出した単語リスト内から，以下のマッチング手法を用いて探し出す．*Infty* は立体とイタリック体を区別して認識を行うが，このマッチングにおいては，それらを同一視して，単純な文字列同士として処理を行う．また，数学記号などの特殊な文字は，バックスラッシュ ‘\’ に置き換えて文字列を生成する．

5.2.1 完全マッチングによる認識結果の確定

認識結果中の単語 w_i に対して，文字列として完全に一致する単語 W_p を PDF から抽出した単語リストの中から見つけていく．完全に一致する単語 W_p が存在した場合，W_p の各文字に対して w_i の各文字の矩形座標を順に割り当てたもの最終的な認識結果とする．これは結局 w_i と同じものになるので，内部的には w_i をそのまま最終的な認識結果として用いる．認識結果中の単語 w_i は，レイアウト解析・行切り分け結果に準じて，基本的には行は上から順に，単語は行中の左から右へ捜査していく．この時，w_i に対して，単語リスト中に複数の完全一致する単語が存在した場合，まず，各完全一致する単語 W_p に対して，以下の様にして，完全一致度 $N_M(w_i, W_p)$ を求める．

（1） w_i の 1 つ前にある単語 w_{i-1} と，単語リスト内で W_p の 1 つ前にある単語 W_{p-1} とを比較する．

（2） もし，w_{i-1} と W_{p-1} が再度完全に一致した場合，w_{i-1} の文字数を N_P に加える．ここで，N_P は前方向に完全一致した文字数のカウンタとし，初期値は 0 とする．更に w_{i-1} の 1 つ前にある単語 w_{i-2} と，W_{p-1} の 1 つ前にある単語 W_{p-2} とを比較し，これらも完全に一致した場合，w_{i-2} の文字数を N_P に加える．

（3） この様にして，認識結果中の単語 w_i の n 個前の単語 w_{i-n} と，PDF からの単語リスト中の単語 W_p の n 個前の単語 W_{p-n} が完全に一致する間，前にさかのぼりながら，w_{i-n} の文字数を N_P に加算していく．

（4） 同様にして，w_i の n 個後ろの単語 w_{i+n} についても，W_{p+n} と完全一致する間，後ろにたどりながら，w_{i+n} の文字数を，後ろ方向に完全一致した文字数のカウンタ N_N に加算していく．

（5） 認識結果中の単語 w_i の前後で，対応する PDF 中の単語リストの単語と完全一致する単語の文字数の合計を，完全一致度として $N_M(w_i, W_p) := N_P + N_N$ と定める．

次に，w_i に対応する PDF 中の単語は，

$N_M(w_i) := \max\{N_M(w_i, W_p) | W_p$ は w_i と完全一致$\}$

と定めた時に，$N_M(w_i) = N_M(w_i, W(i))$ を与える PDF の単語リスト中の単語とし，$W(i)$ と書くことにする．これら単語比較の処理では，単語リスト内の順

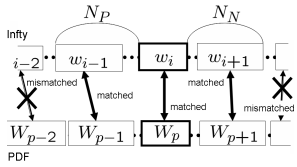

図 6 $N_M(w_i, W_p)$ の意味．この図では，各ボックスは単語を表す．

Fig. 6 Meanings of $N_M(w_i, W_p)$. Each box stands for a word.

番は，PDF 中の位置は考慮せず，単にリスト中の順番のみを用いる．これは，PDF 中の行の順番の間違いを想定している．

5.2.2 確定した単語の前後にある単語のマッチング

完全マッチングによって確定した単語の前，もしくは後ろにある認識結果中の単語 w_i とする．w_i に対して，PDF の単語リスト中の単語 W_p を以下の方法で求める:

（1） w_i の 1 つ前の単語 w_{i-1} が確定していた場合， w_{i-1} と完全一致する単語 $W(i-1)$ の 1 つ後ろの単語を W_p とする．

（2） w_i の 1 つ後ろの単語 w_{i+1} が確定していた場合， $W(i+1)$ の 1 つ前の単語を W_p とする．

（3） w_i の前後の単語 w_{i-1} と w_{i+1} の両方とも確定していた場合，

$$W_p = \begin{cases} N_M(w_{i-1}) \geqq N_M(w_{i+1}) \\ \quad \Rightarrow W(i-1) \text{ の 1 つ後ろの単語}, \\ N_M(w_{i-1}) < N_M(w_{i+1}) \\ \quad \Rightarrow W(i+1) \text{ の 1 つ前の単語}. \end{cases}$$

