

Text Extraction Toolkit (TET)

Version 5.2

PDF 文書からテキスト・画像・メタデータを抽出するためのツールキット



Copyright © 2002-2019 PDFlib GmbH. All rights reserved.
Protected by European and U.S. patents.

PDFlib GmbH
Franziska-Bilek-Weg 9, 80339 München, Germany
www.pdflib.com
電話 +49・89・452 33 84-0

疑問がおりの際は、PDFlib メーリングリストと、tech.groups.yahoo.com/neo/groups/pdflib/infoにあるアーカイブをチェックしてください。

ライセンスご希望の際の連絡先 : sales@pdflib.com
商用 PDFlib ライセンス保持者向けサポート : support@pdflib.com (お使いのライセンス番号をお書きください)

この出版物およびここに含まれた情報はありのままに供給されるものであり、通知なく変更されることがあり、また、PDFlib GmbHによる誓約として解釈されるべきものではありません。PDFlib GmbHはいかなる誤りや不正確に対しても責任や負担を全く負わず、この出版物に関するいかなる類の(明示的・暗示的または法定に関わらず)保証も行わず、そして、いかなるそしてすべての売買可能性の保証と、特定の目的に対する適合性と、サードパーティの権利の侵害とを明白に否認します。

TEtは以下のサードパーティソフトウェアの変更された部分を含んでいます :

CMap resources、Copyright © 1990-2019 Adobe

Zlib 圧縮ライブラリ、Copyright © 1995-2017 Jean-loup Gailly and Mark Adler

TIFFlib 画像ライブラリ、Copyright © 1988-1997 Sam Leffler、Copyright © 1991-1997 Silicon Graphics, Inc.

Eric Young の書いた Cryptographic ソフトウェア、Copyright © 1995-1998 Eric Young (eay@cryptsoft.com)

Independent JPEG Group の JPEG ソフトウェア、Copyright © 1991-2017, Thomas G. Lane, Guido Vollbeding

Cryptographic ソフトウェア、Copyright © 1998-2002 The OpenSSL Project (www.openssl.org)

Expat XML パーサ、Copyright © 2001-2017 Expat maintainers

ICU International Components for Unicode、Copyright © 1995-2012 International Business Machines Corporation and others

OpenJPEG library、Copyright © 2002-2014, Université catholique de Louvain (UCL), Belgium

TEtはRSA Security, Inc. の MD5 メッセージダイジェストアルゴリズムを含んでいます。



目次

- TET の第一歩 7
 - 0.1 ソフトウェアをインストール 7
 - 0.2 TET ライセンスキーを適用 8

- 1 はじめに 11
 - 1.1 TET 機能概要 11
 - 1.2 TET のさまざまな使用法 14
 - 1.3 文書とサンプルへのロードマップ 14
 - 1.4 TET 5.1 の新機能 15
 - 1.5 TET 5.2 の新機能 16

- 2 TET コマンドラインツール 17
 - 2.1 コマンドラインオプション 17
 - 2.2 TET コマンドラインを構築 21
 - 2.3 コマンドラインの例 23
 - 2.3.1 テキストを抽出 23
 - 2.3.2 画像を抽出 23
 - 2.3.3 TETML を生成 24
 - 2.3.4 高度なオプション 24

- 3 TET ライブラリの言語バインディング 25
 - 3.1 例外処理 25
 - 3.2 C バインディング 27
 - 3.3 C++ バインディング 30
 - 3.4 COM バインディング 32
 - 3.5 Java バインディング 33
 - 3.6 .NET バインディング 35
 - 3.6.1 .NET バインディングの種類 35
 - 3.6.2 .NET Core バインディング 35
 - 3.6.3 クラシック .NET バインディング 36
 - 3.6.4 .NET バインディングを利用 37
 - 3.7 Objective-C バインディング 38
 - 3.8 Perl バインディング 40

- 3.9 PHP バインディング 41
- 3.10 Python バインディング 43
- 3.11 Ruby バインディング 44
- 3.12 RPG バインディング 46

4 TET コネクタ 49

- 4.1 Adobe Acrobat 用無償 TET Plugin 49
- 4.2 Lucene 検索エンジン用 TET コネクタ 50
- 4.3 Solr 検索サーバ用 TET コネクタ 53
- 4.4 Oracle 用 TET コネクタ 54
- 4.5 Microsoft 製品用 TET PDF IFilter 57
- 4.6 Apache TIKA ツールキット用 TET コネクタ 59
- 4.7 MediaWiki 用 TET コネクタ 61

5 設定 63

- 5.1 暗号化 PDF から内容を抽出 63
- 5.2 リソース設定とファイル検索 65
- 5.3 代表的シナリオのための推奨方策 69

6 テキスト抽出 73

- 6.1 PDF のさまざまな文書領域 73
- 6.2 ページとテキストの視覚情報 78
- 6.3 テキストカラー 84
- 6.4 日本語・中国語・韓国語テキスト 86
 - 6.4.1 日中韓エンコーディング・CMap 86
 - 6.4.2 日中韓テキストの単語境界 86
 - 6.4.3 縦書き 86
 - 6.4.4 日中韓分解：narrow・wide・vertical 等 87
- 6.5 双方向アラビア文字・ヘブライ文字テキスト 88
 - 6.5.1 双方向の一般的性質 88
 - 6.5.2 アラビア文字テキストを後処理 88
- 6.6 内容分析 90
- 6.7 レイアウト分析と文書スタイル 94
- 6.8 表組・リスト検出 97
- 6.9 領域が空かどうかをチェック 100

6.10 注釈内のテキスト 101

7 高度な Unicode 処理 103

- 7.1 Unicode のさまざまな重要概念 103
- 7.2 テキストの前処理（フィルタリング） 106
 - 7.2.1 すべての粒度のためのフィルタ 106
 - 7.2.2 粒度 word 以上のためのフィルタ 107
- 7.3 Unicode 後処理 109
 - 7.3.1 Unicode 字形統合 109
 - 7.3.2 Unicode 分解 112
 - 7.3.3 Unicode 正規化 116
- 7.4 追加キャラクタとサロゲート 118
- 7.5 グリフに対する Unicode マッピング 119

8 画像抽出 127

- 8.1 画像抽出の基本 127
- 8.2 画像を抽出 130
 - 8.2.1 配置画像と画像リソース 130
 - 8.2.2 ページベースとリソースベースの画像抽出 131
 - 8.2.3 配置画像の視覚情報 133
- 8.3 断片化した画像群を連結 135
- 8.4 小画像・大画像フィルタリング 137
- 8.5 画像の色とマスク 138
 - 8.5.1 色空間 138
 - 8.5.2 画像マスクとソフトマスク 139

9 TET マークアップ言語（TETML） 141

- 9.1 TETML を生成 141
- 9.2 さまざまな TETML の例 143
- 9.3 TETML の詳細を制御 147
- 9.4 TETML の各種エレメントと TETML スキーマ 151
- 9.5 TETML を XSLT で変換 160
- 9.6 さまざまな XSLT サンプル 163

10 TET ライブラリ API リファレンス 167

- 10.1 オプションリスト 167
 - 10.1.1 オプションリスト文法 167

- 10.1.2 基本型 169
- 10.1.3 図形型 172
- 10.1.4 各種言語バインディングにおける Unicode 対応 173
- 10.1.5 エンコーディング名 173
- 10.2 一般関数 175
 - 10.2.1 オプション処理 175
 - 10.2.2 セットアップ 178
 - 10.2.3 PDFlib 仮想ファイルシステム (PVF) 179
 - 10.2.4 Unicode 変換関数 182
 - 10.2.5 例外処理 184
 - 10.2.6 ログ記録 185
- 10.3 文書関数 187
- 10.4 ページ関数 196
- 10.5 テキスト・グリフ詳細抽出関数 206
- 10.6 画像抽出関数 213
- 10.7 TET マークアップ言語 (TETML) 関数 218
- 10.8 pCOS 関数 221

A TET ライブラリクイックリファレンス 225

B 更新履歴 227

索引 229

○ TET の第一歩

0.1 ソフトウェアをインストール

TET は、Windows に対してはインストーラか圧縮パッケージの形で頒布され、それ以外のすべての対応オペレーティングシステムに対しては圧縮アーカイブの形で頒布されます。すべての TET パッケージの中には TET コマンドラインツールと TET ライブラリ / コンポーネント、およびサポートファイル群・説明書・使用例群が含まれます。TET をインストールまたは解凍した後は、以下の手順を推奨します。

- ▶ TET コマンドラインツールのユーザはその実行形式をただちに利用可能です。指定可能なオプションは 17 ページの 2.1「コマンドラインオプション」で解説しますが、TET コマンドラインツールをオプションなしで実行したときにも表示されます。
- ▶ TET ライブラリ / コンポーネントのユーザは 25 ページの 3 章「TET ライブラリの言語バインディング」の中の、使いたい開発環境に対応する節を読み、インストールされた使用例を眺めるとよいでしょう。

商用 TET ライセンスを得た場合には、自分の TET ライセンスキーを 8 ページの 0.2「TET ライセンスキーを適用」に従って入力する必要があります。

日中韓設定 レガシエンコーディングで符号化された日本語・中国語・韓国語（日中韓）テキストを抽出するためには TET はそれに対応する日中韓エンコーディングを Unicode にマップする CMap ファイルを必要とします。この CMap ファイル群はすべての TET パッケージに含まれており、TET のインストールディレクトリ内の *resource/cmap* ディレクトリにインストールされています。

Windows 以外のシステムでは、この CMap ファイル群を以下のように手動で設定する必要があります。

- ▶ TET コマンドラインツールに対しては、この CMap ファイル群があるディレクトリの名前を `--searchpath` オプションで与えます。
- ▶ TET ライブラリ / コンポーネントに対しては、実行時に次のように *searchpath* を設定します。

```
tet.set_option("searchpath=/CMap/リソース/への/パス");
```

また別の方法として、この日中韓 CMap ファイル群へのアクセスを設定するには、適切な *searchpath* 定義を書いた UPR 設定ファイルの場所を *TETRESOURCEFILE* 環境変数に設定するという方法もあります。

評価版の制約事項 TET のコマンドラインツールとライブラリは商用ライセンスがなくても完全機能の評価版として使うことができます。非ライセンス版はいずれもすべての機能に対応していますが、最大 10 ページ・1 MB 容量までの PDF 文書だけを処理できるようになっています。TET の評価版はいずれも製品評価の目的にのみ使用が許されていますので、実用目的には使用しないで下さい。TET を実用目的に使用するには有効な TET ライセンスが必要です。

0.2 TET ライセンスキーを適用

TET を実用目的に使用するには有効な TET ライセンスキーが必要です。TET ライセンスを購入されたら、そのライセンスキーを適用することによって、任意の大きさの文書进行处理できるようにする必要があります。ライセンスキーの適用方法は数通りありますので、以下に述べる方式のいずれかを選択して下さい。

注記 TET ライセンスキーはプラットフォーム依存なので、それぞれ購入対象となったプラットフォーム上でのみ使用することができます。

Windows インストーラ Windows インストーラで作業をしている場合は、製品をインストールする際にライセンスキーを入力することができます。インストーラはライセンスキーをレジストリに追加します（後述）。

ライセンスファイルでの作業 PDFlib はライセンスキー群をライセンスファイルから読み取ります。ライセンスファイルとは、後述の書式に従ったテキストファイルです。すべての TET ディストリビューションに入っているテンプレート *licensekeys.txt* を使うこともできます。「#」キャラクタで始まる行はコメントであり無視されます。2 行目はライセンスファイル自体のバージョン情報を内容として持ちます：

```
# Licensing information for PDFlib GmbH products
PDFlib license file 1.0
TET 5.2 ...あなたのライセンスキー ...
```

ライセンスファイルは、複数の PDFlib GmbH 製品に対するライセンスキーを、別々の行に内容として持つことが可能です。また、複数のプラットフォームに対するライセンスキーを内容として持つこともできますので、一つのライセンスキーを複数プラットフォームで共用することが可能です。ライセンスファイルは以下の方法で設定できます：

- ▶ *licensekeys.txt* というファイルが、すべてのデフォルトディレクトリ内で検索されます（9 ページの「デフォルトファイル検索パス」参照）。
- ▶ *set_option()* API 関数で *licensefile* オプションを指定することもできます：

```
tet.set_option("licensefile={/path/to/licensekeys.txt}");
```

この *licensefile* オプションは、TET オブジェクトをインスタンス化した直後に、すなわち *TET_new()* を呼び出した後に（C の場合）、あるいは TET オブジェクトを生成した後に設定する必要があります。

- ▶ TET コマンドラインツールの *--teto*pt オプションを与え、*licensefile* オプションでライセンスファイルの名前を与えます：

```
tet --teto "licensefile=/path/to/your/licensekeys.txt" ...
```

パス名が空白キャラクタを含む場合には、パスを中括弧で囲む必要があります：

```
tet --teto "licensefile={/path/to/your license file.txt}" ...
```

- ▶ ライセンスファイルを指し示す環境（シェル）変数を設定することもできます。Windows では、システムコントロールパネルを使って、「システム」→「詳細設定」→「環境変数」を選択します。Unix では下記のようなコマンドを適用します：

```
export PDFLIBLICENSEFILE="/path/to/licensekeys.txt"
```


i5/iSeries では、ライセンスファイルは下記のように指定できます（このコマンドは、スタートアッププログラム *QSTRUP* 内で指定することができ、すべての PDFlib GmbH 製品に対して効力を持ちます）：

```
ADDENVVAR ENVVAR(PDFLIBLICENSEFILE) VALUE(<... パス ...>) LEVEL(*SYS)
```

レジストリ内にライセンスキー Windows では、ライセンスファイルの名前を下記のレジストリキーに記入することもできます：

```
HKLM\SOFTWARE\PDFlib\PDFLIBLICENSEFILE
```

あるいは、ライセンスキーを直接下記のレジストリキーに記入することもできます：

```
HKLM\SOFTWARE\PDFlib\TET5\license  
HKLM\SOFTWARE\PDFlib\TET5\5.2\license
```

インストーラは、インストール時に与えられたライセンスキーを、これらのエントリの末尾に書き込みます。

注記 64ビット Windows システム上で手作業でレジストリを操作する際には注意が必要です。通常、64ビットバイナリは Windows レジストリの 64ビットビューとともに動作するのに対して、64ビットシステム上で走る 32ビットバイナリはレジストリの 32ビットビューとともに動作します。32ビット製品に対するレジストリキーを手作業で追加する必要がある場合には、必ず、*regedit* ツールの 32ビットバージョンを使用してください。これは「スタート」→「ファイル名を指定して実行 ...」ダイアログから下記のように呼び出すことができます：

```
%systemroot%\syswow64\regedit
```

デフォルトファイル検索パス Unix・Linux・macOS・i5/iSeries システム上では、パスやディレクトリ名を一切指定していない場合でも、さまざまなファイルがいくつかのディレクトリでデフォルトで検索されます。UPR ファイル（その中にさらなる検索パス群を含めておくこともできます）を検索して読み取る前に、下記のディレクトリが検索されます：

```
<rootpath>/PDFlib/TET/5.2/resource/cmap  
<rootpath>/PDFlib/TET/5.2/resource/codelist  
<rootpath>/PDFlib/TET/5.2/resource/glyphlst  
<rootpath>/PDFlib/TET/5.2  
<rootpath>/PDFlib/TET  
<rootpath>/PDFlib
```

Unix・Linux・macOS の場合、*<rootpath>* は、まず */usr/local* で置き換えられ、ついで HOME ディレクトリで置き換えられます。i5/iSeries の場合、*<rootpath>* は空です。

ライセンス・リソースファイルのデフォルトファイル名 デフォルトでは下記のファイル名が、デフォルト検索パスディレクトリ群の中で検索されます：

```
licensekeys.txt      (ライセンスファイル)  
tet.upr              (リソースファイル)
```

この機能を利用すると、環境変数やランタイムオプションを一切指定しなくてもライセンスファイルを扱うことができます。

TET コマンドラインツールに対するオプション内でライセンスキーを設定 TET コマンドラインツールを使用する場合には、ライセンスファイルまたはライセンスキー自体の名前を内容として持つオプションを与えることもできます：

```
tet --tetopt "license ...あなたのライセンスキー ..." ...さらなるオプション群...
```

TET API 呼び出しでライセンスキーを設定 TET API を使用する場合は、スクリプトやプログラムに以下のような API 呼び出しを加えて、実行時にライセンスキーを設定させることもできます：

- ▶ COM/VBScript の場合：

```
oTET.set_option "license=...あなたのライセンスキー ..."
```

- ▶ C の場合：

```
TET_set_option(tet, "license=...あなたのライセンスキー ...");
```

- ▶ C++・.NET/C#・Java・Ruby の場合：

```
tet.set_option("license=...あなたのライセンスキー ...");
```

- ▶ Perl・Python・PHP の場合：

```
tet->set_option("license=...あなたのライセンスキー ...");
```

- ▶ RPG の場合：

```
d licensekey      s          20
d licenseval      s          50
c                  eval      licenseopt='license=... あなたのライセンスキー ...'+x'00'
c                  callp     TET_set_option(TET:licenseopt:0)
```

この *license* オプションは、TET オブジェクトを実体化させた直後に設定する必要があります。これは具体的には、*TET_new()* を呼び出した直後 (C の場合)、または TET オブジェクトを生成させた直後ということになります。

さまざまなライセンスオプション 一つないし複数のコンピュータ上で TET を使用したり、TET をあなた自身の製品とともに再頒布したりするための、さまざまなライセンスオプションが利用可能です。また当社では、サポート契約やソースコード契約も提供しています。ライセンスの詳細や購入注文フォームは、TET ディストリビューション内にあります。商用ライセンスの取得にご関心がある場合、またはご質問がある場合は、ご連絡ください：

PDFlib GmbH, Licensing Department
Franziska-Bilek-Weg 9, 80339 München, Germany

www.pdflib.com

電話 +49・89・452 33 84-0

FAX +49・89・452 33 84-99

ライセンスに関するお問い合わせ：jp.sales@pdflib.com

PDFlib ライセンス保持者向けサポート：jp.support@pdflib.com

1 はじめに

PDFlib テキスト・画像抽出ツールキット (TET) は、PDF 文書からテキスト・画像を抽出することを目的としています。それ以外の情報を PDF から取り出すために利用することもできます。TET は、以下のような目的を実現するための基盤要素として活用できます：

- ▶ PDF のテキスト内容を検索
- ▶ PDF 内に含まれる全用語の一覧 (コンコーダンス) を生成
- ▶ 大量 PDF ファイルを処理可能な検索エンジンを実装
- ▶ PDF からテキスト抽出して保管・翻訳・その他再利用目的に活用
- ▶ PDF のテキスト内容を他形式へ変換
- ▶ PDF をそれぞれ内容にしたがって処理または変更
- ▶ 複数 PDF 文書のテキスト内容を比較
- ▶ PDF からラスタ画像を抽出
- ▶ PDF からメタデータ等の情報を抽出

TET は、スタンドアロン使用のために設計されており、いかなるサードパーティソフトウェアをも必要としません。堅牢であり、マルチスレッドのサーバ用途にも適しています。

1.1 TET 機能概要

対応する PDF 入力 TET は、さまざまな作成元による数百万種の PDF テストファイルに対して動作試験済です。PDF 1.0 から PDF 1.7 拡張レベル 8 までと PDF 2.0 を受け入れ可能です。これは Acrobat 1 ~ DC に対応します。また、暗号化された文書も受け入れ可能です。TET は、さまざまな種類の異常・破損 PDF 文書の修復を試みます。

注記 TET は XFA フォームには対応していません。XFA は、PDF 標準 ISO 32000 の一部ではなく、別個の形式です。XFA が小さな PDF ラップの中のパッケージされているため、XFA フォームはしばしば PDF 文書と混同されますが、XFA はまったく別のファイル形式であり、専用のソフトウェアを必要とします。

Unicode 対応 TET には、あらゆるテキストに対して信頼性の高い Unicode マッピングを実現するに足る十分な数のアルゴリズムとデータが内蔵されています。PDF 文書内のテキストは Unicode で符号化されているとは限りませんので、TET は PDF 文書から抽出したテキストを Unicode に正規化します：

- ▶ TET はすべてのテキスト内容を Unicode に変換します。C の場合、テキストは UTF-8 形式か UTF-16 形式で返されます。それ以外の言語の場合はネイティブ Unicode 文字列として返されます。
- ▶ 合字など複数文字グリフは、その構成素を並べた Unicode キャラクタ列へと分解されます。
- ▶ ベンダ依存 Unicode 値 (Corporate Use Subarea, CUS) については識別情報が与えられるとともに、厳密な定義済みの意味を持つキャラクタへ可能な限りマップされます。
- ▶ Unicode マッピング情報を欠いたグリフについては識別情報が与えられるとともに、ユーザ指定可能な置換キャラクタへマップされます。
- ▶ 基本多言語面 (BMP) 外のキャラクタに対する UTF-16 サロゲートペアは解釈され保持されます。サロゲートペアと UTF-32 値はすべての言語バインディングにおいて抽出可能です。

PDF 文書のなかには、信頼性の高い Unicode マッピングの実現に必要な情報を十分に持たないものがあります。そのような場合でもテキストを正しく抽出できるよう、TET にはさまざまな設定オプションが用意されており、それを用いることによって、正しい Unicode マッピングの実現に必要な補助的情報を与えることができます。必要なマッピングテーブルの作成支援のため、PDFlib FontReporter という Adobe Acrobat 用無料プラグインを提供いたしております。このプラグインを用いれば、PDF 内のフォント・エンコーディング・グリフの解析が可能です。

日中韓対応 TET は、日本語・中国語・韓国語テキストの抽出に完全対応しています：

- ▶ あらゆる定義済み日中韓 CMap (エンコーディング) が認識され、日中韓テキストは Unicode に変換されます。日中韓エンコーディング変換のための CMap ファイル群が、TET ディストリビューションに同梱されています。
- ▶ 特殊なキャラクタ字形 (全角・半角・縦中横等) を、対応する通常の字形に変換 (字形統合) することもできます。
- ▶ 横書きと縦書きに対応しています。
- ▶ 日中韓フォント名は Unicode へ正規化されます。

双方向ヘブライ文字・アラビア文字テキスト対応 TET は、双方向テキストを扱うための以下の機能を含んでいます：

- ▶ 右書き・双方向テキストを論理順に並べ替え
- ▶ ページの主要テキスト方向を決定
- ▶ アラビア文字の表示形を正規化し、合字を分解
- ▶ 単語の引き伸ばしに使われているアラビア文字のタトゥィールキャラクタを除去

Unicode 後処理 TET の Unicode 後処理機能は以下を含みます：

- ▶ 字形統合：一つないし複数のキャラクタに対して温存・置換・除去のいずれかを行います。対象キャラクタ群を Unicode 集合として指定することができるので便利です。
- ▶ 分解：Unicode 規格で定義されている正準分解または互換分解を適用することも可能です。環境によってはこれによってテキストがより有用になる場合があります。たとえば、アクセント付きキャラクタや分数、商標記号のような記号を温存したり分割したりすることができます。
- ▶ 正規化：出力を、Unicode 規格で定義されている Unicode 正規形 NFC・NFD・NFKC・NFKD のいずれかへ変換します。これによって TET は、データベースや検索エンジンなどいくつかの環境が入力として求める形式と正確に一致した形式を生成することができます。

画像抽出 TET は PDF からラスタ画像を抽出します。断片化された画像の隣接部分は再結合され、後処理と再利用を可能にします (いくつかのアプリケーションによって生成されたマルチストリップ画像等)。小さい画像は、微小な画像素片で出力が散らかることを防ぐために、フィルタをかけて取り除くこともできます。画像にマスクが付けられている場合には、そのマスクも抽出可能です。

画像は、TIFF・JPEG・JPEG 2000・JBIG2 のいずれかの形式で抽出されます。

位置情報 TET は、テキストのページ上の位置やグリフ幅やテキスト方向といった厳密なメトリクスを出力します。テキスト抽出処理に際してはページ上の特定領域を外したり含めたりすることにより、たとえばヘッダ・フッタや余白を無視させたりすることが可能です。

画像については、ピクセルサイズ・物理サイズ・色空間が得られるほか、位置や角度も得られます。

テキストの色 TET はグリフの色に関する情報を提供します。塗りと描線のための色空間と、照応するカラー値を取得できます。複数のグリフの色を簡単に比較するための簡便なショートカットが利用できますので、PDF のさまざまな色空間の煩雑さを取り扱う必要がありません。

単語検出と内容解析 TET には、低次元のグリフ情報を抽出する機能だけでなく、高次元の内容・レイアウト解析を行う高度なアルゴリズムも内蔵されています：

- ▶ 単語区切りを検出して文字群でなく単語を抽出。
- ▶ ハイフンで区切られた単語の各部を再結合（デハイフネーション）。
- ▶ 影付きや擬似太字テキスト等によるテキストのダブリを除去。
- ▶ 段落群を読み順に再連結。
- ▶ ページ上に配置されたテキスト群の順序認識。
- ▶ テキストの行を再構成。
- ▶ ページ上の表組構造を認識。
- ▶ 上付き・下付き・ドロップキャップ（段落頭の大きい先頭キャラクタ群）を認識。

TET Markup Language (TETML) PDF 文書から取得した情報は、TET Markup Language (TETML) という XML 形式で表現することもできます。これは標準的な XML ツール群で処理が可能です。TETML は、テキスト・画像・メタデータ情報を内容として持つほか、オプションとしてフォント・位置関連情報を内容として持つこともできます。TETML はまた、色・色空間情報、およびフォームフィールド・注釈・しおりなどインタラクティブ要素を内容として持ちます。

PDF オブジェクトを容易に指し示すための pCOS インタフェース TET は、任意の PDF オブジェクトを取得するための pCOS インタフェース (*PDFlib Comprehensive Object System*) を含んでいます。pCOS を使うと、PDF 文書から、PDF メタデータやインタラクティブ要素（しおりテキストやフォームフィールドの内容など）、その他あらゆる情報を、簡単な取得インタフェースで取得することができます。pCOS クエリパスの文法は、別途 pCOS パスリファレンスに記述しています。

テキストとは何か TET はさまざまな種類の PDF 文書を扱いますが、目に見えるテキストを抽出できない場合もあります。そのテキストは PDF のテキスト・エンコーディング機能を用いて符号化されている必要があります（すなわちそれはフォントに基づいたものでなければなりません）。以下の種類のテキストはページ上で目に見えてはいても TET で抽出することはできません：

- ▶ ページのスキャナ画像等、ラスタライズされた（ピクセル画像の）テキスト
- ▶ フォントなしにベクトル要素で表されたテキスト

なお、メタデータとハイパーテキスト要素（しおり・フォームフィールド・ノート・注釈等）内テキストは TETML か pCOS インタフェースを用いて抽出できます：詳しくは 73 ページの 6.1 「PDF のさまざまな文書領域」を参照してください。逆に TET は、ページ上で目に見えていないテキストを抽出することもあります。これは以下のような場合に起こる可能性があります：

- ▶ PDF の不可視属性を用いたテキスト（ただし、この種類のテキストをテキスト抽出処理の対象外にするオプションはあります）。

- ▶ テキストが、ページ上の画像等何か他の要素によって隠されている場合。

1.2 TET のさまざまな使用法

TET は、さまざまな開発環境用のプログラミングライブラリ（コンポーネント）としても提供されますし、バッチ操作のためのコマンドラインツールとしても提供されます。両者の機能は同様ですが、それぞれ実用に適する場面が異なっています。TET ライブラリとコマンドラインツールはどちらも、TET の XML ベースの出力形式である TETML を生成することができます。

どちらの TET を選べばよいか、以下にそのガイドラインを掲げます。

- ▶ TET プログラミングライブラリはデスクトップアプリケーションやサーバアプリケーションに組み込んで使うことができます。さまざまなプログラミング言語に対応しています。TET パッケージには、TET ライブラリのすべての対応言語バインディングにおける使用例が同梱されています。
- ▶ TET コマンドラインツールは PDF 文書のバッチ処理に適しています。プログラミングは一切不要で、かわりにさまざまなコマンドラインオプションをそなえており、それを用いて複雑なワークフローでの活用が可能です。
- ▶ TETML 出力は、XML ベースのワークフローと、さまざまな XML 処理ツールや XSLT 等の XML 処理言語に通じた開発者に適しています。
- ▶ TET コネクタは、データベースや検索エンジン等、広く利用されているさまざまなソフトウェアパッケージに TET を統合させるために適しています。
- ▶ TET Plugin は、TET を対話的に利用できるようにする、Adobe Acrobat 用の無償拡張です（詳しくは 49 ページの 4.1 「Adobe Acrobat 用無償 TET Plugin」を参照）。

1.3 文書とサンプルへのロードマップ

TET ライブラリ用プログラミングサンプル TET ディストリビューションは、すべての対応言語バインディングのためのプログラミング作成例を含んでいます。これらのサンプルは、自分のアプリケーションのための出発点として利用したり、自分の TET インストールを試験したりするために利用できます。以下のアプリケーションのためのソースコードから成っています：

- ▶ **extractor** サンプル：PDF 文書からテキストを抽出するための基本的なループを演示しています。
- ▶ **image_resources** サンプル：各ページ上の画像群を抽出して、その寸法などのプロパティについてレポートします。
- ▶ **image_resources** サンプル：PDF 文書から画像をリソース志向な方式（寸法情報を得ない）で抽出するための基本的なループを演示しています。
- ▶ **dumper** サンプル：PDF 文書に関する一般情報を取得するための内蔵 pCOS インタフェースの使用を示しています。
- ▶ **fontfilter** サンプル：フォント名や文字サイズといったフォント関連情報の処理方法を示しています。
- ▶ **glyphinfo** サンプル：グリフに関する情報（フォント・サイズ・位置等）や、**dropcap**・**shadow**・**hyphenation** といったテキスト属性の取得方法を演示しています。テキストカラー情報にアクセスする方法も示しています。
- ▶ **tetml** サンプル：PDF 文書から TETML (PDF の内容を表現するための TET の XML 言語) を生成するためのコードを内容としています。

- ▶ *get_attachments* サンプル: PDF ファイル添付、すなわち別の PDF 文書内に埋め込まれている PDF 文書の処理方法を演示しています。

XSLT サンプル TET ディストリビューションは、いくつかの XSLT スタイルシートを含んでいます。これらは、さまざまな目的を実現するための TETML の処理方法を演示しています:

- ▶ *concordance.xml*: 文書内の単語を頻度の多い順に並べたリストを生成します。
- ▶ *fontfilter.xml*: 文書内の、指定した値よりも大きなサイズで特定のフォントを用いているすべての単語をリストします。
- ▶ *fontfinder.xml*: 文書内のすべてのフォントについて、すべての出現箇所をページ番号と位置情報とともにリストします。
- ▶ *fontstat.xml*: フォントとグリフの統計を生成します。
- ▶ *index.xml*: アルファベット順の索引を生成します。
- ▶ *metadata.xml*: TETML 内に含まれている文書レベル XMP メタデータから、選択したプロパティ群を抽出します。
- ▶ *solr.xml*: Solr エンタプライズ検索サーバ用の入力を生成します。
- ▶ *table.xml*: 表組を CSV ファイル (カンマ区切り値) へ抽出します。
- ▶ *tetml2html.xml*: TETML を HTML へ変換します。
- ▶ *textonly.xml*: TETML 入力から生テキストを抽出します。

TET クックブック TET クックブックは、特定の応用問題を TET ライブラリで解決するためのソースコード作成例の集合です。このクックブックは Java 言語で書かれていますが、他の言語でも容易に利用できます。なぜなら TET API はすべての対応言語バインディングでほぼ等価だからです。いくつかのクックブックサンプルは XSLT 言語で書かれています。TET クックブックは以下のグループにまとめられています:

- ▶ Text: テキスト抽出関連のサンプル群
- ▶ Font: フォント属性に焦点をあてたテキスト関連のサンプル群
- ▶ Image: 画像抽出関連のサンプル群
- ▶ TET & PDFlib+PDI: PDF から TET で情報を抽出して、新たな PDF を元 PDF と抽出情報に基づいて構築するサンプル群。これらのサンプルには、TET に加えて PDFlib+PDI 製品が必要です。
- ▶ TETML: TETML 処理用の XSLT サンプル群
- ▶ Special: その他のサンプル群

TET クックブックは下記 URL で利用可能です:
www.pdfli.com/tet-cookbook

pCOS クックブック pCOS クックブックは、TET に内蔵されている pCOS インタフェースのためのコードの集合です。下記 URL で利用可能です:
www.pdfli.com/pcos-cookbook

pCOS インタフェースの詳細は、TET パッケージに含まれている pCOS パスリファレンスに示されています。

1.4 TET 5.1 の新機能

TET 5.1 の新機能と大幅改善機能を以下に示します:

- ▶ 番号付きリストと番号なしリストがTETML内で識別され表現されるようになりました (ページオプション `structureanalysis={list=true}` によって)
- ▶ 相互参照ストリームを有する破損した入力文書のための修復モード
- ▶ 準拠していない入力文書のための回避策の向上
- ▶ 無効化された画像・色・ベクトルエンジンに対するパフォーマンスの向上と、レイヤーのない文書に対するパフォーマンスの向上
- ▶ メモリ必要量が減少
- ▶ pCOS インターフェースを、証明書セキュリティに対応したバージョン11へアップデート
- ▶ その他バグ修正
- ▶ 言語バインディングのアップデート

1.5 TET 5.2 の新機能

TET 5.2 の新機能と大幅改善機能を以下に示します：

- ▶ 表行・表列の結合の識別など、表認識の向上
- ▶ ページ装飾（本文外のテキスト・画像）に、TETML と API の中で標識
- ▶ 注釈・パターンからテキスト・画像を抽出
- ▶ インライン画像・ソフトマスク内画像(透過グループXObjectによるグラフィック状態)に対応
- ▶ .NET Core のための新たな言語バインディング
- ▶ すべての言語バインディングにおける向上と、最新の言語バージョンのためのアップデート
- ▶ 破損 PDF のための多数のバグ修正・向上・問題回避策
- ▶ サードパーティライブラリ群のためのセキュリティアップデート
- ▶ より複雑なネイティブ色空間でなく、よりシンプルな代替色空間における *Separation・DeviceN* テキストカラーを取得することも可能に
- ▶ pCOS インタフェースを若干拡張

2 TET コマンドラインツール

2.1 コマンドラインオプション

TET コマンドラインツールを利用すれば、プログラミングを一切必要とせずに、1つないし複数の PDF 文書からテキスト・画像を抽出することができます。出力は、プレーンテキスト (Unicode) 形式か、または TET の XML ベースの出力形式である TETML 形式で生成することができます。この TET プログラムはコマンドラインオプションで制御できます。このプログラムは各単語の後に空白キャラクタ (U+0020) を挿入し、また各行の後に U+000A を、各ページの後に U+000C を挿入します。これを呼び出すには次のように 1つないし複数の PDF ファイルを指定します。

```
tet [<オプション群>] <ファイル名>...
```

この TET コマンドラインツールは TET ライブラリの最上位の上に構築されています。

`--docopt`・`--teto`pt・`--imageopt`・`--pageopt` オプションを用いれば、167 ページの 10 章「TET ライブラリ API リファレンス」のオプション一覧表に従ったさまざまなオプションをライブラリに与えることが可能です。表 2.1 にすべての TET コマンドラインオプションを挙げます (この一覧は、この TET プログラムをオプションなしで走らせたときにも表示されます)。

注記 ある種の PDF 文書から日中韓テキストを抽出するには、TET 同梱の CMap ファイル群の置き場所を設定する必要があります (7 ページの 0.1「ソフトウェアをインストール」を参照)。

表 2.1 TET コマンドラインオプション一覧

オプション	引数	機能
--		オプションのリストを終了させます。これは、ファイル名が - キャラクタで始まっているときに有用です。
@filename ¹		オプション群を持つレスポンスファイルを指定します。文法の説明は 21 ページの「レスポンスファイル」を参照してください。レスポンスファイルは、-- オプションの前、かつ最初のファイル名の前でのみ認識されます。レスポンスファイルは、他のオプションに対する引数を置き換えるために用いることはできず、完全なオプション/引数の組み合わせ群を内容とする必要があります。
--docopt	<オプションリスト>	open_document() に対する追加のオプションリスト (188 ページの表 10.8 参照)。tetml オプションの filename サブオプションはここでは使えません。
--firstpage -f	<integer> last	(--imageloop resource に対しては無視されます) テキスト抽出を開始するページの番号。キーワード last で末尾ページを指定、last-1 で末尾ページ前のページ、等々。デフォルト : 1
--format	utf8 utf16	テキスト出力の形式を指定 (デフォルト : utf8) : utf8 BOM (バイトオーダーマーク) 付き UTF-8 utf16 ネイティブバイト順序の BOM 付き UTF-16 このオプションは、つねに UTF-8 で生成される TETML 出力には効力を持ちません。
--help, -? (またはオプションなし)		利用可能なオプションをまとめたヘルプを表示

表 2.1 TET コマンドラインオプション一覧

オプション	引数	機能
<code>--image²</code> <code>-i</code>		文書全体から (<code>--imageloop resource</code> の場合)、または選択したページ群から (<code>--imageloop page</code> の場合)、画像を抽出します。抽出された画像群のファイル名は <code>--imageloop</code> オプションに依存します (下記参照)。
<code>--imageloop</code>	page resource	<p><code>--image</code> オプションによる画像抽出の数え上げの種類を指定します (デフォルト: page、ただし <code>--tetml</code> を指定しているなら resource が強制されます):</p> <p>page 選択されたページ (1 個ないし複数) にあるすべての画像を数え上げます。複数回配置されている画像リソースは複数回抽出されます。</p> <p>resource 文書内のすべてのプレーンおよび連結された画像リソースを抽出します。各画像リソースは、文書内に現れる回数にかかわらず、1 回抽出されます。画像リソース群に対して寸法情報は全く得られませんので、ダミー値 72 dpi が、生成される TIFF 画像の中へ埋め込まれます。</p>
<code>--imageopt</code>	<オプションリスト>	write_image_file() に対する追加のオプションリスト (215 ページの表 10.20 を参照)
<code>--lastpage</code> <code>-l</code>	<integer> last	(<code>--imageloop resource</code> に対しては無視されます) テキスト抽出を終了するページの番号。キーワード last で末尾ページを指定、last-1 で末尾ページの前のページ、等々。デフォルト: last
<code>--outfile</code> <code>-o</code>	<ファイル名>	(複数の入力ファイル名を与えているときは不可) テキスト出力または TETML 出力のファイル名。入力ファイルを一個だけ与えているときのみ、ファイル名「-」を用いて標準出力を指定可能。デフォルト: 入力ファイル名の .pdf・.PDF を .txt (テキスト出力時) か .tetml (TETML 出力時) に置き換えた名前。
<code>--pagecount</code>		その文書の中のページの数、すなわち pCOS パス length:pages の値を、stdout へ、または <code>--outfile</code> を用いて与えられたファイルへ印字。
<code>--pageopt</code>	<オプションリスト>	テキスト出力生成なら open_page() に対する、TETML 出力生成なら process_page() に対する、追加のページオプションリスト (196 ページの表 10.10 と 218 ページの表 10.21 を参照)。テキスト出力の場合、オプション granularity はつねに page に設定されます。
<code>--password,</code> <code>-p</code>	<パスワード>	暗号化文書に対するユーザ・マスタ・添付いずれかのパスワード。場合によっては、シュラッグ機能を利用すると、パスを与えずに暗号化文書をインデックスすることができます (63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照)。
<code>--samedir</code>		出力ファイル群を、入力ファイル (群) と同じディレクトリの中に生成。
<code>--searchpath¹</code> <code>-s</code>	<パス>...	ファイル (CMap 等) を検索する 1 つないし複数のディレクトリの名前。デフォルト: インストール環境に依存
<code>--targetdir</code> <code>-t</code>	<ディレクトリ名>	生成されるテキスト・TETML・画像ファイルの出力ディレクトリ。存在しているディレクトリである必要があります。このオプションは、 <code>--samedir</code> を指定した場合には無視されます。デフォルト: . (すなわちカレント作業ディレクトリ)

表 2.1 TET コマンドラインオプション一覧

オプション	引数	機能
--tetml -m	glyph image word wordplus line page	(--text との組み合わせ不可) テキスト・画像・インタラクティブ要素に関する情報を持った TETML 出力を生成。TETML は UTF-8 形式で生成されま す。与える引数によって、いくつかの種類の中の 1 つを選びます (147 ページの 9.3 「TETML の詳細を制御」を参照) : glyph グリフ位置情報とフォント情報を持ったグリフベースの TETML image 画像情報を持った、しかしテキスト・インタラクティブ要素を持 たない TETML line 行ベースの TETML page ページベースの TETML word 単語枠を持った単語ベースの TETML wordplus 単語枠とすべてのグリフ情報を持った単語ベースの TETML 添付・しおり・移動先は、文書の全ページが処理されるときにのみ、TETML 内に含まれます (--firstpage・--lastpage を参照)。
--teto	<オプションリ スト>	set_option() に対する追加のオプションリスト (175 ページの表 10.2 を参 照)。オプション outputformat は無視されます (かわりに --format を用い てください)。
--text²		(--tetml との組み合わせ不可) 文書からテキストを抽出します (デフォルト で有効)
--verbose -v	0 1 2 3	冗長レベル (デフォルト : 1) : 0 一切出力なし 1 エラーのみ出力 2 エラーとファイル名を出力 3 詳細レポート
--version, -V		TET バージョン番号を印字します。

- このオプションは複数回与えることもできます。
- オプション --image はデフォルトではテキスト抽出を無効にしますが、--text・--tetml と組み合わせることもできます。

画像ファイル名 抽出される画像のファイル名は **--imageloop** オプションに依存します。
--imageloop page の場合には、抽出される配置画像は以下のパターンに従って命名されま
す :

<ファイル名>_p<ページ番号>_<画像番号>.[tif|jpg|jp2|jpf|j2k|jbig2]

画像がページ装飾 (本文外の内容) として指定されている場合には、以下のファイル名パ
ターンが用いられます :

<ファイル名>_p<ページ番号>_<画像番号>_artifact.[tif|jpg|jp2|jpf|j2k|jbig2]

他の画像に対するマスクとして用いられている画像は、以下のファイル名パターンに従っ
て命名されます (画像番号はマスクされる画像の番号) :

<ファイル名>_p<ページ番号>_<画像番号>_mask[_artifact].[tif|jpg|jp2|jpf|j2k|jbig2]

--imageloop resource の場合には、抽出された画像リソース (他の画像に対するマスクとし
て用いられている画像も含む) は、以下のパターンに従って命名されます :

<ファイル名>_I<画像ID>.[tif|jpg|jp2|jpf|j2k|jbig2]

ここで画像 ID は、*images[]* リソース配列内の添字です。これと同じ画像ファイル名パターンが、TETML 属性 *Image/@filename* 内でも用いられます。

2.2 TET コマンドラインを構築

TET コマンドラインの作成にあたっては、以下の規則を守る必要があります。

- ▶ 入力ファイルは、`searchpath` で指定したすべてのディレクトリ内で検索されます。
- ▶ オプションによっては短オプション形が利用可能で、長オプション形との混在も可能です。
- ▶ 長オプションは先頭の数字だけで表すことも可能です。ただしその省略形が一意である場合に限りです。
- ▶ 入力ファイルの暗号化ステータスによっては、テキストを正しく抽出するためにユーザパスワードかマスタパスワードが必要となる場合があります。これは `--password` オプションで与える必要があります。TET はこのパスワードが内容抽出のために充分かどうかを調べ、充分でない場合にはエラーを生成します。

TET はコマンドライン全体をまず調べてからファイルの処理を開始します。コマンドライン上どここのオプション内であればエラーが出たならば、ファイルはどれも一切処理されないうままとまります。

ファイル名 空白キャラクタを含むファイル名は、TET のようなコマンドラインツールで用いる際には若干特殊な取り扱いを要します。空白キャラクタを含んだファイル名を処理させるには、ファイル名全体をダブルクォート文字 " でくくらなければなりません。ワイルドカードが標準的用法に従って使えます。たとえば `*.pdf` は、所与のディレクトリ内でファイル名接尾辞 `.pdf` を持つすべてのファイルを表します。システムによって、大文字小文字を区別するものとしないうものがあることに注意しましょう (`*.pdf` が `*.PDF` と違って等) 。また Windows システム群ではワイルドカードは、空白キャラクタを含むファイル名には効かないので注意して下さい。ワイルドカードはカレントディレクトリ内で評価され、検索パスディレクトリ内では評価されません。

Windows では、すべてのファイル名オプションが Unicode 文字列を受け入れます。たとえばこれは、エクスプローラからファイルをコマンドプロンプトウィンドウへドラッグした際に発生します。

レスポンスファイル オプション群をコマンドラインで直接与える方法以外に、オプション群をレスポンスファイル内で与える方法もあります。レスポンスファイルの内容は、コマンドライン内で `@filename` オプションが見つかった位置に挿入されます。

レスポンスファイルは、オプション群と引数群を持った単純なテキストファイルです。これは以下の文法規則に従う必要があります：

- ▶ オプション値群は空白文字、すなわちスペース・ラインフィード・リターン・タブのいずれかで区切る必要があります。
- ▶ 空白文字を含む値は、ダブルクォーテーション " で囲む必要があります。
- ▶ 値の先頭と末尾のダブルクォーテーションは無視されます。
- ▶ ダブルクォーテーションをリテラルに用いるためには、バックスラッシュでマスクして `\` とする必要があります。
- ▶ バックスラッシュキャラクタは、もう一個のバックスラッシュでマスクして `\\` とする必要があります。

レスポンスファイルは入れ子にすることもできます。すなわち、`@filename` 文法はそれ自体をレスポンスファイルで用いることもできます。

レスポンスファイルは、ファイル名引数に対して Unicode 文字列を持つこともできます。レスポンスファイルは、UTF-8・EBCDIC-UTF-8・UTF-16 のいずれかの形式で符号

化することができ、対応する BOM で始まる必要があります。BOM が見つからないときは、レスポンスファイルの内容は、zSeries では EBCDIC で、それ以外のすべてのシステムでは ISO 8859-1 (Latin-1) で解釈されます。

終了コード TET コマンドラインツールは以下に示す終了コードを返すので、これを利用すれば、要求した操作が正しく遂行できたかどうかを調べることができます：

- ▶ 終了コード 0：すべてのコマンドラインオプションの処理が成功し完結した。
- ▶ 終了コード 1：ファイル処理エラーが 1 件ないし複数発生、しかし処理は継続された。
- ▶ 終了コード 2：コマンドラインオプションの中に何らかのエラーが発見された。処理はその不良オプションの位置で停止したため、入力ファイルは一切処理されなかった。

2.3 コマンドラインの例

以下の例は、TET コマンドラインオプションのいくつかの有用な組み合わせを演示しています。

2.3.1 テキストを抽出

PDF 文書 *file.pdf* からテキストを UTF-8 形式で抽出し、それを *file.txt* に格納：

```
tet file.pdf
```

テキスト抽出から先頭ページと末尾ページを除外：

```
tet --firstpage 2 --lastpage last-1 file.pdf
```

日中韓 CMap が置かれているディレクトリを与えます（日中韓テキスト抽出では必須です）：

```
tet --searchpath /usr/local/cmeps file.pdf
```

PDF からテキストを UTF-16 形式で抽出し、それをファイル *file.utf16* に格納：

```
tet --format utf16 --outfile file.utf16 file.pdf
```

1 個のディレクトリの中のすべての PDF ファイルからテキストを抽出し、生成される *.txt ファイル群を別のディレクトリ（すでに存在している必要があります）の中へ格納：

```
tet --targetdir out in/*.pdf
```

2 個のディレクトリからのすべての PDF ファイルからテキストを抽出し、生成された *.txt ファイル群を、照応する入力文書と同じディレクトリの中へ格納：

```
tet --samedir dir1/*.pdf dir2/*.pdf
```

テキスト抽出をページ上の特定の領域に限定：

```
tet --pageopt "includebox={{0 0 200 200}}" file.pdf
```

さまざまなコマンドラインオプションを内容として持つレスポンスファイルを用いて、カレントディレクトリ内のすべての PDF 文書进行处理します（ファイル *options* にコマンドラインオプション群が入っています）：

```
tet @options *.pdf
```

2.3.2 画像を抽出

file.pdf から画像群をページ志向な方式で抽出し、それらをディレクトリ *out* 内へ格納：

```
tet --targetdir out --image file.pdf
```

file.pdf から画像群をリソース志向な方式で抽出し、それらをディレクトリ *out* 内へ格納：

```
tet --targetdir out --image --imagemap resource file.pdf
```

file.pdf から画像群を画像結合なしに抽出。これは、画像処理のためのページオプション群のリストを与えることで実現できます：

```
tet --targetdir out --image --pageopt "imageanalysis={merge={disable}}" file.pdf
```

2.3.3 TETML を生成

PDF 文書 *file.pdf* に対する TETML 出力を単語モードで生成し、それを *file.tetml* に格納：

```
tet --tetml word file.pdf
```

TETML 出力を、*Options* エレメント一切なしで生成。これは、適切な文書オプションのリストを与えることで実現できます：

```
tet --docopt "tetml={elements={options=false}}" --tetml word file.pdf
```

TETML 出力を、すべてのグリフ情報を持った単語モードで生成し、それを *file.tetml* に格納：

```
tet --tetml word --pageopt "tetml={glyphdetails={all}}" file.pdf
```

画像群を抽出し、テキスト・画像情報を持った TETML を生成：

```
tet --image --tetml word file.pdf
```

画像群を抽出し、画像情報を持った、しかしテキスト情報を持たない TETML を生成：

```
tet --tetml image --image file.pdf
```

下向き座標による TETML 出力を生成：

```
tet --tetml word --pageopt "topdown={output}" file.pdf
```

向上した表組検出による TETML 出力を生成：

```
tet --tetml word --pageopt "vectoranalysis={structures=tables}" file.pdf
```

2.3.4 高度なオプション

Unicode 字形統合を適用します。たとえば空白字形統合：すべての種類の Unicode 空白キャラクタを U+0020 にマッピングします：

```
tet --docopt "fold={{[:blank:]} U+0020}" file.pdf
```

句読点を単語境界として無効にします：

```
tet --pageopt "contentanalysis={punctuationbreaks=false}" file.pdf
```


3 TET ライブラリの言語バインディング

この章では、TET ライブラリで供給されるさまざまな言語バインディングの仕様について解説します。TET ディストリビューションには、対応しているすべての言語バインディングによるいくつかの小さな TET アプリケーションのための完全なサンプルコードが含まれています。

3.1 例外処理

ある種のエラーは多くの言語において例外と呼ばれています。それにはもっともな理由があり、そうしたエラーは単なる例外で、プログラムが始まって終わるまでの間にそう頻繁には起こらないと予想されるからです。一般的なさばき方としては、まずいことが頻繁に起こりそうな関数呼び出しについては通常のエラー報告のしくみ（要はエラーコードを返す）を採用するとして、めったに起こらなさそうなものについてまでそれをやるとコードがあらゆる場合分けによって条件文だらけになってしまうので、それを避けるためにそうしたものについては特殊な例外のしくみを採用するのが普通です。TET でもまさにその通りを行っています。操作によっては、割と頻繁にまずいことが起きると予想できるものがあります。たとえば：

- ▶ 正しいパスワードを知らない PDF 文書を開こうとした（ただし、63 ページの 5.1「暗号化 PDF から内容を抽出」で説明するシュラッグ機能も参照）。
- ▶ 誤ったファイル名で PDF 文書を開こうとした。
- ▶ 修復できないほど破損している PDF 文書を開こうとした。

TET はこのようなエラーを、値 -1 を返すことによって知らせます。API リファレンスに記述している通りです。一方、有害と考えられる出来事ではあっても起きる頻度は割と低いものもあります。たとえば：

- ▶ 仮想メモリが足りなくなった。
- ▶ 関数に与えたパラメタがおかしい（文書のハンドルが無効だった等）。
- ▶ オプションリストを与えたら形式が間違っていた。
- ▶ 必要なリソースなのに（日中韓テキスト抽出には CMap ファイルが必要等）見つからない。

TET がこのような状況を検知した場合には、特別なエラー値が呼び出し元に返るのではなく、例外が発生します。例外にネイティブに対応している言語では、例外の発生は、その言語・環境と与える標準手段を用いて行われます。C 言語バインディングの場合には、TET はカスタムの例外処理のしくみを提供しているので、クライアントはそれを用いる必要があります（27 ページの 3.2「C バインディング」参照）。

重要な留意点としては、例外が起きたら文書の処理は止めなければなりません。例外の後に呼んでも安全なメソッドは `delete()`・`get_apiname()`・`get_errnum()`・`get_errmsg()` だけです。これ以外のメソッドを例外の後に呼ぶと予測できない結果につながる可能性があります。この例外は以下の情報を持っています。

- ▶ 一意のエラー番号。
- ▶ 例外の原因となった API 関数の名前。
- ▶ 問題点を説明した文。

失敗した関数呼び出しの原因を取得 TET の関数によっては、たとえば `open_document()` や `open_page()` 等、呼び出して失敗しても例外が発生しないものがあります（そうした関

数はエラー時には -1 を返します)。そのような場合には、失敗した関数呼び出しの直後に関数 `get_errnum()`・`get_errmsg()`・`get_apiname()` を呼び出せば、問題の性質に関する詳しい情報を得ることができます。

3.2 C バインディング

TET は C 言語で、いくつかの C++ モジュールを用いて書かれています。C バインディングを利用するには、静的または共有ライブラリのいずれかを使用することができ (Windows・MVS の場合は DLL)、自分のソースモジュールにインクルードするためのセントラル TET インクルードファイル `tetlib.h` が必要です。

注記 C 用の TET バインディングを用いるアプリケーションは、C++ リンカでリンクする必要があります。なぜならこのライブラリには C++ で実装されている部分があるからです。C リンカを使用すると、アプリケーションに必要な C++ サポートライブラリ群にリンクしないかぎり、非決定の外部参照を引き起こす可能性があります。

例外処理 TET の API は、C 言語にはネイティブな例外処理がないのを補うために、このライブラリが発生させた例外に対処するためのしくみを提供しています。 `TET_TRY()` マクロと `TET_CATCH()` マクロを用いることにより、例外発生時にエラー処理やクリーンアップを実行させるためのコードを入れ込んだクライアントコードを組み立てることができるのです。これらのマクロはコード内に 2 つの部分に分けられます。1 つは try 節で、例外が発生させる可能性のあるコードを持ち、もう 1 つは catch 節で、例外に対処するコードを持ちます。try ブロックの中から呼び出された API 関数のいずれかが例外が発生させたとき、プログラムの実行はただちに catch ブロックの先頭ステートメントに移ります。TET のクライアントのコードは以下の規則に従う必要があります：

- ▶ `TET_TRY()` と `TET_CATCH()` は必ず対にしなければなりません。
- ▶ `TET_new()` は決して例外を発生させません。try ブロックは、有効な TET オブジェクトハンドルを用いなければ開始させることができないので、`TET_new()` はすべての try ブロックの外で呼び出さなければなりません。
- ▶ `TET_delete()` は決して例外を発生させません。よって、すべての try ブロックの外で安全に呼び出すことができます。catch 節の中で呼び出すこともできます。
- ▶ try ブロックと catch ブロックの両方の中で用いられている変数については特別な注意を払う必要があります。コンパイラは、制御がブロックからブロックへ移ることは知らないで、そのような場合、不適切なコードを生成する可能性があります (レジスタ変数最適化等)。幸い、この種の問題を避ける簡単な規則があります。try ブロックと catch ブロックの両方で用いられる変数は `volatile` と宣言する必要があります。 `volatile` キーワードの使用はコンパイラに、危険な最適化を変数に行ってはならないということを知らせます。
- ▶ try ブロックを抜ける場合には (たとえば return ステートメントによって、ひいては対応する `TET_CATCH()` の実行をバイパスして)、return ステートメントの前に `TET_EXIT_TRY()` マクロを呼び出して、例外のしくみにそのことを通知する必要があります。
- ▶ 例外が発生したら文書処理は止めなければなりません。

以下のコードに、これらの規則の遵守例を示します。クライアントのコード内で TET の例外を扱う際の典型的な書き方もあわせて示しています (完全なサンプルは TET パッケージ内にあります)：

```
TET *tet;
volatile int pageno;
...
/* 新規TETオブジェクトを作成 */
if ((tet = TET_new()) == (TET *) 0)
{
```

```

    printf("TETオブジェクトを作成できませんでした（メモリがいっぱいです）\n");
    return(2);
}
TET_TRY(tet)
{
    for (pageno = 1; pageno <= n_pages; ++pageno)
    {
        /* ページを処理 */
        if (/* エラーが起きた */)
        {
            TET_EXIT_TRY(tet);
            return -1;
        }
    }
    /* API関数群を直接・間接に呼び出すステートメント群 */
}
TET_CATCH(tet)
{
    printf("TET例外 %d が %s() 内で %d ページ上で発生しました: %s\n",
          TET_get_errnum(tet), TET_get_apiname(tet), pageno, TET_get_errmsg(tet));
}
TET_delete(tet);

```

volatile 変数 `TET_TRY()` と `TET_CATCH()` の両方のブロックの中で用いられる変数については特別な注意が必要です。コンパイラは、一つのブロックから別のブロックへの制御の遷移について知りませんので、不適切なコードをこの状況において生成するおそれがあります（レジスタ変数最適化など）。幸い、この問題を避けるためのシンプルなルールがあります：

注記 `TET_TRY()` の `TET_CATCH()` 両方のブロックの中で用いられる変数は `volatile` と宣言されるべきです。

`volatile` キーワードを用いると、その変数に最適化を適用してはならないということがコンパイラへ伝わります。

名前文字列に対する Unicode 処理 C プログラミング言語は、バージョン C11 でのみ、純粋な Unicode 文字列に対応しています。このバージョンはまだ一般的には対応されていませんので、TET は、古典的な `char` データ型に基づいて Unicode 対応を提供しています。API 関数に対する文字列パラメタのなかには**名前文字列**として宣言されているものがあります。これらは `length` パラメタと、文字列の先頭の BOM の有無によって処理のされ方が異なります。C の場合、`length` パラメタが 0 でないときは文字列は UTF-16 と解釈されます。`length` パラメタが 0 のときは、文字列が UTF-8 BOM で始まっていれば UTF-8 と解釈され、EBCDIC UTF-8 BOM で始まっていれば EBCDIC UTF-8 と解釈され、BOM がなければ `auto` エンコーディング（ただし EMBDIC ベースのプラットフォーム上では `ebcdic`）と解釈されます。