以上によって求めた W_p と w_i を動的計画法を用いたマッチング (DP マッチング) にかけ，そのマッチングのコストが，w_i と W_p によって定まる閾値よりも小さければ，W_p を w_i に対応する単語とする．

認識結果中の単語 w と PDF 中の単語 W の DP マッチングとそのコスト $C_{DP}(w, W)$ は以下の手順で求める:

（1） w と W の文字数が同じ N 個である場合，w 中の i 番目の文字を c_i，W 中の i 番目の文字を C_i とした時，全ての $i = 1, \cdots, N$ に対して，c_i と C_i が同じ文字であるか，類似文字であった場合，類似文字考慮した単語の一致として，この時のコスト $C_{DP}(w, W)$ を 0 とする．ここで用いている類似文字の組み合わせを，表 1 に示す．ここで一致しなかった場合は次の処理に移る．

（2） w の文字数を n，W の文字数を N とする．$i = 1, \cdots, n$ と $I = 1, \cdots, N$ に対して，w の i 文字目までと W の I 文字目までのマッチングコスト $C_{DP}(i, I)$ を以下で定義する;

$$C_{DP}(0,0) = 0, C_{DP}(1,0) = C_{DP}(0,1) = 1,$$

$$C_{DP}(i,I) = \min \left\{ \begin{array}{c} C_{DP}(i-1, I) + 1, \\ C_{DP}(i, I-1) + 1, \\ C_{DP}(i-1, I-1) + C(i,I) \end{array} \right\}.$$

ここで，$C(i, I)$ は w の i 番目の文字 c_i と W の I 番目の文字 C_I との比較コストで，

$$C(i,I) = \begin{cases} 0, & c_i \text{ と } C_I \text{ が類似文字である}, \\ 0, & c_i \text{ の認識結果の第 3 候補までに}, \\ & \quad C_I \text{ の類似文字がある}, \\ 1, & \text{上記以外}. \end{cases}$$

としている．これらの値を求めて，w の n 文字目までと W の N 文字目までのマッチングコスト $C_{DP}(n, N)$

(c, C), (s, S), (v, V), (w, W), (x, X), (z, Z)
(1, l (小文字のエル))
(0 (数字のゼロ), O (大文字のオー), o (小文字のオー))
(– (マイナス), - (ハイフン), – (ロングハイフン))

表 1　類似文字の組み合わせ
Table 1　Sets of simillar characters.

を単語全体のマッチングコスト $C_{DP}(w,W)$ とする．次に，この $C_{DP}(w,W)$ が以下で定める閾値 T_{DP} より小さければ w に対応する PDF 中の単語を W とする．更に，単語 w の文字数が 6 以下と短い場合は，$C_{DP}(w,W)$ が閾値 T_{DP} 以上であっても，T'_{DP} より小さければ，w に対応する PDF 中の単語を W とする．ここで閾値 T_{DP}, T'_{DP} は，

$$T_{DP} := \min\left\{4, \frac{\max\{n,N\}}{3}\right\}, T'_{DP} := \frac{\max\{n,N\}}{2},$$

としている．

5.2.3　残りの確定していない単語のマッチング

ここまでのマッチングによって，対応する単語が見つからなかった認識結果中の単語 w の内，文字数が 4 以上の単語に対して，まだ対応する単語の決まっていない PDF の単語リスト中の単語の中で，

$$C_{DP}(w,W) = \min\{C_{DP}(w,W') | \\ |N(w) - N(W')| \leqq 2\},$$

となる W を見つける．ここで C_{DP} は 5.2.2 で定義したマッチングコストで，$N(w)$ や $N(W')$ はそれぞれ，単語 w と W' の文字数とする．$C_{DP}(w,W)$ が以下の閾値 T''_{DP} より小さければ，w に対応する PDF 中の単語を W とする;

$$T''_{DP} := \min\left\{\max\left\{2, \frac{N(w)}{3}\right\}, \frac{N(w)}{2}\right\}.$$

以上においても PDF の単語リスト中に対応する単語が見つからなかった認識結果中の単語は，PDF 中で欠落している単語であるとして，最終的な文字認識結果として残しておく．

5.2.4　PDF から抽出した文字への外接矩形の割り当て

マッチングによって対応付けられた単語のペア (w,W) に対して，どちらを最終的な認識結果とするかを判断する．PDF 中の単語 W の各文字 C に対して，マッチングの結果から，認識結果中の単語 w の中の文字の外接矩形座標を割り当てていく．割り当てられた外接矩形座標と，C の文字種を用いて *Geometric Position Checking* で W がテキスト部になりうるか判断し，テキスト部であるとなれば，W を最終的な認識結果として採用する．W の各文字に対する外接矩形座標の割り当て方は以下の通りである: **w 中の文字 c と W 中の文字 C との対応が 1:1 である場合**: この場合，単純に c の外接矩形を C にそのまま割り当てる．**w 中の複数の文字 $\{\mathbf{c_i}, \cdots, \mathbf{c_{i+n}}\}$ が，W 中の 1 文字 $\mathbf{C_p}$ に対応している場合**: C_p の外接矩形を，$\{c_i, \cdots, c_{i+n}\}$ の各文字の外接矩形の和とする．**w 中の１つの文字 $\mathbf{c_i}$ が，W 中の複数の文字 $\{\mathbf{C_p}, \cdots, \mathbf{C_{p+n}}\}$ に対応している場合**: 各 $C_q \in \{C_p, \cdots, C_{p+n}\}$ の外接矩形は，c の外接矩形を縦に $n+1$ 等分した矩形の q 番目の矩形とする．以上の様にして，PDF 中の各単語の文字に対して外接矩形を割り当てていく．

5.3　数式部分の認識

上記のマッチング処理によって認識結果が変更されている可能性があるので，再度，数式解析を行い，数式部であるかそうでないかの判断を行う．数式であると判断された部分は数式解析によって，更に認識結果の変更が行われるが，テキスト部分に関しては，マッチングによる修正の結果が認識の最終結果として用いられる．

6.　認識結果の出力

以上によって生成された認識結果を再び元画像に埋め込み，テキスト情報を持った PDF を生成する．この時，数式は *Infty* により数学記号や数式構造も認識されているので，その情報は LaTeX や，MathML で埋め込まれ，PDF 内の数式の読み上げも可能となる．これにより，数式の情報が埋め込まれていない PDF に，数式の情報を埋め込むことができ，よりアクセシビリティの高い PDF を自動的に生成することができる．

7.　評価実験と結果

本システムの評価を行うために，OCR によって生成された PDF を再認識することによって，どの程度 PDF に含まれるテキスト情報の精度が上がるのかを調べた．方法としてはまず，我々が文字認識システム等の評価を行うために構築した，正解データベース [7] を用いた．この正解データベースは，600dpi でスキャンされた文書画像，各文字の外接矩形，文字認識，文字種などの正解，数式の構造といった情報を持っている．その中の文書画像を，*ABBY FineReader 7.0* を用いて認識し，結果をテキスト情報を持つ PDF として出力した．*FineReader* は英語だけでなく，様々な

ヨーロッパ言語の文書を非常に高い精度で認識することが出来る OCR システムであるが，数式に関しては非常に簡単なもの以外認識することができない．これを数式認識をしていない一般的なテキスト情報を持った PDF の実験サンプルとして用い，正解データベースと比較し，認識率を求めた．次に，本システムに，この生成した PDF を再認識させ，その認識率を求めた．ここでの認識率とは，正解データベースが持つ各文字の矩形座標に対して，認識結果中の同じ矩形座標にある文字が等しければ正解であるとカウントし，それを全体の文字数で割ったものとしている．

今回の評価実験では，正解データベース中の数学雑誌 15 冊と教科書 1 冊から 13 文書 (531 ページ) を用いた．これらには 787,421 文字，内テキスト部 621,998 文字，数式部 165,423 文字が含まれている．

ここで実験サンプル PDF の正解率 (認識率) を求める際にも，本認識手法と同様に PDF から抽出したテキスト情報を用いた．しかしながら，正解データベースと比較するには，各文字の外接矩形が必要となってくる．そこで，*Infty* によって認識した結果と PDF から抽出したテキスト情報とを，先に述べた *Word Matching Method* を用いてマッチングを行う．この時，テキスト部においては，PDF から抽出した文字を常に最終結果とすることによって，対応する *Infty* の認識結果にある外接矩形座標を PDF から抽出した文字に割り当てる．この様にして PDF 中のテキスト情報に外接矩形座標追加し，正解データベースとの比較を行い，認識率を算出した．また，PDF から抽出されるテキストは ASCII 文字に限られるので，比較対象は ASCII 文字とし，更に，認識や区別が難しい，点類 (" ’ ， . ‘) も対象から除き，ASCII 文字だけでは区別できない，マイナス記号 ‘–’ とハイフン ‘-’ は同一視した．