オプションリストに対する Unicode 処理 オプションリストに文字列を含めるときは特別な注意が必要です。なぜなら、それは UTF-16 形式の Unicode 文字列として表すことはできず、バイト列として表すことしかできないからです。そのため、Unicode のオプションに対しては UTF-8 が用いられます。オプションの先頭の BOM を見て、TET はそれをどう解釈するかを決めます。この BOM を用いて文字列の形式が判定されます。具体的には、文字列オプションの解釈動作は以下の通りです：

- ▶ オプションが UTF-8 BOM (`\xEF\xBB\xBF`) で始まっていると UTF-8 と解釈されます。
- ▶ オプションが EBCDIC UTF-8 BOM (`\x57\x8B\xAB`) で始まっていると EBCDIC UTF-8 と解釈されます。
- ▶ BOM がなければ文字列は *windows* (ただし EBCDIC ベースのプラットフォーム上では *ebcdic*) として扱われます。

注記 `TET_convert_to_unicode()` ユーティリティ関数を用いると、UTF-16 文字列を UTF-8 文字列に変換することができます。Unicode 値を持つオプションリストを作りたいときに便利です。

実行時に読み込まれる DLL として TET を使用 多くのクライアントでは TET を、リンク時に結合される静的結合ライブラリか動的ライブラリとして利用しますが、DLL を実行時に読み込んですべての API 関数へのポインタを動的に取得することも可能です。これはとりわけ、DLL を必要に応じてのみ読み込むために有用です。TET では、この動的な利用法を実現するために特化した機構を用意しています。これは以下の規則に従って動かせます (これは `extractordl.c` サンプルで演示されています) :

- ▶ `tetlib.h` でなく `tetlibdl.h` をインクルード。
- ▶ `TET_new()`・`TET_delete()` でなく `TET_new_dl()`・`TET_delete_dl()` を使用。
- ▶ `TET_TRY()`・`TET_CATCH()` でなく `TET_TRY_DL()`・`TET_CATCH_DL()` を使用。
- ▶ その他すべての TET 呼び出しに関数ポインタを使用。
- ▶ 追加モジュール `tetlibdl.c` をコンパイルして、生成されるオブジェクトファイルに自分のアプリケーションをリンク。

動的読み込みのしくみを `extractordl.c` サンプルで演示しています。

3.3 C++ バインディング

C++ 用のオブジェクト指向ラップが利用可能です。これは `tetlib.h` ヘッダファイルを必要とし、このヘッダファイルは `tetlib.h` をインクルードします。

C++ の文字列処理 TET のテンプレートベースの文字列処理アプローチでは、文字列処理に関して以下の使用パターンが使えます：

- ▶ C++ 標準ライブラリ型 `std::wstring` の文字列が基本文字列型として用いられます。これは、UTF-16 または UTF-32 で符号化された Unicode キャラクターを持つことができます。これはデフォルト動作であり、カスタムデータ型 (次項参照) が `wstring` に対して大きな利点を持たないかぎり、新しいアプリケーションに対して推奨されます。
- ▶ 文字列処理のためのカスタム (ユーザ定義) データ型を、そのカスタムデータ型が `basic_string` クラステンプレートのインスタンス化であり、かつユーザが与える変換メソッドによって Unicode との相互変換が可能であるかぎり、用いることができます。この技法は、`glyphinfo.cpp` サンプルの中で演示されています。

デフォルトインタフェースは、TET メソッドとやりとりされるすべての文字列がネイティブ `wstring` であると見なします。`wchar_t` データ型のサイズによって、`wstring` は UTF-16 で (2 バイトキャラクタ群)、または UTF-32 で (4 バイトキャラクタ群) 符号化された Unicode 文字列を内容として持つと見なされます。ソースコード内のリテラル文字列は、ワイド文字であることを示すために先頭に `L` をつける必要があります。リテラル内で Unicode キャラクターは `\u`・`\U` 文法で作成できます。

注記 EBCDIC ベースのシステムの場合、`wstring` ベースのインタフェースに対するオプションリスト文字列を作成する際には、オプションリスト内に EBCDIC と UTF-16 の `wstring` が混在することを防ぐため、さらに変換を行う必要があります。この変換に便利なコードと利用法が、追加モジュール `utf16num_ebcdic.hpp` にあります。ユーザーはコンパイラオプション `CONVLIT,(UNICODE)` も調べるべきです。このオプションは C++ コード内の文字列リテラルの Unicode への変換を制御します。

C++ のエラー処理 TET API メソッド群は、エラー発生時には C++ 例外を発生させます。これらの例外はクライアントコード内で C++ の `try/catch` 節を用いてキャッチする必要があります。さらなるエラー情報を提供するために、TET クラスはパブリックな `TET::Exception` クラスを提供しており、このクラスは、詳細なエラーメッセージ、例外番号、例外を発生させた TET API 関数の名前を取得するためのメソッドを公開しています。

TET メソッド群が発生させたネイティブな C++ 例外は期待どおりに動作します。以下のコードは、TET が発生させた例外をキャッチします：

```
try {
    TET tet
    ...TET命令群...
} catch (TET::Exception &ex) {
    wcerr << L"Error " << ex.get_errnum()
    << L" in " << ex.get_apiname()
    << L"(): " << ex.get_errmsg() << endl;
}
```

実行時に読み込まれる DLL として TET を利用 C++ バインディングでは、TET を実行時に動的に自分のアプリケーションにアタッチすることができます (29 ページの「実行時に読み込まれる DLL として TET を使用」を参照)。動的読み込みを有効にするには、`tet.hpp`

をインクルードするアプリケーションモジュールをコンパイルする時に下記のようにします：

```
#define TETCPP_DL 1
```

これに加えて、追加モジュール *tetlibdl.c* をコンパイルして、その結果できるオブジェクトファイルに自分のアプリケーションをリンクさせる必要があります(これは *extractordl* サンプルプロジェクトおよび Makefile ターゲットで演示されています)。動的読み込みの詳細は、TET オブジェクト内に隠蔽されていますので、C++ API には影響を与えません：すべてのメソッド呼び出しは、動的読み込みが有効になっているかどうかにかかわらず、同じ見た目になります。

3.4 COM バインディング

TET の COM エディションをインストール TET は COM コンポーネントに対応したすべての環境で利用することができます。TET のインストール方法は簡単で単純です。以下の点に留意して下さい：

- ▶ NTFS パーティションにインストールする場合は、すべての TET ユーザに、そのインストールディレクトリの読み取り権限と、...*TET 5.2 32-bit\bind\COM\bin\tet_com.dll* の実行権限を持たせる必要があります。
- ▶ インストーラはシステムレジストリに対して書き込み権限を持たなければなりません。Administrators グループか Power Users グループの権限であれば通常充分でしょう。

例外処理 TET の COM コンポーネントに対する例外処理は COM の規則に従って行われます。すなわち、TET の例外が起きると、COM の例外が発生し、そのエラーの説明テキストとともに伝達されます。この COM の例外は、そのクライアント環境が対応している任意の COM のエラー処理方式で捕捉・処理することができます。

3.5 Java バインディング

TET の Java エディションをインストール TET は *com.pdflib.TET* という名前で Java パッケージとしてまとめられています。このパッケージはネイティブ JNI ライブラリに依存しますので、両者は適切に設定しておく必要があります。

JNI ライブラリを可能にするために必要な操作は、以下のようにプラットフォームによって異なります：

- ▶ Unix システム群の場合には、*libtet_java.so* (macOS では *libtet_java.jnilib*) ライブラリを、共有ライブラリ用のデフォルトの場所、ないし適切に設定したディレクトリに置く必要があります。
- ▶ Windows の場合には、*tet_java.dll* ライブラリを、Windows のシステムディレクトリ、ないし PATH 環境変数に挙げたディレクトリに置く必要があります。

この TET Java パッケージはファイル *TET.jar* 内にあります。このパッケージを自分のアプリケーションで利用可能にするには、*TET.jar* を *CLASSPATH* 環境変数に追加するか、Java コンパイラへの呼び出しの中にオプション *-classpath TET.jar* を加えるか、またはこれと等価な操作を Java IDE で行う必要があります。JDK で Java VM の設定を行うことによって、ネイティブライブラリが所与のディレクトリ内で検索されるようにするには、*java.library.path* にそのディレクトリの名前を適切に設定します。たとえば

```
java -Djava.library.path=. extractor
```

このプロパティの値は下記のようにして調べられます：

```
System.out.println(System.getProperty("java.library.path"));
```

TET を J2EE アプリケーションサーバとサーブレットコンテナで使う TET はサーバサイド Java アプリケーションに完全に適合しています。TET ディストリビューションは、TET を J2EE 環境で使うためのサンプルコードと設定を含んでいます。以下の設定事項に従う必要があります：

- ▶ サーバがネイティブライブラリを検索するディレクトリはベンダによって異なります。よくある場所としては、システムディレクトリや、背後の Java VM に固有のディレクトリや、ローカルサーバディレクトリを候補に挙げることができます。サーバベンダが提供している説明書を調べて下さい。
- ▶ アプリケーションサーバとサーブレットコンテナはしばしば、特殊なクラスローダを用いており、そのクラスローダは制限されているか、あるいは専用のクラスパスを用いている可能性があります。サーバによっては、特別なクラスパスを定義して、TET パッケージを必ず見つけることができるようにしておくことが必要です。

TET を個別のサーブレットエンジンとアプリケーションサーバで使う際のより詳細な注意点は、TET ディストリビューションの J2EE ディレクトリ内の追加文書に記してあります。

Unicode とレガシエンコーディングの変換 TET ユーザの便宜のため、有用な文字列変換メソッドをここでいくつか挙げます。詳細は Java の文書を参照してください。

下記のコンストラクタは、プラットフォームのデフォルトエンコーディングを用いて、バイト列から Unicode 文字列を生成します：

```
String(byte[] bytes)
```

下記のコンストラクタは、*enc* 引数で与えたエンコーディング (*SJIS*・*UTF8*・*UTF-16* 等) を用いて、バイト列から Unicode 文字列を生成します：

```
String(byte[] bytes, String enc)
```

String クラスの下記のメソッドは、Unicode 文字列を、*enc* 引数で指定したエンコーディングに従った文字列へ変換します：

```
byte[] getBytes(String enc)
```

TET の Javadoc 文書 TET パッケージは TET の Javadoc 文書を含んでいます。この Javadoc は、すべての TET API メソッドの短縮された説明のみを含んでいます。詳しくは、167 ページの 10 章「TET ライブラリ API リファレンス」を参照してください。

TET の Javadoc を Eclipse で設定するには以下のように操作します：

- ▶ パッケージエクスプローラで Java プロジェクトを右クリックし、「*Javadoc* ロケーション」を選択します。
- ▶ 「ブラウズ ...」をクリックし、Javadoc が置かれているパス (TET パッケージ内) を選択します。

これらの操作を行なった後は、「*Java* ブラウズ」パースペクティブや「ヘルプ」メニューなどから TET の Javadoc を閲覧できます。

例外処理 TET の Java 言語バインディングはクラス *TETException* のネイティブな Java 例外を発生させます。TET のクライアントコードは標準的な Java 例外の文法を用いる必要があります：

```
try {
    tet = new TET();
    ...TET命令群...
} catch (TETException e) {
    System.err.println("TET例外が発生しました:");
    System.err.println("[ " + e.get_errnum() + " ] " + e.get_apiname() + ": " +
        e.get_errmsg());
} catch (Exception e) {
    System.err.println(e);
} finally {
    if (tet != null) {
        tet.delete();
    }
}
/* TETオブジェクトを削除 */
```

TET は適切な *throws* 節を宣言するので、クライアントコードはすべての可能な例外を捕捉するか、またはそれらを自身で宣言する必要があります。

3.6 .NET バインディング

3.6.1 .NET バインディングの種類

.NET のための TET バインディングには 2 つの種類があります：

- ▶ .NET Core バインディング：C# Interop に基づいています
- ▶ クラシック .NET バインディング：C++ Interop に基づいています

2 つの .NET バインディングは、表 3.1 に示すとおり、実装の詳細と対応ターゲット環境が異なっています。この情報をもとに、自分のアプリケーションに適したバインディングを選べます：

表 3.1 クラシック .NET バインディングと .NET Core バインディングの比較

	クラシック .NET バインディング： C++ Interop に基づいています	.NET Core バインディング： C# Interop に基づいています
ダウンロードパッケージ	Windows インストーラ	プラットフォームごとの zip または tar.gz パッケージ
パッケージ内容	アセンブリ・説明書・サンプル	アセンブリ・説明書・サンプルを含む NuGet パッケージ
実装	アンマネージドコードによる C++/CLI アセンブリ TET_dotnet.dll	マネージドコードによる C# アセンブリ TET_dotnet.dll と アンマネージドコードによる補助 DLL TET_dotnetcore_native.dll
.NET 統合	暗黙の PInvoke を通じた C++ Interop	明示的な PInvoke を通じた C# Interop
.NET Framework 対応	.NET Framework 4.x	.NET Framework 4.6.1 以上
.NET Core 対応	なし	.NET Standard 2.0
ターゲットオペレーティングシステム	Windows x86・x64	Windows x64・Linux x64・macOS
Windows レジストリの扱い	インストーラがレジストリに TET を登録しライセンスキーを追加	登録不要。ライセンスキーのためのレジストリエントリについては手作業で追加する必要あり
クラス名	TET_dotnet	TET_dotnet

3.6.2 .NET Core バインディング

.NET Core 版 TET は .NET Standard 2.0 に対応しており、これは .NET Core 2.0・.NET Framework 4.6.1・Mono 5.4 など多数の環境に対応していることを意味します。使いたいターゲットプラットフォームのための .NET Core SDK が必要です。

.NET Core バインディングのために用いられているバージョン方式は、.NET のバージョン規則に従っています。.NET Core のバージョン番号は、たとえば NuGet キャッシュや `.csproj` プロジェクトファイルの中で見ることができます。これらのバージョン番号は、TET のメジャー・マイナーリリース番号とは等しくありません。2 つのバージョン方式の間のマッピングは `compatibility.txt` にあります。

この製品は NuGet パッケージとして提供されており、以下のいずれかの方式を用いてローカルにインストールできます：

- ▶ `dotnet` コマンドラインツール（全プラットフォーム）。この方式については次項で詳しく説明します。

- ▶ Visual Studio のパッケージマネージャー UI (Windows・macOS)
- ▶ Visual Studio のパッケージマネージャーコンソール (Windows)
- ▶ *nuget* コマンドラインツール (全プラットフォーム)

提供しているサンプル群のためのプロジェクトファイル群はターゲットフレームワーク .NET Core 2.0 に対して作成されています (ターゲットフレームワークモニカ TFM=*netcoreapp2.0*)。別のフレームワークをターゲットしたい場合には、プロジェクトファイル内の TFM を調整するとよいでしょう。例：

```
<PropertyGroup>
  <OutputType>Exe</OutputType>
  <TargetFramework>netcoreapp3.0</TargetFramework>
</PropertyGroup>
```

dotnet コマンドラインツールを用いて .NET Core 版 TET をインストール *dotnet* ユーティリティを用いてインストール・構成・ビルドを行う過程を、提供している *extractor* プロジェクトを例にとりて説明します：

- ▶ 圧縮されている製品パッケージを、好きなディレクトリへ解凍します。
- ▶ コマンドシェル内で、*extractor* プロジェクトのディレクトリへ *cd*：

```
cd <installdir>\bind\dotnetcore\C#\extractor
```

- ▶ (提供しているサンプル群では、ローカルの *NuGet.Config* ファイルを用いてパッケージを参照していますので、このステップは不要です) アプリケーションのプロジェクトディレクトリへ NuGet パッケージを複製：

```
<installdir>/bind/dotnetcore/TET_dotnet.X.Y.Z.nupkg
```

- ▶ (提供しているサンプル群では、TET への参照をすでに含んでいますので、このステップは不要です) 以下のコマンドを、適切なバージョン番号とともに入力 (バージョン番号は、*.nupkg* ファイルの名前の中にあります)：

```
dotnet add package TET_dotnet X.Y.Z
```

このコマンドは TET 参照を *.csproj* プロジェクトファイルに追加します。かつこれは、ローカルの NuGet パッケージキャッシュに TET がまだ存在していなければインストールします。例：

```
~/.nuget/packages/tet_dotnet/X.Y.Z
```

このキャッシングがありますので、最初のプロジェクトにのみ *.nupkg* を複製する必要があります。その後のプロジェクト群では、パッケージはキャッシュから取られますので、パッケージを必要としません。

- ▶ これで、*extractor* プロジェクトをビルドして走らせてテストすることができます：

```
dotnet build
dotnet run -- TET-datasheet.pdf TET-datasheet.txt
```

その結果、アプリケーションディレクトリ内に **.txt* 出力ファイルが生成されます。

3.6.3 クラシック .NET バインディング

注記 クラシック .NET バインディングに関する詳しい情報が、ディストリビューションパッケージ内と PDFlib Web サイトにある PDFlib-in-.NET-HowTo.pdf 文書にあります。

クラシック .NET バインディングをインストール 提供しているWindowsインストーラを用いて TET をインストールします。このインストーラは、TET アセンブリと補足データファイル・サンプルを対話的にマシンにインストールします。このインストーラはまた、Visual Studio の「参照の追加」ダイアログボックスの .NET タブで TET を簡単に参照できるよう登録も行います。

C# プロジェクト内で .NET バインディングを参照 C# プロジェクト内で .NET バインディングを使用するには、Visual C# .NET で以下のように TET アセンブリへの参照を作成する必要があります：「プロジェクト」→「参照を追加 ...」→「参照 ...」→インストーレーションディレクトリから *TET_dotnet.dll* を選択。コマンドラインコンパイラを用いる場合には、以下の例のようにして TET を参照できます：

```
csc.exe /r:..\..\bin\TET_dotnet.dll extractor.cs
```

3.6.4 .NET バインディングを利用

この項は、両方の種類の .NET バインディングにあてはまります。すぐ使える構成を有する完全なサンプル群が、すべてのパッケージに含まれています。

ひとたび .NET バインディングが正しく参照された後は、*TET_dotnet.TET*・*TET_dotnet.TETException* クラスを使用できます。

エラー処理 .NET バインディングは .NET の例外に対応しており、実行時に問題が起ると例外を発生させ、詳細なエラーメッセージを伝達します。こうした例外を捕捉して適切にそれに対処することはクライアント側の領分です。それをしない場合には .NET Framework がその例外を捕捉し、多くの場合アプリケーションを中断させます。

例外関連情報の伝達のために TET は独自の例外クラス *TET_dotnet.TETException* を定義しています。このクラスはメンバ *get_errnum*・*get_errmsg*・*get_apiname* を持ちます。TET は *IDisposable* インタフェースを実装していますので、クライアントはクリーンアップのために *Dispose()* メソッドを呼び出すことができます。

クライアントコードは、TET によって投げられる .NET 例外を、通常の *try...catch* 構造を用いて処理できます：

```
try {
    tet = new TET();
    ...TET命令群...
} catch (TETException e) {
    // TETによって投げられる例外をキャッチ
    Console.WriteLine("エラー {0}、発生個所={1}(): {2}\n",
        e.get_errnum(), e.get_apiname(), e.get_errmsg());
} finally {
    if (tet != null) {
        tet.Dispose();
    }
}
```

3.7 Objective-C バインディング

C++ 言語バインディングを Objective-C で使用することもできますが、真正な Objective-C 用言語バインディングも用意してあります。下記の種類の TET フレームワークが利用可能です：

- ▶ macOS で利用するための *TET*
- ▶ iOS で利用するための *TET_ios*

いずれのフレームワークも、C++・Objective-C 用言語バインディングを含んでいます。

Objective-C 版 TET を macOS にインストール TET を自分のアプリケーションで使うには、*TET.framework* か *TET_ios.framework* をディレクトリ */Library/Frameworks* へコピーする必要があります。別の場所へ TET フレームワークをインストールすることも可能ですが、Apple の *install_name_tool* を用いる必要があります。それについてはここでは記述しません。TET メソッド宣言群を含んだ *TET_objc.h* ヘッドファイルをアプリケーションのソースコードで取り込む必要があります：

```
#import "TET/TET_objc.h"
```

または

```
#import "TET_ios/TET_objc.h"
```

TET フレームワークをアプリに埋め込むには、XCode のコード署名はフレームワークがバージョン番号 *A* を持つことを前提としていますが、PDFlib 製品は数値のバージョン番号を用いています。この問題を回避するには、以下のように適切に命名したフォルダを作成することができます：

```
cd TET.framework/Versions
mv 5.2 A
rm Current
ln -s A Current
```

引数命名規則 TET メソッド呼び出しの際には、引数を以下の規則に従って与える必要があります：

- ▶ 第一引数の値はメソッド名の直後に、コロンキャラクタで区切って与えます。
- ▶ その後の各引数については、引数の名前と値を（これもコロンキャラクタで互いを区切って）与える必要があります。引数の名前は 167 ページの 10 章「TET ライブラリ API リファレンス」と *TET_objc.h* にあります。

たとえば、API 記述における下記の行は：

```
int open_page(int doc, int pagenumber, String optlist)
```

下記の Objective-C となります：

```
-(NSInteger) open_page:(NSInteger) doc pagenumber:(NSInteger) pagenumber optlist:
(NSString *) optlist;
```

つまりアプリケーションでは、下記のように呼び出しを行う必要があることとなります：

```
page = [tet open_page:doc pagenumber:pageno optlist:pageoptlist];
```

コード補完のための Xcode Code Sense は TET フレームワークで利用できます。

Objective-C のエラー処理 Objective-C バインディングは、TET 例外を、ネイティブな Objective-C 例外へ翻訳します。実行時の問題の場合には、TET はクラス *TETException* のネイティブ Objective-C 例外を発生させます。これらの例外は通常の *try/catch* 機構で処理できます：

```
TET *tet = NULL;

@try {
    tet = [[TET alloc] init];
    ...TET命令群...
}
@catch (TETException *ex) {

    NSLog(@"エラー %ld、発生個所=%@(): %@\n",
          [ex get_errnum], [ex get_apiname], [ex get_errmsg]);
}
@catch (NSEException *ex) {

    NSLog(@"%@: %@", [ex name], [ex reason]);
}
@finally {
    if (tet)
        [tet release];
}
```

get_errmsg メソッドの他に、例外オブジェクトの *reason* フィールドを用いてエラーメッセージを取得することも可能です。

3.8 Perl バインディング

Perl 用 TET ラップは、1 個の C ラップと 2 個の Perl パッケージモジュールから成ります。このモジュールの一つは各 TET API 関数と同等のものを Perl で提供するもので、もう一つは TET オブジェクトのためのものです。C モジュールは、Perl インタプリタが実行時に読み込む共有ライブラリを、パッケージファイルからいくらかの助けを借りてビルドするために用いられます。Perl スクリプトは共有ライブラリモジュールを、`use` ステートメントを通じて参照します。

TET の Perl エディションをインストール Perl 拡張機構は共有ライブラリを実行時に、DynaLoader モジュールを通じて読み込みます。Perl 実行形式が、共有ライブラリに対応した形でコンパイルされている必要があります(多くの Perl 設定ではそのようになっています)。

TET バインディングが動作するためには、Perl インタプリタは TET Perl ラップとモジュール `tetlib_pl.pm`・`PDFlib/TET.pm` を利用可能である必要があります。以下に説明するプラットフォーム固有の方式のほかに、Perl の `@INC` モジュール検索パスに、`-I` コマンドラインオプションを用いてディレクトリを追加することも可能です：

```
perl -I/path/to/tet extractor.pl
```

Unix Perl は、`tetlib_pl.so` (macOS では `tetlib_pl.bundle`)・`tetlib_pl.pm`・`PDFlib/TET.pm` を、カレントディレクトリ内で、あるいは下記 Perl コマンドで印字されるディレクトリ内で検索します：

```
perl -e 'use Config; print $Config{sitearchexp};'
```

Perl はサブディレクトリ `auto/tetlib_pl` も検索します。上記コマンドの典型的出力は下記のようになります：

```
/usr/lib/perl5/site_perl/5.10/i686-linux
```

Windows DLL `tetlib_pl.dll` とモジュール `tetlib_pl.pm`・`PDFlib/TET.pm` が、カレントディレクトリ内で、あるいは下記 Perl コマンドで印字されるディレクトリ内で検索されます：

```
perl -e "use Config; print $Config{sitearchexp};"
```

上記コマンドの典型的出力は下記のようになります：

```
C:\Program Files\Perl5.16\site\lib
```

Perl の例外処理 TET 例外が発生した際には、Perl 例外が発生します。これは、`eval` シーケンスを用いてキャッチ・対処することができます：

```
eval {  
    my $tet = new PDFlib::TET;  
    ...TET命令群...  
};  
if ($@) {  
    die("$0: TET例外が発生しました:\n$@");  
}
```


3.9 PHP バインディング

注記 TET を PHP で利用する際のさまざまな考慮点やオプションに関する情報が、ディストリビューションパッケージ内に含まれている、PDFlib Web サイトからも入手できる *PDFlib-in-PHP-HowTo* 文書の中に含まれています。この文書は主に PDFlib の PHP での利用について論じていますが、その内容は TET の PHP での利用についてもあてはまるものです。

TET の PHP エディションをインストール TET は、PHP に動的に結合できる C ライブラリとして実装されています。TET は、PHP のいくつかのバージョンに対応しています。使っている PHP のバージョンに応じて、適切な TET ライブラリを、アンパックした TET アーカイブから選ぶ必要があります。

PHP の設定を行って、外部の TET ライブラリについて PHP に知らせる必要があります。次の 2 通りの方法があります：

- ▶ 以下の行のうちのいずれかを *php.ini* に追加する：

```
extension=php_tet.dll      ; Windowsの場合
extension=php_tet.so      ; Unix・macOSの場合
extension=php_tet.sl      ; HP-UXの場合
```

PHP は、Unix の場合は *php.ini* 内の変数 *extension_dir* で指定されたディレクトリ内で、Windows の場合はそれに加えて標準システムディレクトリ群の中でも、ライブラリを検索します。下記の一行 PHP スクリプトを用いれば、PHP TET バインディングのどのバージョンがインストールされているかを調べることができます：

```
<?phpinfo()?>
```

これを実行すると、現在の PHP の設定に関する長い情報ページが表示されます。このページ上で、*tet* というタイトルのセクションを見てください。もしこのセクションに

```
PDFlib TET Support      enabled
```

というフレーズ（および TET のバージョン番号）があれば、PHP 用の TET が正しくインストールされています。

- ▶ あるいは、スクリプトの冒頭に以下の行のうちのいずれかを書くことで、TET を実行時に読み込むこともできます：

```
dl("php_tet.dll");      # Windowsの場合
dl("php_tet.so");       # Unix・macOSの場合
dl("php_tet.sl");       # HP-UXの場合
```

PHP のファイル名処理 非限定のファイル名（パス要素のないもの）と相対ファイル名は、PHP の Unix バージョンと Windows バージョンとで扱いが異なります：

- ▶ Unix システムの PHP では、パス要素のないファイルは、スクリプトが読み込まれたディレクトリの中で検索されます。
- ▶ Windows の PHP では、パス要素のないファイルは、PHP DLL が読み込まれたディレクトリの中でのみ検索されます。

PHP の例外処理 PHP は構造化された例外処理に対応しているので、TET の例外は PHP の例外として発生します。通常の *try/catch* 技法を用いて、TET の例外を扱うことができます：

```
try {
    $tet = new TET();
```

...TET命令群...

```
} catch (TETException $e) {
    print "TET例外が発生しました:\n";
    print "[" . $e->get_errnum() . "]" " . $e->get_apiname() . ": "
        $e->get_errmsg() . "\n";
}
catch (Exception $e) {
    print $e;
}
```

Eclipse と Zend Studio を用いた開発 PHP Development Tools (PDT) は、Eclipse と Zend Studio を用いた PHP 開発に対応しています。PDT は、以下に説明する手順によって、コンテキスト依存ヘルプに対応するよう構成することも可能です：

TET がすべての PHP プロジェクトに知られるよう、TET を Eclipse 環境設定に追加：

- ▶ 「ウィンドウ」 → 「設定」 → 「PHP」 → 「ソースパス」 → 「ライブラリー」 → 「新規 ...」を選択することによってウィザードを起動します。
- ▶ 「ユーザー・ライブラリー名」の中に *TET* と入力し、「外部フォルダーの追加 ...」をクリックして、フォルダ *bind\php\Eclipse PDT* を選択。

既存または新規の PHP プロジェクトの中で、この TET ライブラリへの参照を以下のように追加できます：

- ▶ PHP エクスプローラー内で PHP プロジェクトを右クリックし、「インクルード・パス」 → 「インクルード・パスの構成 ...」を選択。
- ▶ 「ライブラリー」タブへ移動し、「ライブラリーの追加 ...」をクリックして、「ユーザー・ライブラリー」 → 「*TET*」を選択。

これらの手順が済めば、TET メソッドの一覧を、PHP エクスプローラービューの中の PHP インクルード・パス /TET/TET ノードの下で見ることができます。新たな PHP コードを書く際に、Eclipse が、すべての TET メソッドについて、コード補完とコンテキスト依存ヘルプを用いて支援します。

3.10 Python バインディング

Python 版 TET をインストール Python の拡張機構は、実行時に共有ライブラリを読み込むことによって動作します。TET バインディングが動作するためには、Python インタプリタが TET Python ラップアを利用可能である必要があります。このラップアは、PYTHONPATH 環境変数内に挙げられているディレクトリ群の中で検索されます。Python ラップアの名前はプラットフォームによって異なります：

- ▶ Unix・macOS : *tetlib_py.so*
- ▶ Windows : *tetlib_py.pyd*

TET ライブラリに加えて、このライブラリがある場所と同じディレクトリの中で、以下のファイルが利用可能である必要があります：

- ▶ PDFlib/TET.py
- ▶ PDFlib/_init_.py (Python 2.7 の場合のみ)

Python のエラー処理 Python バインディングは、エラー発生時に *TETException* を投げます。この Python 例外は、通常の try/except 技法で扱えます：

```
try:
    tet = TET()
    ...TET命令群...

except TETException as ex:
    print("エラー %d、発生箇所=%s(): %s" % (ex.errnum, ex.apiname, ex.errmsg))

except Exception as ex:
    print(ex)

finally:
    if tet:
        tet.delete()
```

3.11 Ruby バインディング

Ruby 版 TET をインストール Ruby の拡張機構は、共有ライブラリを実行時に読み込むことによって動作します。TET バインディングが動作するためには、Ruby インタプリタが Ruby 用 TET 拡張ライブラリへのアクセスを有する必要があります。このライブラリ (Windows・Unix の場合：*TET.so*、macOS の場合：*TET.bundle*) がインストールされる先は通常、local ruby インストールディレクトリの *site_ruby* ブランチ内であり、すなわち下記のような名前のディレクトリ内になります：

```
/usr/local/lib/ruby/site_ruby/<バージョン>/
```

しかし、Ruby は他のディレクトリでも拡張を検索します。このディレクトリの一覧を取得するには下記の ruby 呼び出しを用います：

```
ruby -e "puts $:"
```

この一覧は通常、カレントディレクトリを含みますので、試験目的には、TET 拡張ライブラリとスクリプト群を同一ディレクトリ内に置けばよいでしょう。

Ruby のエラー処理 Ruby バインディングは、TET 例外をネイティブな Ruby 例外へ翻訳するエラーハンドラをインストールします。この Ruby 例外は通常の *rescue* 技法で扱えます：

```
begin
  tet = TET.new
  ...TET命令群...
rescue TETException => pe
  print pe.backtrace.join("\n") + "\n"
  print "エラー [" + pe.get_errnum.to_s + "]" + pe.get_apiname + ": " + pe.get_errmsg
  print " 発生ページ= pageno" if (pageno != 0)
  print "\n"
rescue Exception => e
  print e.backtrace.join("\n") + "\n" + e.to_s + "\n"
ensure
  tet.delete() if tet
end
```

Ruby on Rails Ruby on Rails は、Ruby による Web 開発を支援するオープンソースフレームワークです。Ruby 用 TET 拡張は Ruby on Rails で使えます。TET 作成例を Ruby on Rails で走らせるには以下の手順に従います：

- ▶ Ruby と Ruby on Rails をインストール。
- ▶ 新規コントローラをコマンドラインからセットアップ：

```
$ rails new tetdemo
$ cd tetdemo
$ cp <TETディレクトリ>/bind/ruby/<バージョン>/TET.so vendor/ # .so/.dll/.bundleを使用
$ cp <TETディレクトリ>/bind/data/TET-datasheet.pdf .
$ rails generate controller home demo
$ rm public/index.html
```

- ▶ *config/routes.rb* を編集：

```
...
# public/index.htmlの削除を忘れないように
root :to => "home#demo"
```

- ▶ `app/controllers/home_controller.rb`を以下のように編集して、PDF内容を抽出するためのTETコードを挿入します。出発点として `extractor-rails.rb` サンプルのコードを利用できます：

```
class HomeController < ApplicationController
  def demo
    require "TET"
    begin
      p = TET.new
      doc = tet.open_document(infile, docoptlist)
      ...TETアプリケーションコード、extractor-rails.rb参照...
      ...
      # そして抽出したテキストを最後に表示
      send_data text, :type => "text/plain", :disposition => "inline"
      rescue TETException => pe
      # エラー処理
    end
  end
end
```

- ▶ 自分のインストレーションをテストするには、下記コマンドでWEBrickサーバを開始させ、

```
$ rails server
```

ブラウザで `http://0.0.0.0:3000` を表示させます。PDF 文書から抽出されたテキストがブラウザに表示されます。

TET をローカルにインストール TET を Ruby on Rails でのみ利用したい場合で、TET を Ruby 全体で利用できるようグローバルにインストールすることができないときは、Rails ツリー内の `vendors` ディレクトリ内に TET をローカルにインストールすることも可能です。これはとりわけ、全体で利用できる Ruby 拡張をインストールする権限を有していないけれども TET を Rails で利用したいときに有用です。

3.12 RPG バインディング

TET は、TET 関数群を埋め込んで ILE-RPG プログラム群をコンパイルするために必要なすべてのプロトタイプといくつかの有用な定数を定義する */copy* モジュールを提供しています。

Unicode 文字列処理 TET 関数はすべて可変長の Unicode 文字列を引数として用いますので、*%ucs2* ビルトイン関数を用いてシングルバイト文字列を Unicode 文字列へ変換する必要があります。TET 関数が返す文字列はすべて可変長の Unicode 文字列です。この Unicode 文字列をシングルバイト文字列へ変換するには *%char* ビルトイン関数を用います。

注記 *%CHAR*・*%UCS2* 関数は、カレントジョブの CCSID を用いて Unicode との文字列相互変換を行います。TET とともに提供されている作成例は、CCSID 37 (US EBCDIC) をベースとしています。このコードページは、*CHGJOB CCSID(37)* を用いて設定できます。他のコードページでこれらの作成例を走らせた場合には、オプションリスト内のいくつかの特殊キャラクタ ([[]] 等) が正しく翻訳されない可能性があります。

文字列はすべて可変長文字列として渡されますので、明示的な文字列長をとる関数に *length* 引数を渡してはいけません (可変長文字列の長さは文字列の先頭 2 バイトに格納されています)。

TET に対する RPG プログラムをコンパイル・バインド RPG で TET の関数を利用するには、コンパイルされた TET サービスプログラムが必要です。TET の定義群をコンパイル時にインクルードするには、ILE-RPG プログラムの *D* スペック内でその名前を指定する必要があります：

```
d/copy QRPGLSRC,TETLIB
```

TET のソースファイルライブラリがライブラリリストのトップにない場合は、ライブラリも指定する必要があります：

```
d/copy tetsrcLib/QRPGLSRC,TETLIB
```

ILE-RPG プログラムのコンパイルの際には、開始前にバインディングディレクトリを作成し、そこに TET 付属の TETLIB サービスプログラムを入れておく必要があります。たとえば、ライブラリ TETLIB の中に TETLIB というバインディングディレクトリを作成したいときは、次のように指定します：

```
CRTBNDDIR BNDDIR(TETLIB/TETLIB) TEXT('TETlib Binding Directory')
```

バインディングディレクトリを作成したら、TETLIB サービスプログラムをバインディングディレクトリに追加する必要があります。たとえば、ライブラリ TETLIB の中のサービスプログラム TETLIB を、さきに作成したバインディングディレクトリに追加したいときは、次のように指定します：

```
ADDBNDDIRE BNDDIR(TETLIB/TETLIB) OBJ((TETLIB/TETLIB *SRVPGM))
```

そして、*CRTBNDRPG* コマンドを用いて (または PDM でオプション 14 を用いて) プログラムをコンパイルすれば完了です：

```
ADDLIBLE LIB(TETLIB)
CRTBNDRPG PGM(TETLIB/EXTRACTOR) SRCFILE(TETLIB/QRPGLSRC) SRCMBR(*PGM) DFACTGRP(*NO)
BNDDIR(TETLIB/TETLIB)
```

RPGのエラー処理 ILE-RPG で書かれた TET クライアントは、ILE-RPG が提供する *monitor/on-error/endmon* エラー処理機構を利用することができます。例外を見張るもう一つの方法は、ILE-RPG 内の *PSSR グローバルエラー処理サブルーチンを用いることです。例外が発生した際には、ジョブログは、エラー番号、失敗した関数、例外の理由を示します。TET は、呼び出し側プログラムへエスケープメッセージを送ります。

```
c   eval      p=TET_new
*
c   monitor
*
c   callp     TET_set_option(tet:globaloptlist)
c   eval      doc=TET_open_document(tet:%ucs2(%trim(parm1)):docoptlist)
:
:
*   Error Handling
c   on-error
*   Do something with this error
*   don't forget to free the TET object
c   callp     TET_delete(tet)
c   endmon
```



4 TET コネクタ

TET コネクタは、TET を他のソフトウェアとインタフェースするために必要なグルーコードを提供します。TET コネクタは、TET ライブラリか TET コマンドラインツールをベースにしています。

4.1 Adobe Acrobat 用無償 TET Plugin

この節では、Adobe Acrobat での試験と、任意の PDF 文書との TET の対話的使用のために利用できる TET の無償入手可能なパッケージングである TET Plugin を説明します。TET Plugin は、Acrobat X ~ DC Standard・Pro・Pro Extended で動作します（ただし Acrobat Reader では動作しません）。これは下記の場所から無償でダウンロードできます：

www.pdflib.com/products/tet-plugin

TET Plugin とは TET Plugin は、TET へのシンプルな対話的アクセスを提供します。TET Plugin は Acrobat のプラグインとして動作しますが、背後の内容抽出機能は Acrobat の機能を使わず、完全に TET をベースとしています。TET Plugin は、PDFlib TET のパワーを演示する無償ツールとして提供されています。TET は Acrobat 内蔵のテキスト・画像抽出ツールよりも強力で、多くの便利なユーザインタフェース機能も提供していますので、Acrobat 内蔵のコピー・検索機能のかわりとして有用です。テキストを抽出しようとしたときに、Acrobat ならただのゴミしか返さないような場合でも、PDFlib TET なら多くの文書をうまく処理することができます。TET Plugin は以下の機能を提供しています：

- ▶ PDF 文書内のテキストを、システムのクリップボードかディスクファイルへ複製。
- ▶ PDF を TETML に変換して、それをクリップボードかディスクファイルに入れます。
- ▶ XMP 文書メタデータをクリップボードへ複製。
- ▶ 文書内の単語を検索。
- ▶ ページ上の検索文字列をすべて同時にハイライト。
- ▶ 文書内の画像を、TIFF・JPEG・JPEG 2000・JBIG2 のいずれかのファイルとして抽出。
- ▶ 画像の色空間・位置情報を表示。
- ▶ 必要に応じてテキスト・画像抽出を調整するための詳細な設定が利用可能です。設定セットは保存して再読込することも可能です。

Acrobat のコピー機能にまさっている点 TET Plugin は、Acrobat 内蔵のコピー機能に対していくつかまさっている点があります：

- ▶ 出力を、さまざまなアプリケーションの要請に合わせてカスタマイズすることができます。
- ▶ Acrobat がゴミだけをクリップボードへ複製する場合にも、TET は多くの場合においてテキストを正しく解釈することができます。
- ▶ 未知のグリフ（正しい Unicode マッピングが確立できないもの）は赤色でハイライトされ、ユーザが選んだキャラクタ（クエスチョンマーク等）で置き換え可能です。
- ▶ TET は文書を Acrobat よりずっと速く処理します。
- ▶ 書き出す画像群を対話的に選ぶこともできますし、ページ内または文書内のすべての画像を抽出することもできます。
- ▶ 微小な画像素片を結合して、利用可能な画像にします。
- ▶ タグ付き PDF 内のページ装飾（本文外のテキスト・画像）は、専用の色でハイライトされ、簡単に見分けることができます。

4.2 Lucene 検索エンジン用 TET コネクタ

Lucene はオープンソースの検索エンジンです。Lucene は本来 Java プロジェクトですが、.NET 用バージョンも利用可能です。Lucene について詳しくは lucene.apache.org を参照してください。

注記 暗号化文書は、特定の条件下では *shrug* オプションでインデックスできます（詳しくは、63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照）。これは Connector ファイル群の中で用意されますが、このオプションを手作業で有効にする必要があります。

要件とインストール TET ディストリビューションは、Lucene Java で PDF インデクシングを可能にするために利用できる TET コネクタを含んでいます。以下、この Lucene Java 用コネクタについて詳しく説明します。以下の要件が満たされていることが前提です：

- ▶ Lucene 8.x.x に対し Java 8。
- ▶ Ant ビルドツールが動作するようインストールされている。
- ▶ Lucene コア JAR ファイルを持つ Lucene ディストリビューション。TET とともに配布される Ant ビルドファイルはファイル *lucene-core-x.x.x.jar*・*lucene-analyzers-common-x.x.x.jar*・*lucene-queryparser-x.x.x.jar* を前提しています。このファイルは Lucene ディストリビューションに含まれています。
- ▶ Unix・Linux・macOS・Windows いずれか用の TET 配布パッケージがインストールされている。

Lucene 用 TET コネクタを実装するには、コマンドプロンプトで以下の操作を行います：

- ▶ ディレクトリ `<TET インストールディレクトリ>/connectors/lucene` へ移動。
- ▶ ファイル *lucene-core-x.x.x.jar*・*lucene-analyzers-common-x.x.x.jar*・*lucene-queryparser-x.x.x.jar* をこのディレクトリへ複製。
- ▶ グローバルな、あるいは文書関連・ページ関連の TET オプションを *TetReader.java* に追加することによって設定をカスタマイズすることもできます。たとえば、グローバルなオプションリストを用いて、リソースへの正しい *searchpath* を与えることが可能です（日中韓 CMap がデフォルトインストールと異なるディレクトリにインストールされている場合等に）。
PdfDocument.java モジュールは、ディスクファイルかメモリバッファ（Web クローラによって与えられた等）に格納されている PDF 文書を処理する方法を演示しています。
- ▶ コマンド *ant index* を実行。これはソースコードをコンパイルし、`<TET インストールディレクトリ>/bind/data` ディレクトリ内に含まれる PDF ファイル群に対してインデクサを走らせます。
- ▶ コマンドライン検索を開始するには、コマンド *ant search* を実行します。ここでは、Lucene クエリ言語でクエリを入力できます。

TET と Lucene をコマンドライン検索クライアントでテスト 以下のサンプルセッションは、TET と Lucene でインデクシングを行い、生成されたインデックスを Lucene コマンドラインクエリツールでテストする場合のコマンドと出力を演示しています。この操作はコマンド *ant index* を実行することから始まります：

```
amira (1)$ ant index
Buildfile: build.xml
...
index:
    [echo] Indexing PDF files in directory ".././bind/data"
    [java] adding .././bind/data/Whitepaper-Technical-Introduction-to-PDFA.pdf
```

```
[java] adding ../../bind/data/Whitepaper-XMP-metadata-in-PDFlib-products.pdf
[java] adding ../../bind/data/PDFlib-datasheet.pdf
[java] adding ../../bind/data/TET-datasheet.pdf
[java] 662 total milliseconds
```

```
BUILD SUCCESSFUL
Total time: 1 second
```

```
amira (1)$ ant search
Buildfile: build.xml
```

```
compile:
```

```
search:
```

```
[java] Enter query:
PDFlib
[java] Searching for: pdflib
[java] 4 total matching documents
[java] 1. ../../bind/data/PDFlib-datasheet.pdf
[java] Title: PDFlib, PDFlib+PDI, Personalization Server data sheet
[java] Font : PDFlibLogo-Regular
[java] Font : TheSans-Plain
...
[java] 2. ../../bind/data/Whitepaper-XMP-metadata-in-PDFlib-products.pdf
[java] Title: Whitepaper: XMP Metadata support in PDFlib products
[java] Font : PDFlibLogo-Regular
[java] Font : TheSansLight-Italic
...
[java] 3. ../../bind/data/Whitepaper-Technical-Introduction-to-PDFA.pdf
[java] Title: Whitepaper: A Technical Introduction to PDF/A
[java] Font : PDFlibLogo-Regular
[java] Font : TheSansLight-Italic
...
[java] 4. ../../bind/data/TET-datasheet.pdf
[java] Title: PDFlib TET datasheet
[java] Subject: PDFlib TET extracts text, images, and metadata from PDF documents
[java] Font : TheSans-Plain
[java] Font : PDFlibLogo-Regular
...
[java] Press (q)uit or enter number to jump to a page.
```

```
q
```

```
[java] Enter query:
title:XMP
[java] Searching for: title:xmp
[java] 1 total matching documents
[java] 1. ../../bind/data/Whitepaper-XMP-metadata-in-PDFlib-products.pdf
[java] Title: Whitepaper: XMP Metadata support in PDFlib products
[java] Font : PDFlibLogo-Regular
[java] Font : TheSansLight-Italic
```

```
...
```

2つのクエリが実行されています：1つはテキスト内の単語 *PDFlib* に対して、もう1つは *title* フィールド内の単語 *XMP* に対してです。結果ページングモードを抜けて次のクエリを始められるようにするには *q* を入力する必要があります点に留意してください。

Ant *build.xml* ファイル内のパスとファイル名はすべて、プロパティを通じて定義されています。これは、このファイルをさまざまな環境で使えるようにするためです。すなわち、プロパティ群をコマンドラインで与えることもできますし、上書きさせたいプロパティ群をファイル *build.properties* 内に、あるいはプラットフォーム個別のプロパティをファイル *windows.properties* か *unix.properties* 内に記入することもできます。たとえば、Ant を下記のように呼び出せば、*/tmp* 下にインストールされている Lucene JAR ファイルでサンプルを実行することができます：

```
ant -Dlucene-core.jar=/tmp/lucene-core-x.x.x.jar -Dlucene-analyzers-common.jar=/tmp/lucene-analyzers-common-x.x.x.jar -Dlucene-queryparser.jar=/tmp/lucene-queryparser-x.x.x.jar index
```

メタデータフィールドをインデックス Lucene 用 TET コネクタは以下のメタデータフィールドをインデックスします：

- ▶ *path* (*StringField*)：文書のパス名
- ▶ *modified* (*DateLongField*)：最終更新日 (PDF メタデータからではなく PDF ファイルのタイムスタンプから採られます)
- ▶ *contents* (*ReaderTextField*)：文書の全テキスト内容
- ▶ Title・Subject・Author 等、定義済み・カスタムの PDF 文書情報項目すべて。文書情報項目は、TET に内蔵されている pCOS インタフェースで取得することができます (pCOS について詳しくは pCOS パスリファレンスを参照してください)。たとえば

```
String objType = tet.pcos_get_string(tetHandle, "type:/Info/Subject");
if (!objType.equals("null")) {
    doc.add(new TextField("summary",
        tet.pcos_get_string(tetHandle, "/Info/Subject"),
        Field.Store.YES));
}
```

- ▶ *font*：PDF 文書内のすべてのフォントの名前

PdfDocument.java 内で、インデックスする文書情報項目のセットを変更、あるいは pCOS に基づいて情報を追加することによって、メタデータフィールドをカスタマイズすることも可能です。

PDF ファイル添付 Lucene 用 TET コネクタは、文書内のすべての PDF ファイル添付を再帰的に処理し、各添付のテキストとメタデータをインデックスできるよう Lucene 検索エンジンに与えます。これによって、検索テキストがメイン文書内になく添付内にあるときでも、検索ヒットが生成されます。再帰的添付横断はとりわけ、PDF パッケージ・ポートフォリオに対して重要です。

4.3 Solr 検索サーバ用 TET コネクタ

Solr は高パフォーマンスなオープンソースのエンタプライズ検索サーバで、Lucene 検索ライブラリをベースとしています。XML/HTTP・JSON/Python/Ruby API を有し、ヒットハイライト・ファセット検索・キャッシュ化・レプリケーション・Web 管理インタフェースをそなえています。Java サーブレットコンテナ内で動作します (lucene.apache.org/solr を参照)。

Solr は Lucene コアエンジンを取り巻く追加レイヤとしてふるまいます。インデックスされたデータをシンプルな XML 形式で受け付けます。Solr 入力は TETML をベースに非常に簡単に生成できます。TETML は TET が生成する一種の XML です。Solr 用 TET コネクタは、TETML を Solr が受け付ける XML 形式へ変換する XSLT スタイルシートから成ります。このスタイルシートのための TETML 入力は、TET ライブラリか TET コマンドラインツールで生成できます (141 ページの 9.1 「TETML を生成」を参照)。

注記 暗号化文書は、特定の条件下では *shrug* オプションでインデックスできます (詳しくは、63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照)。暗号化文書をインデックスするには、Solr のための TETML 入力を生成する際に、TET ライブラリか TET コマンドラインツールでこのオプションを有効にする必要があります。

メタデータフィールドをインデックス Solr 用 TET コネクタは、すべての標準文書情報フィールドをインデックスします。各フィールドのキーがフィールド名として用いられます。

PDF ファイル添付 Solr 用 TET コネクタは、文書内のすべての PDF ファイル添付を再帰的に処理し、各添付のテキストとメタデータをインデックスできるよう検索エンジンに与えます。これによって、検索テキストがメイン文書内になく添付内にあるときでも、検索ヒットが生成されます。再帰的添付横断はとりわけ、PDF パッケージ・ポートフォリオに対して重要です。

TETML を変換するための XSLT スタイルシート *solr.xsl* スタイルシートは、*glyph* 以外の任意のモードの TETML 入力を受け付けます。これは、検索サーバに入力データを与えるために必要な XML を生成します。文書情報項目群は、その情報項目の名前 (に文字列値であることを示す *_s* 接尾辞をつけたもの) を保持したフィールドとして与えられ、メインテキストは多数のテキストフィールドで与えられます。文書内の PDF 添付 (PDF パッケージ・ポートフォリオを含む) は再帰的に処理されます：

```
<?xml version="1.0" encoding="UTF-8"?><add>
<doc>
<field name="id">TET-datasheet.pdf</field>
<field name="Author_s">PDFlib GmbH</field>
<field name="CreationDate_s">2015-08-04T23:45:46+02:00</field>
<field name="Creator_s">Adobe InDesign CS6 (Windows)</field>
<field name="ModDate_s">2015-08-04T23:45:46+02:00</field>
<field name="Producer_s">Adobe PDF Library 10.0.1</field>
<field name="Subject_s">PDFlib TET: Text and Image Extraction Toolkit (TET)</field>
<field name="Title_s">PDFlib TET datasheet</field>
<field name="text">PDFlib</field>
<field name="text">datasheet</field>
<field name="text">PDFlib</field>
<field name="text">TET</field>
<field name="text">5</field>
...
```

4.4 Oracle 用 TET コネクタ

Oracle 用 TET コネクタは、TET を Oracle データベースに結合して、PDF 文書を Oracle Text でインデックスレクエリできるようにします。PDF 文書は、データベース内のそのパス名を通じて参照することもできますし、データベース内に BLOB として直接格納することもできます。

注記 暗号化文書は、特定の条件下では *shrug* オプションでインデックスできます（詳しくは、63 ページの 5.1「暗号化 PDF から内容を抽出」を参照）。これは Connector ファイル群の中で用意されますが、このオプションを手作業で有効にする必要があります。

要件とインストール TET コネクタは Oracle 10i と Oracle 11g でテストされています。TET コネクタを利用するためには、データベースを作成する際に **AL32UTF8** データベース文字集合を指定する必要があります。これは、Oracle Express の Universal 版ではつねにそうなります（しかし Western European 版では異なります）。AL32UTF8 は Oracle が推奨しているデータベース文字集合であり、TET で PDF 文書をインデックスする場合にも最良の動作をします。ただし、以下の方式のいずれかに従えば、他の文字集合で TET を Oracle Text に接続することも可能です：

- ▶ Oracle Text 11.1.0.7 からは、必要な文字集合変換をデータベースが行えます。下記にある Oracle Text 11.1.0.7 文書の「Using USER_FILTER with Charset and Format Columns」節を参照してください：

docs.oracle.com/cd/B28359_01/text.11/b28304/cdatadic.htm#sthref497

- ▶ Oracle Text 11.1.0.6 までは、TET フィルタスクリプトが生成する UTF-8 テキストをデータベース文字集合へ変換する必要があります。これは、文字集合変換コマンドを *tetfilter.sh* に追加することによって実現できます：

Unix : *iconv* (オープンソースソフトウェア) か *uconv* (無償の ICU Unicode ライブラリに含まれています) を呼び出します。

Windows : *tetfilter.bat* 内の適切なコードページコンバータを呼び出します。

Oracle 用 TET コネクタを活用できるようにするには、以下のようにして TET フィルタスクリプトを Oracle から利用可能にする必要があります：

- ▶ TET フィルタスクリプトを、Oracle がそれを見つけることができるディレクトリへ複製：

Unix : *connectors/Oracle/tetfilter.sh* を *\$ORACLE_HOME/ctx/bin* へ複製

Windows : *connectors/Oracle/tetfilter.bat* を *%ORACLE_HOME%\bin* へ複製

- ▶ TET フィルタスクリプト (それぞれ *tetfilter.sh*・*tetfilter.bat*) 内の *TETDIR* 変数が必ず TET インストールディレクトリを指しているようにします。
- ▶ 必要に応じて、追加の TET オプション群を、グローバル・文書レベル・ページレベルのいずれかについて *TETOPT*・*DOCOPT*・*PAGEOPT* 変数内で与えることもできます (オプションリストについて詳しくは、167 ページの 10 章「TET ライブラリ API リファレンス」を参照)。これは特に TET ライセンスキーを与えるために有用です。例：

```
TETOPT="license=aaaaaaa-bbbbbb-cccccc-dddddd-eeeeee"
```

TET ライセンスキーを与えるための他の選択肢については 8 ページの 0.2「TET ライセンスキーを適用」を参照してください。

Oracle ユーザに権限を付与 以下の例はいずれも、Oracle ユーザがインデックスを作成レクエリする適切な権限を持っていることを前提としています。以下のコマンド群は、

ユーザ *HR* に適切な権限群を付与します（これらのコマンドは、*system* として発行する必要があります、かつ適切に調整する必要があります）：

```
SQL> GRANT CTXAPP TO HR;
SQL> GRANT EXECUTE ON CTX_CLS TO HR;
SQL> GRANT EXECUTE ON CTX_DDL TO HR;
SQL> GRANT EXECUTE ON CTX_DOC TO HR;
SQL> GRANT EXECUTE ON CTX_OUTPUT TO HR;
SQL> GRANT EXECUTE ON CTX_QUERY TO HR;
SQL> GRANT EXECUTE ON CTX_REPORT TO HR;
SQL> GRANT EXECUTE ON CTX_THES TO HR;
```

例 A : PDF 文書のパス名をデータベースに格納 この例は、インデックスされた PDF 文書群へのファイル名参照をデータベース内に格納します。以下のように操作します：

- ▶ コマンドプロンプトで下記のディレクトリへ移動：

```
<TETインストレーションディレクトリ>/connectors/Oracle
```

- ▶ *tetsetup_a.sql* スクリプト内の *tetpath* 変数を、TET がインストールされているディレクトリを指すように変えます。
- ▶ データベースを用意:Oracle の *sqlplus* プログラムを使って、テーブル *pdftable_a* を作成し、このテーブルに PDF 文書群のパス名を記入し、インデックス *tetindex_a* を作成します（なお、*tetsetup_a.sql* スクリプトの内容は若干プラットフォーム依存です。パス文法が異なるためです）：

```
SQL> @tetsetup_a.sql
```

- ▶ データベースを、インデックスを用いてクエリ：

```
SQL> select * from pdftable_a where CONTAINS(pdffile, 'Whitepaper', 1) > 0;
```

- ▶ インデックスを更新（文書を追加した後に必要です）：

```
SQL> execute ctx_ddl.sync_index('tetindex_a')
```

- ▶ データベースをクリーンアップ（インデックスとテーブルを削除）することもできます：

```
SQL> @tetcleanup_a.sql
```

例 B : PDF 文書を BLOB としてデータベースに格納してメタデータを追加 この例は、PDF 文書本体を BLOB としてデータベースに格納します。PDF データに加えて、いくつかのメタデータを pCOS インタフェースで抽出し、それ用のデータベース列に格納します。*tet_pdf_loader* Java プログラムは、PDF 文書群を BLOB としてデータベースに格納します。メタデータ処理を演示するため、このプログラムは、pCOS インタフェースを用いて、文書タイトル（pCOS パス */Info/Title* を通じて）と文書内のページ数（pCOS パス *length:pages* を通じて）を抽出します。この文書タイトルとページ数はデータベース内の別コラムに格納されます。この例を動作させるには以下のように操作します：

- ▶ コマンドプロンプトで下記のディレクトリへ移動：

```
<TETインストレーションディレクトリ>/connectors/Oracle
```

- ▶ データベースを用意:Oracle の *sqlplus* プログラムを使って、テーブル *pdftable_b* とそのインデックス *tetindex_b* を作成します：

```
SQL> @tetsetup_b.sql
```

- ▶ データベースに内容を入れます: このテーブルに、JDBC を通じて PDF 文書とメタデータを入れます (これはストアドプロシージャではできない点に留意)。TET パッケージとともに供給されている ant ビルドファイルは、Oracle JDBC ドライバに対する **ojdbc14.jar** ファイルが **tet_pdf_loader.java** ソースコードと同じディレクトリにあると前提しています。適切な JDBC 接続文字列を **ant** コマンドで指定します。このビルドファイルは、すべてのプロパティの記述を含んでおり、これを用いて Ant ビルドのオプション群を指定することができます。これらのオプションに対する値をコマンドラインで与えることができます。下記の例では、ホスト名として **localhost**、ポート番号 1521、データベース名として **xe**、ユーザ名・パスワードとして **HR** を用いています (自分のデータベース設定に合わせて適切に変えてください) :

```
ant -Dtet.jdbc.connection=jdbc:oracle:thin:@localhost:1521:xe ←  
-Dtet.jdbc.user=HR -Dtet.jdbc.password=HR
```

- ▶ インデックスを更新 (最初と、文書を追加した後に必要です) :

```
SQL> execute ctx_ddl.sync_index('tetindex_b')
```

- ▶ データベースを、インデックスを用いてクエリ :

```
SQL> select * from pdftable_b where CONTAINS(pdffile, 'Whitepaper', 1) > 0;
```

- ▶ データベースをクリーンアップ (インデックスとテーブルを削除) することもできます :

```
SQL> @tetcleanup_b.sql
```


4.5 Microsoft 製品用 TET PDF IFilter

この節では、PDFlib TET をベースとして構築された別製品である TET PDF IFilter を説明します。TET PDF IFilter の詳しい情報と配布パッケージは www.pdflib.com/products/tet-pdf-ifilter で入手可能です。

TET PDF IFilter は、非商用デスクトップ用途については無償で利用可能です。デスクトップシステム上での商用利用とサーバ上での展開には商用ライセンスが必要です。

PDFlib TET PDF IFilter とは TET PDF IFilter は、PDF 文書からテキストとメタデータを抽出し、それを Windows 上の検索ソフトウェアで利用可能にします。これによって、PDF 文書をローカルデスクトップや企業サーバ、あるいは Web で検索することが可能になります。TET PDF IFilter は、特許を受けた PDFlib Text Extraction Toolkit (TET) をベースとしています。TET は、PDF 文書からテキストを抽出するための定評ある開発者向け製品です。

TET PDF IFilter は、Microsoft の IFilter インデクシングインタフェースの堅牢な実装です。これは SharePoint や SQL Server 等、IFilter インタフェースに対応しているすべての検索製品とともに動作します。そうした製品は HTML 等、特定のファイル形式に対する形式個別のフィルタプログラムを用いており、このフィルタプログラムを IFilter と呼びます。TET PDF IFilter はそのようなプログラムの一つで、PDF 文書に特化したものです。文書を検索するためのインタフェースは、Windows Explorer や Web やデータベースのフロントエンドであってもよいですし、クエリスクリプトやカスタムアプリケーションとすることもできます。対話的検索だけでなく、ユーザインタフェース一切なしでクエリをプログラマ的に発することもできます。

特長 TET PDF IFilter は以下の利点を提供します：

- ▶ 欧文テキスト、日本語・中国語・韓国語（日中韓）テキスト、アラビア文字・ヘブライ文字等の右書き言語に対応。
- ▶ しおり・注釈（コメント）・フォームフィールドからのテキスト。
- ▶ 暗号化文書をインデックスし、また、Acrobat が失敗する PDF からもテキストを抽出。
- ▶ 文書プロパティに対するメタデータインデクシングを構成可能。
- ▶ 自動用字系・言語検出による検索向上。

エンタプライズ PDF 検索 TET PDF IFilter は、スレッドセーフな 32・64 ビット版として利用可能です。TET PDF IFilter と、以下のような IFilter インタフェースに対応しているすべての Microsoft またはサードパーティー製品を用いて、エンタプライズ PDF 検索ソリューションを実装できます：

- ▶ Microsoft SharePoint Server
- ▶ Microsoft Search Server
- ▶ Microsoft SQL Server
- ▶ Microsoft Exchange Server
- ▶ Microsoft Site Server

デスクトップ PDF 検索 TET PDF IFilter を利用すると、たとえば Windows に内蔵されている Windows Search とともにデスクトップ PDF 検索を実装することも可能です。TET PDF IFilter は、デスクトップオペレーティングシステム上での非商用利用については無償ですので、気軽にテストや評価を行うことができます。

受け入れ可能な PDF 入力 TET PDF IFilter は、あらゆる種類の PDF 入力に対応していません：

- ▶ Acrobat DC までのすべての PDF バージョン (ISO 32000-1・ISO 32000-2 も含め)
- ▶ 文書を開くパスワードを必要としない暗号化 PDF
- ▶ 破損した PDF 文書は修復されます。

国際化 欧文テキストに加えて、TET PDF IFilter は日本語・中国語・韓国語 (日中韓) テキストに完全対応しています。すべての日中韓エンコーディングが認識されます。横書き・縦書きに対応しています。テキストのロケール ID (言語・地域識別子) の自動検出が、Microsoft の単語区切り・語幹処理アルゴリズムの結果を向上させ、このことはとりわけ東アジアテキストについて重要です。

ヘブライ文字・アラビア文字といった右書き言語にも対応しています。位置依存表示形は正規化され、テキストは論理順に発出されます。

PDF は単なるページの寄せ集めではない TET PDF IFilter は PDF 文書を、単なるページ群だけの他にも多くの情報を含む可能性のあるコンテナとして扱います。TET PDF IFilter は PDF 文書内の関連するエントリをすべてインデックスします：

- ▶ ページ内容
- ▶ しおり・注釈 (コメント)・フォームフィールド内のテキスト
- ▶ メタデータ (後述)
- ▶ 埋め込まれた PDF と PDF パッケージ / ポートフォリオは、埋め込まれているすべての PDF 文書内のテキストが検索できるよう、再帰的に処理されます。

XMP メタデータと文書情報 TET PDF IFilter の高度なメタデータ実装は、Windows のメタデータのためのプロパティシステムに対応しています。これは XMP メタデータと、標準・カスタム文書情報項目をインデックスします。メタデータインデクシングはいくつかのレベルで設定できます：

- ▶ 文書情報項目群と Dublin Core フィールド群、およびその他の広く用いられる XMP プロパティ群は、Windows シェルプロパティへマップされます。例：*Title*・*Subject*・*Author*。
- ▶ TET PDF IFilter は、有用な PDF 独自のプロパティ群を追加します。例：ページサイズ・PDF/A 準拠レベル・フォント名。
- ▶ すべての定義済み XMP プロパティ群をインデックスできます。
- ▶ ユーザ定義の XMP または PDF ベースのプロパティ群を検索できます。例：企業独自の分類プロパティ、電子署名、ZUGFeRD 準拠。

TET PDF IFilter は、メタデータを全文テキストインデックス内に統合することもできます。結果として、メタデータ対応を持たない全文テキスト検索エンジン (SQL Server 等) であっても、メタデータの検索が可能になります。

Unicode 後処理 TET PDF IFilter はさまざまな Unicode 後処理に対応しており、これを利用して検索結果を向上させることができます：

- ▶ 字形統合：キャラクタに対して温存・除去・置換のいずれかを行います。たとえば句読点や、無関係な用字系のキャラクタを除去することができます。
- ▶ 分解：一つのキャラクタを、等価な他のキャラクタないしキャラクタ列へ置き換えます。たとえば漢字を、それと正準等価な Unicode キャラクタへ置き換えることができます。

4.6 Apache TIKA ツールキット用 TET コネクタ

TIKA は、オープンソースの「既存のパーサライブラリを用いてさまざまな文書からメタデータ・構造化テキスト内容を検出・抽出するためのツールキット」です。TIKA の詳細については tika.apache.org を参照してください。Tika 用 TET コネクタは、Tika に設定されているデフォルトの PDF パーサを置き換え、TET を PDF 形式用のパーサとして接続します。TET コネクタは以下の項目を Tika に与えます：

- ▶ 全ページの非整形のテキスト内容
- ▶ 定義済み・カスタムの文書情報フィールド群
- ▶ 文書のページ数

注記 暗号化文書は、特定の条件下では *shrug* オプションでインデックスできます（詳しくは、63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照）。これは Connector ファイル群の中で用意されますが、このオプションを手作業で有効にする必要があります。TETPDFParser.java ではこれに加えて、*shrug* オプションでは不足の場合にパスワードを与える方法を提供しています。

要件とインストール TET ディストリビューションは、Tika ツールキット用 TET コネクタを含んでいます。以下の説明において `<tet-dir>` は、TET パッケージをアンパックしたディレクトリを意味します。下記の要件を満たす必要があります：

- ▶ JDK 1.5 以降
- ▶ *Ant* ビルドツールの動作中のインストール
- ▶ Unix・Linux・macOS・Windows いずれか用のインストール済み TET ディストリビューションパッケージ。
- ▶ 名前 *tika-app-1.x.jar* の Tika 用プレビルト JAR ファイル。このファイルのためのダウンロード情報は下記の場所にあります：
tika.apache.org/download.html

一般に Tika 1.8 以上を使用できます。ただし Tika 1.9 には、内蔵の PDF パーサをオーバーライドできないバグがあります。ですので TET コネクタを Tika 1.9 とともに使用できるのは、Tika のソースコードに何らかの調整を加えた場合か、あるいは Tika XML 構成ファイルのような機構を用いた場合のみです。

Tika 用 TET コネクタをビルドしてテスト Tika 用 TET コネクタをビルドしてテストするには以下の手順に従います：

- ▶ *tika-app-1.x.jar* をディレクトリ `<tet-dir>/connectors/Tika` へコピー。
- ▶ `<tet-dir>/connectors/Tika` へ移動し、Tika 用 TET コネクタをビルド：

```
ant
```

Tika jar ファイルの名前が *tika-app-1.0.jar* でないときは、jar ファイル名をコマンドラインで与える必要があります：

```
ant -Dtika-app.jar=tika-app-1.x.jar
```

- ▶ ビルドファイルは、Tika 用 TET コネクタでのテストを走らせるターゲットを含んでいます：

```
ant test
```

このコマンドは、テスト文書の内容を XHTML として標準出力に生成するはずですが、自分の選んだ PDF ファイルでテストを行うには、下記のように Ant プロパティ `test.inputfile` をコマンドラインで与えます：

```
ant -Dtest.inputfile=/自分の/ファイル/への/パス.pdf test
```

暗号化文書にパスワードを与える機能については下記のようにテストできます：

```
ant -Dtest.inputfile=<暗号化ファイル.pdf> -Dtest.outputfile=<出力ファイル名> ←  
-Dtest.password=<パスワード> api-test
```

- ▶ Tika用TETコネクタが実際にMIMEタイプ `application/pdf` に対して用いられるかどうかを検証するには、`<tet-dir>/connectors/Tika` ディレクトリで、Unix・macOS システムの場合は下記コマンドを実行します：

```
java -Djava.library.path=<tet-dir>/bind/java -classpath ←  
<tet-dir>/bind/java/TET.jar:tika-app-1.x.jar:tet-tika.jar ←  
org.apache.tika.cli.TikaCLI --list-parser-details
```

Windows の場合：

```
java -Djava.library.path=<tet-dir>/bind/java -classpath ←  
<tet-dir>/bind/java/TET.jar;tika-app-1.x.jar;tet-tika.jar ←  
org.apache.tika.cli.TikaCLI --list-parser-details
```

生成出力内に下記記述が現れるはずですが：

```
com.pdflib.tet.tika.TETPDFParser  
application/pdf
```

- ▶ Tika GUIアプリケーションをTETコネクタとともに動作させるには、ディレクトリ `<tet-dir>/connectors/Tika` で下記コマンドを実行します：

Unix・macOS システムの場合：

```
java -Djava.library.path=<tet-dir>/bind/java -classpath ←  
<tet-dir>/bind/java/TET.jar:tika-app-1.x.jar:tet-tika.jar ←  
org.apache.tika.cli.TikaCLI
```

Windows の場合：

```
java -Djava.library.path=<tet-dir>\bind\java -classpath ←  
<tet-dir>\bind\java\TET.jar;tika-app-1.x.jar;tet-tika.jar ←  
org.apache.tika.cli.TikaCLI
```

Tike 用 TET コネクタをカスタマイズ Tikeコネクタは、`TETPDFParser.java` ソースモジュール内で下記のようにカスタマイズすることもできます：

- ▶ `DOC_OPT_LIST` 変数に文書オプション群を追加。例：shrug オプションで暗号化文書を処理。
- ▶ `PAGE_OPT_LIST` 変数にページオプション群を追加。
- ▶ `SEARCHPATH` 変数で、日中韓 CMap などのリソースへの検索パスをカスタマイズ。あるいは、PDF 文書を処理する際に `tet.searchpath` プロパティを与えることもできます。

4.7 MediaWiki 用 TET コネクタ

MediaWiki は無償の Wiki ソフトウェアであり、Wikipedia をはじめとする多くのコミュニティ Web サイトを動作させるために利用されています。MediaWiki に関する詳しい情報は下記にあります：

www.mediawiki.org/wiki/MediaWiki

注記 暗号化文書は、特定の条件下では *shrug* オプションでインデックスできます（詳しくは、63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照）。これは Connector ファイル群の中で用意されますが、このオプションを手作業で有効にする必要があります。

要件とインストール TET ディストリビューションは、MediaWiki サイトへアップロードされる PDF 文書をインデックスするために利用できる TET コネクタを含んでいます。MediaWiki はネイティブに PDF 文書に対応はしていませんが、PDF を「画像」としてアップロードすれば受け付けます。MediaWiki 用 TET コネクタは、すべての PDF 文書を、それがアップロードされる際にインデックスします。MediaWiki 内にすでに存在している PDF 文書はインデックスされません。以下の必要条件を満たしている必要があります：

- ▶ MediaWiki 1.25 以上
- ▶ Unix・Linux・macOS・Windows のいずれか用の TET バインディングを含む TET 配布パッケージ

MediaWiki 用 TET コネクタを実装するには以下の操作を行います：

- ▶ PHP 用 TET バインディングを、41 ページの 3.9 「PHP バインディング」の説明のようにインストール。
- ▶ ディレクトリ `<TET インストールディレクトリ>/connectors/MediaWiki` からファイル群を `<MediaWiki インストールディレクトリ>/extensions/PDFIndexer` へ複製。
- ▶ 日中韓テキストへの対応が必要な場合は、`<TET インストールディレクトリ>/resource/cmap` 内の CMap ファイル群を `<MediaWiki インストールディレクトリ>/extensions/PDFIndexer/resource/cmap` へ複製。
- ▶ MediaWiki 設定ファイル `LocalSettings.php` に以下の行群を追加：

```
# アップロードされるPDFをインデックスして検索可能にします
wfLoadExtension( 'PDFIndexer' );
```

MediaWiki 用 TET コネクタはどのように動作するか MediaWiki 用 TET コネクタは、PHP モジュール `PDFIndexer.php` から成ります。これは MediaWiki の定義済みフックの一つを用いて、新規 PDF 文書がアップロードされる際にいつも呼び出されるようフックアップされます。これは PDF 文書からテキストとメタデータを抽出して、それを、アップロードされる文書にオプションに付属する、ユーザが与えるコメントの後に追加します。このテキストは、ユーザが文書コメントを表示する際に表示されないよう、HTML コメント内に隠されています。MediaWiki はコメントの内容全文をインデックスします（隠されている全文テキストも含めて）ので、PDF のテキスト内容もインデックスされます。インデックス用テキストは以下のように構築されます：

- ▶ TET コネクタは、すべての標準・カスタム文書情報フィールドのキー・値をインデックスへ与えます。
- ▶ すべてのページのテキスト内容が抽出されて結合されます。
- ▶ 抽出されたテキストのサイズが制限未満であれば、それはまるごとインデックスへ与えられます。この方式の利点は、検索結果が検索語を文脈の中で表示する点です。

- ▶ 抽出されたテキストのサイズが制限を超えている場合は、テキストはユニークな単語群へ減量されます（すなわち、同一の単語が複数回出現しているものについて、その単語を 1 回だけに減量されます）。
- ▶ 減量したテキストのサイズが制限未満であれば、それはインデックスへ与えられます。そうでない場合には、それは切り落とされます。すなわち、その文書の終わりのほうのテキストはインデックスされなくなります。

この制限は、`$wgMaxArticleSize` 構成変数から採られます。この変数のデフォルトは 2048 KB です。上記のサイズテストの一つが制限に触れた場合には、MediaWiki のログ記録が有効にされているならば、警告メッセージが MediaWiki の *DebugLogFile* へ書き込まれます。

PDF 文書を検索 PDF 文書群を検索するには、*Advanced Search* ダイアログの中の名前空間の一覧の中の *File* チェックボックスを有効化する必要があります。

検索結果は、検索語を含む文書の一覧を表示します。テキスト全文がインデックスされている場合（文書が長くて単語リストへ減量された場合ではなく）には、検索語の前後にいくつかの語が表示されて文脈を示します。PDF テキスト内容は MediaWiki インデックスに HTML 形式で与えられますので、テキストの頭に行番号が表示されます。これらの行番号は PDF 文書については意味がありませんので、無視できます。

メタデータフィールドをインデックス MediaWiki 用 TET コネクタは、すべての標準・カスタム文書情報フィールドをインデックスします。各フィールドのキー・値が、検索で利用できるよう、インデックスへ与えられます。MediaWiki はメタデータベースの検索に対応していませんので、文書情報項目を直接検索することはできず、全文テキストの一部としてのみ情報項目を検索できます。

5 設定

5.1 暗号化 PDF から内容を抽出

PDF のセキュリティ機能 PDF 文書は、以下の保護機能を提供するパスワードセキュリティによって保護することができます：

- ▶ ファイルを開いて閲覧するためにユーザパスワード（開くパスワードともいいます）が必要。
- ▶ 権限群やユーザ／マスタパスワードといったセキュリティ設定群のうちのいずれかを変更するためにマスタパスワード（所有者／権限パスワードともいいます）が必要。ユーザパスワードとマスタパスワードのあるファイルは、いずれかのパスワードを与えれば開いて閲覧できます。
- ▶ PDF 文書に対する印刷やテキスト抽出といった特定のアクションを権限設定が制限。
- ▶ 添付パスワードを与えて、文書自体の内容ではなくファイル添付だけを暗号化可能。

PDF 文書がこれらの保護機能のうちのいずれかを用いているとき、それは暗号化されます。文書のセキュリティ設定を Acrobat で表示または変更するには、「ファイル」→「プロパティ ...」→「セキュリティ」→それぞれ「詳細を表示 ...」「設定を変更 ...」をクリックします。

TET は PDF 権限設定に従います。dumper サンプルで演示しているように、パスワードと権限設定を、pCOS パス `encrypt/master · encrypt/user · encrypt/nocopy` 等で取得することができます。pCOS は `pcosmode` 擬似オブジェクトも提供しており、これを用いると、特定の文書についてどの操作が許されているかを知ることができます。

内容抽出ステータス デフォルトでは、文書をうまく開くことができたなら、TET によるテキストと画像の抽出は可能になります (`TET_open_document()` の `requiredmode` オプションを与えた場合にはこの限りではありません)。`nocopy` 権限設定によって、制限 pCOS モードでの内容抽出が許されるか否かが決まります (フル pCOS モードでは内容抽出はつねに許されます)。以下の条件を用いれば、内容抽出が許されているかどうかを調べることができます：

```
if ((int) tet.pcos_get_number(doc, "encrypt/nocopy") == 0)
{
    /* 内容抽出は許されている */
}
```

暗号化文書を処理する必要 PDF 権限設定は、文書作成者がその内容の作成者としての権利を強制することを支援し、PDF 文書の利用者は、テキスト・画像内容を抽出する際にはその文書作成者の権利を尊重する必要があります。デフォルトでは、TET は制限モードで動作し、そのような暗号化文書からいかなる内容をも抽出することを拒否します。しかし、内容抽出はあらゆる場合においてただちに作成者の権利の侵害を構成するわけではありません。内容抽出が許可能な状況として以下のような場合が挙げられます：

- ▶ 少量の内容を引用目的で抽出する場合（「フェアユース」）。
- ▶ 組織に出入りする文書の中に特定のキーワードがないかを調べたい（文書スクリーニング）かもしれません。それを超える内容の再利用は行いません。
- ▶ 文書作成者自身がマスタパスワードを紛失したかもしれません。

- ▶ 検索エンジンが暗号化文書をインデックスする場合。その文書内容をユーザに直接利用可能にはしません（元の PDF へのリンクを示すことによって間接的にのみ利用可能とします）。

最後の例がとりわけ重要です：利用者が暗号化 PDF の内容抽出を許されていない場合であっても、企業内検索や Web ベース検索でその文書を見つけ出すことは可能であるべきです。抽出したテキストを利用者に直接利用可能とせず、文書を見つけ出せるよう検索エンジンのインデックスに供するためにのみ用いるならば、内容を抽出することは許されるでしょう。利用者は元の暗号化 PDF をのみ利用可能となりますので（検索エンジンが内容をインデックスしてヒットリストが PDF へのリンクを含んだ後には）、利用者がその PDF を利用する際には、その文書の内部権限設定が通常通りその文書を保護することになります。

暗号化文書に対する「シュラッグ」機能 TET は、TET ユーザが文書作成者の権利を尊重することについて責任を受け入れる前提のもとに、暗号化文書からテキストと画像を抽出するために利用できる機能を提供しています。この機能は**シュラッグ**と呼ばれ、次のように動作します：*TET_open_document()* に *shrug* オプションを与えることによって、ユーザは、自身がいかなる文書作成者の権利をも侵害する意志を持たないことを言明します。PDFlib GmbH の取引条件は、TET のお客様が PDF 権限設定を尊重するべきであると定めています。

以下のすべての条件が真であるとき、**シュラッグ**機能は有効化されます：

- ▶ *TET_open_document()* に *shrug* オプションが与えられている。
- ▶ 文書がマスタパスワードを必要としているが、それが *TET_open_document()* に与えられていない。
- ▶ 文書がユーザ（文書を開く）パスワードを必要としている場合には、それが *TET_open_document()* に与えられている必要があります。
- ▶ 文書の権限設定でテキスト抽出が許されていない、すなわち *nocopy=true*。

シュラッグ機能は以下の効力を持ちます：

- ▶ *nocopy=true* であっても文書からの内容抽出が許されます。ユーザは文書作成者の権利を尊重する責任を負います。
- ▶ pCOS 擬似オブジェクト *shrug* が *true/1* に設定されます。
- ▶ pCOS がフルモードで動作します（制限モードではなく）。すなわち *pcosmode* 擬似オブジェクトが 2 に設定されます。

shrug 擬似オブジェクトを下記の形に従って用いれば、内容をユーザに直接利用可能としてよいか、それともインデックスすることやその類の間接的用途にのみ利用するべきかを決定することができます：

```
int doc = tet.open_document(filename, "shrug");
...
if ((int) tet.pcos_get_number(doc, "shrug") == 1)
{
    /* インデックスすることのみ許される */
}
else
{
    /* 内容をユーザに渡してもよい */
}
```


5.2 リソース設定とファイル検索

UPR ファイルとリソースカテゴリ 場合によっては TET は、エンコーディング定義やグリフ名マッピングテーブルといったリソースの場所を知って利用する必要があります。リソースの取り扱いをプラットフォームに依存せずかつカスタマイズ可能なものにするために、設定ファイルを与えてそこに利用可能なリソース群とそれぞれのディスクファイル名を記述することができます。静的な設定ファイルだけでなく、`TET_set_option()` を用いてリソースを追加することにより動的な設定も行うことが可能です。設定ファイルに関しては、*Unix PostScript Resource* (UPR) というテキスト形式が用いられます。TET で用いられる形の UPR ファイル形式を以下に説明します。TET は、表 5.1 に挙げるリソースカテゴリに対応しています。

表 5.1 リソースカテゴリ (ファイル名はすべて UTF-8 で指定する必要がある)

カテゴリ	形式 ¹	説明
cmap	キー = 値	CMap のリソース名とファイル名
codelist	キー = 値	コードリストのリソース名とファイル名
encoding	キー = 値	エンコーディングのリソース名とファイル名
glyphlist	キー = 値	グリフリストのリソース名とファイル名
glyphmapping	オプションリスト	193 ページの表 10.9 に従ってグリフマッピング方式を記述したオプションリスト。このリソースは <code>TET_open_document()</code> 内で評価され、その結果は、 <code>TET_open_document()</code> のオプション <code>glyphmapping</code> で指定されたマッピングの後に追加されます。
hostfont	キー = 値	埋め込まれていないフォントに対して用いるべきホストフォントリソースの名前 (キーは PDF フォント名。値は UTF-8 エンコーディングによるホストフォント名)
fontoutline	キー = 値	埋め込まれていないフォントに対して用いるべき TrueType フォントまたは OpenType フォントのフォントとファイル名
searchpath	値	データファイル群を含むディレクトリの相対パスまたは絶対パス

1. UPR 文法では等号「=」を名前と値の間に必要としますが、`set_option()` でリソースを指定する際はこのキャラクタは必要なく、かつ入れてはいけません。

UPR ファイル形式 PDF ファイルは非常に簡単な構造を持ったテキストファイルであり、テキストエディタで書いたり自動的に生成させたりすることが容易にできます。まずはその文法について見てみましょう：

- ▶ 1 行に書けるのは最長 255 キャラクタまでです。
- ▶ バックスラッシュ「\」は行末キャラクタをエスケープします。これは行を延長するのに使えます。
- ▶ ピリオド「.」だけの行はセクションの終了を示します。
- ▶ 注釈行はパーセント「%」で始めることができ、行末で終了します。
- ▶ 空白は無視されます。ただしリソース名とファイル名の中の空白は無視されません。

UPR ファイルは以下の構成要素でできています：

- ▶ ファイルを識別させるための魔法行。以下の形をとります。

PS-Resources-1.0

- ▶ ファイル内に記述されるすべてのリソースカテゴリを列挙したセクション。各行にリソースカテゴリを1つずつ記述します。この列挙はピリオド1つの行によって終了します。
- ▶ ファイル冒頭で列挙された各リソースカテゴリごとにセクション1つずつ。各セクションの先頭行でリソースカテゴリを示し、その後に、利用可能なリソースを記述した行を何行でも列挙することができます。この列挙はピリオド1つの行によって終了します。各リソースデータ行にはリソースの名前を書きます（等号はクオートではさむ必要があります）。リソースがファイル名を必要とする場合は、その名前を等号の後に加える必要があります。リソースエントリ内に列挙されたファイルを TET が検索する際には *searchpath*（後述）が適用されます。

UPR ファイルの記述例 以下に UPR 設定ファイルの記述例を示します：

```
PS-Resources-1.0
searchpath
glyphlist
codelist
encoding
.
searchpath
/usr/local/lib/cmaps
/users/kurt/myfonts
.
glyphlist
myglyphlist=/usr/lib/sample.gl
.
codelist
mycodelist=/usr/lib/sample.cl
.
encoding
myencoding=sample.enc
.
```

ファイル検索と *searchpath* リソースカテゴリ 絶対パスや相対パスだけでなく、パス指定を一切つけずにファイル名を TET に与えることもできます。 *searchpath* リソースカテゴリを用いれば、必要なデータファイル群を含むディレクトリのパス名を列挙指定することができます。ファイルを開く必要があるとき、TET はまず与えられた通りのファイル名を用いてファイルを開こうとします。それが失敗すると、TET は *searchpath* リソースカテゴリに指定されたディレクトリの中でファイルを開こうと試み、1つのディレクトリで失敗すれば次の指定ディレクトリを試し、成功するまで次々と試していきます。複数の *searchpath* エントリは蓄積させることが可能で、逆順に検索されます（後で設定したパスが、前に設定したパスよりも先に検索されます）。この検索を行わせたくないときは、TET 関数でフルパスを指定します。

Windows の場合、TET は *searchpath* リソースカテゴリを、以下のレジストリキーから読んだ値で初期化します：

```
HKLM\SOFTWARE\PDFlib\TET5\5.2\SearchPath
HKLM\SOFTWARE\PDFlib\TET5\SearchPath
HKLM\SOFTWARE\PDFlib\SearchPath
```

これらのレジストリエントリは複数のパスをセミコロン「;」で区切って持つことができます。Windows インストーラは、この *SearchPath* レジストリエントリを、TET インストールディレクトリ内の *resource* ディレクトリの名前で初期化します。

注記 64ビット Windows システム上で手作業でレジストリを操作する際には注意が必要です。通常、64ビットバイナリは Windows レジストリの 64ビットビューとともに動作するのに対して、64ビットシステム上で走る 32ビットバイナリはレジストリの 32ビットビューとともに動作します。32ビット製品に対するレジストリキーを手作業で追加する必要がある場合には、必ず、*regedit* ツールの 32ビットバージョンを使用してください。これは「スタート」→「ファイル名を指定して実行 ...」ダイアログから下記のように呼び出すことができます：

```
%systemroot%\syswow64\regedit
```

デフォルトファイル検索パス Unix・Linux・macOS・i5/iSeries システムの場合、パス・ディレクトリ名を何も指定しなくてもいくつかのディレクトリでファイルが検索されます。UPR ファイル（これがさらに検索パスを含む場合もあります）を検索して読み取る前に、以下のディレクトリが検索されます：

```
<rootpath>/PDFlib/TET/5.2/resource/cmap  
<rootpath>/PDFlib/TET/5.2/resource/codelist  
<rootpath>/PDFlib/TET/5.2/resource/glyphlst  
<rootpath>/PDFlib/TET/5.2/resource/fonts  
<rootpath>/PDFlib/TET/5.2/resource/icc  
<rootpath>/PDFlib/TET/5.2  
<rootpath>/PDFlib/TET  
<rootpath>/PDFlib
```

Unix・Linux・macOS の場合 *<rootpath>* は、まず */usr/local* で、ついで HOME ディレクトリで置き換えられます。i5/iSeries の場合 *<rootpath>* は空です。

ライセンス・リソースファイルのデフォルトファイル名 デフォルトでは、下記のファイル名がデフォルト検索パスディレクトリ群内で検索されます：

licensekeys.txt	(ライセンスファイル)
pdflib.upr	(リソースファイル)

この機能を利用すれば、ライセンスファイルを、環境変数や実行時オプションを何も設定せずに扱うことができます。

UPR リソースファイルを検索 リソースファイルを用いる必要がある場合には、*TET_set_option()* を呼び出してそれを指定することもできますし（後述）、または UPR リソースファイルで指定することもできます。TET はこのファイルを、初めてのリソースが要求された時点で自動的に読み込みます。具体的には以下のように処理されます：

- ▶ **TETRESOURCEFILE** 環境変数が定義されている場合、TET はその値を、読み込むべき UPR ファイルの名前として採用します。そのファイルが読み込めなかったときは例外が発生します。
- ▶ **TETRESOURCEFILE** 環境変数が定義されていない場合、TET は以下の名前のファイルを開こうとします：

```
upr (MVSの場合。データセットが期待される)  
tet.upr (Windows・Unix、その他すべてのシステムの場合)
```

このファイルが読み込めなかったときに例外は発生しません。

- ▶ Windows の場合、TET はさらに以下のレジストリエントリをも読もうとします：

```
HKLM\SOFTWARE\PDFlib\TET\5.2\resourcefile
```

このキーの値 (TET のインストーラはこのキーを作成して値 <インストールディレクトリ>/tet.upr を与えますが、手作業で設定することもできます) は、使用するべきリソースファイルの名前を与えます。このファイルが読み込めなかったときは例外が発生します。

- ▶ クライアント側で実行時に TET に強制してリソースファイルを読み込ませるには、次のように *resourcefile* オプションを明示的に設定します：

```
set_option("resourcefile=/パス/です/tet.upr");
```

この呼び出しは何回でも繰り返すことができます。リソースエントリが蓄積されます。

リソースを実行時に設定 設定のために UPR ファイルを用いるだけでなく、*TET_set_option()* を用いて個々のリソースを直接設定することも可能です。この関数は、リソースカテゴリ名と、対応するリソース名・値の対 (複数可) とを、UPR リソースファイル内のそのカテゴリのセクションに書くのと同じ形で受け入れます。たとえば：

```
set_option("glyphlist={myglyphnames=/usr/local/glyphnames.g1}");
```

1つのオプションリストの中で、1つのリソースカテゴリオプションに対する複数のリソース名を設定することも可能です (ただし *TET_set_option()* への1度の呼び出しの中で、同じリソースカテゴリオプションを複数回繰り返すことはできません)。あるいは、複数回呼び出してリソース設定を蓄積させることもできます。

テキストファイルでのエスケープシーケンス エスケープシーケンスは、UPR ファイルと CMap ファイル以外のすべてのテキストファイル内で使用できます。特殊なキャラクタシーケンスを用いると、テキストファイル内に印字不能キャラクタを含めることができます。すべてのシーケンスはバックスラッシュ「\」キャラクタで始まります：

- ▶ *\x* は 2 桁の 16 進数 (*0 ~ 9*、*A ~ F*、*a ~ f*) を開始します。例：*\x0D*
- ▶ *\nnn* は 3 桁の 8 進数 (*0 ~ 7*) を表します。例：*\015*。シーケンス *\000* は無視されます。
- ▶ シーケンス ** は 1 個のバックスラッシュを表します。
- ▶ 行末のバックスラッシュは行末キャラクタをキャンセルします。

5.3 代表的シナリオのための推奨方策

TETにはさまざまなオプションがあり、それらを活用することで、操作のさまざまな面を制御することが可能です。この項では、TETの典型的な応用シナリオについて、いくつかの推奨方策を示します。以下でふれる関数やオプションについて詳しくは、167ページの10章「TETライブラリAPIリファレンス」を参照して下さい。

速度を最適化 場合によっては、とくに検索エンジンのためにPDFをインデックスする際には、テキスト抽出の速度が最重要であり、最適出力を得ることよりも優先されます。TETのデフォルト設定は、可能なかぎり最良の出力が得られるように選択されていますが、処理を速めるように調整することも可能です。`TET_open_page()`・`TET_open_document()`でオプションを選ぶことによりテキスト抽出のスループットを最大化する方法をいくつか挙げます：

▶ `docstyle=searchengine`

このページオプションは、検索エンジンのためのインデックス処理に影響を及ぼさないやり方で処理を減らすことによって動作を高速化するようにいくつかの内部パラメータをセットアップします。

▶ `engines={image=false textcolor=false vector=false}`

画像抽出とテキストカラー検出が必要ない場合、動作を高速化するために内部処理ステップ群をこの文書オプションで無効化できます。ベクトルエンジンは、クリッピング演算と、表組み検出の向上のためには必要です。

▶ `contentanalysis={merge=0}`

このページオプションは、時間のかかるストリップと区域の結合ステップを無効にするもので、代表的なファイルに対する処理時間を非常に低減します。ただし、内容がページ上に任意の順序でばらまかれているような文書では、テキストが論理順に抽出されなくなるかもしれません。

▶ `contentanalysis={shadowdetect=false}`

このページオプションは、冗長な影付き・擬似太字テキストの検出を無効にします。これによっても、処理時間を短縮できる場合があります。

▶ TETMLを生成する際には、下記の文書オプションを用いて、さまざまなインタラクティブPDF機能に対するTETMLエレメントの生成を無効化することも可能です：

```
tetml={elements={annotations=false bookmarks=false destinations=false fields=false  
javascripsts=false}}
```

単語か行レイアウトか折り返し可能テキストか 以下のように、応用の種類によって、望ましい出力の種類は異なります(ハイフネーションされた単語はつねにこれらの設定でハイフン除去されます)：

▶ 個々の単語(レイアウト無視)：検索エンジンでは、レイアウトがらみの事柄は関心の対象とはならず、テキストの中の単語だけが関心の対象になります。このような場合には、`TET_open_page()`で`granularity=word`を用いて、`TET_get_text()`を1回呼び出すごとに1個の単語が抽出されるようにします。

▶ 行レイアウトを温存：`TET_get_text()`を1回呼び出すごとに1つのページ全体のテキスト内容が抽出されるようにするには、`TET_open_page()`で`granularity=page`を用います。テキストの行と行の間はそれぞれ、ラインフィードキャラクタ U+00A0 で区切られるので、既存の行構造が保持されます。

▶ 折り返し可能テキスト：改行を避け、抽出されたテキストの折り返しを実現するためには、文書オプション`lineseparator=U+0020`とページオプション`granularity=page`を用います。`TET_get_text()`を一回呼び出せばページ内容全体が取得できます。デフォル

トでは、段落どうしは U+000A で区切られます。他の段落区切りを入れさせたい場合には、文書オプション `paraseparator=U+2029`（または他の適切な Unicode 値）を用います。

検索エンジンやインデクサを書く インデクサは通常、テキストのページ上における位置には関心を持っていません（検索された用語をハイライト表示させたい場合を除き）。多くの場合、インデクサは Unicode マッピングにおいて起こるエラーを許容し、得られるテキスト内容すべてを処理します。推奨方策：

- ▶ `TET_open_page()` で `granularity=word` を用います。
- ▶ 句読点を処理する方法をアプリケーションが知っている場合には、ページオプション `contentanalysis={punctuationbreaks=false}` を設定すれば、句読点を隣接テキストと一緒にしておくことができます。

位置情報 応用の種類によっては、位置情報に関する機能が有用でしょう：

- ▶ `TET_get_char_info()` インタフェースが必要になるのは、テキストのページ上における位置や、それぞれのフォント名、テキストカラーなど詳細情報を必要とする場合だけです。テキストの座標に関心がない場合には、`TET_get_text()` を呼び出せば充分です。
- ▶ ページのレイアウトに関して事前情報がある場合は、`TET_open_page()` で `includebox` オプションや `excludebox` オプションを用いて、ヘッダ・フッタやその他本文テキストには含まれない部位を除外することができます。

複雑なレイアウト ある種の文書は、非常に凝ったページレイアウトを用います。たとえば雑誌などでは、TET はページ上の段組みどうしの関係を正しく決めることができない場合があります。このような場合には、処理時間をかけることによって、抽出されるテキストを向上させることが可能です。この目的に適したオプションは、94 ページの 6.7 「レイアウト分析と文書スタイル」にまとめてあります。関連するオプションについて詳しくは、201 ページの表 10.12 を参照してください。

法律文書 法律文書を扱う際には通常、Unicode マッピングの誤りは一切許容されません。それによって文書の内容や解釈が変わってしまう危険があるためです。多くの場合テキストの位置は必要ではなく、テキストは単語ごとに抽出される必要があります。推奨方策：

- ▶ `TET_open_page()` で `granularity=word` オプションを用います。
- ▶ 開くためにパスワードを必要とする文書を処理する必要があるときは、`TET_open_document()` で `password` オプションを用いて正しい文書パスワードを指定します。あるいは、内容抽出が権限設定で許可されていないときは、その文書からテキストを抽出する合法的立場に自分があるならば、`shrug` オプションを用います（64 ページの「暗号化文書に対する「シュラッグ」機能」を参照）。
- ▶ テキストの厳密さを正確に保つには：`TET_get_char_info()` が返すキャラクタ情報構造のフィールドが 1 であったとき、または `TET_get_text()` が返す文字列の中に Unicode 置き換えキャラクタが入っていたときには、ただちに処理を停止させます。テキストモード `glyph` または `wordplus` による TETML 内では、この状況は `Glyph` エレメントの下記の属性で特定できます：

```
unknown="true"
```

`unknownchar` オプションをよくあるキャラクタに設定しないようにします。正しくマップされたキャラクタとの区別が、`unknown` フィールドを調べないかぎりできなくなってしまうためです。

- ▶ テキストの厳密さを保つもう一つの方策としては、ページ上に表示されていないテキストについてはテキスト抽出を無効化するとよいでしょう：

```
ignoreinvisibletext=true
```

PDFlib+PDI で文書を処理 PDFlib+PDI を用いて PDF 文書をページごとに処理している場合には、TET をそこに組み合わせて分割や結合の処理を制御することもできます。たとえば、PDF 文書をページ上の内容に従って分割することが可能になります。作成処理に関与している場合には、テキスト内にそのための適当な処理命令を持った区切りページを挿入することもできます。TET クックブックには、TET で文書を分析してからそれを PDFlib+PDI で処理する例が含まれています。

Unicode 値を持たないレガシ PDF 文書 場合によっては、レガシアプリケーションによって生成された PDF 文書を処理しなければならないことがあります。そのような PDF は、正しい Unicode マッピングに必要な十分な情報を持たないことがあります。デフォルト設定を用いた場合には、TET はそのテキスト内容の一部ないし全部抽出できないかもしれません。推奨方策：

- ▶ まずはテキストをデフォルト設定で抽出してみて、その結果を解析します。正しい Unicode マッピングに必要な十分な情報を与えないフォントを見つけます。
- ▶ このフォントの問題を解決するため、カスタムのエンコーディングテーブルとグリフ名リストを書きます。PDFlib FontReporter を利用してフォントを解析し、Unicode マッピングテーブルを作成します。
- ▶ このカスタムのマッピングテーブルを設定して、テキストをまた抽出してみます。この時は文書の量をはじめより多くしてみます。なおもマップ不能なグリフがある場合には、マッピングテーブルを適切に調整します。
- ▶ マップ不能なグリフを持つ文書が大量にある場合は、必要なマッピングテーブルの作成について PDFlib GmbH が支援できる場合もあります。

PDF 文書を他の形式に変換 PDF 文書のページ内容を、できるだけ多くの情報を保ちながら自分のアプリケーションに取り込みたい場合には、正確なキャラクタメトリックが必要になります。推奨方策：

- ▶ `TET_get_char_info()` を用いて、正確なキャラクタメトリックとフォント名を抽出します。`uv` フィールドを用いて各キャラクタの Unicode 値を抽出している場合でも、`char_info` 構造に内容を取り込むために `TET_get_text()` を呼び出す必要があります。
- ▶ `TET_open_page()` で `granularity=glyph` か `word` のいずれかを用います。自分のアプリケーションに合っている方を選びましょう。`granularity=glyph` で処理をすると、テキストの視覚レイアウトと、TET が処理して生成する論理的テキストとの間に齟齬が生じる場合があります（たとえば、合字グリフによって生成された 2 個のキャラクタは、その合字と同じ幅には収まらないかもしれません）。

カスタムエンコーディングのロゴを持つ企業フォント 多くの場合、カスタムのロゴを含んだ企業フォントは、そのロゴに対する Unicode マッピング情報を含んでいないか、あるいは含んでも誤っています。このようなフォントが含んだ PDF 文書が大量にある場合には、正しい Unicode 値でカスタムのマッピングテーブルを作成することを推奨します。

まず、そのフォントを含んだ PDF に対するフォントレポートを生成させ（121 ページの「PDFlib FontReporter Plugin で PDF 文書を分析」を参照）、マップが誤っているグリフをそのフォントレポート内で見つけます。そのフォントの種類で利用できる設定テーブルを選び、それを用いて、足りない Unicode マッピングを与えることができます。ロゴタイ

プフォントに対するコードリストの詳しい作成例は、122 ページの「コードリストリソースはあらゆる種類のフォントに利用可能」を参照。

TeX 文書 TeX 文書によって生成された PDF 文書は、数値グリフ名や Type 3 フォントをはじめとする、他の製品がテキストをうまく抽出できない原因となる、問題のある特性を含んでいることがよくあります。TET は、このような文書を扱うための多くのヒューリスティックと回避策を含んでいます。しかしある種の TeX 文書は、処理時間をより多く要する、デフォルトでは無効になっている回避策でのみ処理することが可能です。下記の文書オプションを用いれば、こうした文書のための、CPU 消費のより多いフォント処理を有効にすることができます：

```
checkglyphlists=true
```


6 テキスト抽出

6.1 PDF のさまざまな文書領域

PDF 文書は、ページ内容だけではなく、それ以外の多くの場所にテキストを含んでいる可能性があります。たいていのアプリケーションはページ内容のみを扱いますが、他の文書領域が必要な状況も多くあります。

ページ内容は、最も活躍する関数 `get_text()` と `get_image()` で取得することができ、一方、他の文書領域からテキストを取得するには内蔵の pCOS インタフェースが主要な役割を務めます。

この節では以下、TET ライブラリと TETML での領域検索について情報を提供します。あわせて、これらの文書領域を Acrobat XI/DC で検索する方法もまとめます。これは Acrobat で検索ヒットを見つけるために重要です。

ページ上のテキスト ページ内容は PDF 内の主要なテキストです。ページ上のテキストはフォントで視覚表現され、PDF 内で利用可能な多様なエンコーディング技法の一つを用いて符号化されています。

- ▶ Acrobat での表示方法：ページ内容はつねに表示されています。
- ▶ Acrobat XI/DC で一個の PDF を検索する方法：「編集」→「検索」または「編集」→「高度な検索」。Acrobat がグリフを Unicode 値へ正しくマップできない文書内のテキストを、TET は処理できる可能性があります。このような状況では、TET をベースにした TET Plugin を利用することができます (49 ページの 4.1 「Adobe Acrobat 用無償 TET Plugin」を参照)。TET Plugin は、その自前の検索ダイアログを「Plug-Ins」→「PDFlib TET Plugin...」→「TET Find」で提供します。ただしこれは、完全な検索機能を提供するようには意図されていません。
- ▶ Acrobat XI/DC で複数の PDF を検索する方法：「編集」→「高度な検索」の後、「詳細オプションを表示」の中で「検索する場所：」の下で「以下の場所にあるすべての PDF 文書」を選択し、PDF 文書群が入っているフォルダへブラウザ (図 6.1 参照)。
- ▶ TET ライブラリ用サンプルコード：`extractor` サンプル
- ▶ TETML エlement：`/TET/Document/Pages/Page/Content`

定義済み文書情報項目 標準文書情報項目はキー / 値のペアです。

- ▶ Acrobat XI/DC での表示方法：「ファイル」→「プロパティ...」
- ▶ Acrobat XI/DC で一個の PDF を検索する方法：なし
- ▶ Acrobat XI/DC で複数の PDF を検索する方法：「編集」→「高度な検索」の後、ダイアログの下端近くの「詳細オプションを表示」をクリック。「検索する場所：」プルダウンで PDF 文書群のフォルダを選択し、プルダウンメニュー「その他の条件」で「作成日」「更新日」「作成者」「タイトル」「サブタイトル」「キーワード」のいずれかを選択。
- ▶ TET ライブラリ用サンプルコード：`dumper` サンプル
- ▶ TETML エlement：`/TET/Document/DocInfo`

カスタム文書情報項目 標準項目に加えて、カスタム文書情報項目を定義することもできます。

- ▶ Acrobat XI/DC での表示方法：「ファイル」→「プロパティ...」→「カスタム」(Acrobat Reader では利用できません)

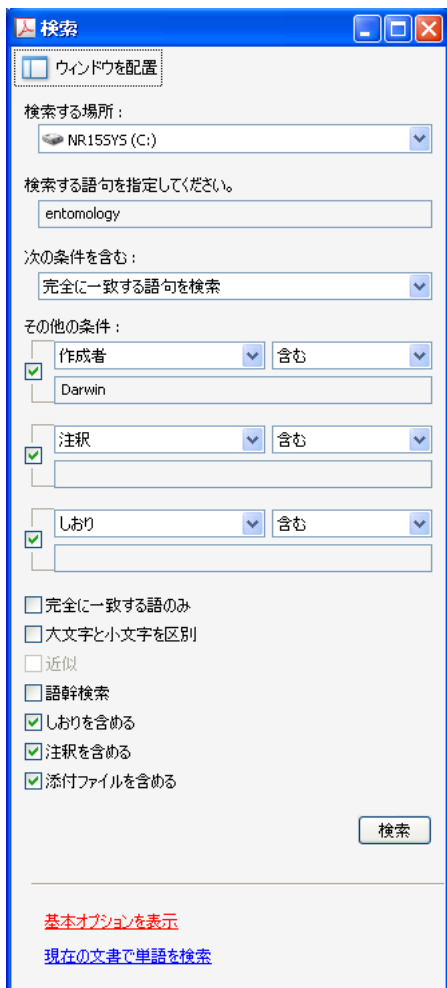


図 6.1
Acrobat の高度な
検索ダイアログ

- ▶ Acrobat XI/DC での検索方法：なし
- ▶ TET ライブラリ用サンプルコード：*dumper* サンプル
- ▶ TETML エレメント：/TET/Document/DocInfo/Custom

文書レベルの XMP メタデータ XMP メタデータは、拡張されたメタデータを内容として持つ XML ストリームから成ります。

- ▶ Acrobat XI/DC での表示方法：「ファイル」→「プロパティ...」→「概要」→「その他のメタデータ...」（Acrobat Reader では利用できません）
- ▶ Acrobat XI/DC で一つの PDF を検索する方法：なし
- ▶ Acrobat XI/DC で複数の PDF を検索する方法：「編集」→「高度な検索」の後、「詳細オプションを表示」をクリック。「検索する場所：」プルダウンで PDF 文書群のフォルダを選択し、プルダウンメニュー「その他の条件」で「XMP メタデータ」を選択（Acrobat Reader では利用できません）。
- ▶ TET ライブラリ用サンプルコード：*dumper* サンプル
- ▶ TETML エレメント：/TET/Document/Metadata

画像レベルの XMP メタデータ XMP メタデータは、画像・ページ・フォントといった文書構成要素にも付けることが可能です。しかし、XMP が通常見つかるのは画像レベルにおいてのみです（文書レベルに加えて）。

- ▶ Acrobat XI/DC での表示方法：「表示」→「表示切り替え」→「ナビゲーションパネル」→「コンテンツ」。ツリー構造の中で画像を見つけ、それを右クリックして「メタデータを表示...」を選択。（Acrobat Reader では利用できません）
- ▶ Acrobat XI/DC での検索方法：なし
- ▶ TET ライブラリ用サンプルコード：pCOS クックブックのトピック *image_metadata*
- ▶ TETML エlement：/TET/Document/Pages/Page/Resources/Images/Image/Metadata

フォームフィールド内のテキスト フォームフィールドはページにかぶさって表示されます。しかし、技術的にはこれはページ内容の一部ではなく、別途のデータ構造によって表現されます。

- ▶ Acrobat XI での表示方法：「ツール」→「フォーム」→「編集」（Acrobat Reader では利用できません）
- ▶ Acrobat DC での表示方法：「ツール」→「フォームを準備」（Acrobat Reader では利用できません）
- ▶ Acrobat XI/DC での検索方法：Acrobat はフォームフィールドの可視内容を検索します
- ▶ TET ライブラリ用サンプルコード（101 ページの 6.10「注釈内のテキスト」を参照）：注釈の体裁ストリームはデフォルトで処理されます:pCOSクックブックのトピック *fields*
- ▶ TETML エlement：/TET/Document/Pages/Page/Fields/Field/Value は、可視の値を内容として持っています。これ以外の情報のための TETML エlement もあります。たとえばデフォルト値のための /TET/Document/Pages/Page/Fields/Field/DefaultValue や、インタラクティブツールチップのための /TET/Document/Pages/Page/Fields/Field/Value などです。

注釈内のテキスト フォームフィールドと同様、注釈（ノート・テキスト注釈等）は別のデータ構造によって表現されます。注釈の興味対象となるテキスト内容はその種類によって異なります。たとえば、Web リンクの場合はその興味対象となる部分は URL でしょうし、それ以外の種類の注釈では印字されるテキスト内容が意味を持つでしょう。

- ▶ Acrobat XI での表示方法：「注釈」→「注釈のリスト」
- ▶ Acrobat DC での表示方法：「ツール」→「注釈」→「注釈のリスト」
- ▶ Acrobat XI/DC で一つの PDF を検索する方法：「編集」→「検索」→ボックス「注釈を含める」をチェック、または注釈のリストツールバーで「検索」ボタンをクリック
- ▶ Acrobat XI/DC で複数の PDF を検索する方法：「編集」→「高度な検索」の後、「詳細オプションを表示」をクリック。「検索する場所：」プルダウンで PDF 文書群のフォルダを選択し、プルダウンメニュー「その他の条件：」で「注釈」を選択。
- ▶ TET ライブラリ用サンプルコード（101 ページの 6.10「注釈内のテキスト」を参照）：注釈書式ストリームはデフォルトで処理されます：注釈の *Contents* エントリを、pCOS を用いて抽出できます。TET クックブックのトピック *text_from_annotations* を参照
- ▶ TETML エlement：/TET/Document/Pages/Page/Annotations/Annotation

しおり内のテキスト しおりは直接にはページと結びついていませんが、特定のページへ飛ぶアクションを内容として持つ場合があります。しおりは階層構造を形成するように入れ子にすることも可能です。

- ▶ Acrobat XI/DC での表示方法：「表示」→「表示切り替え」→「ナビゲーションパネル」→「しおり」

- ▶ Acrobat XI/DC で一つの PDF を検索する方法 : 「編集」 → 「高度な検索」の後、ボックス「しおりを含める」をチェック
- ▶ Acrobat XI/DC で複数の PDF を検索する方法 : 「編集」 → 「高度な検索」の後、「詳細オプションを表示」をクリック。「検索する場所 : 」プルダウンで PDF 文書群のフォルダを選択し、プルダウンメニュー「その他の条件」で「しおり」を選択 (Acrobat Reader では利用できません)
- ▶ TET ライブラリ用サンプルコード : pCOS クックブックのトピック *bookmarks*
- ▶ TETML エレメント : */TET/Document/Bookmarks/Bookmark/Title*

ファイル添付 PDF 文書はファイル添付を含むこともでき (文書レベルかページレベルで)、そのファイル添付自体が PDF 文書であることも可能です。

- ▶ Acrobat XI/DC での表示方法 : 「表示」 → 「表示切り替え」 → 「ナビゲーションパネル」 → 「添付ファイル」
- ▶ Acrobat XI/DC での検索方法 : 「編集」 → 「高度な検索」の後、ボックス「添付ファイルを含める」をチェック (Acrobat Reader では利用できません)。入れ子になった添付は再帰的に検索されません。
- ▶ TET ライブラリ用サンプルコード : *get_attachments* サンプル
- ▶ TETML エレメント : */TET/Document/Attachments/Attachment/Document*

PDF パッケージ・ポートフォリオ PDF パッケージと PDF ポートフォリオは、ファイル添付に追加のプロパティ群を与えたものです。

- ▶ Acrobat XI/DC での表示方法 : Acrobat は、PDF パッケージ専用のユーザインタフェースで、パッケージ / ポートフォリオの表紙と中身の PDF 文書群を表現します。
- ▶ Acrobat XI/DC で一つの PDF パッケージを検索する方法 : 「編集」 → 「ポートフォリオ全体を検索」
- ▶ Acrobat XI/DC で複数の PDF パッケージを検索する方法 : なし
- ▶ TET ライブラリ用サンプルコード : *get_attachments* サンプル
- ▶ TETML エレメント : */TET/Document/Attachments/Attachment/Document*

PDF の各種規格とその他各種 PDF プロパティ この領域は明示的にテキストを含んではおらず、PDF/X・PDF/A ステータス、タグ付き PDF ステータスといった、PDF 文書のさまざまな固有プロパティを集めたコンテナとして用いられます。

- ▶ Acrobat XI/DC : 「表示」 → 「表示切り替え」 → 「ナビゲーションパネル」 → 「規格」 (規格準拠 PDF でのみ現れます)
- ▶ Acrobat XI/DC での検索方法 : なし
- ▶ TET ライブラリ用サンプルコード : *dumper* サンプル
- ▶ TETML エレメント・属性 : */TET/Document/@pdfa* ・ */TET/Document/@pdfe* ・ */TET/Document/@pdfua* ・ */TET/Document/@pdfvt* ・ */TET/Document/@pdfx*

タグ付き PDF とページ装飾 TET は、レイアウトの構造とヒエラルキーを、タグ付き PDF 文書内に存在している構造ツリーを使用することなく、ページ構造から直接再構築します。テキスト・画像のうち、その文書を理解するために必要ではなく、レイアウト目的や装飾のために生成されているものについては、タグ付き PDF 内でページ装飾としてマークされる場合があります。ページ装飾の最もよくある用途は、ページ番号や章見出しなどのランニングヘッダ・フッタです。その用法によって、ページ装飾としてマークされているページ内容を処理することが望ましいかどうか異なります :

- ▶ Acrobat XI/DC での表示方法：「表示」→「表示切り替え」→「ナビゲーションパネル」→「タグ」。「タグ」のメニューで「検索 ...」をクリックして、「ページ装飾」を選択。ページ装飾としてマークされているテキスト・画像・ベクトルグラフィックがハイライトされます。
あるいは、「ツール」→「アクセシビリティ」→「TouchUp 読み上げ順序」を開くという方法もあります。このツールは、ページ上のタグ付き内容を灰色の長方形でハイライトします。ハイライトされていない内容がページ装飾を示しています。
- ▶ Acrobat XI/DC で検索時にページ装飾を無視する方法：なし
- ▶ TET でページ装飾を無視する方法：ページオプション *ignoreartifacts* を与えます。テキスト・画像ページ装飾を、*attributes* フィールド内の *TET_ATTR_ARTIFACT* フラグによって識別できます。
- ▶ TETML：テキスト・画像ページ装飾は TETML 内で *Glyph*・*Text*・*PlacedImage* エレメントの *artifacts* 属性を用いて識別されます。

レイヤー レイヤー（技術的にはオプション内容として知られます）を利用すると、ページ内容の表示と非表示を切り替えることができます。その用法によって、隠しレイヤー上のページ内容を処理することが望ましいかどうか異なります。

- ▶ Acrobat XI/DC での表示方法：「表示」→「表示切り替え」→「ナビゲーションパネル」→「レイヤー」。現在表示されているレイヤーは、その名前の頭に目の印があります。この印をクリックすると、レイヤーの表示と非表示を切り替えることができます。
- ▶ Acrobat XI/DC での検索方法：Acrobat は全レイヤーの内容を検索します。隠しレイヤー上で検索結果が見つかった場合、Acrobat はそのレイヤーを表示させるよう提案します。
- ▶ TET での検索方法：ページオプション *layers* を用いて、内容抽出を表示レイヤーか非表示レイヤーに限定することが可能です。あるいは全レイヤーの内容を処理させることもできますが、これはレイヤーどうしが重なりあっていない場合にのみ意味があるでしょう。
- ▶ TETML：レイヤー内容はページオプション *layers* に従って処理されます。レイヤーの名前とその可視ステートなどの特性は下記 TETML エレメント内にリストされます：
/TET/Document/Pages/Graphics/Layers/Layer