以上の様にして，まず生成した実験サンプルの認識率を，テキスト部 (TEXT) のみ求めた．次に，*Infty* で，実験サンプルを埋め込まれているテキスト情報を使用せずに，PDF を画像としてのみ認識した認識率を，同様の算出基準でテキスト部 (TEXT)，数式部 (MATH)，そして両方を含めた全体の認識率 (TOTAL) を求めた．最後に，同様の基準で実験サンプルの PDF のテキスト情報を用いて，*Infty* で再認識した時の認識率をテキスト部，数式部，全体の認識率を求めた．その結果を表 2 に示す．

この評価実験中，*FineReader* で生成した実験サンプル PDF には以下の様な誤認識の傾向がみられた:

（1） 数式を含む部分がレイアウト解析の際に図と認識されてしまい，その中にあるテキスト部の文字が認識されていない，

（2） 認識に使用する言語情報が数式によって乱される，形が似ている文字，‘o’ と ‘O’, ‘w’ と ‘W’ など，が数式の直後にあると，小文字が大文字と認識されてしまう．

（3） 縦に比較的大きな数式があると，行の大きさの取得を誤り，その後の文字認識が正確に行われない (図 3).

これより，数式がテキスト部の文字認識に実際に悪影響を与えていることが確かめられた．

表 2 において，実験サンプルの元々の認識率 (精度) と，テキスト情報を利用した認識率を見ると，*Infty* による再認識によって，数式情報の付加だけでなく，テキスト部の認識率も向上していることが分かる．しかしながら，テキスト情報を利用しなかった場合と，テキスト情報を利用した場合を比較すると，テキスト部の認識率の向上が見られるが，数式部の認識率が落ちてしまっている．これは主に，マッチングの結果，数式部において，最終的な認識結果として PDF のテキスト情報の方の結果が使われてしまったことによる．例を挙げると，“$q' = dq \mathrm{mod} I_Y$” という式が，*Infty* では，きちんと認識されていた．一方，PDF 中では，“q’=dgmod/y” となっていた．これが，マッチングの際に，*Infty* の認識結果の中に ‘q’ の第 2 候補として，‘g’ が，‘I’ の第 2 候補として ‘/’ が入っていたために，DP コストが閾値以下になり，PDF のテキストが採用されてしまい，結果，“$q' = dg \mathrm{mod} / y$” と認識されてしまった．この様に PDF 中のテキストが誤っていても，認識候補中に文字があれば，認識結果として採用されてしまう問題があった．

追加実験として，テキスト部に関しては誤りのない PDF に対して，数式情報を埋め込む目的で使用する場合を想定して，上記の実験でも使用した正解データベースから生成した PDF を本システムでもう一度認識し，その認識率を測定した．この生成した PDF では，数式は LaTeX のコマンドで記述されている．PDF のテキストを利用して認識した場合，テキスト部，数式部共に認識率 100%を示し，この実験においては，正しく入っているテキスト部の情報を崩さず，数式を埋め込むことに成功していた．

読み上げ順の改善について定量的な評価は行ってい

	TOTAL	TEXT	MATH
Sample PDF	–	99.75%	–
Recognition without text	99.18%	99.71%	97.18%
Recognition using text	99.22%	99.79%	97.09%

表 2 元の PDF の認識率と，PDF のテキスト情報を利用しなかった場合と利用した場合の認識率.

Table 2 Recognition rates of original PDFs, recognition witout text information and recognition usgin text information.

ないが，実際に配布されている PDF を本システムで認識して比較したところ，以下の様な傾向が見られた．まず，数式によって引き起こされる読み上げ順の乱れに関して，例えば数式が上下の行と混じってしまっている場合は，ほぼ正しく行分けが行われ，正しい順番に修正されていた．また，異なるレイアウト中のブロックのテキストが混ざり合っている様な，極端な場合に関しても，きちんとブロックを分けて出力していた．これらは認識の際に PDF 中の読み上げ順序を使わず，*Infty* のレイアウト解析結果のみを用いた事が上手く働いたからであるが，元々きちんと PDF にタグ付け [2] されており，脚注が節の終わりに挿入されるなど，正しい読み上げ順になっていてる PDF を認識にかけた場合，*Infty* による読み上げ順が適用されてしまい，脚注が文書中に挿入されてしまって，かえって読み上げ順を悪くするという場合もあった．これは，*Infty* のレイアウト解析が，画像中の位置によって順番を決定するためだと思われる．