6.2 ページとテキストの視覚情報

デフォルト座標系 デフォルトではTETは、ページとテキストのすべての視覚情報をPDFの標準座標系で表します。ただし、座標系の原点（ページの外にある場合もある）は、ページの表示可能領域の左下隅に一致させます。正確には、**CropBox** が存在するときはその左下隅、そうでないときは **MediaBox** の左下隅が原点になります。ページが **Rotate** キーを持つ場合はページ回転が行われます。この座標系は DTP ポイントを単位として用います。

1 pt = 1 inch / 72 = 25.4 mm / 72 = 0.3528 mm

第1座標は右へ増加し、第2座標は上へ増加します。デフォルトでは、TET に与える座標はすべてこの座標系で表したものでなければなりませんし、TET が返す座標もすべてこの座標系で表されたものになります。PDF 文書内でその座標が実際どのように表されているかは関係ありません。PDF のページサイズを得る方法については pCOS パスリファレンスを参照してください。

下向き座標系 PDF の上向き座標系とは異なり、グラフィック環境によっては上向き座標系を用いているものがあります。開発者によってはこの方を好む場合があります。下向き座標系の利用を実現するため、TET では代替座標系を使うことができます。この代替座標系では、すべての関連する座標はページの左下隅ではなく左上隅に対して解釈され、**y** 座標は下向きに増加します。この下向き機能は、TET のユーザが下向き座標系をごく自然に扱えるようにするために設計されています。追加の利点として、下向き座標は Acrobat で表示される座標値と等しくなります（後述）。ページで下向き座標を有効にするには、ページオプション **topdown={output}** を用います。

Acrobat で座標を表示 Acrobat でページ座標を表示するには以下のように操作します（図 6.2 参照）：

- ▶ Acrobat XI/DC でカーソル座標を表示するには、「表示」→「表示切り替え」→「カーソル座標」を用います。
- ▶ 座標は、Acrobat で現在選択されている単位で表示されます。Acrobat XI/DC で表示単位をポイントに変更する（TET で用いられているのと同様に）には、次のように操作します：「編集」→「環境設定」→「単位とガイド」→「単位」へ行き、「ポイント」を選択。

この表示されている座標はページの左上隅を原点としており、左下隅を原点に持つ PDF・TET のデフォルト座標系とは異なることに留意してください。Acrobat の座標系と揃う下向き座標系を選ぶための方法については前項を参照してください。

テキスト抽出の領域 デフォルトでは TET は、目に見えるページ領域のテキストをすべて抽出します。TET_open_page() の **clippingarea** オプション（196 ページの表 10.10 を参照）を用いると、これを任意の PDF ページ枠エントリ（TrimBox 等）へ変更することができます。キーワード **unlimited** を用いると、いかなるページ枠にもかかわらずすべてのテキストを抽出することができます。デフォルト値 **cropbox** は、Acrobat で目に見える領域内のテキストを抽出するよう TET に指示します。

テキスト抽出の領域はもっと細かく、任意の数の矩形領域を TET_open_page() の **includebox**・**excludebox** オプションで与えることによって指定することもできます。これは部分的なページ内容（選んだ段組等）を抽出したり、あるいは必要ない部分（余白・

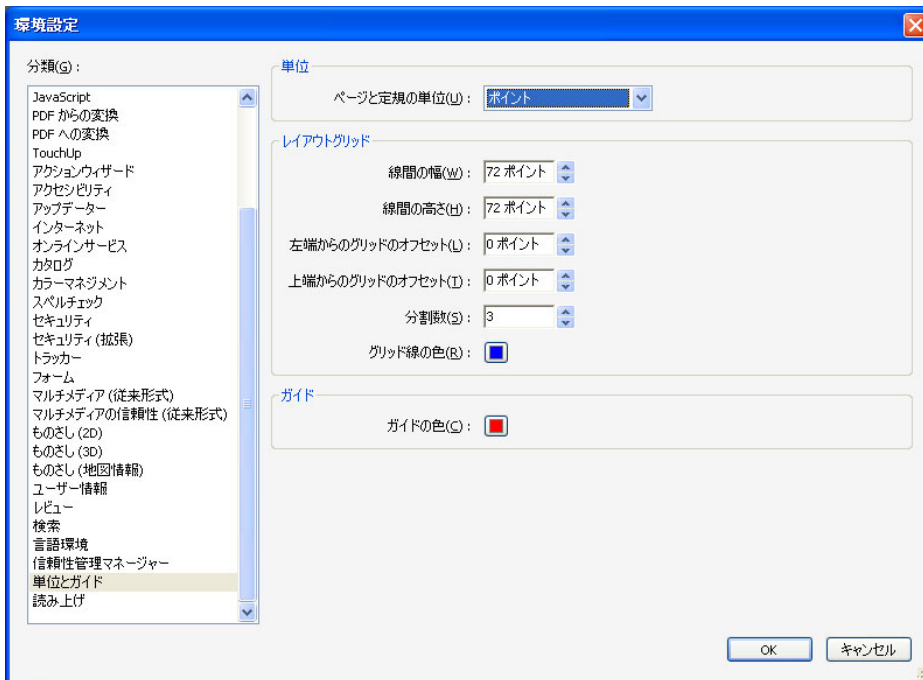


図 6.2 Acrobat の座標表示を設定。カーソル座標を表示するには「表示」→「表示切り替え」→「カーソル座標」を uses。

ヘッダ・フッタ等)を除いたりするために有用です。最終的な切り抜き領域は、*includebox* オプションで指定されたすべての矩形の和を算出し、そこから *excludebox* オプションで指定されたすべての矩形の和を除外することによって構築されます。グリフは、その参照点が切り抜き領域の中にあるとき、その切り抜き領域内にあると判定されます。これはすなわち、キャラクターの一部が切り抜き領域の外に出てもそれがその切り抜き領域内にあると判定される場合があり、またその逆の場合もあることを意味します。

グリフメトリックなど詳細 *TET_get_char_info()* を用いると、任意のグリフに対して返されたキャラクター群のフォント情報やメトリック情報を取得することができます。出力内の各キャラクターに対して、それぞれ以下の値が得られます (図 6.3 と 208 ページの表 10.16 を参照) :

- ▶ **uv** フィールドは、情報取得対象のキャラクター(カレントキャラクター)の UTF-32 Unicode 値を持ちます。このフィールドはつねに UTF-32 を持ちます。ネイティブ Unicode 文字列内で UTF-16 のみに対応している言語バインディングにおいても同様です。この **uv** フィールドを利用すると、BMP 領域外のキャラクターをアプリケーションで取り扱いたいときに、サロゲートペアを解釈する必要なしに取り扱えるようになります。
- ▶ **type** フィールドは、そのキャラクターの種別を表します。定数 *TET_CT_NORMAL* などが設定されます。有形キャラクターと無形キャラクターの 2 種類があります。有形キャラクターに分類されるものとしては、通常のキャラクター (1つのグリフまるごとの結果等) と、1つのグリフに対応する複数のキャラクターの列の先頭キャラクター (合字の 1文字目等) が挙げられます。無形キャラクターに分類されるものとしては、複数のキャラクターの列の中の後続キャラクター (合字の 2文字目等) と、挿入された区切りキャラクターが挙げ




図 6.3
TET のデフォルト座標系 (topdown={output=false})
における縦書きと横書きに対するグリフメトリック

られます。無形キャラクタの場合、位置 (x, y) はもっとも最近の有形キャラクタの終了点を指し、 $width$ と $height$ は 0 になり、その他のフィールドは uv 以外すべてもっとも最近の有形キャラクタと同じになります。この終了点は、方向が $alpha$ (横書き) の場合は (x, y) に $width$ を加えた点になり、方向が -90° (縦書き) の場合は $height$ を加えた点になります。

- ▶ **unknown** フィールドは通常は *false* (C・C++ では 0) ですが、ただし元のグリフが Unicode にマップすることができないために *unknownchar* オプションによる指定キャラクタに置き換えられたときは値 *true* (C・C++ では 1) を持ちます。このフィールドを用いると、クエスチョンマークやスペースなどのありがちなキャラクタを *unknownchar* として指定したような場合に、実際の文書の内容と置き換えキャラクタとを区別することが可能になります。
- ▶ **attributes** フィールドは、TET の内容分析アルゴリズムで決定された下付き・上付き・ドロップキャップ・影付きステータスに関する情報を内容として持ちます。グリフがページ装飾 (本文外の内容) の一部である場合には、これは *attributes* フィールド内においても報告されます。このフィールドには定数 *TET_ATTR_SUB* などが設定されます。
- ▶ **(x, y)** 両フィールドは、そのグリフの参照点の位置を指します。この参照点は横書きではグリフ矩形の左下隅になり、縦書きでは上端中央になります (86 ページの 6.4.1 「日中韓エンコーディング・CMap」参照)。無形キャラクタについては、ページ上に対応するグリフがないので、点 (x, y) はもっとも最近の有形キャラクタの終了点を指します。 y の値は *topdown* ページオプションに依存します。
- ▶ **width** フィールドは、そのグリフに対応するフォントメトリックと文字間隔・水平倍率等のテキスト出力パラメタ群とに従ったグリフの幅を表します。こうしたパラメタが次のグリフの位置を制御するので、隣り合う 2 つのグリフの参照点間の間隔は $width$ とは異なる場合があります。ゼロ幅キャラクタの場合 $width$ はゼロになることがあります。逆に斜体テキスト等、実際のアウトラインの幅がそのグリフの $width$ 値より広がる場合もあります。無形キャラクタの場合 $width$ は 0 になります。

- ▶ **height** フィールドは、縦書きにおいて、その照応するグリフのフォントメトリックとテキストパラメータ群（字間など）に従った高さを表します。この高さは、デフォルト座標系では正の値ですが、下向き座標系では負値になります。等幅縦書きフォントにおいては、すべてのグリフが、追加の字間が適用されない限り、**fontsize** を高さとして持ちます。無形キャラクタ（区切りなど）の場合 **height** は 0 になります。
縦書きの場合には、グリフ高さの概算が与えられます。この概算値はフォント特性群から導出されますので、1つのフォントのすべてのグリフについて等しくなります。印字されているグリフが、ここで与えられたのとちょうど同じ高さ値を持つという保証はありません。
- ▶ 角度 **alpha** は、テキストの進行方向を与えます。これは、標準方向からの偏移で表されます。この標準方向は横書きでは 0° になり、縦書きでは -90° になります（縦書きについて詳しくは後述）。よって角度 **alpha** は、通常の横書きテキストと通常の縦書きテキストに対してはともに 0° になります。**alpha**・**beta** の値は **topdown** ページオプションに依存します。
- ▶ 角度 **beta** は、斜体（擬似イタリック）テキスト等の、テキストにかかった傾斜を表します。この角度は **alpha** に対する垂線から測られます。通常の正立したテキストに対しては 0° になります（横書きでも縦書きでも）。**beta** の絶対値が 90° を超える場合、そのテキストはベースラインを軸に反転して裏返っていることになります。
- ▶ **fontid** フィールドは、そのグリフに対して用いられているフォントの pCOS ID を持ちます。この ID を用いると、フォント名・埋め込み状況・記述方向（横書きか縦書きか）といった詳しいフォント情報を取得することができます。pCOS パスリファレンスに、こうしたフォント情報取得のためのサンプルコードがあります。
- ▶ **fontsize** フィールドは、テキストのサイズをポイント単位で表します。これは正規化されるので、**topdown={output}** の場合も含め、つねに正の値になります。
- ▶ **colorid** フィールドはテキストカラーに対する添字を内容とします。これは、塗り色・描線色・テキスト表現の一意的な組み合わせを表します。1つの文書の中の同じ組み合わせの出現はすべて同じカラー ID で表されます。異なる組み合わせは異なる ID で表されますので、複数のグリフの色が等しいかどうかを、そのカラー ID を比較することによってチェックできます。たとえば、連続するグリフの **colorid** 値を比較することによって、テキストカラーの変化を特定できます。テキストを塗り・描線している実際の色空間と色要素を取得するには **TET_get_color_info()** を用います（84 ページの 6.3「テキストカラー」を参照）。
- ▶ **textrendering** フィールドは、描線・塗り・不可視など、グリフに対する表現の種類と、そのテキストのクリッピングパスとしての可能な用途を表します。これには定数 **TET_TR_FILL** などが設定されます。このフィールドは、PDF で定義されているテキスト表現モードの数値を内容とします（208 ページの表 10.16 を参照）。不可視のテキスト（すなわち **textrendering=3**）は、デフォルトでは抽出されますが、**TET_open_page()** で **ignoreinvisibletext** オプションを用いればそうでなくすることもできます。
Type 3 フォントのテキスト：**textrendering=3**・**7** は不可視テキストになります。**textrendering** のこれ以外の値はすべて意味を持たず無視されます。

フォント固有メトリック TET は、PostScript と PDF が用いているグリフ・フォントメトリックシステムを用いています。ここで簡単に説明しましょう。

文字サイズには通常、キャラクタの各部が重なり合わないために必要な、隣り合う行どうしの最小限の間隔が選ばれます。文字サイズは一般に、フォント内の個々のキャラク




図 6.4 フォント固有メトリック

タよりも大きくなります。なぜなら、文字サイズはアセンダとディセンダにわたるうえ、さらに行間の追加のアキが加わる場合もあるからです。

キャップハイトは、多くの欧文フォントの *T* や *H* のような大文字の高さです。**x ハイト**は、多くの欧文フォントの *x* のような小文字の高さです。**アセンダ**は、多くの欧文フォントの *t* や *d* のような小文字の高さです。**ディセンダ**は、多くの欧文フォントの *j* や *p* のような小文字のベースラインから下端までの間隔です。ディセンダは通常、負の値です。**x ハイト・キャップハイト・アセンダ・ディセンダ**の値は文字サイズの 1000 分の 1 を単位に測られます。

これらの値はフォントによって異なっており、pCOS インタフェースで取得できます。たとえば、以下のコードはアセンダとディセンダの値を取得します：

```
/* アセンダとディセンダの値を取得 */
path = "fonts[" + i + "]/ascender";
System.out.println("アセンダ=" + p.pcos_get_number(doc, path));

path = "fonts[" + i + "]/descender";
System.out.println("ディセンダ=" + p.pcos_get_number(doc, path));
```

なお、**アセンダ**等のフォントメトリック値は、このフォントによるグリフに対して `TET_get_char_info()` を呼び出した後にもみ取得するべきです。言い換えれば、`TET_get_char_info()` から返されたフォント ID を用いることは安全ですが、`fonts[]` 配列内のすべてのフォントを評価することは必ずしも埋め込まれたフォントデータからのメトリック値を与えず、PDF *FontDescriptor* 辞書からの不正確な値を与える可能性があります。詳しくは pCOS パスリファレンスを参照してください。

グリフと単語の終了点 ハイライトを正しく行うためには、単語内の末尾キャラクタの末尾位置が必要になります。`TET_get_char_info()` が返す開始点座標 x, y と $width \cdot \alpha$ 値を用いれば、横書きでのグリフの終了点を、すなわちそのグリフのアドバンスベクトルの終点（グリフ枠の右下隅）を決定することができます：

$$x_{\text{end}} = 1r_x = x + \text{幅} * \cos(\alpha)$$

$$y_{\text{end}} = 1r_y = y + \text{幅} * \sin(\alpha)$$

通常の横書きテキスト（すなわち $\alpha=0$ ）では、これは次の形に省略できます：

```
xend = lrx = x + 幅  
yend = lry = y
```

より一般的には、グリフ枠のサイズを、その右上隅の座標を決定することによって算出できます ($\beta=0$ の場合です。すなわち、この算式はグリフの斜形化を考慮に入れていません) :

```
urx = x + 幅 * cos(alpha) - 向き * 高さ * sin(alpha)  
ury = y + 幅 * sin(alpha) + 向き * 高さ * cos(alpha)
```

ここで、デフォルトの `topdown={output=false}` の場合ならば向き =1、`topdown={output=true}` ならば向き =-1 です (78 ページの「下向き座標系」参照)。高さの値は文字サイズとフォントの幾何情報に依存します。下記は、広く用いられている多くのフォントについて、使える値を与えます (アセンダ値の取得については 81 ページの「フォント固有メトリック」を参照) :

```
高さ = 文字サイズ * アセンダ / 1000
```

多くのグラフィック開発環境において、グリフ変換は以下のように表すことができます :

```
translate(x, y);  
rotate(alpha);  
skew(0, -beta);  
if (abs(beta) > 90)  
    scale(1, -1);
```

これらの変換を行なった後は、グリフ枠の右上隅は以下のように表すことができます :

```
urx = x + 幅  
ury = y + 向き * 高さ
```

縦書きでのグリフ計算 縦書きのテキストについては、終了点の計算は以下のように行われます :

```
xend = x  
yend = y - 高さ
```

グリフ枠の左上隅と右下隅は以下のように算出できます ($\beta=0$ の場合) :

```
ulx = x - 幅/2 * cos(alpha)  
uly = y - 幅/2 * sin(alpha)  
  
lrx = ulx + 幅 * cos(alpha) + 向き * 高さ * sin(alpha)  
lry = uly + 幅 * sin(alpha) - 向き * 高さ * cos(alpha)
```

ここで、デフォルトの `topdown={output=false}` の場合ならば向き =1、`topdown={output=true}` ならば向き =-1 です (78 ページの「下向き座標系」参照)。

6.3 テキストカラー

`TET_get_char_info()` によって返されるテキストカラー ID は、キャラクタに照応するグリフの塗り・描線色を記述します。カラー ID によって表される塗り・描線色は、カラー ID に対して以下の値を返す `TET_get_color_info()` を用いて実現できます。これらの値は、グリフの塗り色と描線色について別々に取得できます：

- ▶ `colorspaceid` フィールドは、`colorspaces[]` 擬似オブジェクト (pCOS パスリファレンス参照) 内の色空間の添字を、あるいはそのグリフに色が適用されていない場合には -1 を内容とします。
- ▶ `patternid` フィールドは、`patterns[]` 擬似オブジェクト (pCOS パスリファレンス参照) 内のパターンの添字を、あるいはそのグリフにパターンが適用されていない場合には -1 を内容とします。
- ▶ `components` 配列は、`colorspaceid` でレポートされた色空間の中で解釈される必要があるカラー値群を内容とします。
- ▶ `n` フィールド (C・C++ 言語バインディングでのみ利用可能) は、`components` フィールド内の関連エントリの数を内容とします。

`glyphinfo` サンプルは、`TET_get_color_info()` によって提供されたカラー値群を解釈する方法と、pCOS を用いて取得された一般的な色空間属性群を用いてこの情報を拡張する方法を演示しています。pCOS クックブックの中の `colorspaces`・`page_colors` トピックは、キャリブレーション済み色空間に対する `WhitePoint` や、`Separation` または `DeviceN` 色空間の代替色空間など、色空間の詳細をさらに取得する方法を演示しています。

袋文字テキスト、すなわちグリフの輪郭を描く (その内部を塗らずに) ことは、PDF 文書ではめったに用いられません。多くの用途において、描線色情報は無視できるでしょう。また、パターンはテキストに対してめったに用いられません。場合によっては、グリフは塗り色と描線色の情報をいずれも保持しないことがあります。不可視テキスト (`textrendering=3`) などがこれにあたります。このケースについては `colorspaceid=-1` によって識別できます。

テキストカラー取得は、下記の文書オプションを用いて無効化することもできます：

```
engines={notextcolor}
```

テキストカラーエンジンが無効化されている場合には、`TET_char_info` の `colorid` フィールドを使用してはいけません。なぜなら、意味ある値を内容としないからです。

表6.1に、各種PDF色空間の概要を示します。特記なき限り、カラー値の範囲は0～1です。

表 6.1 PDF 内の色空間

色空間	色要素の数	注記
デバイス色空間		
DeviceGray	1	デバイス色空間は広く知られていますが、デバイス依存ですので、信頼に足る色情報を表しません。
DeviceRGB	3	
DeviceCMYK	4	
CIE ベース (デバイス独立) 色空間		
ICCBased	1・3・4 のいずれか	ICCBased 色空間は、グレースケール・RGB・CMYK いずれかのカラーのための ICC プロファイルによって定義されます。
Lab	3	Lab 色空間は、CIE 1976 L*a*b* 空間によって定義されます。範囲 0～100 の明度値 1 個と、しばしば範囲 -128～127 のカラー値 2 個を必要とします。

表 6.1 PDF 内の色空間

色空間	色要素の数	注記
CalGray	1	キャリブレーション済み色空間は、WhitePoint を定義し、オプションに BlackPoint も定義します。めったに用いられません。なぜなら ICCBased 色空間のほうが柔軟性が高いからです。
CalRGB	3	

特殊色空間

Pattern	0 (PaintType=1) N (PaintType=2) 0 (PatternType=2)	Pattern 色空間は、ベタ色ではなく何らかの図形パターンを適用するために用いられます。タイリングパターン (PatternType=1) は、何らかの図形形状を繰り返し配置することによって着色し、その際この形状は、固有の色が付いているものであってもよいです (PaintType=1)、ステンシルマスクのように色が付いておらず外部の色を必要とするものも可能です (PaintType=2)。シェーディングパターン (PatternType=2) は、ベタ色ではなく色グラデーションを適用します。
Separation ¹	1	Separation 色空間は、名前付きスポットカラーを記述し、代替色空間を必須とします。この代替色空間は、その名前付きスポットカラーが出力時に直接利用可能でない場合に必要となります。
DeviceN ¹	N	DeviceN は、複数の名前付きスポットカラーのための Separation 色空間の一般化です。CMYK プロセッサーの部分集合を適用するためにも用いられます。
Indexed	1、ただしベース色空間内は N	Indexed 色空間は、少数のさまざまなカラー値 (256 個まで) の効率的保管を可能にし、基礎をなすベース色空間を必須とします。

1. 文書オプション `glyphcolor=alternate` を用いると、Separation または DeviceN のかわりに代替色空間におけるテキスト色を報告できます。

6.4 日本語・中国語・韓国語テキスト

6.4.1 日中韓エンコーディング・CMap

TET は日本語・中国語・韓国語（日中韓）のテキストに対応しており、横書き・縦書きの、任意のレガシエンコーディング（CMap）の日中韓テキストを Unicode に変換します。TET は以下の日中韓キャラクタ集合・補助に対応しています：

- ▶ 日本語：Adobe-Japan1 ~ 6
- ▶ 中国語繁体字：Adobe-CNS1 ~ 6
- ▶ 中国語簡体字：Adobe-GB1 ~ 5
- ▶ 韓国語：Adobe-Korea1 ~ 2

これらの PDF CMap は、さまざまな日中韓キャラクタエンコーディングをカバーしています。たとえば Shift-JIS・EUC・Big-5・KSC 等、多数のエンコーディングです。ローカル独自エンコーディングで符号化された日中韓フォント名（Shift-JIS で符号化された和文フォント名など）は、Unicode へ正規化されます。

注記 レガシエンコーディングで符号化された日中韓テキストを抽出するには、TET に同梱の CMap ファイル群の場所を、7 ページの 0.1 「ソフトウェアをインストール」に従って設定する必要があります。必要な CMap が見つからないときには、構成は修正される必要がありますので、`TET_open_page()` はエラーを返します。

6.4.2 日中韓テキストの単語境界

表意文字キャラクタは単語境界を構成しませんが、句読点、および表意文字キャラクタと非表意文字キャラクタとの間の切り替わりは、なお単語境界を構成します。`granularity=word` の場合、表意文字読点 `U+3001` と表意文字句点 `U+3002` も単語境界を構成します。`granularity=page` の場合、日中韓テキストの行末に行区切りが挿入されません。

6.4.3 縦書き

TET は横書きにも縦書きにも対応しており、それぞれについて適切なメトリック計算をすべて行います。縦書きのテキストを扱う際には以下のことに留意して下さい。

- ▶ グリフの参照点は縦書きの場合にはグリフ矩形の上端中央にあります。テキストの位置は下へ向かって進みます。その進行幅はグリフ高さによって決定され、グリフ幅には依存しません（図 6.3 参照）。
- ▶ 角度 `alpha` は通常の縦書きテキストについては `0°` です。いいかえれば、縦書きのフォントで `alpha=0°` ならば下へ、すなわち `-90°` の方向に向かって進むということです。
- ▶ 上述の違いのため、クライアントコード側では下記の pCOS コードを用いて記述方向を考慮に入れる必要があります（テキストが縦に並んでいるからといって、それが実際には縦書きのフォントを用いているとは限らないことに留意して下さい）：

```
count = p.pcos_get_number(doc, "length:fonts");
for (i=0; i < count; i++)
{
    if (p.pcos_get_number(doc, "fonts[" + id + "]/vertical"))
    {
        /* フォントは縦書きを用いている */
        vertical = true;
    }
}
```

- ▶ 縦書きのテキストと句読点の回転済みグリフは、それぞれ対応する未回転 Unicode キャラクタへマップされます。回転済みキャラクタを温存するには下記の文書オプションを用います：

```
decompose={vertical=_none}
```

6.4.4 日中韓分解：narrow・wide・vertical等

Unicode と多くのレガシエンコーディングでは、全角と半角のキャラクタという概念が使えます（ダブルバイト・シングルバイトキャラクタと呼ばれる時もあります）。デフォルトでは TET は、全角・半角キャラクタをそれぞれ対応する標準幅のキャラクタへ置き換える Unicode 分解 *wide・narrow* を行います。

元の全角・半角キャラクタを温存するには、*decompose* 文書オプションを用いてそれぞれの分解を無効化します：

```
decompose={wide=_none narrow=_none}
```

同様に、*small・square・vertical* 分解も日中韓キャラクタに対して効力を持ちます。これらの分解は（*wide* と *narrow* も含めて）デフォルトではすべて有効になっていますので、キャラクタはそれぞれ対応する標準的キャラクタへ変換されます。元のキャラクタを温存するには、それぞれの分解を無効化します。下記の文書オプションはすべての分解を無効化します：

```
decompose={none}
```

表 6.2 に、日中韓分解を例とともに示します。分解について詳しくは、112 ページの 7.3.2 「Unicode 分解」を参照してください。

表 6.2 日中韓互換分解の例（*decompose* オプションのサブオプション）

分解名	説明	対象 Unicode キャラクタ	分解が有効のとき (デフォルト)	分解が無効のとき
<i>narrow</i>	半角互換字体	U+FF61 ~ U+FFDC、 U+FFE8 ~ U+FFEE	ヲ U+30F2	㇇ U+FF66
<i>small</i>	CNS 11643 互換のための小型字体	U+FE50 ~ U+FE6B	、 U+002C	、 U+FE50
<i>square</i>	日中韓の組文字	U+3250、 U+32CC ~ U+32CF、 U+3300 ~ U+3357、 U+3371 ~ U+33DF、 U+337B ~ U+337F、 U+33FF、 U+1F131 ~ U+1F14E、 U+1F190、 U+1F200、 U+1F210 ~ U+1F231	キ □ U+30AD U+30ED	キ □ U+3314
<i>vertical</i>	縦書き字体	U+309F、 U+30FF、 U+FE10 ~ U+FE19、 U+FE30 ~ U+FE48	〰 U+FE37	{ U+007B
<i>wide</i>	全角字体	U+3000、 U+FF01 ~ U+FF60、 U+FFE0 ~ U+FFE6	￠ U+00A3	￠ U+FFE1

6.5 双方向アラビア文字・ヘブライ文字テキスト

TET は、アラビア文字やヘブライ文字といった右書き用字系による文書からテキストを正しく抽出するために、追加の処理を行います。こうした用字系ではしばしば左書きテキストが挿入されますので（数等）、そのような文書は、双方向であるといえます。双方向テキストの抽出には、以下に説明する処理ステップの一つないし複数が関与します。

6.5.1 双方向の一般的性質

右書き・双方向テキストを並べ替え 右書きの並びと左書きの並びは、論理的なテキストの正しい並びを形成するよう並べ替える必要があります。粒度が **word** 以上の場合、下記のページオプションを用いると、TET はテキストを論理順に発出します（これがデフォルト設定です）：

```
contentanalysis={bidi=logical}
```

双方向処理は下記ページオプションで明示的に無効化することもできます：

```
contentanalysis={bidi=visual}
```

ページの優勢テキスト向きを決定 双方向並べ替えは、単語内のキャラクタ群と行内の単語群に対して効力を持つばかりではなく、それ以外のページレイアウト認識の諸側面に対しても効力を持ちます。混在双方向行は場合によっては、ページ全体が右書きなのか左書きなのかを考慮に入れることなしには安心して並べ替えできないこともあります。この決定を自動的にを行うために、TET はページの優勢テキスト向きを調べ、そのページが主に左書きと見なすべきかそれとも主に右書きと見なすべきかにそのアルゴリズムを合わせます。

この決定は **bidilevel** オプションで上書きすることもできます。たとえば下記のオプションリストは、テキストの大多数が左書きのページ上であっても右書き処理を強制します：

```
contentanalysis={bidilevel=rtl}
```

グリフ順序 `TET_get_char_info()` と TETML 内の *Glyph* エレメントによって返されるグリフ情報は、つねに視覚的順序に従って、すなわち水平ベースラインについては左書きとして並べられます。この左書きグリフ順序によって、クライアントアプリケーションは、テキストの双方向ステータスを調べる必要なしに決め打ちの順序でグリフ座標を受け取ることができます。この動作は、実際のテキスト向きは右書きであるという事実にもかかわらず、アラビア文字やヘブライ文字のフォント内のグリフは概して、その左辺に参照点があり右へ進行しているという現実を反映しています。

6.5.2 アラビア文字テキストを後処理

アラビア文字の表示形を正規化し合字を分解 アラビア文字のキャラクタは、最高 4 種類の形で存在しています。単独形・語頭形・語中形・語尾形です。これらの形は、意味的には同一のキャラクタを表していますが、別々の Unicode 値を持っている場合があります。デフォルトでは TET は、すべての表示形を、それぞれ対応する正準形へ変換します。表 6.3 に示すように、**decompose** オプションを用いて表示形を温存することもできます（112 ページの 7.3.2 「Unicode 分解」を参照）。

PDF 文書では各表示形は、単独形の Unicode キャラクタへマップされていることもあれば、表示形のうちのひとつ（たとえばその文書の ToUnicode CMap 内の）へマップされて

いることもあるため、たとえ分解が無効化されていても、出力が表示形を含むことを TET は保証はできません。

表 6.3 アラビア文字の表示形を decompose オプションで処理

説明とオプションリスト	分解前	分解後 (論理順で)
語尾形・語頭形・単独形・語中形を分解 : decompose オプションなし (デフォルト) または decompose= {final=_all medial=_all initial=_all isolated=_all}	س U+FEB2	س U+0633
	س U+FEB3	س U+0633
	سر U+FD0E	س ر U+0633 U+0631
合字は、実際に合字グリフによって表されている場合にのみ分解されることに留意してください。複数の独立したグリフが用いられている場合には、それらが出力内で温存されます。	س U+FEB4	س U+0633
	لا U+FEFC	ل ا U+0644 U+0627
	ل ا U+0644 U+0627	ل ا U+0644 U+0627
語尾形・語頭形・単独形・語中形を温存 : decompose= {final=_none medial=_none initial=_none isolated=_none} または decompose=none	س U+FEB2	س U+FEB2
	س U+FEB3	س U+FEB3
	سر U+FD0E	سر U+FD0E
	س U+FEB4	س U+FEB4
	لا U+FEFC	لا U+FEFC

アラビア文字のタトウィールキャラクタを除去 タトウィールキャラクタ U+0640 (カシーダとも呼ばれます) は、単語を伸ばして行を埋めつくすようにするために頻繁に用いられます。タトウィールはそれ自体は何のテキスト情報も持ちませんので、通常これは、抽出されるテキスト内では必要ではありません。表 6.4 に示すように、*fold* オプションを用いてタトウィールキャラクタを温存することもできます (109 ページの 7.3.1 「Unicode 字形統合」を参照)。

表 6.4 タトウィールキャラクタ U+0640 を fold オプションで処理

説明とオプションリスト	字形統合前	字形統合後
アラビア文字のタトウィールキャラクタを除去 : fold オプションなし (デフォルト) または fold={{[U+0640] remove}} または fold={default}	- U+0640	なし
アラビア文字のタトウィールキャラクタ (デフォルトでは除去される) を温存 : fold={{[U+0640] preserve}}	- U+0640	- U+0640

6.6 内容分析

PDF 文書は、テキストの個々のキャラクタのページ上における位置のみならず、そのセマンティックス (Unicode マッピング) をも提供します。しかし多くの場合、単語・行・コラム・その他高次のテキストユニットに関する情報を伝えてはくれません。ページ上のテキストを構成するそれぞれの断片には、個々のキャラクタや音節や行、ないしそれらの任意の混合が含まれている可能性があります、明示的に単語や行やコラムの始まりや終わりを示す印はそこには一切ついていないのです。

さらに悪いことには、ページ上のテキスト断片の順序は、論理的な (読む) 順序とは違っている可能性があります。テキストの各部分をページ上に配置する際には規則など何もないのです。たとえば 2 段組みのページの場合でも、その内容の生成順はまず左コラムの 1 行目、次は右コラムの 1 行目、左コラムの 2 行目、右コラムの 2 行目、… となっているかもしれません。が、論理的な順序ならば、まず左コラム内のテキストをすべて処理した後に右コラムのテキストを処理しなければならないわけです。このような文書からテキストを抽出する場合には、ただ PDF ページ上の命令群を再生していただければ、一般には望ましくありません。テキストの論理構造が失われているからです。

TET の内容解析エンジンは、テキスト断片の内容・位置・関係を解析して、以下の目標を達成しようとしています：

- ▶ キャラクタ群から単語を再構成し、単語間に区切りキャラクタを (望まれていれば) 挿入。
- ▶ 冗長テキストを除去 (たとえば影付きに見せるためのダブリ等)。
- ▶ 複数行にまたがってハイフネーションされている単語の各部を再結合。
- ▶ テキストのコラム (区域) を認識。
- ▶ 区域内のテキスト断片をソート。ページ内の区域もソート。

これらの動作について以下詳しく説明します。こうした内容処理を制御するオプションについても解説します。

テキストの粒度 `open_page()` で `granularity` オプションを用いると、`get_text()` を 1 回呼び出すごとに返されるテキストの量を指定することができます。

- ▶ `granularity=glyph` と設定すると、各断片はそれぞれ 1 つのグリフをマップした結果を持ちます。これは複数のキャラクタになることもあります (合字の場合等)。このモードでは内容分析は無効にされ、TET は、ページ上の元通りのテキスト断片をその元通りの順序のまま返します。これは最も速いモードではありますが、これが有用なのは、TET クライアント側で精巧な後処理を行おうとするときのみです (あるいはテキストの論理構造には関心がなくて位置にのみ興味があるとき)。なぜならこのモードではテキストがページ全体に散らばってしまっている可能性があるからです。
- ▶ `granularity=word` と設定すると、単語検出機能アルゴリズムがキャラクタ群をまとめて論理的な単語を再構成します。各断片はそれぞれ 1 つの単語を持ちます。孤立した句読点 (カンマ・コロン・クエスチョンマーク・クオート等) はデフォルトでは独立した断片として返され、連続する句読点キャラクタは一個の単語としてグループ化されます (ピリオドキャラクタを連続させて点線のように見せかけている場合等)。ただし、句読点処理は変更することも可能です (91 ページの「欧文テキストの単語境界検出」を参照)。
- ▶ `granularity=line` と設定すると、単語検出機能によって認識された単語群をまとめて行を再構成します。ハイフン除去が有効のとき (デフォルト) は、行末でハイフンで分割された単語は再結合され、そのハイフン除去された完全な単語はその行に繰り込まれます。

- ▶ `granularity=page` と設定すると、ページ上に含まれるすべての単語が1つの断片で返されます。

複数の単語・行・段落の間には、選択された粒度がその単位より大きければ、それぞれ区切りキャラクタが挿入されます。たとえば `granularity=word` の場合、`TET_get_text()` は呼び出されるごとに単語をきっかり1つずつ返すのですから、単語区切りを挿入する必要などないわけです。

区切りキャラクタを指定するには、`TET_open_document()` の `wordseparator`・`linseparator` オプションを用います（区切りキャラクタを無効にするには `U+0000` を用います）。たとえば：

```
linseparator=U+000A
```

`granularity=glyph` の場合にはすべての内容分析動作が無効にされ、それ以外のすべての粒度設定では有効にされます。しかし、区切りオプションを用いればよりきめ細かな制御も可能です（後述）。

欧文テキストの単語境界検出 単語検出機能は、`glyph` を除くすべての粒度モードで有効にされ、ページ全体にでたらめな順序で散らばっているかもしれない複数のグリフをまとめて論理的な単語を再構成します。欧文テキストの単語境界は2つの判定基準によって認識されます：

- ▶ 精巧なアルゴリズムがグリフどうしの位置関係を解析して、キャラクタのグループを検出し、単語を再構成します。このアルゴリズムはさまざまな属性や特例を考慮して、レイアウトが複雑な場合やページ上のテキスト順序がばらばらな場合でも単語を正確に認識できるよう努めます。

`contentanalysis` ページオプションのサブオプション `usemetrics` を用いて、特殊な場合においてこのアルゴリズムを無効化することもできます。

- ▶ スペースや句読点（コロン・カンマ・ピリオド・括弧等）といったある種のキャラクタは、その幅・位置にかかわらずつねに単語境界と認識されます。`contentanalysis` ページオプションのサブオプション `useclasses` を用いて、特殊な場合においてこのアルゴリズムを無効化することもできます。

単語境界検出の際に句読点キャラクタを無視することは、たとえば、Web URL を扱う際に有用でしょう。URL では多くの場合、ピリオド・スラッシュキャラクタは語の一部と見なされるからです（図 6.5 参照）。`punctuationbreaks` オプションを `false` に設定すると、単語検出機能は句読点キャラクタを単語境界として扱わなくなります：

```
contentanalysis={punctuationbreaks=false}
```

注記 表意文字キャラクタによるテキストに対する単語境界検出は動作が異なります。詳しくは 86 ページの 6.4.2 「日中韓テキストの単語境界」を参照してください。



図 6.5
デフォルト設定 `punctuationbreaks=true` では URL は各部に分解されますが（上）、`punctuationbreaks=false` では各部はひとまとまりのまま保持されます（下）。

ハイフン除去 行末でハイフン区切りされた単語というものは通常、抽出したテキストを論理レベルで処理したいアプリケーションにとっては好ましくありません。そのため TET はハイフン除去、すなわちハイフン区切りされた単語の各部分の再結合を行います。より正確にいうと、行末の単語の末尾にハイフンキャラクタがあり、かつその次の行の最初の単語の先頭が小文字ならば、ハイフンは除去され、単語の前半部は次行後半部と結合されます。ただし同じ区域内に少なくともあと 1 行存在する場合に限りです。ダッシュキャラクタ（ハイフンではない）は変更されないまま温存されます。ハイフン区切りされた単語の各部分に変更が加えられることはなく、ただハイフンが除去されるだけです。ハイフン除去を無効にするには、`open_page()` で下記のオプションリストを用います：

```
contentanalysis={dehyphenate=false}
```

strategische Grundsätze – der
der Nutzung von Synergie-
in Branchen sowie in Unter-
dukterstellung. So verringert
bei der Produkterstellung –
g – seit längerem nicht nur

注記 区域の末尾でハイフン区切りされた単語は認識されませんので、ハイフン除去はそれに対しては一切行われません（すなわちそのハイフンはテキストの中に残ります）。

影付き・擬似太字テキスト除去 PDF 文書はときに、ページの意味内容には貢献しない、ただある種の視覚効果を生み出すためだけの冗長テキストを含んでいます。影付きテキスト効果を生み出すにはたいてい、テキスト本体を少しずつ位置をずらしながら複数複製して重ねるといった方法が採られます。この各層のテキストに不透明な色をつければ、下層のテキストはほとんど隠れ、見える部分が影付き効果を生み出すように見かけ上見えるのです。

同様に、ワープロソフトはときに擬似太字テキスト生成機能に対応しています。ボール

Introduction

ドフォントが入手不可能なときにもテキストを見かけ上太字に見せかけるため、そのテキストはページ上に同じ色で何度も配置されます。その際にほんの少し位置をずらしていけば、太字テキストであるかのように見せられるわけです。

擬似影付きや擬似太字テキスト、ないし同様の視覚効果は、テキストを抽出して再利用しようとする際に困った問題をひき起こします。ただ視覚効果のためだけの冗長テキスト内容が、ページ内容としては不要であるにもかかわらず一緒に処理されてしまうためです。

単語検出機能が有効にされている場合、デフォルトでは TET はこうした冗長な視覚効果を認識して除去します。影付き除去を無効にするには、以下のページオプションを用います：

```
contentanalysis={shadowdetect=false}
```

アクセント付きキャラクタ 多くの言語で、アクセントなどの分音記号が、別のキャラクタのそばに配置されて複合キャラクタを形成します。TeX をはじめとするいくつかの組版プログラムでは、2 つのキャラクタ（字母キャラクタとアクセント）を別々に出力して

1 個の複合キャラクタを生成します。たとえば、**ä** キャラクタを生成するために、まず文字 **a** がページ上に配置され、ついで分音符キャラクタ **¨** がその上に配置されます。TET はこの状況を検出し、2 個のキャラクタを再結合して正しい複合キャラクタを形成します。

6.7 レイアウト分析と文書スタイル

TET は、最も可能性の高いテキスト抽出順序を決定するために、ページ上のテキストのレイアウトを分析します。この自動処理は、いくつかのオプションで支援することも可能です。文書の性質について事前の知識がある場合には、適切なオプションを与えることによってテキスト抽出結果を向上させることができます。

各種文書スタイル さまざまなレイアウトやスタイルの文書进行处理するために、いくつかの内部パラメタが利用可能です。たとえば、新聞のページは大量のテキストが多段組になっていることが多く、事業報告書は余白に注釈がしばしば現れる、などです。TET は、いくつかの種類の文書に対する定義済み設定を含んでいます。これらの設定は、`TET_open_page()` でオプションを用いて有効にすることができます：

```
docstyle=papers
```

入力文書の種類がわかっている場合には、`docstyle` ページオプションおよび（あてはまる場合には）`layouthint` ページオプションの適切な値を与えることを強く推奨します。`docstyle` オプションを与えれば、高度なレイアウト認識アルゴリズムが有効になります。ただし、このオプションに不適切な値を与えてしまうと逆に生成結果が悪化する場合があります。

`docstyle` オプションでは以下の種類が利用可能です（表 6.5 にいくつか典型的な文書スタイルの例を挙げます）：

- ▶ **book**：通常のページによる典型的な書籍レイアウト
- ▶ **business**：ビジネス文書
- ▶ **Cad**：技術または建築図面。通例、非常に断片化しています。
`fancy`：複雑な、またときにイレギュラーなレイアウトを持つ、意匠を凝らしたページ
- ▶ **forms**：構造化されたフォーム
- ▶ **generic**：とくに分類のない最も一般的な文書
- ▶ **magazines**：雑誌の記事。多くは3段組ないしそれ以上で、画像やグラフィックがちりばめられている
- ▶ **papers**：多段組・大紙面・小活字の新聞
- ▶ **science**：科学記事。多くは2段組ないしそれ以上で、画像・式・表組などがちりばめられている
- ▶ **searchengine**：この分類は、入力文書の特定の種類を指すものではなく、TET を検索エンジンのためのインデクサの典型的要請に最適化します。生テキストのみを発出し、処理を高速化するために、いくつかのレイアウト検出機能が無効化されます。たとえば、表組・ページ構造認識が無効化されます。
- ▶ **Simple line**：単純化した行指向のレイアウト。このモードは、ハイフン除去・表組検出を無効化し、テキストを元の行レイアウトになるべく忠実に取得します。これは、似たような文書を多数処理する場合に、かつ、アプリケーションがそのレイアウトをあらかじめ知っている場合に役立つでしょう。
- ▶ **spacegrid**：この分類は、メインフレームシステムでよく生成されるリスト指向のレポートを対象としています。この種の文書の特徴は、視覚レイアウトが、テキストの明示的な位置合わせではなく、空白キャラクタによって作り出されていることです。この種の文書进行处理するには、いくつかの処理ステップ（影付き検出など）をスキップしうるので、テキスト抽出が高速化されえます。

最も適切な文書スタイルを選ぶことによって、処理を速め、テキスト抽出結果を向上させる可能性があります。

表 6.5 いろいろな文書スタイル

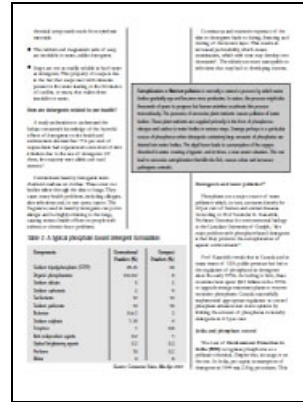
docstyle=book



docstyle=business



docstyle=fancy



docstyle=magazines



docstyle=papers



docstyle=science



docstyle=spacegrid

2010 Census of Population and Housing - Summary File 3

2010 Census of Population and Housing - Summary File 3

2010 Census of Population and Housing - Summary File 3

Characteristic	Total	White	Black	Hispanic	Asian	Native Hawaiian	Other
Total	308,745	208,112	48,112	28,112	12,112	2,112	17,401
Male	154,373	104,056	24,056	14,056	6,056	1,056	8,701
Female	154,372	104,056	24,056	14,056	6,056	1,056	8,700

docstyle=cad

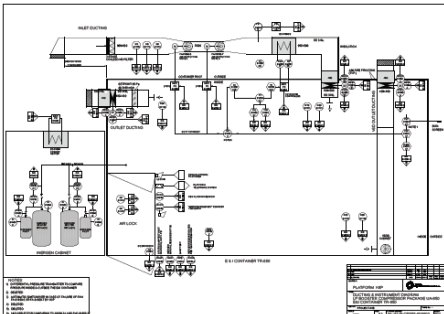


表 6.5 いろいろな文書スタイル

docstyle=simpleline

A screenshot of a document page with a complex layout. It features multiple columns of text, various headings, and a table-like structure. The text is dense and appears to be a technical or financial report. The layout is organized into several distinct sections, with some text in bold and some in italics. The overall appearance is that of a professional, multi-column document.

複雑なレイアウト 文書の種類によっては、非常に凝ったページレイアウトを用いるものがあります。たとえば雑誌や定期刊行物では、TET はページ上の段組間の関係を正しく決定することができない場合があります。このような状況では、処理時間を長くかけることにより、抽出されるテキストを改善することが可能です。これは *structureanalysis*・*layoutanalysis* ページオプションで制御できます。例：

```
structureanalysis={list=true bullets={{fontname=ZapfDingbats}}}  
layoutanalysis = {layoutrowhint={full separation=preservecolumns}}  
layoutdetect=2  
layouteffort=high
```


6.8 表組・リスト検出

表組検出 TET は、表レイアウトを検出して、表組の内容を表行・列・セルに構造化します。表組に関してページ上で検出された情報は API によって直接提供されることなく、下記の例のように TETML 出力内でのみ利用可能となります：

```
<Table llx="302.14" lly="639.72" urx="525.50" ury="731.50">
  <Row>
    <Cell colSpan="3" llx="306.14" lly="641.52" urx="516.67" ury="650.52">
      <Para>
        <Box llx="306.14" lly="641.52" urx="516.67" ury="650.52">
          <Word>
            <Text>TET</Text>
            <Box llx="306.14" lly="641.52" urx="319.70" ury="650.52"/>
          </Word>
          <Word>
            <Text>processes</Text>
            <Box llx="321.67" lly="641.52" urx="356.89" ury="650.52"/>
          </Word>
          <Word>
            <Text>all</Text>
            <Box llx="358.85" lly="641.52" urx="368.15" ury="650.52"/>
          </Word>
          ...
        </Box>
      </Para>
    </Cell>
  </Row>
</Table>
```

TET はオプションに、表組レイアウトを向上させるためにしばしば用いられる縦横の罫線や色付きのボックスを分析することもできます。このベクトルグラフィック分析はデフォルトでは無効化されています。これは、そのような図形要素がある場合には表組・レイアウト検出の結果を向上させます。ベクトルグラフィック分析を有効化するには、たとえば下記のように、ページオプション **vectoranalysis** を用います：

```
vectoranalysis={structures=tables}
```

表セルがベクトルグラフィックによって完全に枠取りされている場合には、TET に、セル枠線のみに基づいて（テキスト位置を分析するのではなく）セルを識別するよう指示することもできます。以下のページオプションは、表組検出の結果を向上させますが、ただし、セルが完全に枠取りされている、かつ表行または表列結合を一切含まない表に対してのみ有効です：

```
vectoranalysis={structures=usevectoronly}
```

デフォルトでは、表組検出機能は、ページの高さまたは幅とほぼ同じ長さの行を無視します。もし長い行を持つ大きな表組が存在していることがわかっている場合には、これらの行を考慮するよう TET に指示することもできます：

```
vectoranalysis={structures=usevectoronly pagesizelines=true}
```

以下のページオプションは、複雑な表レイアウトにおいて、表行・表列結合の識別を有効化します：

```
vectoranalysis={structures=vectoriterative}
```

リスト検出 TET はページ上のリスト構造を検出します。検出されるリストは、1 個ないし複数のリスト項目から成ります。各リスト項目は、1 個のリストラベルと 1 個の本文部から成ります。リストラベルはたとえばビュレット・数字・文字などです。本文部は 1 個ないし複数の段落から成ります。検出できるリストラベルは行の頭にあるもののみです。リストはネストされていてもかまいません。すなわち、あるリスト項目の本文に、また別のリストが内容として入っていてもかまいません。ページ上で検出されたリストに関する情報は、API によって直接は提供されず、TETML 出力内においてのみ利用可能です。たとえば以下の例のような出力になります：

```
<List>
<Item>
  <Label>
    <Word>
      <Text>•</Text>
      <Box llx="35.00" lly="737.00" urx="45.50" ury="767.00"/>
    </Word>
  </Label>
  <Body>
    <Para>
      <Box llx="35.00" lly="737.00" urx="169.15" ury="767.00">
        <Word>
          <Text>four</Text>
          <Box llx="70.00" lly="737.00" urx="85.00" ury="767.00"/>
        </Word>
        <Word>
          <Text>sorts</Text>
          <Box llx="92.50" lly="737.00" urx="169.15" ury="767.00"/>
        </Word>
      </Box>
    </Para>
    ...
  </Body>
</Item>
</List>
```

互換性の理由から、リスト検出はデフォルトでは無効になっており、以下のページオプションを用いて有効化する必要があります：

```
structureanalysis={list=true}
```

以下のオプションをさらに使ってリスト検出を制御することもできます：

- ▶ ページオプション *structureanalysis* のサブオプション *bullets* を使うと、ビュレットキャラクターのために使用されている Unicode 値群とフォント名群を定義することができます。そのデフォルトリストには、リストラベルとして広く使用されているさまざまな Unicode キャラクターが内容として入っています。たとえばアステリスク・ダーシ・ビュレットなどです。
- ▶ ページオプション *contentanalysis* の *numericentities* サブオプションを使うと、複合番号など数値実体をともに構成する句読点と数字との関係を制御できます。たとえば見出しの節番号「10.4」は以下のように扱われます：

デフォルト `contentanalysis={numericentities=keep}` を用いた場合：1 個の単語「10.4」
として
`contentanalysis={numericentities=split}` を用いた場合：個別の単語「10」・「.」・「4」として。

6.9 領域が空かどうかをチェック

TET を活用して、ページ上の特定の領域が空かどうかを、すなわち、後処理用途のために有用かもしれないテキスト・画像・ベクトルグラフィックオブジェクトを内容として持っているかどうかを、チェックすることもできます。たとえば、ページ上のどこかにスタンプ・ページ番号・バーコードなどアイテムを配置する必要があります。ページ内容が可変の場合、ページ上で何らかの既存の内容にかぶらずにスタンプやバーコードを配置できる場所を見つけるのは難しい可能性があります。TET は、目がける領域が実際に空かどうかをチェックすることが可能です。この機能は、TET API を用いて以下のように動作します：

- ▶ *emptycheck* ページオプションは、この機能を有効化し、ページ内容取得をすべて無効化します。
- ▶ チェックさせたい長方形領域の座標を *includebox* ページオプションで与えます。このオプションは多くの場合、複数の枠を受け入れますので、二重の中括弧が必要です（しかし枠 1 個だけでも *emptycheck* は可能です）。

```
includebox={{100 20 500 100}}
```

includebox オプションを与えなかった場合には、クリッピング領域全体がチェックされます。これを用いると空のページを見つけられます。

- ▶ ページ内容を取得するのではなく、*TET_get_text()* はこのチェックの結果として文字列 *empty* か *notempty* のいずれかを返します。

この機能は、TET コマンドラインツールで下記のように使用できます：

```
tet --pageopt "emptycheck includebox={{300 760 450 820}}" input.pdf
box on page 1: empty
box on page 2: empty
box on page 3: notempty
```

TET クックブックの *emptycheck* トピックでは、ページ上の長方形が空かどうかをチェックする方法を演示しています。

6.10 注釈内のテキスト

PDF 文書では、注釈（コメント）がテキスト・画像を内容として持つことがあります。テキストが注釈内に格納される方式には、根本的に異なる 2 種類があります（表 6.6 参照）：

- ▶ 注釈は**体裁ストリーム**を持つことがあります。これは、フォントと色を持った完全な PDF グラフィックモデルを使用できるものです（ページのように）。体裁ストリーム内のテキストには書式と位置があります。体裁ストリームは画像を内容として持つこともあります。体裁ストリームはページ上で表現されますので可視です。TET は体裁ストリームをデフォルトで処理しますが、これは文書オプション `engines={noannotation}` を用いて変更することもできます。
- ▶ 注釈は、**Contents** というエントリを内容として持つこともあります。これは、書式や位置が一切ない単なる Unicode 文字列から成るものです。PDF 規格ではこのエントリを次のとおり記述しています：「それはその注釈のために表示させたいテキストであるか、あるいはもしもその注釈がテキストを表示しない場合にはその注釈の内容を人が読める形で表した代替記述である」。このテキストを使うかどうかは各アプリケーションごとに決める必要があります。**Contents** エントリは、TETML 出力を生成する際にはデフォルトで処理されますが、API を使用する際には pCOS メソッド群を用いて明示的に取得する必要があります。

表 6.6 体裁ストリームと Contents エントリの中の注釈テキストの違い

	注釈の体裁ストリーム	注釈の Contents エントリ
一般		
内容として持てるもの	テキスト・画像	テキスト
テキストが書式・資格情報を持つ	○	×
ページオプション <code>includebox</code> に従う	○	×
ページオプション <code>granularity</code> と文書オプション <code>wordseparator</code> などに従う	○	×
API メソッドを用いた抽出		
関連 API メソッド	TET_get_text() TET_get_image_info() TET_write_image_file()	TET_pcos_get_string() TET_pcos_get_number()
抽出を制御する手段	文書オプション <code>engines={annotation}</code>	アプリケーションのコード
テキストが表れる場所	ページ内容	別途
サンプルコード	<code>extractor · images_per_page</code> サンプル	TET クックブック内の <code>text_from_annotations</code> トピック
その他注記	注釈は、レイアウト分析や画像連結などページ処理に統合されています	アプリケーションは段落区切り U+000D を U+000A へ置換する必要があります
TETML を用いた抽出		
抽出を制御する手段	文書オプション <code>engines={annotation}</code>	ページオプション <code>tetml={elements={annotations}}</code>
テキストが表れる場所	Page の Content エレメント	Annotations エレメント

表 6.6 体裁ストリームと Contents エントリの中の注釈テキストの違い

	注釈の体裁ストリーム	注釈の Contents エントリ
フォント・画像・色空間を Resources セクションへ提供	○	×

PDF 内のフォームフィールドも注釈としてコードされています。ですのでそれも TET の注釈エンジンの対象です。フォームフィールドのアクティブ内容はエントリから /V (value = 値) 取得できます。pCOS クックブックのトピック *formfields* を参照してください。

7 高度な Unicode 処理

7.1 Unicode のさまざまな重要概念

この節では、Unicode に関する基本的な情報を提供します。TET におけるテキスト処理は Unicode 規格に大いに依存しているからです。Unicode Web サイトではさらに詳しい情報が大量に提供されています：

www.unicode.org

キャラクタとグリフ テキストを扱う際には以下の概念をはっきり区別することが重要になります：

- ▶ **キャラクタ**は、言語の中で情報を伝える最小の単位です。代表例としてはラテンアルファベットの音素文字や、日本語の音節文字、中国語の表意文字が挙げられます。キャラクタは意味を持ちます。すなわち意味的な実体であるといえます。
- ▶ **グリフ**は、1つないし複数のキャラクタを表す形状です。グリフは外観を持ちます。すなわち表象的な実体であるといえます。

キャラクタとグリフとの間には一対一の対応は存在しません。たとえば、合字は1つのグリフですが複数のキャラクタを表します。その一方では、1つのグリフを場面に応じて異なるキャラクタを表すために使いまわしたりすることもあります（つまりキャラクタどうしの形が同じという場合が存在します。図 7.1 参照）。

TET の Unicode 後処理によって、グリフ群と生成キャラクタ群との関係はさらに変わることもあります。たとえば、分解によって1個のキャラクタが複数のキャラクタに変換されることがあり、また、字形統合によってキャラクタが除去されることもあります。こうした理由から、キャラクタとグリフの間にはいかなる特定の関係をも前提することはできません。

BMP と PUA Unicode ベースの環境では以下の用語が頻出します：

キャラクタ

グリフ

U+0067 LATIN SMALL LETTER G

U+0066 LATIN SMALL LETTER F +
U+0069 LATIN SMALL LETTER I

U+2126 OHM SIGN または
U+03A9 GREEK CAPITAL LETTER OMEGA

U+2167 ROMAN NUMERAL EIGHT または
U+0056 V U+0049 I U+0049 I U+0049 I

図 7.1
グリフとキャラクタ
の関係

- ▶ **基本多言語面 (BMP)** は、Unicode 範囲 U+0000 ~ U+FFFF 内のコード点から成ります。Unicode 規格は、さらに多くのコードを追加面群に、すなわち範囲 U+10000 ~ U+10FFFF 内に含んでいます。
- ▶ **私用領域 (PUA)** は、私用のために予約されているいくつかの範囲の一つです。Unicode 規格はこの範囲内にいかなるキャラクタも指定していませんので、PUA コード点は一般的なやりとりには使えません。基本多言語面は PUA を範囲 U+E000 ~ U+F8FF 内に含んでいます。第十五面 (U+F0000 ~ U+FFFFFD) と第十六面 (U+100000 ~ U+10FFFFD) はまるごと私用のために予約されています。

さまざまな Unicode 符号化形式 (UTF 形式) Unicode 規格では、各キャラクタに番号 (コード点) を割り当てています。これらの番号をコンピュータ処理で利用するためには、これらを何らかの方法で表す必要があります。Unicode 規格ではこれを符号化形式と呼びます (以前は変換形式と呼んでいました)。この用語はフォントの符号化方式 (エンコーディング) と混同してはいけません。Unicode では以下の符号化形式を定義しています :

- ▶ **UTF-8**: これは、コード点を 1 ~ 4 バイトで表す可変長形式です。範囲 U+0000 ~ U+007F 内の ASCII キャラクタは範囲 00 ~ 7F 内のシングルバイトで表されます。範囲 U+00A0 ~ U+00FF 内の Latin-1 キャラクタは 2 バイトで表され、その第一バイトは必ず 0xC2 か 0xC3 (これらの値は Latin-1 では $\hat{A} \cdot \hat{A}$ を表します) になります。
- ▶ **UTF-16**: 基本多言語面 (BMP) 内のコード点を 16 ビット値 1 個で表します。追加面群内のコード点、すなわち範囲 U+10000 ~ U+10FFFF 内のものは、16 ビット値の対で表します。この対をサロゲートペア (代用対) といいます。サロゲートペア 1 個は、範囲 D800 ~ DBFF 内の高位サロゲート値 1 個と、範囲 DC00 ~ DFFF 内の低位サロゲート値 1 個から成ります。高・低サロゲート値はサロゲートペアの一部としてのみ現れることができ、それ以外の場面では現れることができません。
- ▶ **UTF-32**: 各コード点を 32 ビット値 1 個で表します。

Unicode 符号化スキームと BOM (Byte Order Mark) コンピュータアーキテクチャによってバイトの順序は異なります。すなわち、大きな値 (16 ビットや 32 ビット) を構成するバイト群を、最高位バイトを先頭に格納するか (ビッグエンディアン)、それとも最低位バイトを最初に格納するか (リトルエンディアン) という違いがあります。ビッグエンディアンアーキテクチャのよく知られた例は PowerPC であり、一方 x86 アーキテクチャはリトルエンディアンです。UTF-8 と UTF-16 はシングルバイトよりも大きな値に基づいていますので、バイト順序を考慮する必要がここで生じてきます。符号化スキーム (上述の符号化形式とは異なることに留意) は、符号化形式に加えてバイト順序を指定します。たとえば、UTF-16BE はビッグエンディアンバイト順序の UTF-16 を意味します。バイト順序が事前にわからない場合には、コード点 U+FEFF を用いて指定することもできます。これを BOM (Byte Order Mark) といいます。UTF-8 では BOM は必須ではありませんが、存在することもでき、その場合はバイト列を UTF-8 として識別するために用いることができます。表 7.1 に、さまざまな符号化形式における BOM の表現を挙げます。

表 7.1 さまざまな Unicode 符号化形式における BOM

符号化形式	BOM (16 進)	WinAnsi での視覚表現 ¹
UTF-8	EF BB BF	ï»¿
UTF-16 big-endian	FE FF	þÿ
UTF-16 little-endian	FF FE	ÿþ
UTF-32 big-endian	00 00 FE FF	■ ■ þÿ
UTF-32 little-endian	FF FE 00 00	ÿþ ■ ■

1. 四角 ■ は null バイトを表します。

組文字とキャラクタ列 グリフのなかには、複数のキャラクタの列にマップされるものがあります。たとえば合字は、その構成キャラクタ群に従って複数のキャラクタにマップされます。しかし組文字は分割してよい場合とよくない場合があります（図 7.1 のローマ数字等）、それはフォント内・PDF 内の情報によって決まるとともに、*decompose* 文書オプションにも依存します（109 ページの 7.3 「Unicode 後処理」を参照）。

適切ならば、TET は組文字を構成キャラクタ列に分割します。このキャラクタ列は、*TET_get_text()* が返すテキストに組み込まれます。各キャラクタごとに、その元となったグリフ（群）に関する情報は *TET_get_char_info()* で得ることができますが、その際、そのキャラクタがキャラクタ列内の先頭なのかそれとも後続なのかという情報も一緒に得られるようになっていきます。位置情報はキャラクタ列内の先頭キャラクタに対してのみ返されます。キャラクタ列内の後続キャラクタは固有の位置情報・幅情報というものを一切持たないので、先頭キャラクタと併せて処理する必要があります。

対応グリフを持たないキャラクタ ページ上のグリフは、そのすべてが 1 つないし複数の Unicode キャラクタにマップされますが、逆に TET が出力するキャラクタは、そのすべてが実在のグリフにマップされているとは限りません。対応するグリフを持つキャラクタを有形キャラクタ（real character）と呼び、持たないものを無形キャラクタ（artificial character）と呼びます。このような、直接対応するグリフがないのに出力される無形キャラクタは、いくつかの種類に分類できます。

- ▶ 組文字（上述）は複数の Unicode キャラクタの列にマップされますが、このとき列内の先頭キャラクタは実在のグリフに対応しますが、残りのキャラクタは対応グリフを持ちません。
- ▶ *linseparator*・*wordseparator*・*paraseparator* オプションで挿入される区切りキャラクタは、目に見えるいずれのグリフにも照応しません。

7.2 テキストの前処理（フィルタリング）

TET は、有用でなさそうなテキストを除去するためにいくつかのフィルタを適用します。これらのフィルタはテキストを、いかなる Unicode 後処理ステップをも適用する前に変更します。いくつかのフィルタはつねに有効であり、それ以外は単語検出機能を必要としないので *granularity=word* 以上の場合にのみ有効です。

7.2.1 すべての粒度のためのフィルタ

以下のフィルタはすべての粒度で使用できます。

異常な文字サイズのテキスト 非常に小さなテキストや非常に大きなテキストは無視させることもできます。たとえばページ背景の大きなキャラクタです。上限・下限は *fontsize* オプションで制御できます。デフォルトでは、すべての文字サイズのテキストが抽出されます。

下記のページオプションは、抽出するテキストの文字サイズの範囲を 10 ~ 50 ポイントに制限します。これを外れている文字サイズのテキストは無視されます：

```
fontsize={10 50}
```

不可視テキスト 不可視テキスト（すなわち *textrendering=3* のテキスト）はデフォルトでは抽出されます。PDF 内のテキストは、*textrendering* プロパティ以外にもさまざまな理由で見えなくなっている可能性があることに留意してください。たとえばテキストの色が背景色と同一であるかもしれませんし、テキストがページ上の他のオブジェクトに隠れているかもしれません。ここで記述する動作は *textrendering=3* のテキストにのみ効力を持ちます。この PDF 技法は OCR の生成テキストに対して広く用いられています。スキャンされたラスタ画像に「重ねて」テキストが見えない形で存在しているのです。

不可視テキストは、*TET_get_char_info()* が返す *TET_char_info* 構造の *textrendering* メンバによって識別することもできますし（208 ページの表 10.16 を参照）、あるいは TETML 内の *Glyph/@textrendering* 属性によって識別することもできます。

不可視テキストを無視したいときは下記のページオプションを用います：

```
ignoreinvisibletext=true
```

特定フォント名またはフォント種別のテキストを完全無視 場合によっては、1 個ないし複数のフォントを名前前で指定してそのテキストを完全に無視させることが有用でしょう。たとえば、意味のあるテキストをまったく構成しない記号フォントなどです。あるいは、問題のあるフォントをフォント種別で指定することもできます。これは、装飾のために用いられることのある Type 3 フォントに対して主に有用です。このフィルタは、*glyphmapping* 文書オプションの *remove* サブオプションによって制御できます。

たとえば、Type 3 フォントのテキストをすべて無視：

```
glyphmapping={{fonttype={Type3} remove}}
```

Webdings・Wingdings・Wingdings 2・Wingdings 3 フォントのテキストをすべて無視：

```
glyphmapping={{fontname=Webdings remove} {fontname=Wingdings* remove}}
```

フォント名に対する条件とフォント種別に対する条件とを組み合わせることも可能です。たとえば、文字 A で始まるすべての Type 3 フォントのテキストを無視：

```
glyphmapping={{fonttype={Type3} fontname=A* remove}}
```

ページ装飾 タグ付き PDF 中のページ装飾は、本文外のテキストまたは画像を示します。よくある例はランニングヘッダおよびフッタ、たとえばページ番号です。タグ付き PDF 文書では、このようなページ装飾に標識することができます。デフォルトでは TET はページ装飾を通常の内容と同様に抽出します。しかし、ページオプション *ignoreartifacts* を用いてページ装飾をスキップすることも可能です。このオプションは API と TETML の両方に効力を及ぼします。

あるいは、ページ装飾を、*TET_char_info* 構造 (208 ページの表 10.16 を参照) の *attributes* メンバか、TETML 内の *Glyph/@artifact*・*Text/@artifact* 属性を用いて識別することもできます：

```
<Para>
  <Box llx="76.58" lly="765.12" urx="82.58" ury="777.12">
    <Word>
      <Text artifact="true">6</Text>
      <Box llx="76.58" lly="765.12" urx="82.58" ury="777.12"/>
    </Word>
  </Box>
</Para>
```

7.2.2 粒度 word 以上のためのフィルタ

以下のフィルタは *granularity=word*・*line*・*page* でのみ使用できます。

ハイフン除去 ハイフン除去は、ハイフンを削除して、ハイフンで分割されていた単語の各部分を結合させます。

単語を複数行に分割するために用いられているハイフンは、*TET_char_info* 構造の *attributes* メンバによって識別することもできますし (208 ページの表 10.16 を参照)、あるいは TETML 内の *Glyph/@hyphenation* 属性によって識別することもできます。

ハイフン除去は下記のページオプションによって無効化することができます：

```
contentanalysis={dehyphenate=false}
```

ハイフン報告 ハイフン除去が有効になっているとき、生成されるグリフリスト内、すなわち *TET_get_char_info()* が返すグリフのリスト内で、あるいは TETML 内の *Glyph* エレメント群で、ハイフンネーションされた単語の各部の間のハイフンキャラクタが報告されるかどうかを選ぶことができます。デフォルトではハイフンは除去されます。

しかし、応用によっては、ページ上のハイフンの正確な位置を知る必要がある場合があります。たとえば、TET クックブックの *highlight_search_terms*・*search_and_replace_text* トピックでは、元の単語の上に注釈または置換テキストをかぶせる際にハイフングリフを考慮に入れています。このような状況の場合には、下記のページオプションを用いれば、ハイフン除去処理によって検知されたすべてのハイフンを含めるよう TET に指示することができます：

```
contentanalysis={keeplyphenglyphs=true}
```

ハイフンは、*TET_get_char_info()* が返す *TET_char_info* 構造内の *attributes* メンバの *TET_ATTR_DEHYPHENATION_ARTIFACT* フラグを用いて識別することもできますし (208 ページの表 10.16 を参照)、あるいは、TETML 内で *Glyph/@dehyphenation* 属性の値 *artifact* (タグ付き PDF 内の Artifacts = ページ装飾とは無関係) で識別することもできます。

影付き除去 影付きや擬似太字といった視覚効果のためだけの冗長テキストは削除されます。

影付き・擬似太字テキストは、*TET_char_info* 構造の *attributes* メンバによって識別することもできますし(208 ページの表 10.16 を参照)、あるいは TETML 内で *Glyph/@shadow* 属性によって識別することもできます。

影付き除去は下記のページオプションで無効化できます：

```
contentanalysis={shadowdetect=false}
```

7.3 Unicode 後処理

TET は、抽出したテキストを構成する Unicode キャラクタ群を微調整するためのさまざまな制御手段を提供しています。この節で述べる各種の後処理ステップは、Unicode 規格で定義されているものです。これらは TET で利用可能であり、以下の順序で処理されます：

- ▶ 字形統合は、*fold* 文書オプションによって制御され、特定のキャラクタ群に対して温存・除去・置換のいずれかを行います。例：単語の分割に用いられているハイフンを除去。アラビア文字のタトゥールキャラクタを除去。
- ▶ 分解は、*decompose* 文書オプションによって制御され、1 個のキャラクタを 1 個ないし複数の等価なキャラクタへ置き換えます。例：合字を分割。全角英数・記号をおのの対応する非全角キャラクタへマップ。
- ▶ 正規化は、*normalize* 文書オプションによって制御され、テキストを正規化 Unicode 形式の一つへ変換します。例：字母キャラクタと分音キャラクタを結合して通用キャラクタ化。オーム記号をギリシャ文字オメガへマップ。

注記 Unicode 後処理は、*granularity=glyph* と TETML 内の *Glyph* エレメントには適用されません。これらの場合には字形統合・分解・正規化は行われません。

7.3.1 Unicode 字形統合

字形統合は、1 個ないし複数の Unicode キャラクタを処理して、各キャラクタに対して特定の操作を適用します。以下の操作が利用可能です：

- ▶ キャラクタを温存。
- ▶ キャラクタを除去。
- ▶ 別の（固定の）キャラクタへ置き換え。

字形統合は連鎖されません：字形統合の出力が、利用可能な字形統合によってさらに処理されることはありません。字形統合は、Unicode テキスト出力に対してのみ効力を持ち、*TET_char_info* 構造内で、または TETML の *<Glyph>* エレメント群で報告されるグリフの集合に対しては効力を持ちません。たとえば、ある Unicode キャラクタ群が字形統合によって除去された場合でも、その元のキャラクタ群を生み出したそれに対応するグリフ群は報告されます。

読みやすくするために、以下の表の中の例では、*fold* 文書オプションリストのサブオプションを個別に記しています。複数の字形統合を適用したいときには、これらのサブオプションを連結して単一の大きな *fold* オプションリストにする必要があることに留意してください。*fold* オプションを複数回与えてはいけません。たとえば、下記は誤りです：

```
fold={ [[:blank:]] U+0020 } fold={ [_dehyphenation remove] }      誤り！
```

下記の文書オプションリストは、複数の字形統合に対する正しい文法を示しています：

```
fold={ [[:blank:]] U+0020 } [_dehyphenation remove] }
```

字形統合のさまざまな例 表 7.2 に、字形統合のさまざまな応用を演示するさまざまな *fold* オプションの例を挙げます。これらのオプションは、*TET_open_document()* に対するオプションリストの中で与える必要があります。TET は、全 Unicode キャラクタから選択された部分集合に対して字形統合を適用することもできます。これを Unicode 集合といいます。その文法は、171 ページの「Unicode 集合」で解説しています。

表 7.2 さまざまな fold オプションの例

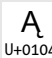








説明とオプションリスト	字形統合前	字形統合後
1 個の Unicode 集合内のすべてのキャラクタを除去		
ISO 8859-1 (Latin-1) 内のキャラクタのみを出力内に保持、すなわち、基本 欧文ブロック外のすべてのキャラクタを除去： fold={{[^\u0020-\u00FF] remove} default}	 U+0104	なし
すべての非アルファベットキャラクタ (句読点・数字など) を除去： fold={{[:Alphabetic=No:] remove} default}	7 U+0037	なし
数字以外のすべてのキャラクタを除去： fold={{[^[:General_Category=Decimal_Number:]] remove} default}	7 U+0037	7 U+0037
すべてのダッシュ・約物キャラクタを除去します： fold={{[:General_Category=Dash_Punctuation:] remove} default}	A U+0041	なし
すべての双方向制御キャラクタを除去します： fold={{[:Bidi_Control:] remove} default}	- U+002D	なし
標準または表意文字異体字シーケンス (IVS) に対するすべての異体字セ クタを除去します： fold={{[[\uFE00-\uFE0F][\U000E0100-\U000E01EF]] remove} default}	   U+2268 U+FE00 U+2268	 U+2268
1 個の Unicode 集合内のすべてのキャラクタを別のキャラクタへ置き換え		
空白字形統合：Unicode 空白キャラクタのすべての種類を U+0020 へマ ップ： fold={{[:blank:] U+0020} default}	- U+00A0	U+0020
ダッシュ字形統合：Unicode ダッシュキャラクタのすべての種類を U+002D へマ ップ： fold={{[:Dash:] U+002D} default}	- U+2011	- U+002D
すべての未割り当てキャラクタ (すなわち、キャラクタが割り当てられてい ない Unicode コード点) を U+FFFD へマ ップ： fold={{[:Unassigned:] U+FFFD} default}	U+03A2	 U+FFFD
個別のキャラクタに対して特別処理		
改行位置のすべてのハイフンキャラクタを温存しつつ、残りのデフォルト字 形統合を保持。これらのキャラクタは TET によって内部的に識別されていま すので (固定の Unicode プロパティを持つのではなく)、この字形統合のド メインを指定するにはキーワード <code>_dehyphenation</code> を用います： fold={{_dehyphenation preserve} default}	- U+002D	- U+002D
アラビア文字のタトウィールキャラクタ (デフォルトでは除去されます) を 温存： fold={{[U+0640] preserve} default}	- U+0640	- U+0640
さまざまな約物キャラクタをおのおの対応する ASCII キャラクタへ置き換 え： fold={{[U+2018] U+0027} {[U+2019] U+0027} {[U+201C] U+0022} {[U+201D] U+0022} default}	" U+201C	" U+0022
フォント独自の PUA キャラクタを処理。例：日本語の外字やロゴフォント		
デフォルト動作：PUA キャラクタ群を Unicode 置換キャラクタ U+FFFD へ置 き換え： fold={{[:Private_Use:] U+FFFD} default}		 U+FFFD

表 7.2 さまざまな fold オプションの例

説明とオプションリスト	字形統合前	字形統合後
PUA キャラクタ群を温存： fold={{[:Private_Use:] preserve} default}		
PUA キャラクタ群を除去： fold={{[:Private_Use:] remove} default}		なし
マップ不能グリフ群に対する TET PUA 値を除去するが、フォントからの PUA キャラクタ群を温存： fold={{_tet_pua remove} {[:Private_Use:] preserve} default}	 	

デフォルト字形統合 granularity=glyph の場合を除き、TET は、表 7.3 で説明する、以下のデフォルト字形統合を適用します：





```
{[:blank:] U+0020}
{ _tetpua unknownchar }
{[:Private_Use:] U+FFFD}
{ _dehyphenation remove }
{[\u0640][:Control:][:Unassigned:]] remove}
```

カスタムの字形統合をデフォルト字形統合と結合するには、カスタム字形統合オプション群の後にキーワード *default* を与える必要があります（これは表 7.2 のすべての例に示されています）。たとえば、下記の *fold* 文書オプションリストは、ハイフン除去される単語の中のハイフン群を温存した後に、デフォルト字形統合を適用します：

```
fold={ { _dehyphenation preserve } default }
```

すべてのデフォルト字形統合を明示的に無効化したい場合でない限り、*fold* 文書オプションリストにはキーワード *default* を追加することを推奨します。

表 7.3 デフォルト字形統合

字形統合と説明	入力例	出力
空白字形統合：Unicode 空白キャラクタのすべての種類を U+0020 へマップ： {[:blank:] U+0020}	U+00A0	U+0020
マップ不能グリフ群に対する TET PUA 値を、unknownchar オプションで指定されたキャラクタへマップ（または指定されたアクション preserve/remove を適用）： { _tetpua unknownchar }		 U+FFFD
PUA キャラクタ群を Unicode 置換キャラクタ U+FFFD へマップ： {[:Private_Use:] U+FFFD}		 U+FFFD
ハイフン除去される単語群の中のハイフンを除去： { _dehyphenation remove }	- U+002D	なし
アラビア文字のタトウォールキャラクタ群と、制御キャラクタ群と、Unicode 内で割り当てられていないキャラクタ群を除去（これらの字形統合は、TETML 出力を生成する際には、他のすべての字形統合の後につねに実行されます）： {[\u0640][:Control:][:Unassigned:]] remove}	- U+0640	なし
	U+000C U+03A2	

7.3.2 Unicode 分解

分解は、1 個のキャラクタを、他の 1 個ないし複数の等価なキャラクタ列へ置き換えます。¹ ある Unicode キャラクタが、他の 1 個ないし複数のキャラクタと実際には同じ意味でありながら、歴史的理由により Unicode 内で別々のコードを与えられているとき（多くはレガシ符号化形式との可逆のからみで）、その Unicode キャラクタはそのキャラクタ（群）と（互換あるいは正準）等価であるといえます。分解は情報を破壊します。これは、元のキャラクタとその等価キャラクタとの使い分けに関心がない場合には有用です。しかし使い分けに関心がある場合には、その分解は適用するべきではありません。

注記 ここで用いている「分解」という用語は、Unicode 規格で定義されているものですが、実際には多くの分解は、1 個のキャラクタを複数の部分へ分割するのではなく、1 個のキャラクタを別の 1 個のキャラクタへ変換します。

正準分解 互いに正準等価であるキャラクタまたはキャラクタ列は、同一の抽象キャラクタを表現しており、したがって必ず同一の体裁と動作を持つべきものです。よくある例としては、合成済みキャラクタ（例： Ä ）と連結キャラクタ列（例： $\text{A} \text{¨}$ ）が挙げられます： Ä (U+00C4) と $\text{A} \text{¨}$ (U+0041 U+0308) が挙げられます：2 つの表現は互いに正準等価です。1 つの表現から別の表現へ切り替えても情報は失われません。正準分解は、1 つの表現を、正準表現と見なされる別の表現へ置き換えます。

Unicode コードチャート² では、正準マッピングには記号 IDENTICAL TO \equiv (U+2261) が付けられています（キャラクタテーブルにはなし）。分解名 *<canonical>* と暗黙的に見なされません。表 7.4 にいくつかの例を挙げます。

表 7.4 正準分解：decompose オプションのサブオプション（正準等価なキャラクタには、Unicode コードチャートで記号 IDENTICAL TO \equiv (U+2261) が付けられています）

分解名	説明	分解前	分解後
<i>canonical</i> ¹	正準分解	Ä U+00C0	$\text{A} \text{¨}$ U+0041 U+0300
		林 U+F9F4	林 U+6797
		Ω U+2126	Ω U+03A9
		ば U+3070	$\text{は} \text{¨}$ U+306F U+3099
		Ń U+FB2F	$\text{N} \text{¨}$ U+05D0 U+05B8

1. デフォルトではこの分解は、特定のキャラクタ群を温存するために、すべてのキャラクタに対しては適用されません。詳しくは、111 ページの「デフォルト字形統合」を参照してください。

1. Unicode 分解に関する完全な説明は www.unicode.org/versions/Unicode8.0.0/Unicode5.2.0/cho2.pdf (2.12 節) および www.unicode.org/versions/Unicode8.0.0/cho3.pdf (3.7 節) 下記を参照してください。

2. www.unicode.org/Public/8.0.0/charts/ を参照。

互換分解 互換等価なキャラクタどうしは、同一の抽象キャラクタを表しますが、その体裁や動作は互いに異なっている可能性があります。例としては、アラビア文字キャラクタの単独形 (س) U+0633 等) と位置依存表示形 (س · س · س) U+FEB2 U+FEB4 U+FEB3 等) が挙げられます。互換等価キャラクタは組版上互いに異なるものです。この組版情報を除去すると、情報が失われる可能性があります。ある種の応用の場合 (検索等) には処理を単純化できるでしょう。

Unicode コードチャートでは、互換マッピングには記号 ALMOST EQUAL TO U+2248 が付いており、その後、分解名 (「タグ」ともいいます) が `<noBreak>` のように山括弧にくくって書かれています。タグ名が書かれていないものについては、`<compat>` と見なされます。このタグ名は、表 7.5 のオプション名と同一です。いくつかの例に見られるように、分解の結果、1 個のキャラクタが複数キャラクタ列へ変換されることもあります。

注記 PDF 文書によっては、グリフが、分解されていない Unicode 値ではなく、分解済みキャラクタ列へマップされていることもあります。その場合には `decompose` オプションは出力に対して効力を持ちません。

分解のさまざまな例 TET における分解は、文書オプション `decompose` で制御できます。1 種類の分解が、全 Unicode キャラクタに対してではなく、いくつかのキャラクタに対してのみ適用されるよう制限することもできます。ある分解の適用対象となる部分集合を、そのドメインといいます。表 7.5 に、すべての Unicode 分解に対するサブオプションを例とともに挙げます。

以下の `decompose` オプションの例は、`TET_open_document()` に対するオプションリストの中で与える必要があります。`decompose` オプションリスト内の分解名は表 7.5 から取られます。

すべての分解を無効化：

```
decompose={none}
```

全角 (ダブルバイト)・半角キャラクタを温存：

```
decompose={wide=_none narrow=_none}
```

すべての正準等価キャラクタをおのおの対応キャラクタへマップ：

```
decompose={canonical=_all}
```

下記のオプションリストは `circle` 分解を有効化しますが、それ以外の分解はすべて無効化します：

```
decompose={none circle=_all}
```

反対に、下記のオプションリストはすべての分解を有効化します (なぜなら、他のオプションを省略するとデフォルトが有効になるからです)：

```
decompose={circle=_all}
```

デフォルト分解 デフォルトでは、`fraction` 以外のすべての分解が有効になっています。多くのデフォルト分解は `_all` ドメインに対して (すなわちすべてのキャラクタに対して) 適用されますが、いくつかは、表 7.6 に従った、より小さなデフォルトドメインに対して適用されます。分解を扱う正攻法は正規化によることです (116 ページの 7.3.3 「Unicode

表 7.5 互換分解 : decompose オプションのサブオプション一覧 (互換等価なキャラクタには、Unicode コードチャートで記号 ALMOST EQUAL TO \approx U+2248 が付けられています)

分解名	説明	分解前	分解後 (論理順で)
<i>circle</i>	丸囲みキャラクタ	① U+3251	2 1 U+0032 U+0031
<i>compat</i>	その他の互換分解。例：広く用いられている合字	fi U+FB01	f i U+0066 U+0069
<i>final</i>	語尾形。特にアラビア文字の	س U+FEB2	س U+0633
<i>font</i>	フォントバリエーション。例：数学の集合の文字、ヘブライ文字の合字	Ⓒ U+2102	Ⓒ U+0043
<i>fraction</i>	俗用分数字体	¼ U+00BC	1 / 4 U+0031 U+2044 U+0034
<i>initial</i>	語頭形。特にアラビア文字の	س U+FEB3	س U+0633
<i>isolated</i>	単独形。特にアラビア文字の	سر U+FD0E	س ر U+0633 U+0631
<i>medial</i>	語中形。特にアラビア文字の	س U+FEB4	س U+0633
<i>narrow</i>	半角キャラクタ	ㄣ U+FF66	ㄣ U+30F2
<i>nobreak</i>	改行禁止キャラクタ	␣ U+00A0	␣ U+0020
<i>none</i>	明示的に decompose オプションリストで指定されていないすべての分解を無効化	(すべてのキャラクタを変更せず温存)	
<i>small</i>	CNS 11643 互換のための小型字体	， U+FE50	， U+002C
<i>square</i>	日中韓の組文字	キ □ U+3314	キ □ U+30AD U+30ED
<i>sub</i>	下付き字体	₁ U+2081	₁ U+0031
<i>super</i>	上付き字体	ₐ U+00AA ™ U+2122	ₐ U+0061 ™ M U+0054 U+004D
<i>vertical</i>	縦書き字体	⸮ U+FE37	{ U+007B
<i>wide</i>	全角字体	£ U+FFE1	£ U+00A3

正規化」を参照)。 *granularity=glyph* のときは、Unicode 後処理は無効化されますので、その場合には分解はいずれも有効にはなりません。

表 7.6 Unicode 分解 (decompose オプションのサブオプション) のデフォルトドメイン一覧

分解	TET におけるデフォルト
<i>canonical</i>	<p>canonical={[[U+0374 U+037E U+0387 U+1FB6 U+1FEF U+1FFD U+2000 U+2001 U+2126 U+212A U+212B U+2329-U+232A]]}</p> <p>デフォルトドメインは正準重複 (シングルトン) を含みますが、それ以外の正準等価キャラクタを含みません。デフォルトが <i>_all</i> でないのは、Ä <small>U+00C4</small> のようなキャラクタを温存するためです。</p>
<i>compat</i>	<p>compat={[[U+FB00-U+FB17]]}</p> <p>デフォルトドメインは欧文とアルメニア文字の合字を含みますが、それ以外の互換キャラクタを含みません。デフォルトが <i>_all</i> でないのは、IJ <small>U+0132</small> のようなキャラクタを温存するためです。</p>
<i>fraction</i>	<p>fraction=<i>_none</i></p> <p>分数はデフォルトでは分解されません。分解すると整数部と分数部が合わさって不適切な数字列になるおそれがあるからです。たとえば、クライアントアプリケーションがキャラクタ列 $\text{9 } \frac{1}{2}$ (数値 9.5 を表す) を $\text{9 } \frac{1}{2}$ <small>U+0039 U+00BD</small> と勘違いして、数値 (91)/2=45.5 と解釈してしまうおそれがあります。</p>
<i>sub</i> <i>super</i>	<p>sub={[[U+208A-U+208E]]}</p> <p>super={[[U+207A-U+207E]]}</p> <p>デフォルトドメインは数学記号のみを含みます。上付き・下付き数字はデフォルトでは分解されません。これは、上で <i>fraction</i> について述べたのと同様の数値解釈上の問題を避けるためです。商標記号 TM <small>U+2122</small> のようなキャラクタはデフォルトでは T M <small>U+0054 U+004D</small> へ分解されません。</p>
その他 すべて	<p>上記にないすべての分解は、デフォルトですべてのキャラクタに対して有効になっています：</p> <p>circle=<i>_all</i> final=<i>_all</i> ... vertical=<i>_all</i> wide=<i>_all</i></p>

7.3.3 Unicode 正規化

Unicode 規格では、正準等価と互換等価の概念に基づき、4 種類の正規形を定義しています。¹すべての正規形は、結合記号を特定の順序に置き、分解と合成を異なる方式で適用します：

- ▶ 正規形 C (NFC) は、正準分解の後に正準合成を適用します。たとえばこの合成形 C は Ä を、1 個のキャラクタ Ä U+00C4 として格納します。NFC は、Windows における Unicode テキストと、Web 上と、多くのデータベースにおいて、推奨される形式です。
- ▶ 正規形 D (NFD) は、正準分解を適用します。たとえばこの分解形 D は Ä を、ベースキャラクタと、結合するダイアクリティカルキャラクタとの、シーケンス $\text{A} \text{¨}$ U+0041 U+0308 として格納します。
- ▶ 正規形 KC (NFKC) は、互換分解の後に正準合成を適用します。言い換えれば、いくつかのキャラクタが、互換な基本形へマップされます。たとえば合字 fi U+FB01 はシーケンス $\text{f} \text{i}$ U+0066 U+0069 へマップされます。
- ▶ 正規形 KD (NFKD) は、互換分解を適用します。これは形 KC と似ていますが、正準合成を適用しません。

どの正規形を選ぶかは、用途の要請によって異なります。表 7.7 に、さまざまなキャラクタに対する正規化の効果を演示します。

TET は 4 種類の Unicode 正規形すべてに対応しています。Unicode 正規化は *normalize* 文書オプションで制御できます。例：

```
normalize=nfc
```

TET はデフォルトでは正規化を適用しません。*decompose* オプションと *normalize* オプションはかち合うおそれがあることから、*normalize* オプションを *none* 以外の値に設定するとデフォルト分解は無効化されます。

表 7.7 Unicode 正規形の例

正規化前	NFC	NFD	NFKC	NFKD
Ä <small>U+00C4</small>	Ä <small>U+00C4</small>	$\text{A} \text{¨}$ <small>U+0041 U+0308</small>	Ä <small>U+00C4</small>	$\text{A} \text{¨}$ <small>U+0041 U+0308</small>
$\text{A} \text{¨}$ <small>U+0041 U+0308</small>	Ä <small>U+00C4</small>	$\text{A} \text{¨}$ <small>U+0041 U+0308</small>	Ä <small>U+00C4</small>	$\text{A} \text{¨}$ <small>U+0041 U+0308</small>
$\text{¨} \text{A}$ <small>U+0308 U+0041</small>	$\text{¨} \text{A}$ <small>U+0308 U+0041</small>	$\text{¨} \text{A}$ <small>U+0308 U+0041</small>	$\text{¨} \text{A}$ <small>U+0308 U+0041</small>	$\text{¨} \text{A}$ <small>U+0308 U+0041</small>
fi <small>U+FB01</small>	fi <small>U+FB01</small>	fi <small>U+FB01</small>	$\text{f} \text{i}$ <small>U+0066 U+0069</small>	$\text{f} \text{i}$ <small>U+0066 U+0069</small>

¹ 正規形は、Unicode 規格付録 #15「Unicode Normalization Forms」で仕様化されています (www.unicode.org/versions/Unicode8.0.0/cho3.pdf#G21796 および www.unicode.org/reports/tr15/ を参照)。

表 7.7 Unicode 正規形の例

正規化前	NFC	NFD	NFKC	NFKD
3 5 U+0033 U+2075	3 5 U+0033 U+2075	3 5 U+0033 U+2075	3 5 U+0033 U+0035	3 5 U+0033 U+0035
Å U+212B	Å U+00C5	A ° U+0041 U+030A	Å U+00C5	A ° U+0041 U+030A
TM U+2122	TM U+2122	TM U+2122	T M U+0054 U+004D	T M U+0054 U+004D
IV U+2163	IV U+2163	IV U+2163	I V U+0049 U+0056	I V U+0049 U+0056
ᵀ U+FB48	ᵀ U+05E8 U+05BC	ᵀ U+05E8 U+05BC	ᵀ U+05E8 U+05BC	ᵀ U+05E8 U+05BC
가 U+AC00	가 U+AC00	ㄱ ㅏ U+1100 U+1161	가 U+AC00	ㄱ ㅏ U+1100 U+1161
ぢ U+3062	ぢ U+3062	ぢ ㄴ U+3061 U+3099	ぢ U+3062	ぢ ㄴ U+3061 U+3099
10月 U+32C9	10月 U+32C9	10月 U+32C9	1 0 月 U+0031 U+0030 U+6708	1 0 月 U+0031 U+0030 U+6708

7.4 追加キャラクターとサロゲート

Unicode の基本多言語面 (BMP) の外にある追加キャラクター、すなわち Unicode 値が **U+FFFF** を超えるキャラクターは、1 つの UTF-16 値では表すことができず、サロゲートペアと呼ばれる 2 つの UTF-16 値を必要とします。追加キャラクターの例としては、**U+1DXXX** にあるさまざまな数学記号・音楽記号や、**U+20000** から始まる日中韓の拡張キャラクターが挙げられます。TET はまた、PDF 文書内で Unicode マッピングが一切見つからなかったグリフに Unicode 値を割り当てるために補助私用領域を使用します。デフォルトでは、これらのキャラクターは Unicode 置換キャラクター U+FFFD によって置き換えられます。しかし、オプションを用いると、それらは BMP 外の Unicode 値として、すなわち U+FFFF を超える値として、出力内に出現可能になります (119 ページの「マップ不能グリフと TET PUA」を参照)。

TET は追加キャラクターを解釈・保持し、それに対応する UTF-32 値を、ネイティブな Unicode 文字列が UTF-16 にしか対応していない言語バインディングにおいても利用可能にしています。1 番目のサロゲート値に対して `TET_get_char_info()` が返す `uv` フィールドは、対応する UTF-32 値を持ちます。これを利用すれば、UTF-32 に対応していない UTF-16 環境で作業をしている場合でも追加キャラクターの UTF-32 値を直接利用可能です。

1 番目の (高位) サロゲートと 2 番目の (低位) サロゲートは保持されます。`TET_get_text()` が返す文字列は 2 個の UTF-16 値を内容として持ちます。

7.5 グリフに対する Unicode マッピング

PDF 内のテキストは、さまざまなフォントやエンコーディング方式によって表されている可能性があるのに対し、TET は、PDF 内の元のテキスト表現にかかわらず、グリフから抽象情報を抽出し、すべてのテキストを Unicode キャラクタへ正規化します。PDF 内で見つかった情報を、おのおの対応する Unicode 値へ変換することを、**Unicode マッピング**といい、これはテキストの意味を理解する（テキストの視覚表現を画面上や紙に展開するのではなく）ために必須です。正しい Unicode マッピングを与えるために、TET は、PDF 文書内で見つかるさまざまなデータ構造を照会したり、埋め込まれた、あるいは外部のフォントファイルを照会したり、内蔵の、あるいはユーザが与えたテーブルを照会したりします。さらに TET は、非標準なグリフ名に対して Unicode マッピングを決定するいくつかの方式も適用します。

あらゆる方策を尽くしてもなお、一部のテキストが Unicode へマップできない PDF 文書も若干あります。このような場合に対処するため、TET は、問題のある PDF ファイルに対する Unicode マッピングを制御するために利用できるさまざまな設定機能を提供しています。

マップ不能グリフと TET PUA PDF 内のテキストが Unicode へマップできない場合、その原因は何種類かあります。たとえば、Type 1 フォントが未知のグリフ名を含んでいることが原因かもしれません。あるいは、TrueType・OpenType・CID のいずれかのフォントの場合には、グリフ ID で指定されていて、フォントまたは PDF の中に Unicode 値が含まれていないことが原因かもしれません。もしも TET が Unicode 値を、PDF 文書と、埋め込みおよび外部フォントと、構成されたテーブル群と内部テーブル群の中の情報を調べた後で決定できない場合、そのグリフはマップ不能ととらえられます。

マップされていないグリフ群は、**TET_char_info** 構造の **unknown** メンバ（208 ページの表 10.16 を参照）を用いて、あるいは TETML 内の **Glyph/@unknown** 属性を用いて特定できます。

TET は、すべてのマップ不能グリフに、TET 私有領域（TET PUA）内の値を減じながら割り当てます。この TET PUA は、フォント内で割り当てられている PUA 値群との衝突を避けるために、補助私有領域内に、すなわち BMP 外に位置しています。TET PUA は **fold** オプションのソースとしてキーワード **_tetpua** を用いて指定できます。

デフォルトでは、マップ不能グリフ群に対する TET PUA 値群は Unicode 置換キャラクタ U+FFFD で置き換えられます。この動作は、**unknownchar** 文書オプションを用いて変更可能です。このオプションは、任意の Unicode キャラクタに設定することもできますし、マップ不能グリフ群に対する TET PUA 値を温存または除去するように設定することもできます。表 7.2 に、いろいろな用途におけるこの **fold・unknownchar** オプションのさまざまな組み合わせを挙げています。

表 7.8 マップ不能グリフ群に対する TET PUA 値の扱いを unknownchar 文書オプションを用いて指定



説明とオプションリスト	生入力	結果
デフォルト動作：マップ不能グリフ群に対する TET PUA 値を Unicode 置換キャラクタ U+FFFD で置き換え：unknownchar=U+FFFD		 U+FFFD

表 7.8 マップ不能グリフ群に対する TET PUA 値の扱いを `unknownchar` 文書オプションを用いて指定

説明とオプションリスト	生入力	結果
マップ不能グリフ群に対する TET PUA 値を疑問符（またはその他任意の適切な Unicode キャラクタ）で置き換え。これはテキスト内の問題のあるグリフ群を目で見て特定するのに有用でしょう： <code>unknownchar=?</code>	☒	? U+003F
マップ不能グリフ群に対する TET PUA 値を除去： <code>unknownchar=remove</code>	☒	なし
マップ不能グリフ群に対する TET PUA 値を温存。これはデバッグや分析に有用でしょう： <code>unknownchar=preserve</code>	☒	(TET PUA 値)

私用領域 (PUA) 内のキャラクタ フォントまたは PDF 文書がグリフを私用領域内の Unicode キャラクタへマップしていることがあります。これは日本語の外字フォントやロゴフォントなど世界的に標準化された意味を一切持たない記号に対して広く用いられています。このような PUA キャラクタは、一般的な Unicode ワークフローの中で意味のある活用ができませんので、デフォルトでは Unicode 置換キャラクタ U+FFFD で置き換えられます。PUA 値を扱える用途において PUA 値を温存する方法については表 7.2 を参照してください。

Unicode マッピング制御の概要 TET には、実際には Unicode 値を持たない PDF 文書から、それでも何とかしてテキストをうまく抽出できるよう処理するための、さまざまな代替機能が備わっています。しかしながらそれでもなお、PDF やフォントデータの構造内で十分な情報が得られないためにテキストを抽出することができない文書というものは存在します。TET は、Unicode マッピング情報を追加供給するために活用することのできるさまざまな設定機能を持っています。この節ではそうした機能について解説します。

`TET_open_document()` で `glyphmapping` オプションを用いると (187 ページの 10.3 「文書関数」を参照)、グリフに対する Unicode マッピングを何通りかの方式で制御することができます。利用可能な方式の概要を以下に列挙します (組み合わせで利用することも可能)。こうした制御は、フォントごとに適用することもできますし、1 つの文書内のすべてのフォントに対してグローバルに適用することもできます：

- ▶ `forceencoding` サブオプションを用いると、PDF における定義済みのエンコーディング `WinAnsiEncoding`・`MacRomanEncoding` が用いられるたびに、すべて別のエンコーディングで処理させることができます。
- ▶ `codelist・tounicodecmap` サブオプションを用いると、Unicode 値のリストをシンプルテキスト形式 (`codelist` リソース) で与えることができます。
- ▶ `glyphlist` サブオプションを用いると、非標準グリフ名を Unicode 値にマップしたリストを与えることができます。
- ▶ `glyphrule` サブオプションを用いると、グリフ名の数値から Unicode 値をアルゴリズム的に導き出すための規則を定義することができます。`encodinghint` オプションを用いると、内部規則を制御することができます。
- ▶ 定義済みのエンコーディングはすでに何ダースもありますが、それに加えてカスタムのエンコーディングを定義することも可能で、これは `encodinghint` オプションで、または `glyphrule` オプションの `encoding` サブオプションで利用することができます。
- ▶ PDF が十分な情報を与えずフォントが PDF に埋め込まれてもいないときに外部のフォントから Unicode マッピング情報が得られるよう設定しておくことも可能です。

PDFlib FontReporter Plugin¹ で PDF 文書を分析 正しいUnicodeマッピングテーブルを作りたいとき、それに必要な情報を得るには、問題を含むその PDF 文書を分析しなければなりません。

PDFlib GmbH はこうした場面で役立つ TET の無償派生製品 PDFlib FontReporter を提供しています。これは、フォント・エンコーディング・グリフの情報を簡単に収集できる Adobe Acrobat プラグインです。このプラグインは、実際の各グリフに以下の情報を付した詳しいフォントレポートを作成します。

- ▶ その対応するコード : 16 進の 1 桁目が左端の列に示され、16 進の 2 桁目が上端の行に示されます。CID フォントの場合はヘッダに印字されるオフセットを加えると、グリフに対応するコードが得られます。
- ▶ そのグリフ名 : もしあれば。
- ▶ そのグリフに対応する (1 つないし複数の) Unicode 値 (Acrobat がそれを決定できる場合)。

こうしたさまざまな情報は、TET のグリフマッピング制御に対して重要な役割を演じます。あるフォントレポートの一例から 2 つのページを抜き出して図 7.2 に示します。FontReporter Plugin によって作成されたフォントレポートを利用すれば、PDF フォントを分析し、ひいては TET がテキストを正しく抽出できるようにマッピングテーブルを作ることが可能です。TET のテキスト抽出を制御するために Unicode マッピングテーブルやグリフ名ヒューリスティックスを書こうと思うならば、それに対応するフォントレポートに目を通しておくことを強く推奨します。

1. PDFlib FontReporter Plugin は www.pdflib.com/products/fontreporter から無償ダウンロード可能です。

PDFlib FontReporter																	PDFlib FontReporter																
PIAPOC+ThesisAntiqua-Normal, Type1, Embedded, Subset																	ShinGo-Medium, CIDFontType0																
Encoding: custom, symbol bit, ToUnicode table, CharSet table																	Encoding: Identity-H																
																	Character collection: Adobe-Japan1-2																
																	CID x0300 (50 glyphs)																
x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF	x0	x1	x2	x3	x4	x5	x6	x7	x8	x9	xA	xB	xC	xD	xE	xF		
0x																0x																	
1x																1x																	
2x																2x																	
3x																3x																	
4x																4x																	
5x																5x																	
6x																6x																	
7x																7x																	
8x																8x																	
9x																9x																	
Ax																Ax																	
Bx																Bx																	
Cx																Cx																	
Dx																Dx																	
Ex																Ex																	
Fx																Fx																	

図 7.2 Adobe Acrobat 用 PDFlib FontReporter Plugin が作成するフォントレポートの例

優先規則 TETはグリフマッピング制御を以下の順番で適用します：

- ▶ codelist・ToUnicode CMap リソースがまず照会されます。
- ▶ フォントが内部 ToUnicode CMap を持つならそれが次に考慮されます。
- ▶ グリフ名について TET は、外部か内部のグリフ名マッピング規則を、どちらかフォントとグリフ名の一致するものが見つかれば適用します。
- ▶ 最後の手段として、ユーザが与えたグリフリストが適用されます。

コードリストリソースはあらゆる種類のフォントに利用可能 コードリストはグリフリストに似ており、ただ各コードのグリフ名でなく Unicode 値を指定する点が違います。同じ鋳造場で作られた複数のフォントならば、互いに同一のコード割り当てを使用していることもあるかもしれませんが、一般にはコード（グリフ ID ともいう）というのはフォントごとに異なるものです。その結果、フォントごとに別々のコードリストが必要になります。コードリストはテキストファイルであり、各行ごとに、1つのコードに対する Unicode マッピングを以下の規則に従って記述しています：

- ▶ パーセント記号「%」の後のテキストは無視されます。これは注釈に使えます。
- ▶ 1列目にはグリフのコードを10進か16進記法で書きます。これは1バイトフォントの場合は0～255の範囲、CIDフォントの場合は0～65535の範囲内の値でなければなりません。



図 7.3

あるロゴタイプのフォントに対するフォントレポートを見たところ、このフォントは誤った Unicode マッピングを持っていることがわかった。これはカスタムのコードリストで直すことが可能。

- ▶ その後につづけてその行には、そのコードに対する Unicode コード点を 7 つまで書くことができます。値は 10 進か（前に `x` か `ox` をつけて）16 進記法で与えることができます。UTF-32 に対応していますので、サロゲートペアも使えます。

コードリストはファイル名の拡張子として `.cl` を用いるきまりになっています。コードリストは `codelist` リソースカテゴリを用いて設定を行うことができます。コードリストリソースが何も明示的に指定されていない場合、TET は `<mycodelist>.cl`（ここで `<mycodelist>` はリソース名）という名前のファイルを `searchpath` ヒエラルキーの中で探します（詳しくは、65 ページの 5.2 「リソース設定とファイル検索」を参照）。つまりいいかえれば、リソース名とファイル名（から拡張子 `.cl` を除いたもの）とが同一のときはリソースを設定する必要はないということで、なぜならその場合 TET は下記の呼び出しと等価な動作を暗黙に行うからです（ここで `name` は任意のリソース名）：

```
set_option("codelist {name name.cl}");
```

次の例はコードリストの使用例です。ここでは、図 7.3 に示すようにロゴタイプのグリフが誤ってマップされている場合を想定します。このフォントでは、1 つのグリフが実際には複数のキャラクタを表しており、キャラクタをすべて並べると会社のロゴタイプが形成されるようになっているのですが、各グリフが誤ってキャラクタ `a・b・c・d・e` にマップされてしまっているのです。これを直すには以下のコードリストを作ればよいでしょう：

% GlobeLogosOne フォントの各コードに対する Unicode マッピング

```
x61      x0054 x0068 x0065 x0020      % The
x62      x0042 x006F
x63      x0073 x0074 x006F x006E x0020 % ston
x64      x0047 x006C x006F
x65      x0062 x0065      % be
```

そして `TET_open_document()` で下記のオプションを用いてコードリストを与えます（このコードリストは `GlobeLogosOne.cl` というファイルにあり、検索パスで見つかるようにしてあるとして）：

```
glyphmapping {{fontname=GlobeLogosOne codelist=GlobeLogosOne}}
```

ToUnicode CMap リソースはあらゆる種類のフォントに利用可能 PDF は ToUnicode CMap というデータ構造に対応しています。これを用いると、フォントの各グリフに対する Unicode 値を与えることができます。このデータ構造が PDF ファイル内に存在する場合、TET はそれを利用します。あるいは、ToUnicode CMap を外部ファイルとして与えることも可能です。これは PDF 内の ToUnicode CMap が不完全な場合や、誤った内容を含んでいるときや、存在しない場合に有用です。ToUnicode CMap はコードリストよりも優先されます。ただ、コードリストのほうが ToUnicode CMap よりも形式が簡単なため、好んで用いられます。

CMap では、ファイル名に拡張子をつけなくまっています。ToUnicode CMap は `cmap` リソースカテゴリを用いて設定を行うことができます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。`cmap` リソースの内容は、標準的な CMap の文法に従う必要があります。¹ToUnicode CMap を **Warnock** ファミリのすべてのフォントに適用するには、`TET_open_document()` で下記のオプションを用います：

```
glyphmapping {{fontname=Warnock* tounicodecmap=warnock}}
```

グリフリストリソースは 1 バイトフォントに利用可能 グリフリスト (グリフ名リストの略) を用いると、非標準のグリフ名に対してカスタムの Unicode 値を与えたり、あるいは標準のグリフ名に対する既存の値を無視させて別の値を使わせたりすることができます。グリフリストはテキストファイルであり、以下の規則に従って各行ごとに、1 つのグリフ名に対する 1 つの Unicode マッピングを記述します：

- ▶ パーセント記号「%」の後のテキストは無視されます。これは注釈に使えます。
- ▶ 1 列目にはグリフ名を書きます。フォント内で用いられている任意のグリフ名を書くことができます (すなわち、標準のグリフ名の Unicode 値を無視させて別の値を使わせることも可能)。グリフ名の中にパーセント記号を入れたい場合は `1%` とシーケンスで書く必要があります (パーセント記号は注釈を開始させる役割を持つので)。
- ▶ 1 つのグリフ名に対しては 1 つのマッピングだけが許されます。同一のグリフ名に対して複数のマッピングがある場合はエラーとして扱われます。
- ▶ その後につづけてその行には、そのグリフ名に対する Unicode コード点を 7 つまで書くことができます。値は 10 進記法か (前に `x` か `ox` をつけて) 16 進記法で与えることができます。UTF-32 に対応していますので、サロゲートペアも使えます。
- ▶ グリフ名の中に印字不能キャラクタを入れたい場合はテキストファイル用のエスケープシーケンスを用います (65 ページの 5.2 「リソース設定とファイル検索」を参照)。

グリフリストはファイル名の拡張子として `.gl` を用いるまっています。グリフリストは `glyphlist` リソースを用いて設定を行うことができます。グリフリストリソースが何も明示的に指定されていない場合、TET は `<myglyphlist>.gl` (ここで `<myglyphlist>` はリソース名) という名前のファイルを `searchpath` ヒエラルキーの中で探します (詳しくは、65 ページの 5.2 「リソース設定とファイル検索」を参照)。つまりいいかえれば、リソース名とファイル名 (から拡張子 `.gl` を除いたもの) とが同一のときはリソースを設定する必要はないということで、なぜならその場合 TET は下記の呼び出しと等価な動作を暗黙に行うからです (ここで `name` は任意のリソース名)：

```
set_option("glyphlist {name name.gl}");
```

グリフマッピングの優先規則によって、フォントが ToUnicode CMap を含んでいる場合にはグリフリストは照会されません。以下の例はグリフリストの使用例です：

% TeX 文書で用いられるグリフ名に対する Unicode 値

```
precedesequal 0x227C
similarequal  0x2243
negationslash 0x2044
union         0x222A
prime        0x2032
```

1. partners.adobe.com/public/developer/en/acrobat/5411.ToUnicode.pdf を参照

CMSY で始まるすべてのフォント名に対して *tarski.gl* というグリフリストを適用したいときは、*TET_open_document()* で下記のオプションを用います：

```
glyphmapping {{fontname=CMSY* glyphlist=tarski}}
```

1 バイトフォントの数値グリフ名を規則で解釈させる PDF 文書内のグリフ名はときに、何らかの定義済みのリストから採って来られないで、アルゴリズム的に生成されていることがあります。これはその PDF を生成したアプリケーションの「機能」かもしれませんし、あるいはプリンタドライバがフォントを別の形式に変換したことによるものかもしれませんが、その過程で元のグリフ名が失われ、*Goo, G01, G02, …* のような規則的な名前前に置き換えられていることがあるのです。TET は、普及しているさまざまなアプリケーションやドライバが生成する数値グリフ名を処理するためのグリフ名規則を内蔵しています。ただ、グリフ名が同じであってもそれが別々のエンコーディングに対して生成される場合もあるので、*TET_open_document()* で *encodinghint* オプションを与えて、文書内に現れる規則的なグリフ名が従うべきエンコーディングを指定することもできるようになっています。たとえば文書にロシア語のテキストが入っていることがわかっているのに、PDF 内の情報不足でうまくそれが抽出できない場合は、オプション *encodinghint=cp1250* を与えてキリル文字コードページを指定することができます。

こうした数値グリフ名を解釈する内蔵の規則のほかに、自分でカスタムの規則を定義することもできます。それには *TET_open_document()* で *glyphmapping* オプションに *fontname · glyphrule* サブオプションを用います。その際には以下の情報を与える必要があります：

- ▶ その規則を適用するべきフォントの完全名か短縮名 (*fontname* オプション)
- ▶ グリフ名の接頭辞、すなわち数値部の前につくキャラクタ列 (*prefix* サブオプション)
- ▶ 数値を解釈する際の基数 = 10 進か 16 進か (*base* サブオプション)
- ▶ できた数値コードを解釈するべきエンコーディング (*encoding* サブオプション)

たとえばフォント *T1, T2, T3, …* 内のグリフ名が *coo, co1, co2, …, cFF* で、各グリフ名が WinAnsi キャラクタの 16 進位置 (*oo, …, FF*) にそれぞれ対応していることがわかった (PDFlib FontReporter を利用するなどして) 場合には、*TET_open_document()* で下記のオプションを用います：

```
glyphmapping {{fontname=T* glyphrule={prefix=c base=hex encoding=winansi} }}
```

外部フォントファイルとシステムフォント PDF が Unicode マッピングのための十分な情報を持たず、しかもフォントが埋め込まれていないときは、TET が Unicode マッピングの導出に利用できるフォントデータが追加されるよう設定することもできます。フォントデータはディスク上の TrueType か OpenType のフォントファイルから来るようにすることもでき、その場合は *fontoutline* リソースカテゴリを用いてそのように設定することが可能です。あるいは macOS や Windows システム上では、TET はホストオペレーティングシステム上にインストールされたフォントを利用することもできます。こうしたホストフォントを利用させないようにするには *TET_open_document()* で *usehostfonts* オプションを用います。

ディスクファイルを *WarnockPro* フォントのために設定するには下記の呼び出しを行います：

```
set_option("fontoutline {WarnockPro WarnockPro.otf}");
```

外部フォントファイルの設定については、詳しくは、65 ページの 5.2 「リソース設定とファイル検索」を参照してください。

8 画像抽出

8.1 画像抽出の基本

さまざまな画像形式 TET は PDF ページ群からラスタ画像群を抽出し、その抽出した画像を、以下のいずれかの形式で格納します：

- ▶ TIFF (*.tif*) 画像は多くの場合に生成されます。TET が生成する TIFF 画像の多くは、あらゆる TIFF ビューア・コンシューマと互換です。ただし、いくつかの高度な TIFF 機能、とりわけ追加スポットカラーチャンネル (138 ページの「スポットカラー」を参照) には、すべての画像ビューアが対応しているわけではありません。当社では Adobe Photoshop を TIFF 画像の有効性のベンチマークと見なしています。
- ▶ JPEG (*.jpg*) は、PDF 内で JPEG アルゴリズムで圧縮されている画像について生成されます (*DCTDecode* フィルタ)。PDF 文書内の JPEG 圧縮されている画像データは検証されます。ただし、*TET_write_image_file()* か *TET_get_image_data()* でオプション *validatejpeg=false* を用いて検証を無効化することもできます。そうすると処理がやや速くなるかもしれませんが、DCT 圧縮された画像が TIFF として抽出される場合もあります。なぜなら、すべての PDF 色空間を JPEG で表現できるわけではないからです (スポットカラーなど)。
- ▶ JPEG 2000 (*.jpx*) は、PDF 内で JPEG 2000 アルゴリズムを用いて圧縮されている画像について生成されます (*JPXDecode* フィルタ)。JPEG 2000 には複数の種類があります。メインの種類は、MIME タイプ *image/jp2* とファイル名接尾辞 *.jp2* を持ち、ISO 15444-1 (Annex I) に従って符号化されます。拡張された種類は、MIME タイプ *image/jpx* を持ち、ISO 15444-2 (Annex M) に従って符号化されます。これは、CMYK や Lab カラーといった追加機能をサポートし、ファイル名接尾辞として *.jpf* を用います (MIME タイプと推奨接尾辞の違いに留意)。最後に、生 JPEG 2000 コードストリームは、裸のピクセルデータのみを内容とし、色空間情報など追加のプロパティを一切持ちません。これはファイル名接尾辞 *.jzkc* を持って抽出されます。
JPEG 2000 出力を扱えない用途においては、文書オプション *allowjpeg2000=false* を用いてこの抽出形式を避けることができます。この場合には JPEG 2000 ではなく 8 ビットまたは 16 ビットの TIFF 画像が生成されますので、出力が大きくなる可能性もあります。JPX 圧縮されたデータに対する TIFF 画像は、スポットカラー情報を温存しなければならない場合、または画像連結が行われた場合にも生成されます。JPX 圧縮された画像が TIFF として抽出される場合には、その JPX ストリームの中の暗示的な内部 ICC プロファイル群は無視されます。たとえば、sRGB の JPEG 2000 画像はブレンな RGB の TIFF として抽出されます。
- ▶ JBIG2 (*.jbig2*) は、PDF 内で JBIG2 アルゴリズムを用いて圧縮されている画像について生成されます (*JBIG2Decode* フィルタ)。JBIG2 ファイルは、ISO 14492 に従った「シーケンシャル編成」を用いて生成されます。

画像をディスクまたはメモリへ抽出 TET API は、PDF 文書から抽出した画像を 2 種類の方式で受け渡すことができます：

- ▶ *TET_write_image_file()* API 関数は、画像ファイルをディスク上に生成します。この画像ファイルのベースファイル名は *filename* オプションで指定する必要があります。TET は画像形式に応じて適切な接尾辞を自動的に付加します。