8. おわりに

今回，PDF から取り出したテキスト情報と，PDF を画像として認識した認識結果を組み合わせることにより，より精度の高い情報を PDF から得るシステムの提案とその手法，更には，評価実験も行った．既存の認識システムによって生成した PDF を再認識することにより，本システムが PDF 中の数式部分にテキスト情報を追加するだけでなく，数式周辺の文字の誤認識もある程度修正することを示した．このシステムが提供するインターフェイスを用いて，簡単に数式を含んだ PDF を認識させ，数式の情報を持たない PDF から，数式の情報をもった PDF を生成することが可能である．しかしながら，今回 PDF から抽出したテキスト情報は，*Ghostscript* の機能を利用して，ASCII テキストファイルから得るので，PDF 中にあるフォントや，位置といった有用な情報は使用することが出来なかった．今後，PDF から直接情報を取得する様にすれば，認識率だけでなく，読み上げ順に影響するレイアウト解析においても，より大きな効果が得られると期待できる．評価実験でも，数式部の認識においては，本手法の悪影響が僅かに見られ，これを改善するには，マッチングの対象となる単語の見直しや DP マッチングの際のコスト設定の見直しなどが必要である．また，読み上げ順の改善についても，“適切な読み上げ順” を考慮したレイアウト解析の改良が必要だと思われる．今回は英語文書のみ認識対象としたが，今後，特に日本語への適用を実装していきたい．

文　献

[1] 渡辺哲也, “視覚障害者の Windows パソコン及びインターネット利用・学習状況,” 独立行政法人国立特殊教育総合研究所報告書 D-190, 2003.

[2] 吉本浩二 渡辺哲也, スクリーンリーダによる PDF 文書へのアクセシビリティについて, ヒューマンインタフェース学会研究報告集 vol.5, no.5, 2004.

[3] “Web Content Accessibility Guidelines 2.0,” http://www.w3.org/TR/2006/WD-WCAG20-20060427/

[4] M. Suzuki, F. Tamari, R. Fukuda, S. Uchida, T. Kanahori, “INFTY — An Integrated OCR System for Mathematical Documents”, *ACM Symposium on Document Engineering*, pp.95–104, 2003

[5] “Ghostscript, Ghostview and GSview,” http://www.cs.wisc.edu/~ghost/

[6] Y. Eto and M. Suzuki, “Mathematical formula recognition using virtual link network,” *Proc. ICDAR*, pp.762–767, 2001.

[7] M. Suzuki, S. Uchida and A. Nomura, “A Ground-Truthed Mathematical Character and Symbol Image Database”, *Proceedings of 8th International Conference on Document Analysis and Recognition*, ICDAR 2005,pp.675–679, Seoul, Korea.

（平成 xx 年 xx 月 xx 日受付）

金堀　利洋

1997 岡山大学理学部卒．2002 九州大学数理学研究科博士課程単位取得後退学．同年，筑波技術短期大学障害者高等教育センター助手．2003 数理学博士．現在，筑波技術大学障害者高等教育研究支援センター助教授．主に視覚障害者支援システム開発に従事．

鈴木　昌和　（正員）

1969 京都大学理学部卒．1971 京都大学大学院理学研究科修士課程修了．同年，京都大学大学院理学研究科博士課程進学．1973 フランス政府給費留学生として渡仏，パリ大学第 11 部数学科博士過程．1975 フランス国立科学研究センター研究員．1977 Doctorat d’Etat ès Sciences (パリ大学 VII)．同年，九州大学工学部講師．現在，九州大学大学院数理学研究院教授．NPO 法人サイエンス・アクセシビリティ・ネット代表理事．主に，多変数関数解析，代数幾何，近年，科学技術文書認識，視覚障害者支援システム開発に従事．電子情報通信学会・日本数学会・情報処理学会会員．

Abstract The awareness of Web Accessibility is widely spreading to society, but then a lot of contents are provided as PDF files on the Web. In provided PDF files, information of characters is not embedded in the proper reading order [2]. Information of mathematical formulae is rarely embedded in an accessible way. A scientific PDF document generated by OCR system often has many recognition errors caused by mathematical formulae. Therefore, it is very difficult to read that scientific PDF documents correctly for visually impaired people. In this report, we present a system which can provide high-quality and accessible document information of a scientific PDF documents, especially containing mathematical formulae, by correcting recognition results of PDF's printed images with extracted character information from the PDF documents. We show experimental results in order to evaluate the system.

Key words Visually Impaired People, Web Accessibility, PDF Accessibility, OCR, Mathematical Formula Recognition