- ▶ `TET_get_image_data()` API 関数は、画像データをメモリ内で受け渡します。これは、画像データを他の処理構成要素へ、ディスクファイルを扱う必要なしに受け渡したいときに便利です。

詳細は、自分の画像抽出上の要請に依存します (131 ページの 8.2.2 「ページベースとリソーススペースの画像抽出」を参照)。いずれの場合にも、抽出画像の種別を知ることが可能です (次項参照)。

抽出画像のファイル形式と名前を知る 画像ファイル種別は、TETML 内の `Image/@extractedAs` 属性で報告されています。API レベルでは、以下のコードを用いて抽出画像の種別を知ることができます。

```
int imageType = tet.write_image_file(doc, tet.imageid, "typeonly");
```

```
/* 画像種別を表す数値を形式接頭辞へマップ */
String imageSuffix;
switch (imageType) {
case TET.IF_TIFF:
    imageSuffix = ".tif";
    break;

case TET.IF_JPEG:
    imageSuffix = ".jpg";
    break;

case TET.IF_JP2:
    imageSuffix = ".jp2";
    break;

case TET.IF_JPF:
    imageSuffix = ".jpf";
    break;

case TET.IF_J2K:
    imageSuffix = ".j2k";
    break;

case TET.IF_JBIG2:
    imageSuffix = ".jbig2";
    break;

default:
    System.err.println("write_image_file() が未知の値を返しました "
        + imageType + ", 画像をスキップします, エラー : "
        + tet.get_errmsg());
}
```

画像ファイル名は TETML 内では `Image/@filename` 属性でレポートされます。API レベルでは画像ファイル名を `TET_write_image_file()` へ与えることができます。

TET コマンドラインツールによって生成される画像ファイル名の構造については 17 ページの 2.1 「コマンドラインオプション」で解説しています。

画像の XMP メタデータ PDF では、XMP 形式を用いて、文書全体または文書の一部に対してメタデータを付与しています。XMP に関するさらなる情報が www.pdflib.com にあります。

画像オブジェクトには、PDF 文書の中で、XMP メタデータが関連づけられていることがあります。Acrobat XI/DC では画像 XMP の存在を下記のようにチェックできます：

- ▶ 「表示」→「表示切り替え」→「ナビゲーションパネル」→「コンテンツ」をクリック。
- ▶ ツリー構造内でその画像を見つけ、それを右クリックして「メタデータを表示...」を選択。
- ▶ その画像がハイライトされ、XMP パネルが現れて、その中に、その選択した画像に対する XMP メタデータが表示されます。

XMP メタデータが存在しているときは、TET はデフォルトでは、出力形式 JPEG・TIFF の抽出画像について、その中にそれを埋め込みます。この動作は、`TET_write_image_file()`・`TET_get_image_data()` の `keepxmp` オプションで制御することができます。このオプションが `false` に設定されているときは、TET は、画像出力ファイルを生成する際に画像メタデータを無視します。

画像のメタデータが入手可能な場合、TET は TETML 出力内でその画像に `Metadata` エレメントを付けます。この動作は `tetml={elements={metadata}}` 画像オプションを用いて制御できます。

pCOS クックブック内の `image_metadata` トピックでは、画像ファイルを一切生成せず

に pCOS インタフェースを用いて画像メタデータを直接抽出する方法を演示しています。画像オブジェクトに XMP を紐付ける通常の PDF の方式をバイパスし、マーク付きコンテンツのプロパティ群に基づく代替方式を用いている XMP 画像メタデータに対して、TET は特別なヒューリスティックを実装しています。この造りは基本的に Adobe InDesign によって生成されます。なお、この種の画像 XMP は、pCOS を通じては利用可能でなく、TETML と、抽出された画像ファイルの中でのみ利用可能です。

ページ装飾の識別または除去 タグ付き PDF 内のページ装飾は、本文外のテキストまたは画像を示します。デフォルトではページ装飾は通常の内容と同様に抽出されます。しかし、ページオプション `ignoreartifacts` を用いてページ装飾を除去することもできます。

あるいは、ページ装飾画像を、`TET_image_info` 構造 (214 ページの表 10.19 を参照) の `attributes` メンバか TETML 内の `PlacedImage/@artifact` 属性を用いて識別することもできます。ページ属性状態は、TET コマンドラインツールで `--imageloop page` を用いて画像群を抽出する際に生成される画像ファイル群の名前へも反映されます (19 ページの「画像ファイル名」を参照)。

制約 場合によっては、抽出された画像の形状が、PDF ページ上での表現と異なって見えることがあります：

- ▶ 画像が、水平 (上下反転) または垂直に鏡映されて見えることがあります。これは、TET は画像の元のピクセルデータを抽出しており、その画像にその PDF ページ上で何らかの変換が適用されていてもそれを考慮していないということが原因です。
- ▶ ソフトマスクを別の画像に対して適用することによって実現されているマスク効果は、抽出される画像では表れません。ただし、マスクを別個の画像として抽出することはできます。

8.2 画像を抽出

8.2.1 配置画像と画像リソース

TET では、配置画像と画像リソースを区別します：

- ▶ **配置画像**は、ページ上の画像に照応します。配置画像は視覚特性群を持ちます：それは特定の位置に配置されており、寸法（ポイント・ミリメートルなど絶対単位で測られる）を持っています。多くの場合その画像はページ上で可視になっていますが、場合によっては、ページ上の他のオブジェクトによって隠されていたり、可視ページ領域の外に配置されていたり、全体的ないし部分的にクリップされていたりして、不可視になっています。配置画像は TETML 内では *PlacedImage* エレメントで表されています。配置画像の処理は *clippingarea*・*excludebox*・*includebox* オプションに従います。
- ▶ **画像リソース**は、実際のピクセルデータ・色空間・要素数・要素あたりビット数などを表現するリソースです。配置画像と違って、画像リソースは明示的な視覚情報を一切持ちません。ただし、幅・高さ特性（ピクセル単位で測られる）は持っています。画像リソースはそれぞれ一意な ID を持っており、それを用いてそのピクセルデータを抽出することができます。画像リソースは TETML 内では *Image* エレメントで表されています。画像リソースの処理は *clippingarea*・*excludebox*・*includebox* オプションに従いません。

1 個の画像リソースが、その文書内の任意の数の配置画像の元として使われることがあります。通常、画像リソースはそれぞれ 1 回だけ配置されますが、繰り返し、同一ページ上や複数ページ上に配置されることもあります。たとえば、文書内の各ページのヘッダに繰り返し用いられる企業ロゴの画像を考えてみましょう。ページ上のロゴはそれぞれ、1 個の配置画像から成っていますが、最適化された PDF においては、それらの配置画像がすべて同一の画像リソースに紐付けられることが可能です。一方、最適化されていない PDF においては、配置ロゴはそれぞれ、同一の画像リソースの自分用の複製を元に行っていることがあります。これは見た目は同じ結果になりますが、PDF 文書のファイルサイズは大きくなります。最適化されていない PDF 文書は、どのページからも参照されていない画像リソース（すなわち未使用リソース）を含んでいることもあります。

表 8.1 で、配置画像と画像リソースのさまざまな特性を比較しています。

文書内に画像がいくつあるか なんと、この質問には簡単な答えがありません。答えは以下の決定によって変わります：

- ▶ 画像リソースを数えたいか、それとも配置された画像を数えたいのか。
- ▶ 連結済画像の一部分としてのみ用いられている、単独では配置されていない画像を数えたいのか。
- ▶ 別の画像に対するマスクとしてのみ用いられている画像を数えたいのか。
- ▶ 本文外の画像（ページ装飾）を数えたいのか。
- ▶ 注釈・パターン・ソフトマスク内の画像を数えたいのか（132 ページの「PDF 内の画像の取得源」を参照）。

TET と pCOS 擬似オブジェクトを用いれば、これらすべての種類の画像数の答えを知ることができます。TET クックブック内の *image_count* トピックでは、画像のさまざまな数え方の可能性を演示しています。それは以下のような出力を生成します：

```
No of raw image resources before merging: 82
No of placed images: 12
No of images after merging (all types): 83
normal images: 1
```

表 8.1 配置画像と画像リソースの比較

特性	配置画像	画像リソース
TETML エレメント	PlacedImage	Image
ページへの紐付け	○	—
ピクセル単位の幅と高さ	○	○
視覚情報：ポイント単位の幅と高さ、およびページ上の位置	○	—
ページ装飾として標識可能	○ : TET_get_image_info() が返す attributes メンバの中での TET_ATTR_ARTIFACT ビットと、TETML 内の PlacedImage/@artifact 属性	—
視覚上の出現回数	1	0、1 ないし複数
一意な ID	× : TET_get_image_info() が返す imageid メンバと、TETML 内の PlacedImage/@image 属性は、背後の画像リソースを特定するにすぎません	○ : TET_get_image_info() が返す imageid メンバと、TETML 内の Image/@id 属性
TET コマンドラインツールにおけるファイル名規則	<ファイル名>_p<ページ番号>_<画像番号>.[tif jpg jp2 jpf j2k jbig2]	<ファイル名>_I<画像 ID>.[tif jpg jp2 jpf j2k jbig2]
TET コマンドラインツールにおける画像マスクの扱い	マスクは下記として抽出されます : <ファイル名>_p<ページ番号>_<画像番号>_mask.[tif jpg jp2 jpf j2k jbig2]	マスクは、それ自身の画像 ID に従って、そのファイル名にラベルを追加せずに抽出されます。

```
artificial (merged) images: 1
consumed images: 81
No of relevant (normal or artificial) image resources: 2
```

8.2.2 ページベースとリソースベースの画像抽出

配置画像と画像リソースの違いは、すなわち、画像抽出について 2 種類の根本的に異なるアプローチをもたらします：ページベースとリソースベースの画像抽出ループです。どちらの方式も、画像をディスクファイルかメモリへ抽出するために用いることができます。

ページベースの画像抽出 この場合には、アプリケーションは正確なページレイアウトと配置画像に関心があり、画像データの重複はいとわないこととなります。ページベースのループで画像を抽出すると、配置画像ごとに 1 つずつ画像ファイルが生成されますので、複数の抽出配置画像に同一の画像データが含まれることがあります。アプリケーション側で画像 ID の重複をチェックすることで画像の重複を避けることもできるでしょう。しかし、一意な画像リソースを抽出したいなら、リソースベースの画像抽出ループを用いるほうが簡単です（後述）。

ページベースの画像抽出ループは、TET コマンドラインツールではオプション `--imageloop page` で有効にすることができます。API レベルでのページベースの画像抽出のためのコードは、TET クックブックの `images_per_page` クックブックトピック・サンプル内で演示しています。これらのサンプルは、画像の幾何情報を取得する方法も示しています。

ページベースの画像抽出ループの詳細（上述のサンプルコードを参照してください）：`TET_get_image_info()` が、配置画像に関する視覚情報と、その背景画像データの pCOS 画

像 ID (*imageid* フィールドで) を取得します。この ID を用いて、*TET_pcos_get_number()* で画像の色空間や、幅・高さをピクセル単位で表したものといたさらなる詳細を取得したり、*TET_write_image_file()* または *TET_get_image_data()* でその画像のピクセルデータ本体を取得したりすることができます。*TET_get_image_info()* はその画像のピクセルデータ本体には触りません。同一の画像が 1 つないし複数のページ上で複数回参照されている場合、その対応する ID は同一になります。

リソーススペースの画像抽出 この場合には、アプリケーションは文書内の画像リソースに関心があり、どの画像がどのページで用いられているかはいとわなないことになります。複数回 (1 つないし複数のページ上に) 配置されている画像リソースが 1 回だけ抽出されます。その半面、どのページにも全く配置されていない画像も抽出されます。

リソーススペースの画像抽出ループは、TET コマンドラインツールではオプション *--imageloop resource* で有効にすることができます。API レベルでのリソーススペースの画像抽出のためのコードは、*image_resources* サンプル・クックブックトピック内で演示しています。

リソーススペースの画像抽出ループの詳細 (上述のサンプルコードを参照してください) : 画像リソースを抽出する前に、画像連結が必ず行われているように、すべてのページが開かれます。画像連結が関係ない場合はこのステップはスキップできます。画像を抽出するためには、その対応する画像 ID が必要です。このコードは、0 から最大画像 ID までのすべての値を評価します。この最大 ID は以下のようにクエリされます :

```
n_images = (int) tet.pcos_get_number(doc, "length:images");
```

連結済画像の消費済部分 (マルチストリップ画像のストリップなど) をスキップするために、*mergetype* pCOS 擬似オブジェクトを用いて各画像リソースの種別が調べられます。これによって、画像連結処理によって消費された画像部分をスキップすることができます (最終的な連結済画像にのみ関心があるからです)。ひとたび画像 ID がわかれば、関数 *TET_write_image_file()* か *TET_get_image_data()* を呼び出せば、画像データをディスクファイルへ書き出すか、ピクセルデータをメモリ内で受け渡すことができます。

PDF 内の画像の取得源 PDF 文書は、画像をさまざまな所に内容として持つことができ、なかには意外な所もあります。TET は以下のすべての場所で画像を探します :

- ▶ 最も通常の取得源はページ記述本体です。
- ▶ 注釈またはフォームフィールドは、ラスタ画像を含む任意のグラフィックを持つ体裁ストリームを内容として持っていることがあります。このような画像については、*TET_get_image_info()* によって返される *attributes* フィールド内の *TET_ATTR_ANNOTATION* フラグと、TETML 内の *PlacedImage* エレメントの *source="annoation"* 属性を用いて識別できます。文書オプション *engines={annotation=false}* を用いて注釈の処理を無効化することも可能です。
- ▶ タイリングパターンは、任意のテキストと、ラスタ画像を含むグラフィックを内容として持っていることがあります。このような画像については、*TET_get_image_info()* によって返される *attributes* フィールド内の *TET_ATTR_PATTERN* フラグと、TETML 内の *PlacedImage* エレメントの *source="pattern"* 属性を用いて識別できます。パターンは、繰り返し表現されて、塗られるオブジェクトをタイルしますので、画像の位置は、ページ上で見える位置とは一致しないことがあります。TET は、内容を抽出する前に、パターンをページの左下隅に配置します。
- ▶ グラフィック状態は、ラスタ画像を含む任意のグラフィックを持つソフトマスクを記述する透過グループ XObject を内容として持っていることがあります (この技法はし

ばしば影付き効果のために用いられます)。このような画像については、`TET_get_image_info()` によって返される `attributes` フィールド内の `TET_ATTR_SOFTMASK` フラグと、TETML 内の `PlacedImage` エレメントの `source="softmask"` 属性を用いて識別できます。

TETML では、画像の取得源の場所を、`PlacedImage/@source` 属性を用いて識別できます。

8.2.3 配置画像の視覚情報

各配置画像の視覚情報を取得することもできます。`TET_get_image_info()` によって返される情報の中で各画像について以下の値が得られます (図 8.1 参照) :

- ▶ `x · y` フィールドは、画像参照点の座標です。参照点は通常、画像の左下隅です。ただし、ページ上の座標系変換によって参照点が変わることもあります。たとえば、画像が水平反転されていれば、参照点は画像の左上隅になるでしょう。`y` の値は `topdown` ページオプションに依存します。
- ▶ `width · height` フィールドは、ページ上の配置画像の物理的寸法に対応します。これらはポイント (すなわち 1/72 インチ) 単位で与えられます。
- ▶ 角度 `alpha` は、ピクセル行の向きを記述します。この角度は範囲 $-180^\circ < \alpha < +180^\circ$ をとります。角度 `alpha` は、画像をその参照点を中心に回転させます。正立した画像については `alpha` は 0° になります。`alpha` と `beta` の値は `topdown` ページオプションに依存します。
- ▶ 角度 `beta` は、ピクセル列の向きを記述します。これは `alpha` の垂線に平行です。この角度は範囲 $-180^\circ < \beta < +180^\circ$ 、ただし $\pm 90^\circ$ 以外の値をとります。角度 `beta` は画像を斜形化し、`beta=180^\circ` は画像を `x` 軸で反転します。正立した画像については、`beta` は範囲 $-90^\circ < \beta < +90^\circ$ をとります。`abs(beta) > 90^\circ` なら、その画像はベースラインで反転されています。
- ▶ `imageid` フィールドは、画像の pCOS ID を内容として持ちます。これを用いると、pCOS 関数群で詳しい画像情報を取得したり、`TET_write_image_file()` か `TET_get_image_data()` で画像ピクセルデータを取得したりすることができます。
- ▶ `attributes` フィールドは、画像がページ装飾 (本文外の内容) として標識されている場合にセットされるビット `TET_ATTR_ARTIFACT` を内容として持ちます。このフィールドは、画像が見つかった場所を記述するビット値 `TET_ATTR_ANNOTATION · TET_ATTR_PATTERN · TET_ATTR_SOFTMASK` も内容として持つことができます。




図 8.1
画像の幾何情報

画像変形の結果として、抽出画像の向きは誤りに見える場合があります。なぜなら、抽出される画像データは、PDF 内の画像リソースに基づいているからです。PDF ページ上で配置画像に対して適用されている回転や反転といった変形はいずれも、抽出されるピクセルデータには適用されません。元のピクセルデータが抽出されます。

画像のすべての隅の座標を算出 `TET_get_image_info()` を用いて取得される $x \cdot y$ フィールドは、その画像の参照点を与えます。参照点は多くの場合、画像の左下隅に位置しています。画像の $x/y \cdot width/height \cdot alpha/beta$ 値を用いて、画像のすべての隅の座標を、以下のように算出できます：

```
llx = x  
lly = y
```

```
lrx = x + width * cos(alpha)  
lry = y + width * sin(alpha)
```

```
ulx = x + dir * height * (tan(beta)*cos(alpha) - sin(alpha))  
uly = y + dir * height * (tan(beta)*sin(alpha) + cos(alpha))
```

```
urx = x + width * cos(alpha) + dir * height * (tan(beta)*cos(alpha) - sin(alpha))  
ury = y + width * sin(alpha) + dir * height * (tan(beta)*sin(alpha) + cos(alpha))
```

ここで、デフォルトの場合 `topdown={output=false}` では `dir=1` です。下向き座標では、すなわち `topdown={output=true}` の場合には (78 ページの「下向き座標系」を参照)、`dir=-1` に設定する必要があります。かつ、隅が入れ替わります。すなわち、`ll` を `ul` と入れ替え、`lr` を `ur` と入れ替える必要があります。

画像解像度 画像解像度を dpi (dots per inch) 単位で算出するには、ピクセル単位の画像幅をポイント単位の画像幅で割り、それに 72 をかける必要があります：

```
while (tet.get_image_info(page) == 1) {  
    String imagePath = "images[" + tet.imageid + ""]";  
    int width = (int) tet.pcos_get_number(doc, imagePath + "/Width");  
    int height = (int) tet.pcos_get_number(doc, imagePath + "/Height");  
  
    double xDpi = 72 * width / tet.width;  
    double yDpi = 72 * height / tet.height;  
    ...  
}
```

回転されたり斜形化されたりしている画像については、dpi 値は無意味かもしれないことに留意してください。画像の dpi 計算のための完全なコードは、TET クックブックの `determine_image_resolution` トピック内にあります。

TET はデフォルトでは、生成する TIFF 画像群の中に、TIFF 仕様を満たすために、ダミーの解像度値 72 dpi を記録します。`TET_write_image_file()` の `dpi` オプションを用いると、算出した解像度値をかわりに埋め込ませることができます。算出した解像度値を TET が自動的に埋め込むことができない理由は、ある特定の画像が複数回配置されているかもしれない、その際、それぞれ異なる寸法で、したがって異なる解像度で配置されている可能性もあるからです。値 `dpi=0` を用いると、このダミー解像度値は記録されません。

TET コマンドラインツールは、ページベースの画像ループで動作している時に、算出した解像度を埋め込みます。

8.3 断片化した画像群を連結

画像を、PDF 文書内で表現されているとおりに抽出することが望ましくない場合もあります：一見 1 個の画像であるものが、実はたくさんの小画像を並べたものである場合が多くあるのです。このように画像を断片化する理由としてよくあるのは以下のとおりです：

- ▶ アプリケーションやドライバのなかには、マルチストリップ TIFF 画像を断片化 PDF 画像群へ変換するものがあります。ストリップの数は数ダースから何百個にも及ぶ場合があります。
- ▶ スキャンソフトウェアのなかには、スキャンしたページを小さな断片（ストリップまたはタイル）に分割するものがあります。断片の数は通常、数ダースを超えることはありません。
- ▶ アプリケーションのなかには、印刷出力や PDF 出力を生成する際に画像を小さな断片に分割するものがあります。極端な例としては、とりわけ Microsoft Office アプリケーション群によって作成された文書では、1 つのページが数千もの小画像断片を含んでいる場合もあります。
- ▶ Adobe InDesign などページレイアウトプログラムのなかには、PDF 出力を生成する際に、画像を小さく、かつ時には異なる寸法に分割するものがあります（図 8.2 参照）。




図 8.2
この画像は小さな部分群へ分割されていますが（上）、TET はこれをただ 1 個の再利用可能な画像として抽出します（下）。

TET の画像連結エンジンは、このような状況を検出して、画像断片を再結合して1つの大きな、かつ、より有用な画像にします。連結候補群が、結合して大きな画像にできる場合には、それらは連結されます。透過の分割・統合は、結合して長方形を作り出すことが不可能な不規則な画像レイアウトを発生させることがあります。

画像連結を無効化するには下記のページオプションを用います：

```
imageanalysis={merge={disable}}
```

pCOS における連結画像 連結された画像は、`images[]/mergetype` pCOS 擬似オブジェクトによってそのように識別できます。それは、連結された画像については値1 (*artificial*) を持ち、連結処理によって消費された画像については2 (*consumed*) を持ちます。消費済画像は一般に、受け取ったアプリケーション側では無視するべきです。

画像間の空隙と重なり 画像の位置合わせにおける不正確を補償するために、隣りあう画像どうしの間の一量空隙または重なりは許容されます。デフォルトでは、この空隙または重なりが1ポイントよりも小さければ、画像は連結されます。この値は下記のページオプションを用いて変更可能です：

```
imageanalysis={merge={gap=2}}
```

新聞や雑誌から画像を抽出する際には、多くの場合、より大きな空隙/重なり値が必要です。

画像はいつ連結されるか ページ上の画像の分析と連結は、おのこの `TET_open_page()` への呼び出しによって引き起こされます。これは、以下の結果につながります：

- ▶ pCOS `images[]` 配列内のエントリ数は、すなわち `length:images` 擬似オブジェクトの数は、増えていく可能性があります：ページが順次処理されていくにつれて、画像連結によってできた擬似画像が配列に加わっていくからです。ですので、`images[]` 配列を通じてすべての連結済画像を抽出するためには、`length:images` を取得して画像データを抽出する前に、文書内のすべてのページを開く必要があります。擬似（連結済）画像は、`images[]/mergetype` 擬似オブジェクトで、それに対応するフラグ *artificial* (数値1) でマークされています。
- ▶ 一方、`images[]` 配列内の要素のなかには、連結済画像の一部としてのみ用いられるものがあります。しかし、消費済のエントリは、`images[]` 配列から除去されるのではなく、`images[]/mergetype` 擬似オブジェクトで、それに対応するフラグ *consumed* (数値2) でマークされています。

8.4 小画像・大画像フィルタリング

TET は、ページ上に小画像がたくさんあるときは、それらを見捨てます。なぜなら多くの場合、それらは意味を持たないか、使い道がないからです。多くの小画像は、画像連結処理によって結合されて1つの大画像にされることが多いので、画像連結の後に小画像は除去されます。連結して大きな画像を形成させることができない画像のみが、小画像除去の候補となります。かつそれらは、*imageanalysis* ページオプションの *heightrange/sizerange/widthrange* サブオプションで指定される寸法条件を満たす必要があります。画像フィルタリングを完全に無効化するには、下記のページオプションを用います：

```
imageanalysis={sizerange={1 unlimited}}
```

デフォルトでは、幅か高さが 20 ピクセル未満の画像は無視されます。画像自体が小さくても、もっと大きなマスクが紐付けられている（すなわちそのマスクの寸法が指定範囲内である）場合には、その画像とそのマスクは無視されません。

pCOS における小画像・大画像 *heightrange/sizerange/widthrange* オプションに従って除去された画像群は、*TET_write_image_file()* と *TET_get_image_data()* によって無視されますが、pCOS の *images[]* 配列内にはなお存在します。pCOS の擬似オブジェクト *images[]/small* を用いてこれを識別できます（このキーワード *small* は、画像がフィルタされた原因が小さすぎたからであっても大きすぎたからであっても用いられます）。

8.5 画像の色とマスク

8.5.1 色空間

画像の色再現性 表 6.1 に、PDF のさまざまな色空間の概観を示しています。画像についてはすべての色空間に対応しています。TET は画像を抽出する際に、画像品質を下げません：

- ▶ ラスタ画像がダウンサンプルされることはありません。
- ▶ 画像の色空間は、出力内で温存されます。CMYK から RGB への変換や、同様の色変換を TET が適用することはありません。

ICC プロファイル PDF 内の画像は、ICC プロファイルを割り当てられている場合があります。これによって正確な色再現が可能になります。デフォルトでは TET は、紐付けられた ICC プロファイルを処理し、生成される TIFF または JPEG 画像ファイルへそれを埋め込みます。`TET_write_image_file()`・`TET_get_image_data()` のオプション `keepiccprofile=false` を用いて ICC プロファイル埋め込みを無効化することも可能です。これによって画像ファイルのサイズが小さくなりますが、かわりに色の忠実性が犠牲になります。正確な色再現を必要とするワークフローに対して ICC プロファイル埋め込みを無効化することは推奨しません。

スポットカラー PDF 内の画像は、名前付きカラーで着色されている場合があります。通常、名前付きカラーはカスタムスポットカラーを指定するために用いられますが、これと同じしくみを用いて CMYK プロセスカラーの部分集合（シアン・マゼンタチャンネルのみなど）を画像に適用することも可能です。PDF 内の *Separation* 色空間はただ 1 つの名前付きカラーを保持するのに対し、*DeviceN* 色空間を用いると複数の名前付きカラーを割り当てることができます。*Separation* カラーには、代替色というものが伴っており、これによって、そのスポットカラーが利用可能でない場合（モニタ上など）でもその色を表現することが可能になっています。たとえば、*Company Red* という名前の *Separation* カラーがある場合に、RGB か CMYK のようなよく知られた色空間における代替表現を持っていれば、*Company Red* が名前付きカラーとして利用可能でないデバイス上においてもこのスポットカラーを表示できますので有用です。

TET は、*Separation* または *DeviceN* カラーを持った画像を次のように抽出します：CMYK プロセスカラー名は特定されます：もし名前付きカラーの名前が *Black* であれば、それはプロセスカラーとして扱われ、その画像はグレースケール画像として抽出されます。カラー名 *Cyan*・*Magenta*・*Yellow* も特定され、その画像は CMYK 画像として抽出されます。カスタムスポットカラー名は、すなわち *Cyan*・*Magenta*・*Yellow*・*Black* 以外の名前は、文書オプション *spotcolor* に従ってさまざまな方式で処理できます：

- ▶ `spotcolor=convert` の場合（これがデフォルトです）、スポットカラーは、照応する代替色空間へ、可能であれば変換されます。そのような変換が可能でない場合には、この方式は `spotcolor=ignore`（ただ 1 つのカスタムスポットカラーに対して）か `spotcolor=preserve`（複数のカスタムスポットカラーに対して）のように動作します。
- ▶ オプション `spotcolor=ignore` は、`spotcolor=convert` と同様ですが、ただし、ちょうど 1 個のカスタムスポットカラーを持った画像はグレースケール画像として抽出され、そのスポットカラー名は失われます。
- ▶ `spotcolor=preserve` の場合、スポットカラー名は温存され、画像は、グレースケールまたは CMYK 画像に 1 個ないし複数のスポットカラーチャンネルを加えたものとして抽出されます。これは TIFF 出力を必要とします。生成される TIFF の種類は、Adobe





図 8.3
Adobe Photoshop が、spotcolor=preserve を用いて抽出された TIFF 画像のスポットカラーチャンネル群を「チャンネル」ウィンドウに表示 (左)。いずれかのアイコンをダブルクリックするとその代替色が表示されます (上)。

Photoshop と互換プログラム群を用いて表示可能です (図 8.3 参照)。シンプルな TIFF ビューア群はこの追加スポットカラーチャンネルを無視することが多いです。

表 8.2 に、スポットカラー名と文書オプション *spotcolor* の設定とのさまざまな組み合わせに対する出力形式をまとめました：

表 8.2 Separation ・ DeviceN カラーを持った画像に対する出力形式

Separation または DeviceN カラー名	spotcolor=ignore	spotcolor=convert	spotcolor=preserve
Black のみ	グレースケール		
1 個ないし複数の Cyan ・ Magenta ・ Yellow ・ Black	CMYK (使われていないチャンネルは空)		
ちょうど 1 個のカスタムスポットカラー (すなわち Cyan ・ Magenta ・ Yellow ・ Black 以外)	グレースケール	可能であれば代替色空間 ¹	空のグレースケールチャンネルに名前付きチャンネル 1 個を追加
複数のカラー名、かつすべて Cyan ・ Magenta ・ Yellow 以外	可能であれば代替色空間 ¹		グレースケールチャンネルに名前付きチャンネル 1 個ないし複数を追加
複数のカラー名、かつ 1 個ないし複数の Cyan ・ Magenta ・ Yellow を含む	可能であれば代替色空間 ¹		CMYK に名前付きチャンネル 1 個ないし複数を追加

1. 代替色空間への変換が可能でない場合には、spotcolor=ignore (ただ 1 つのカスタムスポットカラーに対して) か spotcolor=preserve (複数のカスタムスポットカラーに対して) のように動作します。

8.5.2 画像マスクとソフトマスク

マスク情報と、他の画像をマスクするために用いられている画像データ本体を、TET を用いて取得できます。PDF は下記の種類の画像マスクに対応しています：

- ▶ ステンシルマスク：1 ビット画像であり、PDF キー *ImageMask* を持ちます。画像が、一部不透明で一部透明なステンシルとして用いられます：デフォルトでは、その画像がピクセル値 0 を持つ箇所には色が適用され、その画像がピクセル値 1 を持つ箇所では背景がそのまま見えます。
- ▶ マスク：他の画像に対して適用される 1 ビットグレースケール画像です (PDF キー *Mask*)。これは、どの画像領域が塗られるべきで、どこがマスクアウトされる (そのまま見せる) べきかを指定します。

- ▶ ソフトマスク：他の画像に対して適用される、任意のビット深度のグレースケール画像です (PDF キー *SMask*)。これは、マスクされた画像とその背景との間の滑らかな遷移を与えますので、リアルな透明効果を実現します。

ハードマスクとソフトマスクの違いはビット深度だけですので、TET 内では統一的に扱われます。

TETML における画像マスク 画像マスクは TETML 内では下記のように処理されます：

- ▶ ステンシルマスク：1 ビット画像自身がステンシルマスクとして用いられていれば、TETML 属性 *Image/@stencilmask* がそのことを標識します。
- ▶ マスク：画像に画像マスク (*Mask* または *SMask*) が紐付けられていれば、TETML 属性 *Image/@maskid* がそれを参照します。そのマスク画像の詳細は、*images[]* 配列内のそのマスク画像のエントリの中で取得できます。

TET コマンドラインツールにおける画像マスク 画像マスクは TET コマンドラインツールにおいては下記のように処理されます (ステンシルマスクに関する情報は得られません)：

- ▶ *--imagemap page* を用いて画像を抽出すると、すべてのプレーンな画像が通常通り抽出されます。この抽出されたプレーン画像群のうちのいずれか 1 つに対するマスクとして用いられている画像群も、その画像ファイル名に接尾辞 *_mask* を用いて抽出されます。
- ▶ *--imagemap resource* を用いて画像を抽出すると、すべてのプレーンな画像とマスク画像が抽出されます。生成されるファイル名は、そのマスク画像の *image/@id* TETML 属性を含んでいますので、アプリケーションは、TETML 内で参照されている画像に照応するファイルの場所を知ることができます。

pCOS における画像マスク 画像マスクは pCOS 擬似オブジェクト *images[]* と *TET_pcot_get_number()* では下記のように処理されます：

- ▶ ステンシルマスクとして用いられている画像は *images[]/stencilmask* 擬似オブジェクトによって識別できます。
- ▶ 画像がソフトマスクを割り当てられて持っている場合、その照応する *images[]/maskid* 擬似オブジェクトは -1 以外の値を持ちます。この値は、そのマスクの画像 ID を示しており、*images[]* 配列内の照応するエントリを用いてそのマスクのさらなる詳細をクエリするために用いることができます。

API における画像マスク 画像マスクは TET API では下記のように処理されます：

- ▶ *TET_get_image_info()* は、ページ上に配置されているプレーンな画像群のみを数え上げ、マスク群をスキップします。その *image_info* 構造の中の *imageid* フィールドを用いてその画像の pCOS ID を取得することができ、その ID を用いて、上述のように pCOS を通じてマスクとステンシルマスクの情報をクエリすることができます。

TET_write_image_file() と *TET_get_image_data()* を用いて、マスクされた画像の *maskid* pCOS オブジェクトを用いて取得した画像 ID を用いることによって、そのマスクのピクセルデータを取得できます。これは *images_per_page* サンプルで演示されています。あるいは、pCOS の *images[]* 配列内のすべてのエントリをなめることによって、すべてのプレーン画像とマスク画像に対する画像ファイルを生成することもできます。これは *image_resources* サンプルで演示されています。

9 TET マークアップ言語 (TETML)

9.1 TETML を生成

PDF 文書の内容をプログラミングインタフェース経由で提供するのみならず、TET では、XML 出力を生成することも可能です。TET が生成するこの XML 出力を TET マークアップ言語 (TETML) と呼んでいます。TETML は、PDF ページ群のテキスト内容を含んでいるほか、テキスト位置・フォント・文字サイズなどの情報も含んでいることがあります。TET がページ上に表組のような構造を検出したときは、その表組は TETML 内で表・表行・セルエレメントの階層構造として表されます。なお、表組情報は TET プログラミングインタフェースでは得ることができず、TETML を通じてのみ得ることができます。TETML は、画像・色空間、および注釈・フォームフィールド・しおりなどインタラクティブ要素に関する情報も含んでいます。

PDF 文書を TETML へ変換するには、TET コマンドラインツールか TET ライブラリのいずれかを用いることができます。いずれの場合にも、TETML 生成の詳細を制御するために利用できるさまざまなオプションがあります。

TET コマンドラインツールで TETML を生成 TET コマンドラインツールを用いる場合は、`--tetml` オプションで TETML オプションを生成することができます。下記のコマンドは TETML 出力文書 `file.tetml` を生成します：

```
tet --tetml word file.pdf
```

さまざまなオプションを用いて、文書の一部分のページのみを変換したり、処理オプションを与えたりすることもできます。詳しくは、17 ページの 2.1 「コマンドラインオプション」を参照してください。

TET ライブラリで TETML を生成 TET ライブラリでは、API 呼び出しの簡単な連鎖を用いて TETML 出力を生成することができます。`tetml` サンプルでは、TETML を生成するための正則的なコードシーケンスを演示しています。このサンプルプログラムは、すべての対応言語バインディングで利用可能です。

TETML はページごとに生成されますので、クライアントがページ群の部分集合のみを処理することを選択することも可能です。最後のページを処理した後に TETML トレーラを生成する必要があります：

```
final int n_pages = (int) tet.pcos_get_number(doc, "length:pages");
```

```
/* 文書内のすべてのページについてループ */
for (int pageno = 1; pageno <= n_pages; ++pageno)
{
    tet.process_page(doc, pageno, pageoptlist);
}
```

```
/* これは最後のページ関連の呼び出しと一緒にすることも可能です */
tet.process_page(doc, 0, "tetml={trailer}");
```

`TET_open_document()` に `filename` オプションが与えられている場合、TETML 出力は、指定されたディスクファイルへ書き込まれます。そうでない場合には、TETML はメモリ内に蓄積され、`TET_get_tetml()` を用いて取り出せます。これは、TETML ストリーム全体に

対してただ 1 回の呼び出しで行うこともできますし（小さな文書に対してのみ推奨）、あるいは複数回の呼び出しで、TETML ストリーム全体のうちの一部分を各呼び出しごとに取得することもできます。

生成された TETML ストリームは、現在利用されている多くのプログラミング言語が提供している XML 対応を用いて XML ツリーへパースすることができます。XML 対応内蔵の言語バインディングのための *tetml* サンプルプログラムでは、TETML ツリーを処理する様子も演示しています。

TETML の中身 TETML 出力は UTF-8（USS または MVS を用いた zSeries 上 :EBCDIC-UTF-8）で符号化されており、以下の情報を含んでいます（これらの項目のいくつかはオプションです）：

- ▶ 一般文書情報：暗号化ステータス・PDF 規格・タグ付き PDF など
- ▶ 文書情報フィールド・XMP メタデータ
- ▶ 各ページのテキスト内容（単語または段落。行を含めることも可能）
- ▶ グリフのフォント・位置情報・色
- ▶ グリフに対するレイアウト属性（下 / 上付き・ドロップキャップ・影付き）
- ▶ ハイフネーション属性
- ▶ テキスト・画像のページ装飾（本文外の内容）状態
- ▶ 構造情報。例：表組・リスト
- ▶ ページ上の配置画像に関する情報
- ▶ リソース情報、すなわちフォント・色空間・画像・ICC プロファイル
- ▶ 出力インテント情報
- ▶ レイヤー情報（オプション内容としても知られています）
- ▶ インタラクティブ要素：しおり・名前付き移動先・注釈・フォームフィールド・アクション・JavaScript
- ▶ リンク・フォームフィールド・しおりの移動先の容易な参照として、テキストストリーム内にアンカーが提供されます
- ▶ 電子署名
- ▶ PDF 処理中に例外が発生した場合はエラーメッセージ

TETML 内では、さまざまなエレメントと属性がオプションです。詳しくは、147 ページの 9.3 「TETML の詳細を制御」を参照してください。

9.2 さまざまな TETML の例

以下の TETML サンプル群はいくつかの重要な機能を演示しています。TETML エレメントとその説明の完全な一覧は 151 ページの 9.4 「TETML の各種エレメントと TETML スキーマ」にあります。

文書のヘッダとテキスト出力 下記の断片は、TETML 文書の最も重要な各部分を示しています：

```
<?xml version="1.0" encoding="UTF-8"?>
<!-- Created by the PDFlib Text and Image Extraction Toolkit TET (www.pdflib.com) -->
<TET xmlns="http://www.pdflib.com/XML/TET5/TET-5.0"
  xmlns:xsi="http://www.w3.org/2001/XMLSchema-instance"
  xsi:schemaLocation="http://www.pdflib.com/XML/TET5/TET-5.0
  http://www.pdflib.com/XML/TET5/TET-5.0.xsd"
  version="5.1">
<Creation platform="Win64" tetVersion="5.2" date="2019-07-05T18:26:02+02:00" />
<Document filename="TET-datasheet.pdf" pageCount="6" filesize="508093" linearized="true"
pdfVersion="1.7">
<DocInfo>
<Author>PDFlib GmbH</Author>
<CreationDate>2015-08-05T17:43:14+02:00</CreationDate>
<Creator>Adobe InDesign CS6 (Windows)</Creator>
<ModDate>2015-08-05T17:43:15+02:00</ModDate>
<Producer>Adobe PDF Library 10.0.1</Producer>
<Subject>PDFlib TET: Text and Image Extraction Toolkit (TET)</Subject>
<Title>PDFlib TET datasheet</Title>
</DocInfo>
<Metadata>
<x:xmpmeta xmlns:x="adobe:ns:meta/" x:xmpptk="Adobe XMP Core 5.3-c011 66.145661, 2012/02/
06-14:56:27
">
  <rdf:RDF xmlns:rdf="http://www.w3.org/1999/02/22-rdf-syntax-ns#">
    ...XMPメタデータ...
  </rdf:RDF>
</x:xmpmeta>
</Metadata>
<Options> tetml={filename={TET-datasheet.word.tetml}}</Options>
<Pages>
<Page number="1" width="595.28" height="841.89">
<Options> granularity=word tetml={}</Options>
<Content granularity="word" dehyphenation="false" dropcap="false" font="false"
geometry="false" shadow="false" sub="false" sup="false">
<Para>
<Box llx="235.80" lly="796.02" urx="397.67" ury="816.72">
  <Word>
    <Text>PDFlib</Text>
    <Box llx="235.80" lly="796.02" urx="291.91" ury="814.02"/>
  </Word>
  <Word>
    <Text>datasheet</Text>
    <Box llx="306.14" lly="796.22" urx="397.67" ury="816.72"/>
  </Word>
</Box>

...さらなるページ内容群...

</Content>
```

```

</Page>
...さらなるページ群...
<Resources>
<Fonts>
<Font id="F0" name="TheSans-Plain" fullname="FXLUMY+TheSans-Plain" type="Type 1 CFF"
embedded="true" ascender="1170" capheight="675" italicangle="0" descender="-433"
weight="400" xheight="497"/>
<Font id="F1" name="PDFlibLogo2-Regular" fullname="DUMIKC+PDFlibLogo2-Regular"
type="Type 1 CFF" embedded="true" ascender="800" capheight="700" italicangle="0"
descender="-9" weight="400" xheight="537"/>
...さらなるフォント群...
</Fonts>
<Images>
<Image id="I0" filename="TET-datasheet_I0.tif" extractedAs=".tif" width="885"
height="565" colorspace="CS3" bitsPerComponent="8"/>
<Image id="I1" filename="TET-datasheet_I1.tif" extractedAs=".tif" width="1253"
height="379" colorspace="CS4" bitsPerComponent="8"/>
...さらなる画像群...
</Images>
<ColorSpaces>
<ColorSpace id="CS0" name="DeviceCMYK" components="4"/>
<ColorSpace id="CS1" name="DeviceGray" components="1"/>
...さらなる色空間群...
</ColorSpaces>
</Resources>
...
</Pages>
</Document>
</TET>

```

グリフの座標と色 選択する TETML モードに応じて、グリフのさらなる詳細を TETML 内で表すこともできます。TETML モードについて詳しくは、147 ページの「TETML モードを選択」で説明します。上記サンプルにグリフ詳細が加わった 1 つの変化形を以下に示します。*Glyph* エレメントは、フォント・位置・色情報を含んでいます（色の表現について詳しくは後述）：

```

<Word>
<Text>datasheet</Text>
<Box llx="306.14" lly="796.22" urx="397.67" ury="816.72">
<Glyph font="F0" size="20.5000" x="306.14" y="796.22" width="11.42" fill="C0">d</Glyph>
<Glyph font="F0" size="20.5000" x="317.87" y="796.22" width="10.68" fill="C0">a</Glyph>
<Glyph font="F0" size="20.5000" x="328.61" y="796.22" width="7.61" fill="C0">t</Glyph>
<Glyph font="F0" size="20.5000" x="336.52" y="796.22" width="10.68" fill="C0">a</Glyph>
<Glyph font="F0" size="20.5000" x="347.51" y="796.22" width="8.71" fill="C0">s</Glyph>
<Glyph font="F0" size="20.5000" x="356.53" y="796.22" width="11.79" fill="C0">h</Glyph>
<Glyph font="F0" size="20.5000" x="368.63" y="796.22" width="10.41" fill="C0">e</Glyph>
<Glyph font="F0" size="20.5000" x="379.35" y="796.22" width="10.41" fill="C0">e</Glyph>
<Glyph font="F0" size="20.5000" x="390.07" y="796.22" width="7.61" fill="C0">t</Glyph>
</Box>
</Word>

```

色の値と色空間 色は、色空間（*DeviceRGB* など）とカラー値によって表されます。テキストに対するカラー値は、塗り色と描線色について利用可能です。PDF において描線されたグリフは非常に稀ですので、塗り属性を目にする機会のほうがずっと多いでしょう。画像に対するカラー値は実際のピクセルデータから来ます。テキスト・ベクトルグラフィック・画像に対する色空間は、*Resources* セクション内の *ColorSpaces* エレメント内にリスト

されています。各 *ColorSpaces* エレメントは、色空間の種類に応じた詳細を内容としています。いくつかの色空間は他の色空間を参照しています。たとえば *Indexed* 色空間は、基礎を成すベース色空間を必要とします。また、*Separation* と *DeviceN* は代替色空間を必要とします：

```
<Resources>
<ColorSpaces>
<ColorSpace id="CS0" name="DeviceCMYK" components="4"/>
<ColorSpace id="CS1" name="DeviceGray" components="1"/>
<ColorSpace id="CS2" name="Indexed" components="1" base="CS0" hival="255">
  <Lookup>000000000705000349340029745300416F50003E775600...</Lookup>
</ColorSpace>
<ColorSpace id="CS0" name="Separation" components="1" alternate="CS0">
  <Colorant name="PANTONE 294 CVC"/>
  <Function type="interpolate">
    ...
    <C1>
      <Value>0.93</Value>
      <Value>0.62</Value>
      <Value>0.00</Value>
      <Value>0.00</Value>
    </C1>
    <Exponent>1</Exponent>
  </Function>
</ColorSpace>
...
</ColorSpaces>
</Resources>
```

TETML における表組 TET によって特定された表組は、TETML 内で表組・表行・セル構造を用いて表現されます。複数列にわたるセルは *colSpan* 属性を用いて標識されます：

```
<Table>
<Box llx="302.14" lly="639.72" urx="525.50" ury="731.50">
  <Row>
    <Box llx="311.64" lly="721.10" urx="521.50" ury="730.70"/>
    <Cell>
      <Box llx="311.64" lly="721.10" urx="375.22" ury="730.70"/>
      <Para>
        <Word>
          <Text>Device-dependent</Text>
          <Box llx="311.64" lly="721.90" urx="375.22" ury="729.90"/>
        </Word>
      </Para>
    </Cell>
    <Cell>
      <Box llx="397.91" lly="721.10" urx="431.99" ury="730.70"/>
      <Para>
        <Word>
          <Text>CIE-based</Text>
          <Box llx="397.91" lly="721.90" urx="431.99" ury="729.90"/>
        </Word>
      </Para>
    </Cell>
    ...
  </Row>
  <Box llx="306.14" lly="641.52" urx="516.67" ury="650.52"/>
```

```

<Cell colSpan="3">
  <Box llx="306.14" lly="706.42" urx="516.67" ury="716.02"/>
  <Para>
    <Word>
      <Text>TET</Text>
      <Box llx="306.14" lly="641.52" urx="319.70" ury="650.52"/>
    </Word>
    <Word>
      <Text>.</Text>
      <Box llx="514.83" lly="641.52" urx="516.67" ury="650.52"/>
    </Word>
  </Para>
</Cell>
</Row>
</Box>
</Table>

```

インタラクティブ要素 リンク・しおり・フォームフィールドなども、下記の例に示すとおり、TETML 内で利用可能です：

```

<Page number="6" width="595.27600" height="841.89000">
<Annotations>
<Annotation id="ANNO" type="Link" anchor="A0">
  <Box llx="327.14" lly="64.89" urx="395.08" ury="79.18"/>
  <Action type="URI" trigger="activate" URI="mailto:sales%40pdflib.com"/>
</Annotation>
<Annotation id="ANN1" type="Link" anchor="A1">
  <Box llx="327.14" lly="52.89" urx="391.05" ury="67.18"/>
  <Action type="URI" trigger="activate" URI="http://www.pdflib.com"/>
</Annotation>
</Annotations>

```

リンクの内部のテキストは、**A**（アンカー）エレメントでラップされます。このエレメントは、視覚的に定義された PDF 注釈と、それに照応するページ内容、すなわちそのリンクを起動するテキストとの間の関係を与えます。たとえばリンクが、1 つの単語や段落の中の一部分にわたっているかもしれません。アンカーは必ずしも TETML エレメント全体にわたっているとは限りませんので、リンク内容をただ 1 個の **A** エレメントで囲むのではなく、**start/stop** アンカーエレメントが別々に必要になります：

```

<A id="A1" type="start"/>
<Word>
  <Text>www.pdflib.com</Text>
  <Box llx="327.14" lly="56.71" urx="391.05" ury="65.71"/>
</Word>
<A id="A1" type="stop"/>

```

9.3 TETML の詳細を制御

さまざまな TETML モード TETML は、さまざまなモードで生成することができます。各モードは、含むフォント・位置情報の量が異なり、また、テキストをより大きな単位（粒度）にまとめるやり方が異なっています。この TET モードは、各ページに対して個別に指定することが可能です。多くの場合、TETML ファイルは全ページに対するデータを同一のモードで含みます。以下の TET モードは、テキスト・画像情報およびインタラクティブ要素を含んでいます：

- ▶ **glyph** モード：各グリフのテキスト・フォント・座標・色を含み、単語グループ化や構造情報を一切含まない低レベルな種類です。これはページ上の元のテキスト情報を表していますので、デバッグや分析の用途を想定しています。
- ▶ **word** モード：テキストが単語ごとにまとめられ、各単語の座標を持つ **Box** エレメントが加わります。フォント情報は一切得られません。このモードは、単語ベースで動作するアプリケーションに適しています。約物キャラクタはデフォルトでは独立した単語として扱われますが、この動作はページオプションで変えることもできます（91 ページの「欧文テキストの単語境界検出」を参照）。テキストの行を **Line** エレメントで特定させることも可能です。これは **tetml** ページオプションで制御されます。
- ▶ **wordplus** モード：**word** モードと似ていますが、単語内の全グリフのフォント・座標の詳細と色情報が加わります。座標は、**topdown** ページオプションに従って、左下隅か左上隅からの相対位置で表されます。**wordplus** モードでは、フォントの使われ方を分析し、単語内でのフォントや文字サイズなどの変化を追うことが可能です。**wordplus** は、関連する TETML エレメントをすべて含む唯一の TETML モードですので、あらゆる種類の処理作業に適しています。その反面、これは TETML 内に大量の情報を含みますので、最も大きな量の出力を生成します。
- ▶ **line** モード：個別の **Line** エレメントを構成するすべてのテキストを含みます。そのうえ、複数の行が 1 個の **Para** エレメント内にまとめられることもあります。**line** モードは、受取先アプリケーションが行ベースのテキスト入力しか扱えない場合にのみ推奨します。
- ▶ **page** モード：段落レベルから始まる構造情報を含みますが、フォント・座標の詳細は一切含みません。なお、**page** モードにおけるレイアウト検出の結果は、**word** モードと若干異なる場合があります。なぜなら、画像と移動先に対するアンカーの扱いが異なるからです。

画像情報にのみ関心がある場合には、TETML 内の他の種類の出力をスキップすることも可能です。

- ▶ **image** モード：配置画像と画像リソースに関する情報を含みますが、テキスト・フォント関連のエレメントもインタラクティブ要素に関する情報も一切含みません。

表 9.1 に、各種テキストモード内に存在する TETML エレメントを挙げます。

TETML モードを選択 TET コマンドラインツール（17 ページの 2.1 「コマンドラインオプション」を参照）では、望むページモードを、**--tetml** オプションに対する引数として指定することができます。下記のコマンドは、**wordplus** モードで TETML 出力を生成します。

```
tet --tetml wordplus file.pdf
```

TET ライブラリでは、TETML モードは直接指定することはできず、オプション群の組み合わせとして指定します：

表 9.1 各種 TETML モードにおけるテキスト関連エレメント。PlacedImage と Image はつねに存在します。

TETML モード	構造	表組	テキストの位置	グリフの詳細
<i>glyph</i>	—	—	—	Glyph・Color
<i>word</i>	Para・Word オプション： Line・List	Table・Row・Cell	Word 内の Box オプション：Para 内の Box	—
<i>wordplus</i>	Para・Word オプション： Line・List	Table・Row・Cell	Word 内の Box オプション：Para 内の Box	Glyph・Color
<i>line</i>	Para・Line	—	オプション：Para 内の Box	—
<i>page</i>	Para	Table・Row・Cell	オプション：Para 内の Box	—
<i>image</i>	—	—	—	—

- ▶ 最小エレメント内のテキストの量を、*TET_process_page()* の *granularity* オプションで指定することができます。
- ▶ *granularity=glyph* または *word* の場合には、さらにグリフ詳細の量を指定することも可能です。グリフ情報の一部分が必要ないときは、*tetml* オプションの *glyphdetails* サブオプションでそれを省略させることもできます。
- ▶ テキスト出力を一切させないようにするために (すなわち *image* モード)、下記の文書オプションを用いてテキストエンジンを無効化することもできます：

```
engines={notext}
```

下記のページオプションリストは、すべてのグリフ詳細を含めた *wordplus* モードで TETML 出力を生成します：

```
granularity=word tetml={ glyphdetails={all} }
```

表 9.2 に、各種 TETML モードを作成するためのオプションをまとめます。

表 9.2 TET ライブラリで各種 TETML テキストモードを作成

TETML モード	文書オプション	TET_process_page() のオプション
<i>glyph</i>	tetml={glyphdetails={all}}	granularity=glyph
<i>word</i>	—	granularity=word
<i>wordplus</i>	tetml={glyphdetails={all}}	granularity=word
<i>Line</i> エレメント付き <i>word</i>	tetml={elements={line}}	granularity=word
<i>Line</i> エレメント付き <i>wordplus</i>	tetml={glyphdetails={all} elements={line}}	granularity=word

表 9.2 TET ライブラリで各種 TETML テキストモードを作成

TETML モード	文書オプション	TET_process_page() のオプション
<i>line</i>	—	granularity=line
<i>page</i>	—	granularity=page
<i>image</i>	<pre>engines={notext novector} tetml={elements={annotations=false docinfo=true bookmarks=false destinations=false fields=false javascripts=false metadata=true options=true}}</pre>	

TETML 出力を制御するための文書オプション この項では、生成される TETML 出力を直接制御するさまざまなオプションの効力をまとめます。他のすべての文書オプションは、処理の詳細を制御するために用いることができます。文書オプションの完全な説明は、188 ページの表 10.8 にあります。

文書関連のオプションは、`--docopt` コマンドラインオプションに、または `TET_open_document()` 関数に与える必要があります。

`tetml` オプション¹は、TETML の一般的な諸側面を制御します。いくつかの TETML エレメントは、必要なければ、`elements` サブオプションを用いてなくすこともできます。下記の文書オプションリストは、生成される TETML 出力内に文書レベルの XML メタデータがないようにしています：

```
tetml={ elements={nometadata} }
```

`engines` オプションを用いると、TET カーネルの処理エンジン群のいくつかを無効化できます。下記のオプションリストは、テキスト内容を処理しますが、テキストカラーの取得と画像処理を無効化するよう TET に命じています：

```
engines={notextcolor noimage}
```

下記の文書オプションは、`granularity=page` の場合にのみ意味を持ちます。これは、デフォルトの行区切りキャラクタをラインフィールドからスペースへ変更します：

```
lineseparator=U+0020
```

TETML を生成する際に与えられたすべての文書オプションは、下記の文書オプションで無効化されないかぎり、`/TET/Document/Options` エレメント内に記録されます：

```
tetml={ elements={nooptions} }
```

インタラクティブ要素に対する TETML 出力を制御するための文書オプション TETML は、PDF 文書内のインタラクティブ要素に関する情報も含むことができます。文書オプション `tetml` にサブオプション `elements` を指定すると、さまざまな要素に対する TETML 出力を有効化したり無効化したりすることが可能です。例：

```
elements={annotations=true bookmarks=true destinations=true fields=true javascripts=true}
```

TETML 出力を制御するためのページオプション ページオプションの完全な説明は表 10.10 にあります。ページ関連のオプションは、`--pageopt` コマンドラインオプションに、または `TET_process_page()` に与える必要があります。

1. tetml オプションは 2 種類あることに留意してください。1 つは文書レベルのもので 1 つはページレベルのもので。

`tetml` ページオプションは、**Glyph** エレメント内の座標・フォント関連情報を有効化または無効化します。下記のページオプションリストは、**Glyph** エレメント内のフォント詳細を有効化していますが、それ以外のグリフ属性はないようにしています：

```
tetml={ glyphdetails={font} }
```

下記のページオプションリストは、TETML 出力に **Line** エレメントを加えています：

```
tetml={ glyphdetails={font} elements={line} }
```

下記のページオプションは、下付きと上付きを示すために、**Glyph** エレメントに **sub**・**sup** 属性を追加しています：

```
tetml={ glyphdetails={sub sup} }
```

下記のページオプションは、**all** を用いて、**Glyph** エレメントに可能なすべての属性を生成しています：

```
tetml={ glyphdetails={all} }
```

下記のページオプションは、デフォルトの上向き座標ではなく下向き座標を要請しています：

```
topdown={output}
```

下記のページオプションリストは、TET に対して、約物キャラクタを隣接する単語に結合するよう指示しています。すなわちこの場合、約物キャラクタは独立した単語としては扱われません：

```
contentanalysis={nopunctuationbreaks}
```

TETML を生成する際に与えられたすべてのページオプションは、下記の文書オプションで無効化されないかぎり、**/TET/Document/Pages/Page/Options** エレメント内に（各ページごとに個別に）記録されます：

```
tetml={ elements={nooptions} }
```

例外処理 PDF 解析中にエラーが発生した場合、TET は一般には、可能ならばその問題を修復または無視しようとし、可能でないなら例外を発生させます。しかし、TET で TETML 出力を生成している際には、PDF 解析上の問題は通常、TETML 内の **Exception** エレメントとして報告されます：

```
<Exception errnum="4506">Object 'objects[49]/Subtype' does not exist</Exception>
```

TETML を処理している際に、期待したエレメントでなく **Exception** エレメントが現れた場合をいかに処理するかは、アプリケーション側で手はずを整える必要があります。

TETML 出力ファイルの生成を妨げる問題の場合は（オプションが無効、出力ファイルへの書き込み権限がないなど）、実行時例外が発生し、有効な TETML 出力は生成されません。

9.4 TETML の各種エレメントと TETML スキーマ

すべての TETML エレメント・属性とそれらの関係についての正式な XML スキーマ定義 (XSD) が、TET ディストリビューションに含まれています。TET 名前空間は下記です：

<http://www.pdflib.com/XML/TET5/TET-5.0>

このスキーマは Web 上の下記 URL からダウンロードすることもできます：

<http://www.pdflib.com/XML/TET5/TET-5.0.xsd>

各 TETML 文書のルートエレメント内には、TETML 名前空間とスキーマロケーションがともに存在しています。

表 9.3 に、すべての TETML エレメントの役割を説明します。TET 5.0 より後に導入されたエレメントと属性にはその旨記しています。図 9.1・図 9.2 に、TETML エレメント群の XML 階層構造を図示します。

表 9.3 TETML エレメント・属性一覧

TETML エレメント	説明と属性
A	(granularity=glyph・word の場合のみ) ページ内容内の注釈・移動先・フィールドに対するアンカー 属性：id・type (値 start・stop の type はテキストを囲み、値 rect の type は内容のないアンカーを略記)
Action	PDF アクションを記述。 属性：filename・name・javascript・URI・trigger・type
Annotation	PDF 注釈 (フォームフィールドは Field エレメントで記述されるので除く) を記述。注釈に照応するポップアップ注釈がある場合、そのポップアップは、ネストされた Annotation エレメントとして表されます。 属性：alignment・anchor・color・creationdate・destination・hidden・icon・id・intent・interiorcolor・invisible・moddate・name・onscreen・opacity・open・print・readonly・rotate・subject・symbol・type 子エレメント：Action・Box・Annotation・Contents・Title
Annotations	Annotation エレメント群のコンテナ 属性：xml:space
Attachment	PDF 添付については、ネストされた Document エレメント内にその内容を記述します。非 PDF の添付については、その名前のみが挙げられ、内容は記述されません。 属性：name・level・pagenumber
Attachments	Attachment エレメント群のコンテナ
BitPerSample	サンプリング関数すなわち Function/@type="sampled" に対するサンプルあたりビット数
BlackPoint	CalGray・CalRGB・Lab 色空間に対する黒点の三刺激値 属性：x・y・z
Body	(TET 5.1) リスト本文 子エレメント：Para・List・Table・PlacedImage・A

表 9.3 TETML エレメント・属性一覧

TETML エレメント	説明と属性
Bookmark	Bookmark・Title エレメントを内容として持つことによって、PDF しおり（アウトラインエントリとも呼ばれます）のテキストとプロパティ群とネストされたしおり群を記述 属性：color・destination・fontstyle・open 子エレメント：Action・Bookmark・Title
Bookmarks	Bookmark エレメント群のコンテナ 属性：xml:space
Bounds	ステッチ関数すなわち Function/@type="stitching" に対する間隔群 子エレメント：Value
Box	単語か段落か注釈かフォームフィールドの座標を記述します。属性 llx と lly が Box の左下隅を、urx と ury が右上隅を記述します ¹ 。1 個の単語または段落が複数の Box エレメントを含む場合もあります。たとえばハイフン区切りされた単語が複数のテキスト行にわたっている場合や、単語の先頭が大きなドロップキャップキャラクタになっている場合などです。 属性：llx・lly・urx・ury ² ・ulx・uly ² ・lrx・lry ² 子エレメント：A・Glyph・Line・Para・PlacedImage・Table・Text・Word 親エレメント：Para・Word
Co	補間関数すなわち Function/@type="interpolate" に対する起点カラー値 子エレメント：Value
C1	補間関数すなわち Function/@type="interpolate" に対する終点カラー値。このエレメントはスポットカラーの代替色を記述します。簡便な機能として、サンプリング関数すなわち Function/@type="sampled" に対しても、このエレメントを作ることができます。ただし、PDF 内ではそのような関数に対してこれは存在していません。 子エレメント：Value
Calculator	PostScript 関数すなわち Function/@type="PostScript" に対するオペレータ群
Cell	1 個の表セルの内容を記述。 属性：colSpan・llx・lly ² ・urx・ury ² ・ulx ¹ ・uly ² ・lrx・lry ² ・rowSpan (TET 5.2)
Color	PDF カラーを記述。 属性：colorspace・id・svgname・pattern
Colorant	Separation または DeviceN 色空間のインキ 属性：name・colorspace
Colors	Color エレメント群のコンテナ
ColorSpace	PDF 色空間を記述。 属性：alternate・base・components・hival・iccprofile・id・name・pattern・subtype 子エレメント：BlackPoint・Colorant・Exception・Function・Gamma・Lookup・Matrix・Process・Range・WhitePoint
ColorSpaces	ColorSpace エレメント群のコンテナ
Content	ページ内容を階層構造として記述します。 属性：granularity・dehyphenation・dropcap・font・geometry・shadow・sub・sup
Contents	Annotation の子として：注釈の内容 Field の子として：フォームフィールドの内容

表 9.3 TETML エlement・属性一覧

TETML Element	説明と属性
Creation	TET 実行に関する日付とオペレーティングシステムプラットフォームと、TET のバージョン番号を記述します。 属性 : date · platform · tetVersion
Decode	サンプリング関数すなわち Function/@type="sampled" に対するサンプル値群のマッピング子Element : Value
Destination	文書内の PDF 移動先を記述。 属性 : anchor · bottom ² · id · left · name · page · right · top ² · type · zoom
Destinations	Destination Element 群のコンテナ
DefaultValue	フォームフィールドのデフォルト値
DocInfo	定義済・カスタム文書情報項目 子Element : Author · CreationDate · Creator · GTS_PDFXConformance · GTS_PDFXVersion · GTS_PPMLVDXConformance · GTS_PPMLVDXVersion · ISO_PDFEVersion · Keywords · ModDate · Producer · Subject · Title · Trapped · Custom (属性 : key) · CustomBinary (属性 : key)
Document	PDF ファイル名・サイズ・PDF バージョン番号を含む一般的文書情報を記述します。 属性 : filename · destination · pageCount · filesize · linearized · pdfVersion · pdfa (TET 5.2 : PDF/A-4 に対する新しい値群) · pdfe · pdfua (TET 5.2 : PDF/UA-2 に対する新しい値群) · pdfvcr (TET 5.2) · pdfx · pdfvt (TET 5.2 : PDF/VT-3 に対する新しい値群) · pdfx (TET 5.2 : PDF/X-6 に対する新しい値群) · revisions (TET 5.0) · tagged · usagerights (TET 5.0) 子Element : Action · Attachments · Bookmarks · Destinations · DocInfo · Encryption · Exception · JavaScripts · Metadata · Options · OutputIntents · Pages · SignatureFields · XFA
Domain	関数に対する入力値の間隔 (群) 子Element : Value
Encode	ステッチ関数すなわち Function/@type="stitching" に対する入力値群のマッピング子Element : Value
Encryption	さまざまなセキュリティ設定を記述。 属性 : keylength · algorithm · attachment · description · masterpassword · userpassword · noprint · nomodify · nocopy · noannots · noassemble · noforms · noaccessible · nohiresprint · plainmetadata
Exponent	補間関数すなわち Function/@type="interpolate" に対する補間指数
Exception	TET が発生させて TETML へ変換した例外に関連するエラーメッセージ・番号。PDF データ構造が正しくないために入力から十分な情報を抽出できない場合には、この Exception Element が他の Element を置き換えることがあります。 下記の Element が Element を子として持てます : Annotation · Annotations · Attachment · Attachments · Bookmark · Bookmarks · Color · ColorSpace · ColorSpaces · Document · Field · Fields · Font · Fonts · ICCProfile · Image · Images · Metadata · Page · Pattern · Patterns · SignatureField · SignatureFields 属性 : errnum

表 9.3 TETML エレメント・属性一覧

TETML エレメント	説明と属性
Field	PDF フォームフィールドを記述。 属性 : alignment · anchor · backgroundcolor · bordercolor · caption · captiondown · captionrollover · destination · export · exportvalue (type=radiobutton · checkbox の場合のみ) · hidden · id · mappingname · name · onscreen · print · readonly · required · rotate · sort · state · type · visible 子エレメント : Action · Box · Contents · Field (type=radiogroup のフィールドを構成するボタン群に対して) · DefaultValue · OptionalValue · Tooltip · Value
Fields	Field エレメント群のコンテナ 属性 : xml:space
Font	フォントリソースを記述。必須の name 属性は正準フォント名を内容として持ち、オプションな fullname 属性はサブセット接頭辞を含むフォント名を持ちます。 属性 : ascender · capheight · descender · embedded · fullname · id · italicangle · type · name · vertical · weight · xheight
Fonts	Font エレメント群のコンテナ
Function	Separation または DeviceN 色空間に対する濃度変換関数 属性 : type 子エレメント : BitsPerSample · Bounds · Calculator · C0 · C1 · Decode · Domain · Encode · Functions · Exponent · Order · Range · Samples · Size
Functions	ステッチ関数すなわち Function/@type="stitching" に対するサブ関数群のコンテナ 子エレメント : Function
Gamma	CalGray または CalRGB 色空間に対するガンマ値群 子エレメント : Value
Glyph	1 個のグリフに対するフォント・位置情報の詳細を記述。このエレメントは、そのグリフが生み出す Unicode キャラクタ (1 個ないし複数) を内容として持ちます。1 個のグリフが複数のキャラクタを生成することもあります。たとえば合字の場合などです。単語に対する Glyph エレメント群は、1 個ないし複数の Box エレメント内にまとめられています。 属性 : x · y ² · width · height (縦書き、かつグリフ高さがその文字サイズと異なる場合のみ) · alpha ² · beta ² · shadow · dropcap · fill · font · size · stroke · sub · sup · textrendering · unknown · dehyphenation · artifact (TET 5.2)
Graphics	Colors · ICCProfiles · Layers エレメントのコンテナ
ICCProfiles	ICCProfile エレメント群のコンテナ
ICCProfile	ICC カラープロファイルを記述 属性 : checksum · iccversion · id · deviceclass · embedded · fromCIE · profilecs · profilename · toCIE
Image	画像リソースを、すなわち、画像を構成するピクセル配列本体を記述。 属性 : bitsPerComponent · colorspace · extractedAs · filename · height · id · maskid · mergetype · stencilmask · width 属性 Image/@filename は、TET コマンドラインツールでオプション --imagemloop resource を用いることによって作成される画像ファイル名と同一です (19 ページの「画像ファイル名」を参照)。
Images	Image エレメント群のコンテナ

表 9.3 TETML エレメント・属性一覧

TETML エレメント	説明と属性
Item	(TET 5.1) リスト項目。リストラベルと本文を内容として持ちます。さらに A・PlacedImage エレメントを内容として持ちえます。 子エレメント : Label・Body・A・PlacedImage
JavaScript	JavaScript コードのシーケンスを記述 属性 : id・name
JavaScripts	JavaScript エレメント群のコンテナ
Label	(TET 5.1) リストラベル 子エレメント : Word
Layer	オプション内容グループ (OCG。通常はレイヤーと呼ばれています) を記述 属性 : name・visible・label・locked 子エレメント : Layer
Layers	Layer エレメント群のコンテナ
Line	1 個の行に対するテキスト。Line は Word エレメント群を含むこともありえます。 属性 : llx・lly ² ・urx・ury ² ・ulx ¹ ・uly ² ・lrx・lry ² (すべて TET 5.2 で導入) 子エレメント : Text・Word
List	(TET 5.1) リスト項目群のコンテナ。さらに A・PlacedImage エレメントを内容として持ちえます。このエレメントは、リスト検出が有効化されているときのみ出力されます。 属性 : id 子エレメント : Item・A・PlacedImage
Lookup	Indexed 色空間すなわち ColorSpace/@name="Indexed" に対するルックアップテーブル。これは、その Indexed 色空間のベース色空間の中で解釈されるべき値の 16 進列を内容とします。
Matrix	CalRGB 色空間の変換行列 子エレメント : Value
Metadata	文書・フォント・画像のいずれかと紐付けられる XMP メタデータ。
OptionalValue	フォームフィールドのオプション値
Options	TETML を生成するために用いられた文書またはページオプション。
Order	サンプリング関数すなわち Function/@type="sampled" に対するサンプル補間の次数
OutputIntent	文書かページの出力インテントを記述 属性 : iccprofile・subtype 子エレメント : OutputCondition・OutputConditionIdentifier・RegistryName・Info
OutputIntents	OutputIntent エレメント群のコンテナ
Page	1 個のページの内容。 属性 : hasdefaultcmyk・hasdefaultgray・hasdefaultrgb・height・label・number・topdown・width 子エレメント : Action・Annotations・Content・Exception・Fields・Options・OutputIntents
Pages	Page エレメント群のコンテナ

表 9.3 TETML エレメント・属性一覧

TETML エレメント	説明と属性
Para	1 個の段落を構成するテキスト。 子エレメント : A · Box · Word
Pattern	PDF パターンを記述 属性 : id · patterntype · painttype · tilingtype
Patterns	Pattern エレメント群のコンテナ
PlacedImage	ページ上に配置されている画像のインスタンスを記述。 属性 : alpha ² · beta ² · artifact (TET 5.2) · height · image · source (TET 5.2) · width · x · y ²
Process	下位種別 NChannel の DeviceN 色空間のプロセス色空間記述 属性 : colorspace 子エレメント : Component
Range	ColorSpace の子として : Lab 色空間の範囲 Function の子として : 関数に対する出力値の範囲 子エレメント : Value
Resources	ColorSpaces · Fonts · Images · Patterns リソースコンテナのコンテナ
Row	1 個ないし複数の表セルのコンテナ 子エレメント : Cell
Samples	サンプリング関数すなわち Function/@type="sampled" に対するサンプルの 16 進列
SignatureField	署名済みか未署名の署名フィールドを記述 属性 : cades · field · fillablefields · permissions · preventchanges · sigtype · visible
SignatureFields	SignatureField エレメント群のコンテナ
Size	サンプリング関数すなわち Function/@type="sampled" に対する各入力次元の中のサンプルの数 子エレメント : Value
Table	1 個ないし複数の表行のコンテナ 属性 : llx, lly ² , urx, ury ² , ulx ¹ , uly ² , lrx, lry ² 子エレメント : Row
TET	TETML ルートエレメント。属性 : version
Text	単語などのエレメントのテキスト内容 属性 : artifact (TET 5.2)
Title	Annotation の子として : 注釈のタイトル Bookmark の子として : しおりのタイトル DocInfo の子として : 文書情報項目 Title
Tooltip	フォームフィールドのツールチップ
Value	フォームフィールドの値
WhitePoint	CalGray · CalRGB · Lab 色空間に対する白点の三刺激値 属性 : x · y · z

表 9.3 TETML エlement・属性一覧

TETML エlement	説明と属性
Word	1 個の単語
XFA	文書が XFA フォーム情報を内容として持っています 属性 : type (つねに static。なぜなら TET は動的 XFA フォームを処理することを拒否するからです)

1. Box が表す矩形の各辺がページの各辺と平行な場合には、4 個の値 $llx \cdot lly \cdot urx \cdot ury$ が左下隅と右上隅を表します。そうでない場合には、これに加えて左上隅と右下隅の座標も $ulx \cdot uly \cdot lrx \cdot lry$ として存在します。
2. 垂直座標と角度はすべて、topdown ページオプションに従って、左下隅か左上隅のいずれかからの相対位置で表されます。

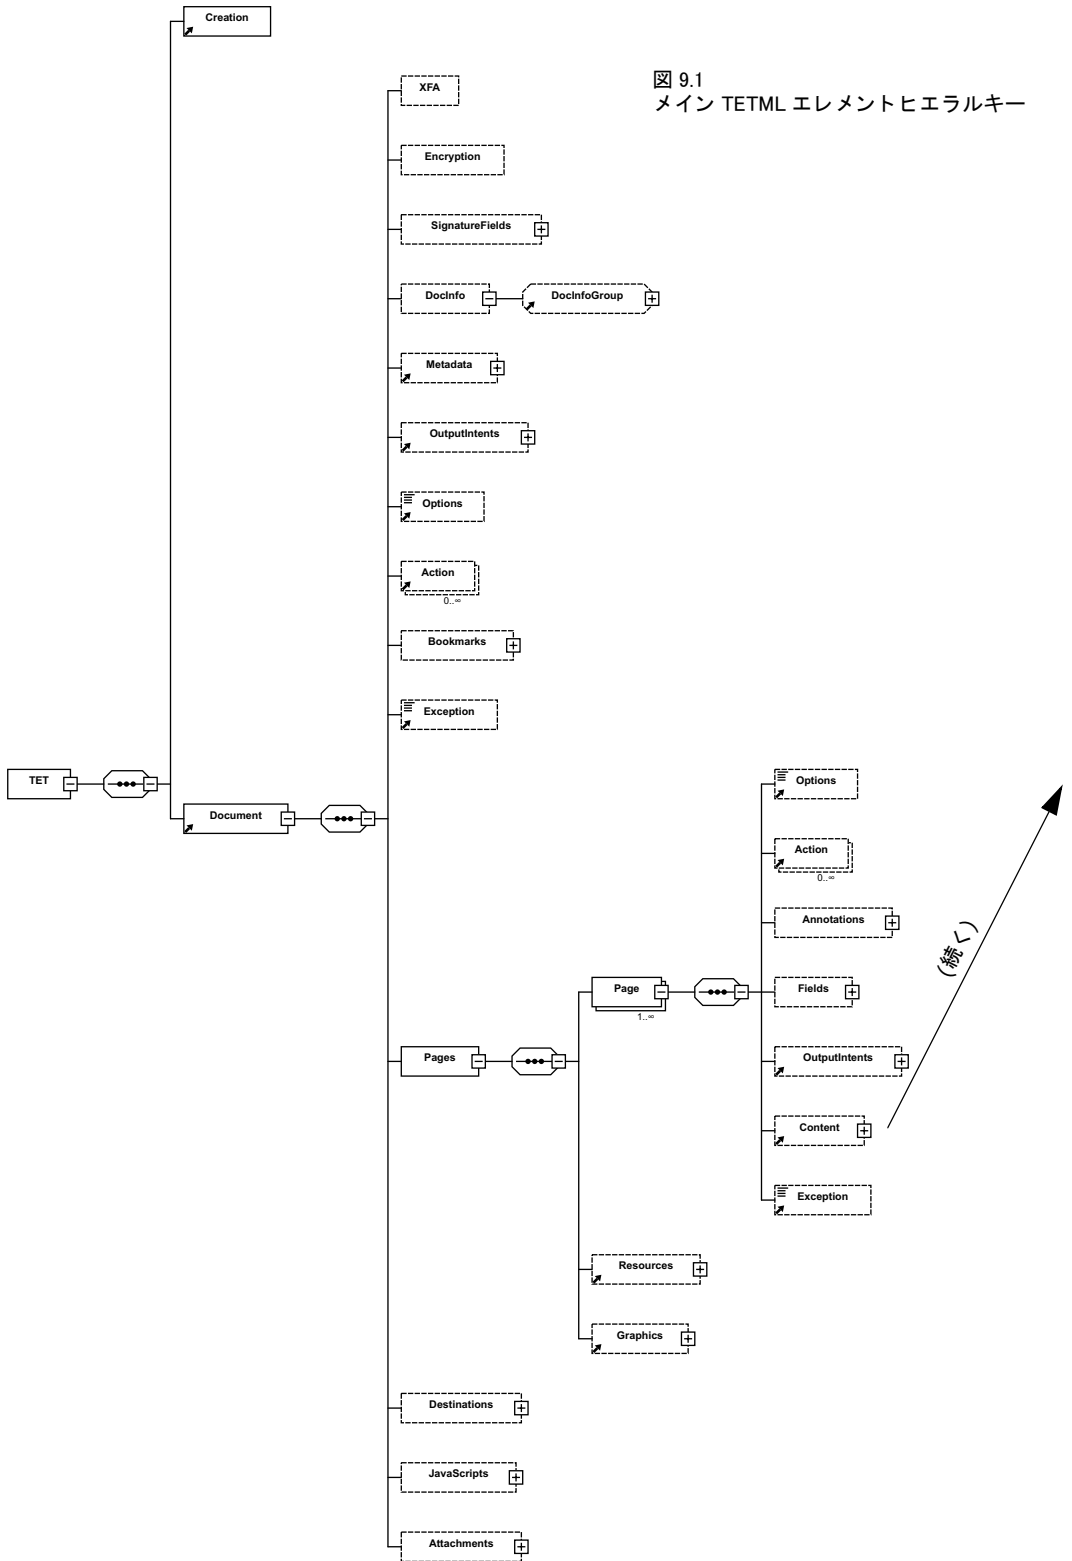
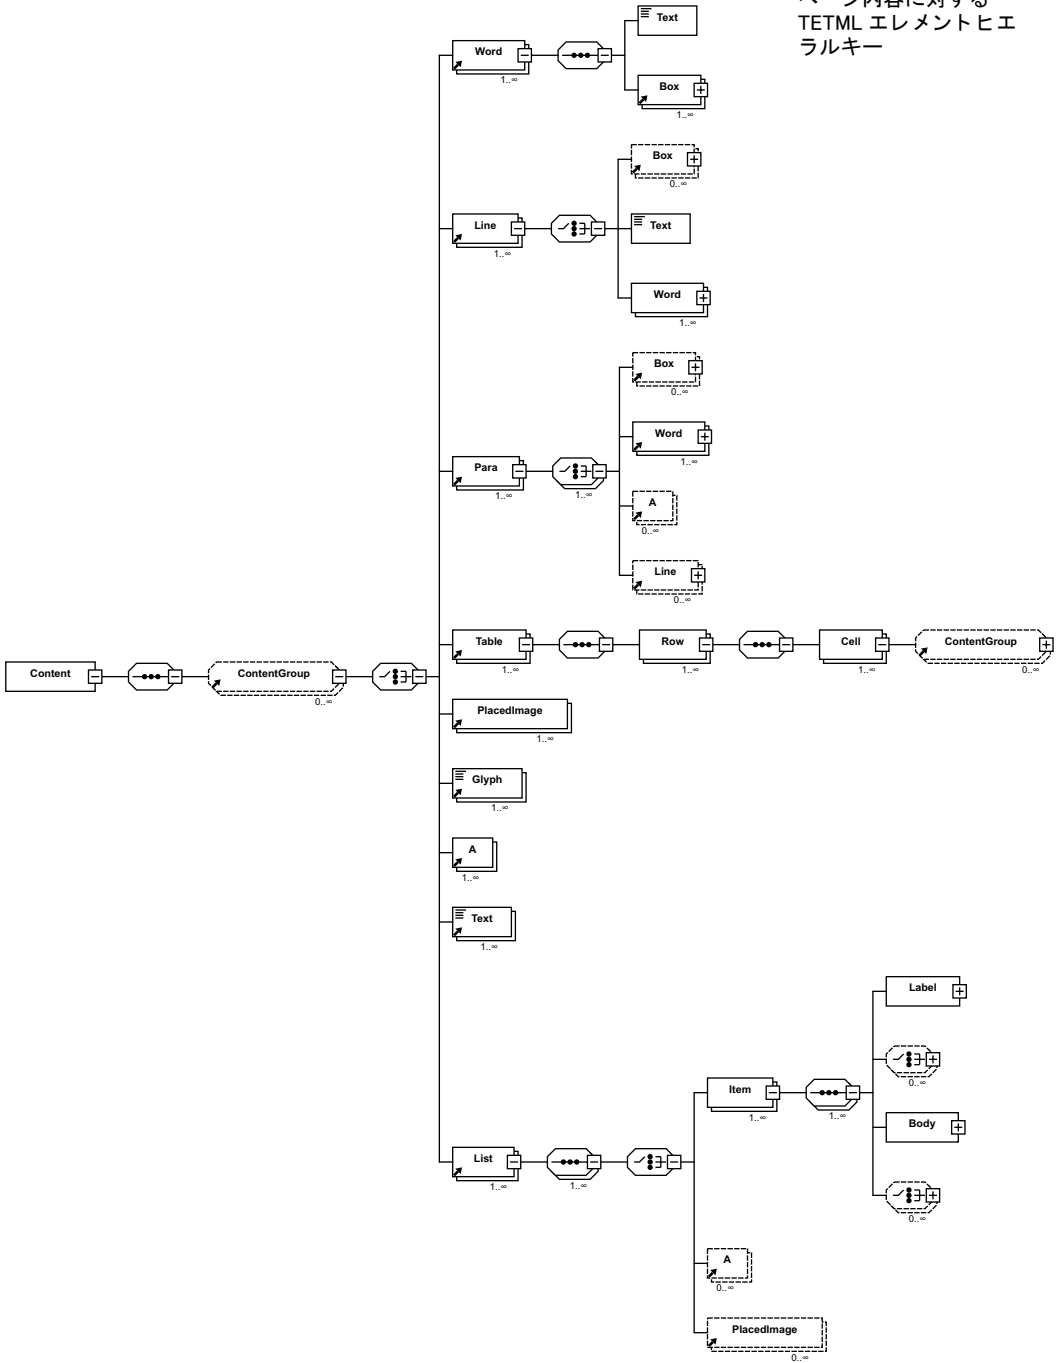


図 9.1
メイン TETML エレメントヒエラルキー

(続く)

図 9.2
ページ内容に対する
TETML エlement ヒエ
ラルキー



9.5 TETML を XSLT で変換

XSLT のごく簡単な概略 XSLT (*eXtensible Stylesheet Language Transformations* の略) は、XML 文書を他の文書へ変換するための言語です。その入力には必ず XML 文書ですが (私たちの場合は TETML)、出力は必ずしも XML である必要はありません。XSLT では、任意の計算を行うこともでき、プレーンテキストや HTML 出力を生成することもできます。XSLT スタイルシートを用いて TETML 入力を処理し、その入力に基づいた新しいデータセットを、テキスト・XML・CSV・HTML いずれかの形式で生成しましょう。この TETML 入力には、PDF 文書の内容を反映しています。TETML 文書は、141 ページの 9.1 「TETML を生成」で説明したように、TET コマンドラインツールで、または TET ライブラリで生成されています。

XSLT は非常に強力ですが、通常のプログラミング言語とはかなり異なっています。XSLT プログラミングの初歩をこの節で解説しようとするつもりはありません。それに關する情報源を参照してください。

とはいえ、読者が TETML 文書の XSLT 処理にすばやく着手し実現できるよう手助けすることは私たちの望みです。この節では、XSLT スタイルシートを動作させるために最も重要な環境を説明するとともに、この目的のために広く利用されているソフトウェアを挙げます。XSLT スタイルシートを XML 文書に適用するには XSLT プロセッサが必要です。無償や商用のさまざまな XSLT プロセッサが入手可能であり、そのなかにはスタンドアロンなやり方で利用できるものもあれば、プログラミング言語の助けによって自分のプログラムの中で利用可能なものもあります。

XSLT スタイルシートでは、処理の詳細を制御するために環境からスタイルシートへ渡されるパラメタを活用することも可能です。私たちの XSLT サンプルのなかにもスタイルシートパラメタを利用しているものがいくつかありますので、さまざまな環境でパラメタをスタイルシートへ受け渡す方法についても情報を提供します。

さまざまなパッケージングで利用できる、広く利用されている XSLT プロセッサには、以下のようなものがあります：

- ▶ Microsoft の MSXML という XML 実装、*msxsl.exe* という無償のプログラムが Microsoft によって提供されています。
- ▶ Microsoft の .NET Framework XSLT 実装
- ▶ .NET Core XSLT 実装
- ▶ Saxon (www.saxonica.com)。無償版と商用版が入手可能です。Java に基づいていますが、.NET・C/C++・PHP 版もあります。
- ▶ Xalan (xalan.apache.org)。Apache ファウンデーションがホストしているオープンソースプロジェクトです (C++ 実装と Java が入手可能です)。
- ▶ GNOME プロジェクトのオープンソースの *libxslt* ライブラリ (xmlsoft.org/XSLT) と、それに照応する *xsltproc* コマンドラインツールが、大多数の Linux ディストリビューションにあります。

コマンドラインで XSLT XSLT スタイルシートをコマンドラインから適用することは、便利な開発・試験環境を提供します。以下のさまざまな例は、XSLT スタイルシートをコマンドライン上で適用する方法を示しています。以下のサンプル群は、入力ファイル *TET-datasheet.tetml* をスタイルシート *tetml2html.xsl* で処理しており、その際、XSLT パラメタ *toc-generate* (スタイルシート内で用いられている) を値 *o* に設定しており、生成された出力を *TET-datasheet.html* へ書き出しています：

- ▶ Java ベースの Saxon プロセッサは、下記のように使えます：

```
java -jar saxon9.jar -o TET-datasheet.html TET-datasheet.tetml tetml2html.xsl
```


- ▶ **ant** ビルドツールを用いて XSLT スクリプトを適用することもできます。XSLT を適用するための最小限のビルドファイルは下記のようになります：

```
<project name="tetml2html" default="tetml2html">
  <target name="tetml2html">
    <xslt in="TET-datasheet.tetml" style="tetml2html.xsl" out="TET-datasheet.html"/>
  </target>
</project>
```

TET ディストリビューション内の *build.xml* ファイルは、すべてのサンプルに対する XSLT タスクを内容としています。**ant** コマンドは、すべての XSLT サンプルを適用して、入力文書 *TET-datasheet.pdf* を TETML へ変換します。下記のコマンドは他の PDF 入力文書を処理します：

```
ant -Dinput.pdf=myfile.pdf
```

- ▶ **xsltproc** ツール：多くの Linux ディストリビューションに含まれています。スタイルシートを TETML 文書に適用するには下記のコマンドを用います：

```
xsltproc --output TET-datasheet.html --param toc-generate 0 tetml2html.xsl ←
TET-datasheet.tetml
```

TET ディストリビューション内の *runxslt.sh* シェルスクリプトを使うと、すべての XSLT サンプルを、**xsltproc** を用いて実行することができます (**ant** を 1 回実行することによって TETML 入力ファイル群を生成してください)。

- ▶ Xalan C++：コマンドラインツールを提供しており、これは下記のようにして起動できます：

```
Xalan -o TET-datasheet.html -p toc-generate 0 TET-datasheet.tetml tetml2html.xsl
```

- ▶ MSXML パーサを有する Windows システム上では、**msxsl.exe** プログラムを以下のように利用できます：

```
msxsl.exe TET-datasheet.tetml tetml2html.xsl -o TET-datasheet.html toc-generate=0
```

TET ディストリビューション内の *runxslt.ps1*・*runxslt.vbs* スクリプトを使うと、すべての XSLT サンプルを、**msxml** を用いて実行することができます (**ant** を 1 回実行することによって TETML 入力ファイル群を生成してください)。

自分のアプリケーション内で XSLT 自分のアプリケーションの中に XSLT 処理を組み込みたい場合には、XSLT プロセッサの選択は当然、使うプログラミング言語と環境に依存します。TET ディストリビューションは、さまざまな重要な環境のためのサンプルコードを含んでいます。**runxslt** サンプル群は、TETML 文書を読み込み、XSLT スタイルシートをパラメタ付きで適用し、生成された出力をファイルへ書き出す方法を演示しています。これらのプログラムは、引数なしで実行された場合には、TET ディストリビューションとともに提供されているすべての XSLT サンプルを実行します。あるいは、TETML 入力ファイル名・XSLT スタイルシート名・出力ファイル名と追加のパラメタ / 値ペア群について引数群を与えることもできます。**runxslt** サンプル群は、XSLT 処理を自分のアプリケーションへ組み込むための出発点として活用することができます：

- ▶ Java 開発者は、**javax.xml.transform** パッケージ内のメソッド群を利用できます。これは *runxslt.java* サンプルで演示しています。

- ▶ .NET クラシック開発者は、*System.Xml.Xsl.XslTransform* 名前空間内のメソッド群を利用できます。これは *runxslt.ps1* PowerShell スクリプトで演示しています。同様のコードを、C# や他の .NET 言語で利用できます。
- ▶ .NET Code 開発者は *XslCompiledTransform* クラスを利用できます。これは *runxslt.cs* サンプルで演示されています。
- ▶ COM オートメーションに対応しているすべての Windows ベースのプログラミング言語は、MSXML パーサが提供している *MSXML2.DOMDocument* オートメーションクラスのメソッド群を利用できます。これは *runxslt.vbs* サンプルで演示しています。同様のコードを、他の COM 対応言語で利用できます。

Perl など他の多くのプログラミング言語では、XSLT 拡張が利用可能です。

Web サーバで XSLT XML から HTML への変換は XSLT の用途として代表的なものですので、XSLT スタイルシートを Web サーバ上で動作させたいときも多くあります。いくつかの重要なシナリオ：

- ▶ ASP または ASP.NET を持つ Windows ベースの Web サーバでは、上述の COM または .NET インタフェースを使用できます。
- ▶ Java ベースの Web サーバでは *javax.xml.transform* パッケージを使用できます。
- ▶ PHP ベースの Web サーバでは *XSLTProcessor* クラスを使用できます。

9.6 さまざまな XSLT サンプル

TET ディストリビューションは、XSLT を TETML に適用した場合の強力を演示する XSLT スタイルシートをいくつか含んでいます。これらは、TETML アプリケーションの出発点として活用することもできます。この節では、この XSLT サンプル群の概要を紹介するとともに、サンプル出力を掲載します。160 ページの 9.5 「TETML を XSLT で変換」で、XSLT スタイルシートを動作させるための多くのオプションを説明しています。このスタイルシート群の機能と内部動作に関して詳しくは、XSLT コードのコメントに記してあります。このスタイルシートサンプル群のいくつかの一般的側面：

- ▶ 多くの XSLT サンプルはパラメータに対応しており、これを用いてさまざまな処理詳細を制御することができます。これらのパラメータは、XSLT コード内で設定することもできますし、環境 (*ant* など) から上書きすることもできます。
- ▶ 多くの XSLT サンプルでは、特定の TETML モード (たとえば *word* モード。詳しくは、147 ページの「さまざまな TETML モード」を参照) の TETML 入力が必要とします。それらのサンプルは、誤った入力から自己を守るために、与えられた TETML 入力が必要に準拠しているかどうかをチェックして、準拠していないならエラーを報告します。
- ▶ XSLT サンプルのなかには、文書内の PDF 添付を再帰的に処理するものがあります (これは後述の説明の中でその旨記しています)。しかし多くのサンプルは PDF 添付を無視します。それらも、添付を処理するように拡張することが容易なように書かれています。 *Attachments* エレメント内の対象エレメントを選択すれば充分です。関連する *xsl:template* エレメント自体に変更を加える必要はありません。

コンコーダンスを生成 *concordance.xsl* スタイルシートは、*word* または *wordplus* モードの TETML 入力を受け付けます。これはコンコーダンスを、すなわち、文書内の単語を出現頻度の高い順に並べた一覧を生成します。これは、言語分析のためのコンコーダンスや、翻訳者のための相互参照や、整合性チェックなどを生成するのに有用でしょう。

List of words in the document along with the number of occurrences:

```
the 138
and 91
TET 87
to 63
of 59
for 57
PDF 53
text 51
in 50
a 44
is 37
be 36
as 34
are 34
PDFlib 32
...
```

フォントフィルタリング *fontfilter.xsl* スタイルシートは、*glyph* または *wordplus* モードの TETML 入力を受け付けます。これは文書内の、特定のフォントを用いた、かつ指定された値より大きなサイズの単語の一覧を作ります。これは、特定のフォント / サイズの組み合わせを検出したり、品質管理のために有用でしょう。同じコンセプトを用いて、大きな文字サイズを用いたテキスト部分に基づいた目次を生成することもできます。

Text containing font 'TheSansBold-Plain' with size greater than 10:

```
[ThesisAntiqua-Bold/32.0000] PDFlib
[ThesisAntiqua-Bold/32.0000] TET
[ThesisAntiqua-Bold/32.0000] 5
[ThesisAntiqua-Bold/14.0000] What
[ThesisAntiqua-Bold/14.0000] is
[ThesisAntiqua-Bold/14.0000] PDFlib
[ThesisAntiqua-Bold/14.0000] TET
[ThesisAntiqua-Bold/14.0000] ?
[ThesisAntiqua-Bold/14.0000] PDFlib
[ThesisAntiqua-Bold/14.0000] TET
[ThesisAntiqua-Bold/14.0000] Features
[ThesisAntiqua-Bold/14.0000] Challenges
[ThesisAntiqua-Bold/14.0000] with
[ThesisAntiqua-Bold/14.0000] PDF
[ThesisAntiqua-Bold/14.0000] Text
[ThesisAntiqua-Bold/14.0000] Extraction
[ThesisAntiqua-Bold/14.0000] Challenges
...
```

フォントの使用箇所を検索 *fontfinder.xml* スタイルシートは、*glyph* または *wordplus* モードの TETML 入力を受け付けます。文書内のすべてのフォントについて、特定のフォントを用いているテキストの出現箇所をすべて、そのページ番号とページ上の位置とともに一覧にします。これは、望ましくないフォントを検出して整合性をチェックしたり、特定の悪い文字サイズの使用を見つけたりするために有用でしょう。

TheSans-Plain used on:

page 1:
(306, 796)

ThesisAntiqua-Bold used on:

page 1:
(306, 757), (412, 757), (474, 757), (28, 514), (67, 514), (81, 514), (128, 514), (152, 514),
...

フォント統計 *fontstat.xml* スタイルシートは、*glyph* または *wordplus* モードの TETML 入力を受け付けます。これはフォントとグリフの統計を生成します。これは、品質管理に有用なほか、各フォントについてマップなしグリフ（すなわち、いかなる Unicode キャラクターをもマップできないグリフ）も報告されますので、アクセシビリティ試験にも有用でしょう。

17048 total glyphs in the document; breakdown by font:

```
85.21% TheSansLight-Plain: 14527 glyphs
5.19% TheSansLight-Italic: 885 glyphs
4.83% ThesisAntiqua-Bold: 823 glyphs, 3 uses of ligatures: fi
2.87% TheSansMonoCondensed-Plain: 489 glyphs
0.33% TheSansSemiLight-Caps: 57 glyphs
0.33% TheSansLight-Plain: 56 glyphs
0.25% TheSansLight-Italic: 42 glyphs
0.17% TheSansExtraLight-Italic: 29 glyphs
0.16% TheSansLight-Plain: 28 glyphs
0.16% TheSansLight-Plain: 28 glyphs
0.16% TheSansLight-Italic: 28 glyphs
0.16% TheSansLight-Plain: 28 glyphs
```

0.06% TheSansBold-Plain: 10 glyphs
0.05% TheSans-Plain: 9 glyphs
0.04% WarnockPro-It: 7 glyphs, 7 uses of ligatures: fi fl ffi Th sp ct st
0.01% PDFlibLogo2-Regular: 1 glyphs, 1 uses of ligatures: PDFlib
0.01% WarnockPro-Regular: 1 glyphs

索引を生成 *index.xml* スタイルシートは、*word* または *wordplus* モードの TETML 入力を受け付けます。これは索引を、すなわち、文書内の単語をアルファベット順に並べ、おののページ番号とともに一覧にしたものを生成します。数字と約物キャラクタは無視されます。

Alphabetical list of words in the document along with their page number:

A
able 5
about 2
About 6
accent 3
Accented 3
accents 3
accept 5
Accepted 1
access 6
accessible 6
achieved 3
Acrobat 1 2 4 6
actual 2
actually 5
added 5
adding 6
addition 1 2 5
additional 2 4 5
Adobe 2 5 6
advanced 1
algorithm 3 4
...

XMP メタデータを抽出 *metadata.xml* スタイルシートは、任意のモードの TETML 入力を受け付けます。これは文書レベルの XMP メタデータを対象としており、XMP からいくつかのメタデータプロパティを抽出します。文書内の PDF 添付 (PDF パッケージ・ポートフォリオを含め) は再帰的に処理されます：

```
dc:creator = PDFlib GmbH  
xmp:CreatorTool = Adobe InDesign CS6 (Windows)
```

表組内容を CSV 形式で抽出 *table.xml* スタイルシートは、*word*・*wordplus*・*page* のいずれかのモードの TETML 入力を受け付けます。これは、選択された表組の内容を抽出して、その表組内容を含む CSV ファイル (カンマ区切り値) を生成します。CSV ファイルは、あらゆる表計算アプリケーションで開くことができます。これは、PDF 文書内の表組の内容を再利用するのに有用でしょう。

TETML を HTML へ変換 *tetml2html.xml* スタイルシートは、*wordplus* モードの TETML 入力を受け付けます。これは TETML を、ブラウザで表示できる HTML へ変換します。このコンバータは、PDF 文書と同等の視覚表現を生成しようとするものではなく、以下の側面を演示するものです：

- ▶ HTMLページの冒頭にリンク付きの目次を生成し、その項目群をPDFしおりや文書内の見出しに基づいて生成。
- ▶ 見出しエレメント (*H1*・*H2*など)を、設定可能な文字サイズ・フォント名に基づいて生成。
- ▶ URI 型のリンク注釈を HTML リンクへ変換。
- ▶ TETML内の表組エレメントをHTML表組構造へマップすることによって表組をブラウザに表示。
- ▶ TETML 内のリストエレメントを HTML の番号なしまたは番号付きリストへマップ。
- ▶ 各ページについて画像の一覧を生成し、各画像を、照応する画像ファイルへリンク。
- ▶ PDF 注釈からリンクを生成。

生テキストを TETML から抽出 *textonly.xsl* スタイルシートは、任意のモードの TETML 入力を受け付けます。これは、すべての *Text* エレメントを取得しつつ、他のすべてのエレメントを無視することにより、生テキスト内容を抽出します。文書内の PDF 添付 (PDF パッケージ・ポートフォリオを含め) は再帰的に処理されます。

10 TET ライブラリ API リファレンス

10.1 オプションリスト

オプションリストは、さまざまな API 関数呼び出しを制御するための、強力で、それでいて簡単な方式です。多くの API メソッドでは、オプションリストが使えるようになっていますので、関数に膨大な引数を与える必要がありません。略して *optlist* ともいいます。これは、任意の数のオプションを内容として持つことのできる文字列です。オプションリストは、さまざまなデータ型や、リストのような複合データに対応しています。多くの言語バインディングでは、オプションリストは、必要なキーワードと値を連結していくことによって、簡単に構築することができます。

バインディング C 言語バインディング : *sprintf()* 関数を用いてオプションリストを構築するとよいでしょう。

バインディング .NET 言語バインディング : C# プログラマーは、*AppendFormat()* *StringBuilder* メソッドは整形エントリを表すのに中括弧 `{}` を用いて、それが引数の文字列表現へ置き換えられることに留意する必要があります。一方 *Append()* メソッドでは、中括弧キャラクタにいかなる特別な意味をも持たせていません。オプションリスト文法は中括弧キャラクタを利用していますので、*AppendFormat()* と *Append()* のどちらのメソッドを使うかを選ぶときには注意が必要です。

10.1.1 オプションリスト文法

正式なオプションリスト文法定義 オプションリストは、以下の規則に従って構築する必要があります :

- ▶ オプションリスト内のすべての要素 (キーと値) は、1 個ないし複数の右記区切りキャラクタによって区切る必要があります : スペース・タブ・キャリッジリターン・ニューライン・等号「=」。
- ▶ 一番外側の囲み中括弧は、要素には含まれません。 `{}` と書けば空要素を意味します。
- ▶ 一番外側の中括弧の中の区切りキャラクタは、要素を分割する効力をもはや持たず、要素の一部分となります。ですので、区切りキャラクタを含む要素は、中括弧で囲む必要があります。
- ▶ 先頭または末尾に中括弧を持つ要素は、中括弧で囲む必要があります。
- ▶ 要素が片方だけの中括弧を含む場合には、その中括弧は直前にバックスラッシュキャラクタを付けて保護する必要があります。要素の閉じ中括弧の直前のバックスラッシュも、直前にバックスラッシュキャラクタを付ける必要があります。
- ▶ オプションリストはバイナリゼロ値を含んではいけません。

オプションリストは、このリファレンスの仕様に従ってリスト値を持つことがありえます。リスト値は 1 個ないし複数の要素 (これ自体もまたリストである場合もあります) を内容として持ちます。それらは上述の規則に従って区切られますが、等号は区切りキャラクタとしてもはや見なされないという点が唯一異なります。

単純オプションリスト 多くの場合、オプションリストは 1 個ないし複数のキー / 値対を内容として持ちます。キーと値は、また複数のキー / 値対も同様に、1 個ないし複数の

空白キャラクタ（スペース・タブ・キャリッジリターン・ニューライン）で区切る必要があります。あるいは、キーは等号「=」で値と区切ることもできます：

```
key=value
key = value
key value
key1 = value1 key2 = value2
```

可読性を増すため、キーと値の間には等号を用い、隣り合うキー/値対の間には空白を用いることを推奨します。

オプションリストは左から右へと評価されますので、オプションは同一リスト内で複数回与えることもできます。この場合、最後に現れたオプションがそれ以前の上書きします。下記の例では、1番目のオプションでの割り当ては2番目によって上書きされますので、オプションリスト処理後に **key** は値 **value2** を持つこととなります：

```
key=value1 key=value2
```

リスト値 リストは、1個ないし複数の区切られた値を内容として持ちます。この値は単純値であることもありますし、それ自身がリスト値であることもあります。リストは中括弧 **{}** で囲まれており、リスト内の値群は空白キャラクタで区切る必要があります。例：

```
searchpath={/usr/lib/tet d:\tet}          (ディレクトリ名2個を持つリスト)
```

リストは、ネストされたリストを内容として持つこともあります。この場合、各リストの間は空白で区切る必要があります。区切りキャラクタは、隣り合うキャラクタ **}** と **{** の間には挿入する必要がありますが、同じ種類の中括弧どうしの間では省くこともできます：

```
fold= { {[:Private_Use:] remove} {[U+FFFD] remove} } (リスト2個を持つリスト)
```

リストがちょうど1個のリストを内容として持つときも、ネストされたリストの中括弧群を省くことはできません：

```
fold= { {[:Private_Use:] remove} } (ネストされたリスト1個を持つリスト)
```

ネストされたオプションリストとリスト値 オプションによっては、オプションリスト型またはオプションリストのリスト型を受け付けるものがあります。オプションリスト型のオプションは、1個ないし複数の子オプションリストを内容として持ちます。オプションリストのリスト型のオプションは、1個ないし複数のネストされたオプションリストを内容として持ちます。ネストされたオプションリストを扱う際には、囲む中括弧の数を正しく指定することが重要です。いくつかの例を以下に挙げます。

オプション **contentanalysis** の値はオプションリストであり、そのオプションリスト自体が1個のオプション **punctuationbreaks** を内容として持ちます：

```
contentanalysis={punctuationbreaks=false}
```

下記の例で、オプション **glyphmapping** の値は、オプションリストただ1個を内容として持つオプションリストのリストです：

```
glyphmapping= { {fontname=GlobeLogosOne codelist=GlobeLogosOne} }
```

下記の例で、オプション **glyphmapping** の値は、オプションリスト2個を内容として持つオプションリストのリストです：


```
glyphmapping { {fontname=CMSY* glyphlist=tarski} {fontname=ZEH* glyphlist=zeh}}
```

オプションリスト 1 個を内容として持つリストにおいて、そのオプションリストの中の *fontname* 値がスペースを含んでいるので、さらに中括弧で囲む必要があります：

```
glyphmapping={ {fontname={Globe Logos One} codelist=GlobeLogosOne} }
```

キーワード 2 個を内容として持つリスト：

```
fonttype={Type1 TrueType}
```

異なる型が混在したリスト。内側のリスト群は、Unicode 集合 1 個とキーワード 1 個を内容として持っており、外側のリストは、オプションリスト 2 個とキーワード *default* を内容として持っています：

```
fold={ {[:Private_Use:] remove} {[U+FFFD] remove} default }
```

矩形 1 個を内容として持つリスト：

```
includebox={{10 20 30 40}}
```

はまりやすい罫 この項では、オプションリスト文法についてよくある誤りを挙げます。中括弧は区切りキャラクタではありませんので、下記は誤りです：

```
key1 {value1}key2 {value2}                      誤り!
```

これはエラーメッセージ *Unknown option 'value2'* を引き起こします。同様に、下記は区切りキャラクタが抜けているので誤りです：

```
key{value}                                      誤り!  
key={{value1}{value2}}                      誤り!
```

中括弧は照応している必要がありますので、下記は誤りです：

```
key={open brace { }                          誤り!
```

これはエラーメッセージ *Braces aren't balanced in option list 'key={open brace {}'* を引き起こします。文字列の中のただ 1 個の中括弧は、バックスラッシュキャラクタを直前に付ける必要があります：

```
key={closing brace \} and open brace \{ }    正しい!
```

文字列値の末尾のバックスラッシュは、直後が閉じ中括弧キャラクタである場合には、もう 1 個のバックスラッシュを直前に付ける必要があります：

```
key={\value\}                                誤り!  
key={\value\\}                              正しい!
```

10.1.2 基本型

文字列 文字列は、一般に非ローカライズのキーワードのために用いられるプレーン ASCII 文字列です (EBCDIC プラットフォームでは EBCDIC 文字列)。空白または「=」キャラクタを含む文字列は、`{ }` で囲む必要があります：

password={ secret string } (3個 of 空白を含む文字列値)
contents={length=3mm} (1個 of 等号を含む文字列値)

キャラクタ `{}` は、文字列の一部としたい場合には、\キャラクタを直前に付ける必要があります：

password={weird\}string} (右中括弧を含む文字列値)

要素の閉じ中括弧の直前のバックスラッシュは、直前にバックスラッシュキャラクタを付ける必要があります：

filename={C:\path\name\\} (1個 of バックスラッシュで終わる文字列)

空文字列は、中括弧の対で構築できます：

`{}`

Unicode 非対応言語バインディング: オプションリストの先頭が [EBCDIC-]UTF-8 BOM である場合には、オプションリストの内容・ハイパーテキスト・名前文字列はそれぞれ [EBCDIC-]UTF-8 文字列として解釈されます。

クォートされていない文字列値 以下の状況においては、オプション値内のキャラクタ群本体が、optlist 構文キャラクタ群と衝突する場合があります：

- ▶ パスワードまたはファイル名が、開閉照応していない中括弧やバックスラッシュ等特殊キャラクタを含んでいる場合があります
- ▶ オプションリスト内に日本語 SJIS ファイル名 (Unicode 非対応の言語バインディングにおいてのみ問題となります)

任意のテキストまたはバイナリデータを与えてもオプションリスト構文の構成要素とぶつからないシンプルなくみを提供するために、クォートされていないオプション値を、長さの指定子とともに与えることも可能になっています。その場合は以下の構文を用います：

キー[n]=値
キー[n]={値}

ここで 10 進値 n は以下を表します：

- ▶ Unicode 対応言語バインディングの場合：UTF-16 コードユニットの数
- ▶ Unicode 非対応言語バインディングの場合：その文字列を構成するバイトの数

この文字列値を囲む中括弧はオプションですが、強く推奨されます。スペース等区切り文字で始まる文字列に対してはこれらは必須です。文字列値内の中括弧・区切り文字・バックスラッシュは、何ら特殊な解釈を受けずにリテラルに処理されます。

スペース・中括弧キャラクタを含む 7 文字のパスワードを指定する例。文字列全体を中括弧で囲っており、これらの中括弧はオプション値の中身ではありません：

password[7]={ ab}c d}

Unichar Unichar は、1 個 of Unicode 値であり、いくつか of 種類 of 文法に対応しています：10 以上 of 10 進値 (例：173)、接頭辞 $x \cdot X \cdot ox \cdot oX \cdot U+$ のいずれかを付けた 16 進値 ($xAD \cdot oxAD \cdot U+ooAD$)、数値参照、文字参照、グリフ名参照から「&」・「;」修飾を除いたもの ($shy \cdot \#xAD \cdot \#173$)。例：

unknownchar=?	(リテラル)
unknownchar=63	(10進)
unknownchar=x3F	(16進)
unknownchar=0x3F	(16進)
unknownchar=U+003F	(Unicode記法)
lineseparator={CRLF}	(標準グリフ名参照)

1桁の数字キャラクタは、10進 Unicode 値としてではなく、リテラルに扱われます：

replacementchar=3 (U+0033 THREE。U+0003ではありません！)

Unichar は 16 進範囲 `0 ~ 0x10FFFF` (10 進 `0 ~ 1114111`) 内になければいけません。

Unicode 集合 Unicode 集合は、以下の構成要素によって構築することができます：

- ▶ パターンは、一連のキャラクタを角括弧でまとめたものであり、Unicode キャラクタ群と Unicode プロパティ集合群のリストを内容として持ちます。
- ▶ リストは、Unicode キャラクタの連鎖であり、2 個のキャラクタの間に「-」で示した範囲を持つことができます。例：`U+FB00-U+FB17`。連鎖は、Unicode 順に左から右までのすべてのキャラクタの範囲を示します。複数の Unicode キャラクタは、間を空白で区切らずに直接つなげて書く必要があります。例：`U+0048U+006C`。
- ▶ リスト内の Unicode キャラクタは以下のように指定できます：
 - ASCII キャラクタはリテラルとして指定できます
 - ちょうど 4 桁の 16 進数字：`\uhhhh` または `U+hhhh`
 - ちょうど 5 桁の 16 進数字：`U+hhhhh`
 - 1 ~ 6 桁の 16 進数字：`\x{hhhhhh}`
 - ちょうど 8 桁の 16 進数字：`\Uhhhhhhhh`
 - エスケープされたバックスラッシュ：`\\`
- ▶ Unicode プロパティ集合は、Unicode プロパティによって指定されます。プロパティ名を指定するための文法は、POSIX と Perl 文法の拡張であり、ここで **type** は Unicode プロパティの名前を (www.unicode.org/Public/UNIDATA/PropertyAliases.txt 参照)、**value** はその値を (www.unicode.org/Public/UNIDATA/PropertyValueAliases.txt 参照) 表します：
 - POSIX 式文法：`[:type=value:]`
 - POSIX 式文法で否定：`[:^type=value:]`
 - Perl スタイル文法：`\p{type=value}`
 - Perl スタイル文法で否定：`\P{type=value}`**type=** は、Category・Script プロパティについては省けますが、それ以外のプロパティについては必要です。
- ▶ 集合演算をパターンに適用することもできます：
 - 2 個の集合の和をとるには、単純にそれらを連結します：`[:letter:] [:number:]`
 - 2 個の集合の積をとるには、「&」演算子を用います：`[:letter:] & [U+0061-U+007A]`
 - 2 個の集合の差をとるには、「-」演算子を用います：`[:letter:]-[U+0061-U+007A]`
 - 補集合を得るには、開き「[」の直後に「^」を入れます：`^[U+0061-U+007A]`
 - それ以外の場所では、「^」は特別な意味を持ちません。

表 10.1 にいろいろな Unicode 集合の例を挙げます。下記 Web サイトを利用すると、いろいろな Unicode 集合表現を対話的に試すことができます：

unicode.org/cldr/utility/list-unicodeset.jsp

表 10.1 いろいろな Unicode 集合の例

Unicode 集合の指定	その Unicode 集合内のキャラクタ群
[U+0061-U+007A]	a から z までの小文字
[U+0640]	アラビア文字タトウィールの 1 キャラクタのみ
[\x{0640}]	アラビア文字タトウィールの 1 キャラクタのみ
[U+FB00-U+FB17]	欧文・アルメニア文字の合字群
[^U+0061-U+007A]	a から z まで以外のすべてのキャラクタ
[:Lu:] [:UppercaseLetter:]	すべての大文字 (Unicode 集合の短形式と長形式)
[:L:] [:Letter:]	L で始まるすべての Unicode カテゴリ (Unicode 集合の短形式と長形式)
[:General_Category=Dash_Punctuation:]	一般カテゴリ Dash_Punctuation 内のすべてのキャラクタ
[:Alphabetic=No:]	すべての非アルファベットキャラクタ
[:Private_Use:]	私用領域 (PUA) 内のすべてのキャラクタ

論理値 論理値は、値 *true* または *false* をとります。論理値オプションで値を省略すると、値 *true* と見なされます。*name=false* の短縮記法として *noname* を用いることも可能です:

```
usehostfonts          (usehostfonts=trueと同等)
nousehostfonts       (usehostfonts=falseと同等)
```

キーワード キーワード型のオプションは、決められたキーワードの定義済リストの 1 つをとることができます。例:

```
clippingarea=cropbox
```

オプションによっては、数値とキーワードのいずれかの値をとるものもあります。

数値 オプションリストは、いくつかの数値型に対応しています。整数型は、10 進と 16 進の整数をとります。x・X・0x・0X のいずれかで始まる正の整数は 16 進値を意味します:

```
-12345
0
0xFF
```

float は、10 進浮動小数点数または整数をとります。ピリオドまたはカンマを浮動小数点値の小数点として使えます。指数記法にも対応しています。以下の値はすべて同等です:

```
size = -123.45
size = -123,45
size = -1.2345E2
size = -1.2345e+2
```

10.1.3 図形型

矩形 矩形は、矩形の左下隅と右上隅の *x・y* 座標を指定する float 値 4 個のリストです。座標を解釈するための座標系 (デフォルトまたはユーザ座標系) はオプションによって異なりますので、都度説明してあります。例:

```
includebox = {{0 0 500 100} {0 500 500 600}}
```

10.1.4 各種言語バイディングにおける Unicode 対応

あるプログラミング言語または環境が Unicode 文字列にネイティブ対応している場合、そのバイディングを Unicode 対応と呼ぶことにします。以下の言語バイディングは Unicode 対応です：

- ▶ C++
- ▶ COM
- ▶ .NET・.NET Core
- ▶ Java
- ▶ Objective-C
- ▶ Python
- ▶ RPG

これらの環境における文字列処理は単純です：すべての文字列はネイティブ UTF-16 形式の Unicode 文字列として与えられます。クライアントによって与えられた Unicode 文字列を、言語ラップが正しく処理し、自動的に特定のオプション群を設定します。

以下の言語バイディングはデフォルトでは Unicode 対応ではありません：

- ▶ C
- ▶ Perl
- ▶ PHP
- ▶ Ruby

Unicode 非対応の言語バイディングに対しては UTF-8 の使用が推奨されます。API のなかには、言語バイディングが Unicode 対応か非対応かによって異なる点がいくつかあります。このような相違については、この章において、それぞれ照応する API の説明の箇所で記述されます。

`TET_convert_to_unicode()` 関数を使うと、UTF-8・UTF-16・UTF-32 文字列の間での変換と、任意のエンコーディングから Unicode への変換を行うことができます。その際に、BOM を付けることも可能です。

10.1.5 エンコーディング名

さまざまなオプションと引数がエンコーディングの名前をサポートしています。たとえば `TET_set_option()` の `filenamehandling` オプション、`TET_open_document()` の `forceencoding` オプション、`TET_convert_to_unicode()` の `inputformat` 引数です。以下のキーワードをエンコーディング名として与えることができます：

- ▶ キーワード `auto`：特定の環境に対して最も自然なエンコーディングを指定：
 - ▶ Windows 上：カレントのシステムコードページ
 - ▶ Unix・macOS 上：`iso8859-1`
 - ▶ i5/iSeries 上：カレンドジョブのエンコーディング (`IBMCCSIDoooooooooooo`)
 - ▶ zSeries 上：`ebcdic`
- ▶ `winansi` (= `cp1252`)
- ▶ `iso8859-1` ~ `iso8859-10`、`iso8859-13` ~ `iso8859-14`
- ▶ `cp1250` ~ `cp1258`
- ▶ `macroman`・`macroman_euro` (通貨をユーロへ置き換えたもの)・`macroman_apple` (通貨をユーロへ置き換え、さらに追加の数学／ギリシア記号を含む)

- ▶ *adobesymbol* : Adobe Symbol エンコーディングを指定
- ▶ *U+XXXX* (指定した値から始まる 256 個のキャラクタ)
- ▶ *ebcdic* (=コードページ 1047) ・ *ebcdic_37* (=コードページ 037)
- ▶ 日中韓エンコーディング *cp932* ・ *cp936* ・ *cp949* ・ *cp950*
- ▶ 以下のシステム上では、ホストシステム上で利用可能なすべてのエンコーディングを使用できます：
 - ▶ Windows : *cpXXXX*
 - ▶ Linux : *iconv* 機構に知られているすべてのコードセット
 - ▶ i5/iSeries : *CCSID* 接頭辞を持たない任意の *Coded Character Set Identifier*
 - ▶ zSeries : 任意の *Coded Character Set Identifier* (*CCSID*)
- ▶ カスタムエンコーディングをリソースとして定義し、そのリソース名で参照することもできます。

10.2 一般関数

10.2.1 オプション処理

C++ Java C# `void set_option(String optlist)`

Perl PHP `set_option(string optlist)`

C `void TET_set_option(TET *tet, const char *optlist)`

TET に対する 1 個ないし複数のグローバルオプションを設定します。

optlist 表 10.2 に従ってグローバルオプション群を指定したオプションリスト。1 つのオプションが複数回与えられたときは、最後に出現したものがそれ以前のものを上書きします。1 個のオプションに複数の値を与えるためには (*searchpath* など)、このオプションのリスト引数内ですべての値を与えてください。

右記のオプションが使えます：*asciifile*・*cmap*・*codelist*・*encoding*・

filenamehandling・*fontoutline*・*glyphlist*・*hostfont*・*license*・*licensefile*・*logging*・

mmiolimituserlog・*outputformat*・*resourcefile*・*searchpath*・*shutdownstrategy*

詳細 表 10.2 でその旨記されているオプションについては、この関数を複数回呼び出して値を蓄積させることもできます。その旨記していないオプションでは、新しい値が古い値を上書きします。

表 10.2 TET_set_option() のグローバルオプション一覧

オプション	説明
<i>asciifile</i>	(論理値。i5/iSeries・zSeries 上でのみ対応) ASCII エンコーディングのテキストファイル (UPR 設定ファイル・グリフリスト・コードリストなど) を受け付けます。デフォルト：i5/iSeries では true、zSeries では false
<i>cmap</i> ^{1,2}	(名前文字列のリスト) 文字列対のリスト。各対は、CMap リソース 1 個の名前と値を内容として持ちます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。
<i>codelist</i> ^{1,2}	(名前文字列のリスト) 文字列対のリスト。各対は、コードリストリソース 1 個の名前と値を内容として持ちます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。
<i>encoding</i> ^{1,2}	(名前文字列のリスト) 文字列対のリスト。各対は、エンコーディングリソース 1 個の名前と値を内容として持ちます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。

表 10.2 TET_set_option() のグローバルオプション一覧

オプション	説明
filename-handling	(キーワード) ファイル名のエンコーディングを示します。Unicode 非対応言語バインディングにおいて UTF-8 BOM なしに関数引数として与えられたファイル名については、このオプションに従って解釈されることにより、そのファイルシステムにおいて不正となるキャラクタに対する防護が行われるとともに、そのファイル名の Unicode 版が生成されます。指定したエンコーディングの外にあるキャラクタをファイル名が含んでいる場合にはエラーが発生します。デフォルト: Windows・macOS では unicode、i5/iSeries では auto、それ以外では honorlang: ascii 7 ビット ASCII basicebcdic コードページ 1047 に従った、ただし Unicode 値 <= U+007E のみの基本 EBCDIC basicebcdic_37 コードページ 0037 に従った、ただし Unicode 値 <= U+007E のみの基本 EBCDIC honorlang (i5/iSeries では非対応) 環境変数 LC.ALL・LC.CTYPE・LANG が解釈されます。LANG で指定されているコードセットが利用可能な場合にはそれがファイル名に適用されます。 legacy auto エンコーディング (すなわちカレントシステムエンコーディング) を用いてファイル名を解釈し、honorlang パラメタが設定されているなら LANG 変数を解釈。 unicode (EBCDIC-) UTF-8 形式の Unicode エンコーディング すべての 8 ビットおよび日中韓エンコーディングの名前 173 ページの 10.1.5 「エンコーディング名」に従ったエンコーディング名
fontoutline^{1, 2}	(名前文字列のリスト) 文字列対のリスト。各対は、FontOutline リソース 1 個の名前と値を内容として持ちます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。
glyphlist^{1, 2}	(名前文字列のリスト) 文字列対のリスト。各対は、グリフリストリソース 1 個の名前と値を内容として持ちます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。
hostfont^{1, 2}	(名前文字列のリスト) 文字列対のリスト。各対は、埋めこまれていないフォントに対して用いたいホストフォントの PDF フォント名と UTF-8 符号化された名前を内容として持ちます。
license	(文字列) ライセンスキーを設定します。これは、TET_open_document*() を初めて呼び出す前に設定する必要があります。
licensefile	(文字列) ライセンスキー (群) を内容として持つファイルの名前を設定します。このライセンスファイルは、TET_open_document*() を初めて呼び出す前に 1 回だけ設定することができます。あるいは、ライセンスファイルの名前は、PDFLIBLICENSEFILE という環境変数で、または (Windows では) レジストリを通じて与えることもできます。
logging¹	(オプションリスト。非サポート) 表 10.7 に従ってログ記録出力を指定するオプションリスト。あるいは、ログ記録オプション群は、TETLOGGING という環境変数で、または Windows ではレジストリを通じて与えることもできます。空のオプションリストにすると、前回の呼び出しで設定したオプション群によってログ記録が有効になります。環境変数が設定されている場合には、ログ記録は、TET_new() への最初の呼び出しの直後から開始されます。
mmiolimit	(整数) メモリマップされる入力ファイルのサイズの上限を MB (=1024×1024 バイト) 単位で。このオプションを 0 (ゼロ) に指定すると、メモリマッピングは無効化されます。メモリマップの無効化は、非 Windows システム群において、リモートファイルが使用中に突然利用不能になる際の問題を回避するために使用することも可能です。デフォルト: 32 ビットプラットフォームと i5/iSeries では 50、それ以外では 2048
userlog	(名前文字列。非サポート) ログ記録が有効にされている場合にログファイルへ書き込まれる任意の文字列。

表 10.2 TET_set_option() のグローバルオプション一覧

オプション	説明
output-format	(キーワード。C・Ruby・RPG・Perl・Python・PHP 言語バインディングのみ) TET_get_text() が返すテキストの形式を指定します： utf8 文字列は、(C の場合はヌル終端の) UTF-8 形式で返されます。 utf16 文字列は、そのマシンのネイティブバイト順序の UTF-16 形式で返されます。 utf32 文字列は、そのマシンのネイティブバイト順序の UTF-32 形式で返されます。 ebcdicutf8 (EBCDIC ベースのシステムでのみ利用可能) 文字列は、ヌル終端 EBCDIC 符号化 UTF-8 形式で返されます。i5/iSeries ではコードページ 37 が、zSeries ではコードページ 1047 が用いられます。 デフォルト：C・Ruby・Perl・Python・PHP の場合は utf8、i5/iSeries・zSeries 上の C・RPG の場合は ebcdicutf8
resourcefile	(名前文字列) UPR リソースファイルの相対または絶対ファイル名。このリソースファイルはただちに読み込まれます。既存のリソースは温存され、その値は再設定された場合には新しいもので上書きされます。明示的なリソースオプションは、リソースファイル内のエントリの後に評価されます。 リソースファイル名は、環境変数 TETRESOURCEFILE で、または Windows のレジストリキーで与えることもできます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。デフォルト：tet.upr (MVS では upr)
searchpath¹	(名前文字列のリスト) 読み込みたいファイル群を含むディレクトリの相対または絶対パス名(群)。この検索パスは複数回設定することもでき、その場合にはエントリは蓄積され、設定した順に使用されます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。ディレクトリ名が空白キャラクタを含んでいる場合の問題を避けるために、エントリが 1 個しかなくても二重中括弧を用いることを推奨します。空文字列 (すなわち {}) にすると、デフォルトエントリ群を含む既存のすべての検索パスエントリが削除されます。Windows では、検索パスはレジストリエントリを通じて設定することもできます。デフォルト：プラットフォーム依存、66 ページの「ファイル検索と searchpath リソースカテゴリ」を参照してください。
shutdown-strategy	(整数) すべての TET オブジェクトに対して 1 回割り当てられるグローバルリソースの解放の方式。グローバルリソースはそれぞれ、それが初めて必要とされた時点で初期化されます。このオプションは 1 個のプロセス内のすべての TET オブジェクトに対して同じ値に設定する必要があります。そうでない場合は動作は未定義です (デフォルト：0)： <ul style="list-style-type: none"> 0 そのリソースを何個の TET オブジェクトが使用しているかを参照カウンタが追跡します。最後の TET オブジェクトが削除されて参照カウンタが 0 に落ちた時に、そのリソースは解放されます。 1 リソースはそのプロセスの終わりまで保持されます。これはパフォーマンスを若干向上させる可能性があります。最後の TET オブジェクトが削除された後に必要なメモリが増加します。

1. 複数呼び出すとオプション値を蓄積できます。
 2. UPR 文法とは異なり、名前と値の間の等号「=」は必須ではなく、許容もされません。

10.2.2 セットアップ

C `TET *TET_new(void)`

新規 TET オブジェクトを作成します。

戻り値 後続の呼び出しで使用する TET オブジェクトへのハンドル。メモリが得られなかったためにこの関数が成功しなかったときは NULL を返します。

バインディング オブジェクト指向言語バインディングでは、この関数は TET コンストラクタ内に隠蔽されていますので、利用できません。

Java `void delete()`

C# `void Dispose()`

C `void TET_delete(TET *tet)`

TET オブジェクトを削除して、関連する内部リソースをすべて解放します。

詳細 TET オブジェクトを削除すると、その開いている文書も自動的にすべて閉じられます。TET オブジェクトは、閉じられた後は、いかなる関数でも使用してはいけません。

バインディング オブジェクト指向言語バインディングでは、この関数は TET デストラクタ内に隠蔽されていますので、一般に必要ではありません。ただし Java では、自動的なガベージコレクションに加えて明示的なクリーンアップを可能にするために、利用可能となっています。.NET では、処理の最後に、非マネージのリソースをクリーンアップするために `Dispose()` を呼び出すべきです。

10.2.3 PDFlib 仮想ファイルシステム (PVF)

C++ `void create_pvf(wstring filename, const void *data, size_t size, wstring optlist)`

C# Java `void create_pvf(String filename, byte[] data, String optlist)`

Perl PHP `create_pvf(string filename, string data, string optlist)`

C `void TET_create_pvf(TET *tet,
const char *filename, int len, const void *data, size_t size, const char *optlist)`

メモリ内で与えられたデータから、名前付きの仮想の読み取り専用ファイルを作成します。

filename (名前文字列) 仮想ファイルの名前。これは、後続する TET 呼び出しにおいてこの仮想ファイルを参照するために使える任意の文字列です。

len (C 言語バインディングのみ) **filename** が UTF-16 文字列の場合の長さ (バイト単位で)。len=0 ならば、ヌル終端文字列を与える必要があります。

data 仮想ファイルのためのデータへの参照。COM では、これは仮想ファイルを構成するデータを内容として持つ Byte の Variant です。C・C++ では、これはメモリ位置へのポインタです。Java では、これは byte 配列です。Perl・PHP では、これは文字列です。

size (C・C++ のみ) このデータを内容として持つメモリブロックの長さをバイト単位で。

optlist 表 10.3 に従ったオプションリスト。右記のオプションが使えます: *copy*

詳細 仮想ファイル名は、入力ファイル名をとる任意の API 関数に対して与えることができます。こうした関数のなかには、そのデータがもう必要なくなるまでその仮想ファイルにロックをかけるものもあります。仮想ファイルは、`TET_delete_pvf()` によって明示的に、あるいは `TET_delete()` で自動的に削除されるまで、メモリ内に保持されます。

各 TET オブジェクトは、それぞれ自分自身の PVF ファイルのセットを保持します。仮想ファイルを、異なる TET オブジェクト間で共有することはできません。複数スレッドで個別の TET オブジェクトを操作している場合、PVF の使用を同期する必要はありません。**filename** で、すでにある仮想ファイルと同じ名前を指定すると例外が発生します。この関数では、**filename** がすでに通常のディスクファイルで使われているかどうかはチェックしません。

copy オプションを与えていないかぎり、与えたデータを、それに対応する `TET_delete_pvf()` への呼び出しが成功する前に、呼び出し側で変更したり解放 (削除) したりしてはいけません。この決まりに従わないとクラッシュするおそれが高いです。

表 10.3 TET_create_pvf() のオプション一覧

オプション	説明
<i>copy</i>	(論理値) true の場合、PDFlib は、与えられたデータの内部コピーをただちに作成します。この場合、与えたデータを、この呼び出しの直後に呼び出し側で廃棄してもかまいません。デフォルト: C・C++ の場合は false、しかしそれ以外のすべての言語バインディングでは true

C++ Java C# `int delete_pvf(String filename)`

Perl PHP `int delete_pvf(string filename)`

C `int TET_delete_pvf(TET *tet, const char *filename, int len)`

指名された仮想ファイルを削除し、そのデータ構造を解放します。

filename (名前文字列) `TET_create_pvf()` に与えたのと同じ、仮想ファイルの名前。

len (C 言語バインディングのみ) **filename** が UTF-16 文字列の場合の長さ (バイト単位で)。**len=0** ならば、ヌル終端文字列を与える必要があります。

戻り値 指定された仮想ファイルが存在しているがロックされている場合は -1、それ以外の場合は 1。

詳細 ファイルがロックされていなければ、TET はただちに、**filename** に関連づけられたデータ構造を削除します。**filename** という名前の有効な仮想ファイルが存在しない場合には、この関数は何も警告など出さずに終了します。この関数を呼び出して成功した後は、その **filename** は再利用することもできます。仮想ファイルはすべて、`TET_delete()` で自動的に削除されます。

詳細な動作は、これに対応する `TET_create_pvf()` への呼び出しの際に `copy` オプションを与えていたかどうかによって依存します：`copy` オプションを与えていた場合には、ファイルの管理データ構造とファイル内容本体 (データ) の両方が解放されますが、そうでなかった場合には、内容は解放されません。後者の場合にはクライアント側で内容を解放することが期待されています。

C++ Java C# `int info_pvf(String filename, String keyword)`

Perl PHP `int info_pvf(string filename, string keyword)`

C `int TET_info_pvf(TET *tet, const char *filename, int len, const char *keyword)`

仮想ファイルまたは PDFlib 仮想ファイルシステム (PVF) のプロパティを取得します。

filename (名前文字列) 仮想ファイルの名前。**keyword=filecount** の場合この **filename** は空とすることができます。

len (C 言語バインディングのみ) **filename** が UTF-16 文字列の場合の長さ (バイト単位で)。**len=0** ならば、ヌル終端文字列を与える必要があります。

keyword 表 10.4 に従ったキーワード。

戻り値 **keyword** によって要求されたファイルパラメータの値。

詳細 この関数は、仮想ファイルまたは PDFlib 仮想ファイルシステム (PVF) のさまざまなプロパティを返します。プロパティをキーワードで指定します。

表 10.4 TET_info_pvf() のキーワード一覧

オプション	説明
filecount	カレント TET オブジェクトのために保持されている PDFlib 仮想ファイルシステム内のファイルの総数。filename 引数は無視されます。
exists	そのファイルが PDFlib 仮想ファイルシステム内に存在しているなら (かつ削除されていないなら) 1、そうでないなら 0

表 10.4 TET_info_pvf() のキーワード一覧

オプション	説明
<i>size</i>	(存在する仮想ファイルに対してのみ) 指定した仮想ファイルのサイズをバイト単位で。
<i>iscopy</i>	(存在する仮想ファイルに対してのみ) 指定した仮想ファイルが作成された際に copy オプションが与えられていたなら 1、そうでないなら 0
<i>lockcount</i>	(存在する仮想ファイルに対してのみ) 指定した仮想ファイルに対して TET 関数によって内部的にセットされたロックの数。このロックカウントが 0 にならなければそのファイルは削除されることができません。

10.2.4 Unicode 変換関数

C++ **string** *convert_to_unicode(wstring inputformat, string input, wstring optlist)*

C# **Java String** *convert_to_unicode(String inputformat, byte[] input, String optlist)*

Perl PHP **string** *convert_to_unicode(string inputformat, string input, string optlist)*

C **const char *TET_convert_to_unicode(TET *tet, const char *inputformat, const char *input, int inputlen, int *outputlen, const char *optlist)**

任意のエンコーディングの文字列を、さまざまな形式の Unicode 文字列へ変換します。

inputformat 入力文字列の解釈を指定する Unicode テキスト形式またはエンコーディング名:

- ▶ Unicode テキストの各形式: *utf8*・*ebcdicutf8* (EBCDIC プラットフォーム上で)・*utf16*・*utf16le*・*utf16be*・*utf32*
- ▶ 173 ページの 10.1.5 「エンコーディング名」に従ったエンコーディング名
- ▶ キーワード *auto* は右記の動作を指定します: 入力文字列に UTF-8 か UTF-16 の BOM がある場合には、それを用いて正しい形式が決定され、そうでない場合はカレントシステムコードページと見なされます。

input Unicode へ変換したい文字列。

inputlen (C 言語バインディングのみ) 入力文字列の長さをバイト単位で。 *inputlen=0* ならば、ヌル終端文字列を与える必要があります。

outputlen (C 言語バインディングのみ) 返される文字列の長さ (バイト単位で) を格納させたいメモリ位置への C スタイルポインタ。

optlist 表 10.5 に従ってオプションを指定したオプションリスト:

- ▶ 入力フィルタオプション: *charref*・*escapesequence*
- ▶ Unicode 変換オプション: *bom*・*errorpolicy*・*inflate*・*outputformat*

戻り値 指定した引数とオプションに従って入力文字列から生成された Unicode 文字列。入力文字列が、指定した入力形式に従っていない (無効な UTF-8 文字列など) ときは、*errorpolicy=return* であれば空の出力文字列が返され、*errorpolicy=exception* であれば例外が発生します。

詳細 この関数は Unicode 文字列変換全般に有用でしょう。これは、適当な Unicode 変換機能を提供していない環境で作業するユーザの利便のために提供されています。

バインディング C バインディング: 返される文字列は、最大 10 エントリを持つリングバッファに格納されます。10 個を超える文字列が変換されたときには、バッファは再利用されますので、10 個を超える文字列を同時に利用したい場合には、クライアント側でその文字列を複製しておく必要があります。たとえば *printf()* 文 1 個の中にはこの関数への呼び出しを最大 10 個まで引数として入れることができます。10 個を超える文字列が同時に使用されないならば、その戻り文字列は互いに独立であることが保証されているからです。

C++ バインディング: *inputformat* と *optlist* は通常通り *wstring* として渡す必要がありますが、*input* と戻りデータは *string* 型を持つ必要があります。

Python バインディング: UTF-8 の戻り値は文字列として返ります。Python 3: 非 UTF-8 の戻り値はバイト列として返ります。

表 10.5 TET_convert_to_unicode() のオプション一覧

オプション	説明
charref	(論理値) true の場合、数値・文字実体参照とグリフ名参照の置き換えを有効にします。デフォルト : false
bom	(キーワード。outputformat=utf32 のときは無視されます。Unicode 対応言語バインディングに対しては none のみ許されます) 出力文字列にバイト順序マーク (BOM) を付加する方式。使えるキーワード (デフォルト : none) : add BOM を付加。 keep 入力文字列に BOM があるなら BOM を付加。 none BOM を付加しない。 optimize outputformat=utf8 または ebcdicutf8 かつ出力文字列が範囲 < U+007F のキャラクターのみを含む場合を除いて BOM を付加。
errorpolicy	(キーワード) 変換エラーの際の動作 (デフォルト : exception) : return 文字参照が解決できないとき、置換キャラクタ U+FFFD が使用されます。変換エラーの場合には空文字列が返されます。 exception 変換エラーの場合には例外が発生します。
escape-sequence	(論理値) true の場合、文字列内のエスケープシーケンスの置き換えを有効にします。デフォルト : false
inflate	(論理値。inputformat=utf8 の場合のみ。outputformat=utf8 のときは無視されます) true の場合、無効な UTF-8 入力文字列は例外を発生させず、指定された出力形式のインフレートされたバイト文字列が生成されます。これはデバッグに有用でしょう。デフォルト : false
output-format	(キーワード) 生成したい文字列の Unicode テキスト形式 : utf8・ebcdicutf8 (EBCDIC プラットフォーム上で)・utf16・utf16le・utf16be・utf32。空文字列は utf16 と同等です。デフォルト : utf16 Unicode 対応言語バインディング : 出力形式は強制的に utf16 になります。 C++・RPG 言語バインディング : 右記の出力形式のみ許されます : ebcdicutf8・utf8・utf16・utf32。

10.2.5 例外処理

C++ Java C# **String** *get_apiname()*

Perl PHP **string** *get_apiname()*

C **const char ****TET_get_apiname(TET *tet)*

例外を発生させた、または失敗した API 関数の名前を得ます。

戻り値 例外を発生させた関数の名前、または、呼び出されてエラーコードを持って失敗した最近の関数の名前。エラーがなかった場合は空文字列が返されます。

C++ Java C# **String** *get_errmsg()*

Perl PHP **string** *get_errmsg()*

C **const char ****TET_get_errmsg(TET *tet)*

最後に発生した例外の、または失敗した関数呼び出しの原因のテキストを得ます。

戻り値 最後に発生した例外の説明を、または、呼び出されてエラーコードを持って失敗した最近の関数の原因を内容として持つテキスト。エラーがなかった場合は空文字列が返されません。

C++ Java C# **int** *get_errnum()*

Perl PHP **long** *get_errnum()*

C **int** *TET_get_errnum(TET *tet)*

最後に発生した例外の、または、失敗した関数呼び出しの原因の番号を得ます。

Get the number of the last thrown exception or the reason for a failed function call.

戻り値 例外の番号、または、呼び出されてエラーコードを持って失敗した最近の関数のエラーコード。エラーがなかった場合はこの関数は 0 を返します。

C **TET_TRY(tet)**

C **TET_CATCH(tet)**

C **TET_RETHROW(tet)**

C **TET_EXIT_TRY(tet)**

例外処理ブロックをセットアップします。例外をキャッチします。例外を再び投げます。例外機構に対し、対応する *TET_CATCH()* ブロックに入ることなく *TET_TRY()* ブロックから抜けることを通知します。*TET_RETHROW()* を用いると、例外をキャッチした後に、より高いレベルの関数へそれを再び投げることができます。

詳細 (C 言語バインディングのみ) 27 ページの 3.2 「C バインディング」を参照。

10.2.6 ログ記録

ログ記録機能を利用すると、API 呼び出し群を追跡することができます。そのログファイルの内容は、デバッグ目的に有用なほか、PDFlib GmbH サポートから求められることがあります。表 10.6 に、`TET_set_option()` (175 ページの 10.2.1 「オプション処理」を参照) でログ記録機能を有効にするためのオプションを挙げます。

表 10.6 `TET_set_option()` のログ記録関連キー一覧

キー	説明
<code>logging</code>	表 10.7 に従ったログ記録オプション群を持つオプションリスト
<code>userlog</code>	ログファイルへ複製される文字列

ログ記録オプションは、以下の方法で与えることができます：

- ▶ `TET_set_option()` の `logging` オプションに対するオプションリストとして。例：

```
tet.set_option("logging={filename={debug.log} remove}");
```
- ▶ `TETLOGGING` という環境変数で。この場合、ログ記録出力は、API 関数のいずれかを最初に呼び出した時から開始されます。

表 10.7 `TET_set_option()` の `logging` オプションのサブオプション一覧

キー	説明
(空リスト)	<code>disable</code> で無効化されているログ出力を有効化。
<code>disable</code>	(論理値) ログ出力を無効化。デフォルト : <code>false</code>
<code>enable</code>	(論理値) ログ出力を有効化。
<code>filename</code>	(文字列) ログファイルの名前 (<code>stdout</code> と <code>stderr</code> も受け付けます)。すでに内容があるとき、出力はその末尾に追加されます。ログファイル名はあるいは、 <code>TETLOGFILENAME</code> という環境変数で与えることもできます (この場合、このオプション <code>filename</code> はつねに無視されます)。デフォルト : <code>tet.log</code> (Windows と macOS では / ディレクトリ内。Unix では / <code>tmp</code> 内)
<code>flush</code>	(論理値) <code>true</code> の場合、ログファイルは、必ず出力が実際にフラッシュされるよう、出力のたびに閉じられ、次の出力の時にまた開かれます。プログラムのクラッシュを追跡する際に、ログファイルが途中で終わってしまっている場合に有用でしょう。ただし速度はかなり遅くなります。 <code>false</code> の場合、ログファイルは 1 回だけ開かれます。デフォルト : <code>false</code>
<code>includepid</code>	(論理値。MVS では不可) ログファイル名内にプロセス ID を含める。複数のプロセスが同一のログファイル名を使用する場合にはこれを有効化するべきです。デフォルト : <code>false</code>
<code>includetid</code>	(論理値。MVS では不可) ログファイル名内にスレッド ID を含める。同一プロセス内の複数のスレッドが同一のログファイル名を使用する場合にはこれを有効化するべきです。デフォルト : <code>false</code>
<code>includeoid</code>	(論理値。MVS では不可) ログファイル名内にオブジェクト ID を含める。同一スレッド内の複数の TET オブジェクトが同一のログファイル名を使用する場合にはこれを有効化するべきです。デフォルト : <code>false</code>
<code>remove</code>	(論理値) <code>true</code> の場合は、新しい出力を書きこむ際に、既存のログファイルは削除されます。デフォルト : <code>false</code>

表 10.7 TET_set_option() の logging オプションのサブオプション一覧

キー	説明
removeon-success	(論理値) 生成したログファイルを、例外が発生した場合を除き、TET_delete() で削除。これは、マスタスレッドアプリケーションにおいてたまに発生する問題や、散発的にしか起こらない問題を分析したい際に有用でしょう。このオプションを includepid/includetid/includeoid と適当に組み合わせることを推奨します。
stringlimit	(整数) テキスト文字列内のキャラクタの数の上限。0 なら無制限。デフォルト : 0
classes	(オプションリスト) 整数型のオプション群を内容として持つリスト。ここで各オプションはログ記録クラスを記述し、おのおのの値はそのログ記録レベルを記述します。レベル 0 はログ記録クラスを無効化し、正の数值はクラスを有効にします。レベルが上がるほど詳細な出力を与えます。以下のオプションが使えます (デフォルト : {api=1 warning=1}) :
api	すべての API 呼び出しを、その引数と結果とともにログ記録します。api=2 の場合は、すべての API 追跡行の頭にタイムスタンプが生成されるとともに、非推奨の関数・オプションにはその旨注記されます。
convert	文字列変換
filesearch	SearchPath または PVF を通じたファイルの場所特定に関連するすべての試みをログ記録します。
resource	Windows レジストリ・UPR 定義を通じたリソースの場所特定のすべての試みを、そのリソース検索の結果とともにログ記録します。
user	userlog オプションで与えられたユーザ指定のログ記録出力。
warning	すべての警告を、すなわち、無視または内部修復できるエラー状況をログ記録します。warning=2 の場合は、例外を発生させずに、TET_get_errmsg() を通じて取得できるメッセージテキストを残す関数からのメッセージと、ファイルを開こうとした試みの失敗すべての原因もログ記録されます。

10.3 文書関数

C++ Java C# `int open_document(String filename, String optlist)`

Perl PHP `long open_document(string filename, string optlist)`

C `int TET_open_document(TET *tet, const char *filename, int len, const char *optlist)`

内容を抽出したい、ディスクベースの、または仮想の PDF 文書を開きます。

filename 開きたい PDF ファイルのフルパス名。ファイルは `SearchPath` リソースを用いて検索されます。

Unicode 非対応言語バインディングでは、このファイル名は `filenamehandling` オプションに従って UTF-8 へ変換されます (`filenamehandling=unicode` の場合と、与えたファイル名が UTF-8 BOM で始まっている場合を除き)。`len` が 0 以外の場合 (C 言語バインディングのみ) には、このファイル名はオプション `filenamehandling` にかかわらず UTF-16 から UTF-8 へ変換されます。このファイル名が変換できない場合と、このファイル名が有効な UTF-8 か UTF-16 を構成していない場合には、エラーが発生します。

Windows 上では、UNC パスまたはマップされたネットワークドライブを用いても大丈夫ですが、ただし必要な権限を持っていない限りなりません (ASP で動作させる場合にはこの限りでないかもしれません)。

len (C 言語バインディングのみ) `filename` が UTF-16 文字列の場合の長さ (バイト単位で)。`len=0` ならば、ヌル終端文字列を与える必要があります。

optlist 表 10.8 に従って文書オプション群を指定したオプションリスト。右記のオプションが使えます:

`acceptdynamicxfa` • `allowjpeg2000` • `checkglyphlists` • `decompose` • `encodinghint` • `engines` • `fold` • `glyphcolor` • `glyphmapping` • `ignoreactualtext` • `lineseparator` • `normalize` • `inmemory` • `paraseparator` • `password` • `repair` • `requiredmode` • `shrug` • `spotcolor` • `tetml` • `unknownchar` • `usehostfonts` • `wordseparator`

戻り値 エラー時は -1、そうでないなら文書ハンドル。たとえば、入力文書または TETML 出力ファイルを開くことができないときはエラーになります。-1 が返された場合には、`TET_get_errmsg()` を呼び出してエラーの詳細を知ることが推奨します。

詳細 1 個の TET オブジェクト内で、任意の数の文書を同時に開いておくことができます。しかし、1 個の TET オブジェクトを複数のスレッドで同時に、アクセスを同期するロック機構なしで使用してはいけません。

暗号化: 文書が暗号化されている場合は、その権限設定が内容抽出を許しているならば、そのユーザパスワードを `password` オプションで与える必要があります。権限設定が内容抽出を許していない場合には、その文書のマスタパスワードを与える必要があります。`requiredmode` オプションを指定している場合は、正しいパスワードがなくても文書を開くことができますが、操作は制限されます。`shrug` オプションを用いると、保護された文書から一定の条件下で内容抽出を可能にすることができます (63 ページの 5.1「暗号化 PDF から内容を抽出」を参照)。

i5/iSeries 上での対応ファイルシステム: TET は、PC タイプのファイルシステムでのみテストされています。ですので、入力・出力ファイルは、IFS (統合ファイルシステム) 内の PC タイプファイル内になければなりません。`QSYS.lib` ファイルシステム内の入力ファイルはテストされておらず、サポートされていません。`QSYS.lib` ファイルは多くの場合、

レコードベースまたはデータベースオブジェクトのために用いられますので、TET を *QSYS.lib* オブジェクトとともに使用すると予期しない動作結果を招くおそれがあります。TET ファイル I/O ストリームはつねにストリームベースであり、レコードベースではありません。

表 10.8 TET_open_document()・TET_open_document_callback() の文書オプション一覧

オプション	説明
<i>accept-dynamicxfa</i>	(論理値) true の場合、動的 XFA フォームを成功裏に開くことができます。pCOS パスをクエリすることのみが合理的な活動です。TET_open_page() を呼び出すことは、意味あるテキスト・画像をまったく抽出できませんので、失敗します。デフォルト : false
<i>allowjpeg-2000</i>	(論理値) true の場合、TET_write_image_file()・TET_get_image_data() に対する出力形式として JPEG 2000 (*jp2・*jpf・*j2k のいずれか) が許されます。そうでない場合、JPEG 2000 は避けられて TIFF が選択され、その結果として画像ファイルが大きくなる場合があります。デフォルト : true
<i>check-glyphlists</i>	(論理値) true ならば、TET は、テキスト抽出が始まる前に、すべての condition=allfonts の内蔵グリフマッピング規則をチェックします。そうでないなら、グローバルなグリフマッピング規則は適用されません。このオプションは処理速度を低下させますが、デフォルトで Unicode ヘマッピングできないグリフ名を持つある種の TeX 文書に対して有用です。デフォルト : false
<i>decompose</i>	<p>(キーワードかオプションリスト。granularity=glyph と TETML 内の Glyph エレメントに対しては無意味) 指定した Unicode 分解タグを持つ、かつ、指定した Unicode 集合の一部であるすべてのキャラクタに適用される Unicode 分解。これらの条件はサブオプションの名前と値で与えられます。分解を用いると、等価な Unicode キャラクタ間の違いを除去するか温存することができます (109 ページの 7.3 「Unicode 後処理」を参照)。</p> <p>デフォルト : 113 ページの「デフォルト分解」を参照してください。ただし、normalize オプションが none 以外の値を持つときは、すべてのデフォルト分解は無効化されます。すなわち、normalize オプションを設定するとデフォルトが decompose=none に設定されます。ユーザ指定の分解はなお適用できます。</p> <p>リストに換えて、以下のキーワードを与えることもできます :</p> <p>none 何の分解も適用されません。</p> <p>default 他の指定した分解の前に、デフォルト分解 (113 ページの「デフォルト分解」を参照) が適用されます。</p> <p>分解のための以下のサブオプションが使えます :</p> <p>canonical・circle・compat・final・font・fraction・initial・isolated・medial・narrow・nobreak・small・square・sub・super・vertical・wide</p> <p>これらの各サブオプションは、分解のドメインを、すなわち、分解が適用される Unicode キャラクタの集合を指定する文字列またはキーワードを受け付けます。文字列は、ドメインの Unicode 集合を指定します。これを用いると、指定した分解タグを持つキャラクタの部分集合に分解を制限することができます。このドメインの外のキャラクタは変更されません。</p> <p>Unicode 集合の文字列に換えて、以下のキーワードを与えることもできます :</p> <p>_all 全 Unicode キャラクタの集合。すなわち、分解は、指定した分解タグを持つすべてのキャラクタに適用されます。</p> <p>_none 空集合。すなわち、分解はまったく適用されません。</p>
<i>encodinghint</i>	(文字列 ¹) 標準規則ではマップできず、定義済内部グリフマッピング規則によってのみマップできるグリフ名に対する Unicode マッピングを決定するために用いられるエンコーディングの名前。キーワード none を用いると、すべての定義済規則を無効化することができます。デフォルト : winansi

表 10.8 TET_open_document()・TET_open_document_callback()の文書オプション一覧

オプション	説明
engines	<p>(オプションリスト) ページ解析のための TET エンジン群を有効化または無効化します。無効化されたエンジン群は何も情報を提供しません。必要のないエンジン群を無効化するとパフォーマンスが向上します (デフォルト: すべてのエンジンが有効):</p> <p>annotation (論理値) 注釈エンジンを有効化。注釈内容が image・text サブオプションに従って処理されます。</p> <p>image (論理値) ページ・注釈からの画像抽出を有効化。</p> <p>text (論理値) ページ・注釈からのテキスト抽出を有効化。</p> <p>textcolor (論理値) テキストカラーエンジンを有効化。</p> <p>vector (論理値) ベクトルグラフィックエンジンを有効化。これは、クリッピングと表組検出の向上のために意味を持ちます。</p>
fold	<p>(キーワード、またはリストのリスト。それぞれの内側のリストの 1 番目の要素は Unicode 集合またはキーワード、2 番目の要素は Unichar またはキーワード。granularity=glyph と TETML 内の Glyph エレメントに対しては無意味) Unicode 集合かキーワードとして指定した字形統合ドメイン内のすべてのキャラクタに対し、字形後統合 (等価マッピング) を適用します。この字形統合は、lineseparator または paraseparator または wordseparator オプションで追加した区切りキャラクタを除くすべてのテキストに対して適用されます (109 ページの 7.3 「Unicode 後処理」を参照)。デフォルト: 111 ページの表 7.3 を参照。</p> <p>リストに換えて、以下のキーワードを与えることもできます:</p> <p>none 字形統合は一切適用されません。</p> <p>サブリストに換えて、以下のキーワードを与えることもできます:</p> <p>default デフォルト字形統合が適用されます。ユーザーが与える字形統合にはこのキーワードを付け加えることを強く推奨します。なぜなら、デフォルト字形統合を無効化すると、望ましくない効果が表れるおそれがあるからです。</p> <p>各リストの 1 番目の要素は、字形統合のドメインを、すなわちその字形統合が適用される Unicode キャラクタの集合を指定します。文字列は、ドメインの Unicode 集合を指定します。1 個のキャラクタが、fold オプション内で指定している複数の集合に含まれている場合には、最初に一致した集合の定義が他のすべてに優先します。予期せぬ結果を避けるため、重ならない集合を用いることを推奨します。</p> <p>ドメインを Unicode 集合として指定する方法以外に、以下のキーワードを用いることもできます:</p> <p>_dehyphenation 改行位置でハイフン区切りされた単語内で見つかったハイフンキャラクタに字形統合が適用されます。これらのキャラクタは、TET_get_char_info() が返す attributes メンバ内と、TETML 内の Glyph/@dehyphenation 属性で、TET_ATTR_DEHYPHENATION_ARTIFACT としてフラグされます。</p> <p>_tetpua マップ不能グリフ群に割り当てられた TET PUA 値群に字形統合が適用されます。これらのキャラクタは、TET_get_char_info() によって返される unknown メンバと、TETML 内の Glyph/@unknown 属性を用いてフラグされています。</p> <p>各リストの 2 番目の要素は、字形統合のターゲットキャラクタまたはアクションを内容として持ちます。これは以下の種類のいずれかで指定します:</p> <p>(Unichar) そのドメイン内のすべてのキャラクタを、指定した Unicode キャラクタへ置き換えます。</p> <p>preserve ドメイン内のキャラクタは変更されません。</p> <p>remove ドメイン内のキャラクタが除去されます。</p> <p>shift ドメイン内のすべてのキャラクタを、指定した値だけシフトさせます (負の値も可)。</p> <p>unknownchar ドメイン内のすべてのキャラクタを、unknownchar オプションで指定したキャラクタへ置き換えるか、あるいは unknownchar オプションで指定したアクションを適用します。</p>

表 10.8 TET_open_document()・TET_open_document_callback()の文書オプション一覧

オプション	説明
glyphcolor	<p>(キーワード) テキストの塗り・描線色を報告させたい色空間を選択。このオプションは、Separation または DeviceN カラーを用いているテキストに対してのみ意味を持ちます。これは、TET_char_info()/TET_get_color_info() と TETML の両方で報告される色情報に効力を及ぼします。使用するキーワード (デフォルト : native) :</p> <p>native すべてのテキスト色に対してネイティブ PDF 色空間を用います。</p> <p>alternate Separation・DeviceN テキスト色に対して代替色空間を用います。</p>
glyphmapping	<p>(オプションリストのリスト) オプションリストのリスト。ここで各オプションリストは、標準メソッドでマップできない 1 個ないし複数のフォント / エンコーディングの組み合わせに対するグリフマッピング方法を記述します。このマッピングは、設定された順に用いられます。最後のオプションリストがフォント名ワイルドカード「*」を含んでいる場合には、それ以前のマッピングは用いられなくなります。各規則は、表 10.9 に従ったオプションリストを内容として持ちます。特定のフォント名にマッチするすべてのグリフマッピングがこのフォントに適用されます (デフォルト : 定義済内蔵グリフマッピング群が適用されます)。</p> <p>なお、グリフマッピング規則は、UPR ファイル内の外部リソースとして指定することもできます (65 ページの 5.2 「リソース設定とファイル検索」を参照)。</p>
ignore-actualtext	<p>(論理値) true の場合、文書内のす ActualText マッピングはすべて無視されます。デフォルト : false</p>
linseparator	<p>(Unichar, granularity=page の場合のみ) 行どうしの間 (ただしページの最終行の後を除く) に挿入させたいキャラクタ²。デフォルト : U+000A</p>
normalize	<p>(キーワード。granularity=glyph と TETML 内の Glyph エレメントに対しては無意味) テキスト出力を、Unicode 正規化形の 1 つへ正規化します :</p> <p>none いかなる正規化も適用しません。</p> <p>nfc 正規化形 C (NFC) : 正準分解の後に正準合成</p> <p>nfd 正規化形 D (NFD) : 正準分解</p> <p>nfkc 正規化形 KC (NFKC) : 互換分解の後に正準合成</p> <p>nfkd 正規化形 KD (NFKD) : 互換分解</p> <p>Unicode 正規化形には正準分解と互換分解がかかわってきますので、オプション decompose と normalize の組み合わせは注意深く行う必要があります。normalize オプションを none 以外の値に設定すると、分解のデフォルトは decompose=none に設定されます。</p>
inmemory	<p>(論理値。TET_open_document()のみ) true の場合、TET はファイル全体をメモリ内へ読み込み、それをそこで処理します。これは、システムによっては驚異的なパフォーマンス向上につながるがありますが (とくに MVS)、そのかわりメモリ使用量も増えます。false の場合、文書の個々の部分が必要に応じてディスクから読み込まれます。デフォルト : false</p>
paraseparator	<p>(Unichar, granularity=page の場合のみ) 段落間に挿入させたいキャラクタ²。デフォルト : U+000A</p>
password	<p>(文字列) 暗号化された文書に対するユーザパスワード・マスタパスワード・添付パスワードのいずれか。その文書の権限設定がテキストコピーを許している場合には、ユーザパスワードで充分ですが、そうでない場合はマスタパスワードを与える必要があります。</p> <p>文書の暗号化ステータスを取得する方法と、ユーザまたはマスタパスワードを知らなくても適用できる pCOS 操作については、pCOS パスリファレンスを参照してください。</p> <p>shrug オプションを用いると、保護された文書から一定の条件下で内容抽出を可能にすることができます (63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照)。</p>

表 10.8 TET_open_document()・TET_open_document_callback()の文書オプション一覧

オプション	説明
repair	(キーワード) 破損 PDF 文書の扱い方を指定します。文書の修復は、通常のパースよりも時間がかかりますが、ある種の破損 PDF が処理できるようになる可能性があります。ただし文書によっては、修復できないほど破損している場合もあります (デフォルト : auto) : force 文書に問題があってもなくても、無条件に文書の修復を試みます。 auto PDF を開く際に問題が検出されたときのみ文書を修復します。 none 文書の修復の試みは一切行われません。PDF 内に問題があるときは、関数呼び出しは失敗します。
requiredmode	(キーワード) 文書を開く際に受け入れられる最小 pCOS モード (最小 : minimum/ 制限 : restricted/ フル : full)。結果の pCOS モード (pCOS バスリファレンス参照) が、求めたモードよりも低くなる場合は呼び出しは失敗します。呼び出しが成功したときは、結果の pCOS モードが最低でもこのオプションで指定したものであることが保証されます。ただし、それより高くなる場合もあります。たとえば、暗号化されていない文書に対して requiredmode=minimum を指定すると、結果はフルモードになります。デフォルト : full
shrug	(論理値) true の場合、シュラッグ機能が有効になり、保護された文書から一定の条件下で内容抽出が可能になります (63 ページの 5.1 「暗号化 PDF から内容を抽出」を参照)。shrug オプションを用いる場合には、その PDF 文書作成者の権利を尊重してください。デフォルト : false
spotcolor	(キーワード) TET_write_image_file() と TET_get_image_data() におけるスポットカラー画像の取り扱いを制御。Separation または DeviceN 色空間の、すなわち 1 個ないし複数の名前付きプロセスまたはスポットカラーを持つ画像は、以下のように抽出されます (デフォルト : ignore) : convert カスタムスポットカラーが全く使用されていない場合にはグレースケールまたは CMYK 画像を出力。そうでない場合には、スポットカラー群を、照応する代替色空間へ変換。画像によっては、代替色空間への変換が可能でない場合もあります。その場合には、この方式は、spotcolor=ignore (カスタムスポットカラーが 1 個だけある場合) か spotcolor=preserve (カスタムスポットカラーが複数ある場合) のように動作します。 ignore convert と同様ですが、ただしカスタムスポットカラーを 1 個だけ持つ画像はグレースケール画像として抽出され、そのスポットカラー名は失われます。 preserve (強制的に TIFF 出力) グレースケールまたは CMYK 画像を、カスタムスポットカラー名群のために必要な場合には、1 個ないし複数の追加スポットカラーチャンネルを持った状態で出力。スポットカラー群を追加チャンネル群内に温存している TIFF 画像を扱えるのは Adobe Photoshop と互換プログラム群のみであり、いくつかの単純な TIFF ビューアでは扱えません。

表 10.8 TET_open_document()・TET_open_document_callback() の文書オプション一覧

オプション	説明
tetml	(オプションリスト) TETML 出力が開始され、そして TET_process_page() でページごとに作成できます。以下のサブオプションが使えます：
elements	(オプションリスト) 出力内に特定の TETML エレメントを含めるかどうかを指定します：
annotations	(論理値) 文書が注釈を内容として持っている場合に /TET/Document/Pages[]/Page/Annotations を出力。デフォルト：true
attachments	(論理値) 文書がしおりを内容として持っている場合に /TET/Document/Pages[]/Page/Attachments を出力。デフォルト：true
bookmarks	(論理値) 文書がしおりを内容として持っている場合に /TET/Document/Bookmarks を出力。デフォルト：true
destinations	(論理値) 文書が移動先を内容として持っている場合に /TET/Document/Destinations を出力。デフォルト：true
docinfo	(論理値) 文書が文書情報項目を内容として持っている場合に /TET/Document/DocInfo を出力。デフォルト：true
fields	(論理値) 文書が AcroForm フィールドか電子署名を内容として持っている場合に /TET/Document/Pages[]/Page/Fields と TET/Document/SignatureFields を出力。デフォルト：true
javascripts	(論理値) 文書が JavaScript を内容として持っている場合に /TET/Document/JavaScripts を出力。デフォルト：true
metadata	(論理値) 文書が文書または画像レベルで XMP メタデータを内容として持っている場合に /TET/Document/Metadata および/または /TET/Document/Images[]/Image/Metadata を出力。デフォルト：true
options	(論理値) エレメント /TET/Document/Options と /TET/Document/Pages[]/Page/Options。デフォルト：true
encodingname	(キーワード) 生成される TETML のテキスト宣言の XML エンコーディング宣言内で用いたい名前。出力はつねに UTF-8 で生成されます (デフォルト：UTF-8)：
_none	エンコーディング宣言は作成されません。出力は同様に UTF-8 形式になります。
UTF-8	宣言 encoding="UTF-8" が作成されます。
	これ以外のエンコーディング名は、エンコーディング宣言内にリテラルに用いられません。適切なエンコーディング名を与えるとともに、TET が TETML 出力を完成させた後に、生成された TETML (UTF-8 です) を、指定したエンコーディングへ変換することは、クライアント側の役割です。
filename	(文字列) TETML ファイルの名前。filename を与えなかった場合には、出力はメモリ内に生成され、TET_get_tetml() で取得することができます。関数呼び出しが失敗した (すなわち、PDF 入力文書をうまく開くことができなかった) 場合には、TETML 出力は生成されません。
unknown-char	(Unichar かキーワード) マップ不能グリフに対するキャラクタまたは TET PUA キャラクタに対して適用させたい動作 (119 ページの「マップ不能グリフと TET PUA」を参照)。以下のキーワードを使えます (デフォルト：Unicode 置換キャラクタ U+FFFD)：
remove	マップ不能グリフは除去されます。値 U+0000 は remove と等価です。
preserve	マップ不能グリフは TET PUA 値によって表されます。
usehostfonts	(論理値) true の場合、埋めこまれていないが Unicode マッピングを決定するために必要なフォントのデータは、macOS または Windows ホストオペレーティングシステム上で検索されます。デフォルト：true
wordseparator	(Unichar。granularity=line・page の場合のみ) 単語どうしの間に挿入させたいキャラクタ ² 。デフォルト：U+0020

1. 表 10.9 の脚注 1 を参照

2. 区切りキャラクタを無効化するには U+0000 を用います。

表 10.9 TET_open_document()・TET_open_document_callback() の glyphmapping オプションのサブオプション一覧

オプション	説明
codelist	(文字列) フォントに適用させたいコードリストリソースの名前。これは、埋めこまれた ToUnicode CMap またはエンコーディングエントリよりも優先されます。
fold	Unicode 集合として指定された字形統合ドメインの中のすべてのキャラクタに字形前統合 (等価マッピング) を適用。表 10.8 のオプション fold の説明を参照してください。キーワード remove・preserve・unknownchar を使用することはできません。shift キーワードを用いたフォント個別の字形統合を活用すると、フォントの ToUnicode CMap 中の規則的な誤りを修正することもできます。
fontname	(名前文字列) 規則に対して選択されるフォント (群) の名前の一部分ないし全体。部分集合接頭辞を与えているときは、指定した部分集合だけが選択されます。部分集合接頭辞を一切与えていないときは、名前 (部分集合接頭辞なしの) がマッチするすべてのフォントが選択されます。ワイルドカードキャラクタ「*」を用いて、複数の類似のフォント名を指定することもできます。デフォルト : *
fonttype	(キーワードのリスト) グリフマッピングは、指定した種類のフォントに対してのみ適用されます : * (あらゆる種類のフォントを意味します)・Type1・MMType1・TrueType・CIDFontType2・CIDFontType0・Type3。デフォルト : *
force-encoding	(文字列) 1 個か 2 個のリスト。名前が 2 個あるときは、1 番目は winansi・macroman・custom のいずれかでなければなりません。ここで custom は任意のエンコーディングにマッチします) 8 ビットエンコーディングのフォント : 1 番目のエンコーディングを、2 番目の名前で指定したエンコーディングリソースへ置き換えます。エントリが 1 個しか与えられていないときは、指定されたエンコーディングを用いて MacRoman・WinAnsi・MacExpert エンコーディングのすべてのインスタンスが置き換えられます。このオプションがフォントにマッチした場合には、その同じフォントに対しては他のグリフマッピングは一切適用されません。 CID フォント : 値 1 個 unicode にのみ対応しています。これは CID 値を Unicode 値として解釈します。
forcettsymbol-encoding	(キーワードまたは文字列 ¹⁾) 埋め込まれた、実際にはテキストフォントである擬似 TrueType 記号フォントに対する Unicode マッピングを決定するために使われるエンコーディングの名前か、または以下のキーワードの 1 つ (デフォルト : none) : auto フォントの内蔵エンコーディング (後述) が、記号範囲 U+F000 ~ U+F0FF 内の Unicode キャラクタを少なくとも 1 個含んでいる場合には、encodinghint オプションで指定したエンコーディングを用いて擬似記号キャラクタが実テキストキャラクタへマップされます。そうでない場合には、encodinghint は使われず、キャラクタは builtin キーワードに従ってマップされます。 builtin フォントの post テーブル内のグリフ名の Unicode マッピングから得られる、フォントの内蔵エンコーディングを用います。 none エンコーディングを一切強制しません。 有名な TrueType フォント Wingdings* と Webdings* はつねに記号フォントとして扱われます。
globalglyphlist	(論理値) true の場合は、指定したグリフリストは TET オブジェクトの終了までメモリ内に保持されますので、複数の文書に対して適用することもできます。デフォルト : false
glyphlist	(文字列) 適用したいグリフリストリソースの名前

表 10.9 TET_open_document()・TET_open_document_callback() の glyphmapping オプションのサブオプション一覧

オプション	説明
glyphrule	(オプションリスト) 数値グリフ名に対するマッピング規則 (定義済規則に加えて)。このオプションリストは以下のサブオプションを内容として持つ必要があります:
prefix	(文字列。空でも可) 規則が適用されるグリフ名の接頭辞。ワイルドカードキャラクタ「?」も使えます。これは、ちょうど 1 個のキャラクタに、このキャラクタが 0 ~ 9 以外であれば、マッチします。
base	(キーワード) グリフ名の解釈を指定します:
ascii	シングルバイトグリフ名はおのおのリテラル ASCII キャラクタとして解釈されます (例: 1 は U+0031 へマップされます)。
auto	グリフ名が 10 進と 16 進のどちらの値を表すのかを自動的に決定します。結果が一意でない場合には、10 進と見なされます。
dec	グリフ名はコードの 10 進表現として解釈されます。
hex	グリフ名はコードの 16 進表現として解釈されます。
encoding	(文字列) この規則に対して用いられるエンコーディングリソースの名前。キーワード none を指定すると、規則は無効になります。
ignoreto-unicodemap	(論理値) true の場合には、フォントに対する ToUnicode CMap は無視されます。デフォルト: false
override	(論理値。glyphlist または glyphrule オプションとともに用いてのみ意味を持ちます) true の場合には、グリフマッピング規則は、標準 (内蔵) のグリフ名マッピング群より前に適用されます (すなわち、新しいマッピング群が内蔵のマッピング群よりも優先されます)。そうでない場合には、この規則は内蔵のマッピング群の後に適用されます。デフォルト: true
remove	(論理値) true の場合、抽出されたテキストから、指定したフォント名 (複数可) および/またはフォント種別 (複数可) を用いているテキストはすべて除去されます。
tounicode-cmap	(文字列) フォントに適用させたい ToUnicode CMap リソースの名前。これは、埋め込まれた ToUnicode CMap またはエンコーディングエントリよりも優先されます。

1. 173 ページの 10.1.5 「エンコーディング名」に従ったエンコーディング名

```

C++ int open_document_callback(void *opaque, tet_off_t filesize,
                               size_t (*readproc)(void *opaque, void *buffer, size_t size),
                               int (*seekproc)(void *opaque, tet_off_t offset),
                               wstring optlist)

C int TET_open_document_callback(TET *tet, void *opaque, tet_off_t filesize,
                                  size_t (*readproc)(void *opaque, void *buffer, size_t size),
                                  int (*seekproc)(void *opaque, tet_off_t offset),
                                  const char *optlist)

```

内容抽出したい PDF 文書を、カスタムデータソースから開きます。

opaque 入力 PDF 文書に関連づけた何らかのユーザデータへのポインタ。このポインタは、コールバック関数群の 1 番目の引数として渡され、いかようにでも使うことができます。TET はこの不透明ポインタをいかなる形においても使用しません。

filesize PDF 文書のサイズをバイト単位で。

readproc *size* バイトを *buffer* で指し示されたメモリへ複製する C コールバック関数。文書の終わりに到達した場合には、求められたよりも少ないデータを複製することができます。この関数は、複製したバイト数を返す必要があります。

seekproc 文書内のカレント読み取り位置を設定する C コールバック関数。**offset** は文書の先頭からの位置を表します (0 を最初のバイトとして)。この関数は、成功したときには 0 を、そうでなかったときには -1 を返す必要があります。

optlist 表 10.8 に従って文書オプション群を指定したオプションリスト。

戻り値 **TET_open_document()** 参照。

詳細 **TET_open_document()** 参照。

バインディング この関数は、C・C++ 言語バインディングでのみ利用可能です。**tet_off_t** 型は内で条件的に定義されています。これは通常、2GB を超える大きなファイルに対するオフセット型として 64 ビット値を保持します。アプリケーションは大容量ファイルサポート (LFS) とともにビルドされる必要があります。

C++ Java C# **void close_document(int doc)**

Perl PHP **close_document(long doc)**

C **void TET_close_document(TET *tet, int doc)**

文書ハンドルと、その文書に関連づけられたすべての内部リソースを解放します。

doc **TET_open_document*()** で得られた有効な文書ハンドル。

詳細 文書を閉じると、その開いているページ群もすべて自動的に閉じられます。**TET_delete()** を呼び出すと、開いている文書とページはすべて自動的に閉じられます。とはいえ、文書が必要なくなった時点で明示的に閉じるのが良いプログラミング習慣です。閉じられた文書ハンドルは、その後はいかなる関数呼び出しにおいても使用してはいけません。

10.4 ページ関数

C++ Java C# *int open_page(int doc, int pagenumber, String optlist)*

Perl PHP *long open_page(long pagenumber, string optlist)*

C *int TET_open_page(TET *tet, int doc, int pagenumber, const char *optlist)*

内容抽出したいページを開きます。

doc *TET_open_document*()* で得られた有効な文書ハンドル。

pagenumber 開きたいページの物理的番号。最初のページをページ番号 1 とします。総ページ数は *TET_pcos_get_number()* と pCOS パス *length:pages* で取得できます。

optlist 表 10.10 に従ってページオプション群を指定したオプションリスト。右記のオプションが使えます：

clippingarea · *contentanalysis* · *docstyle* · *emptycheck* · *excludebox* · *fontsize* · *granularity* · *ignoreartifacts* · *ignoreinvisibletext* · *imageanalysis* · *includebox* · *layers* · *layoutanalysis* · *layouteffort* · *structureanalysis* · *topdown* · *vectoranalysis*。

戻り値 ページのハンドル。エラーの場合には -1。-1 が返された場合には、*TET_get_errmsg()* を呼び出してエラーの詳細を知ることが推奨します。

詳細 1 個の文書内で任意の数のページを同時に開いておくことができます。同じページを異なるオプションで複数回開くこともできます。しかし、1 つのページを処理している途中でオプションを変えることはできません。

レイヤー定義 (オプション内容グループ)：ページ上のすべての可視レイヤーの内容がデフォルトで抽出されます。この動作は *layers* オプションを用いて変えることもできます。

表 10.10 *TET_open_page()* · *TET_process_page()* のページオプション一覧

オプション	説明
clippingarea	(キーワード。includebox を指定しているとこれは無視されます) テキストと画像が抽出される領域を指定します (デフォルト : cropbox) :
mediabox	MediaBox を用います (これは必ず存在します)
cropbox	CropBox を用います (Acrobat で表示される領域です)。なければ MediaBox を用います
bleedbox	BleedBox を用います。なければ CropBox を用います
trimbox	TrimBox を用います。なければ CropBox を用います
artbox	ArtBox を用います。なければ CropBox を用います
unlimited	位置にかかわらずすべてのテキストを考慮します。
content-analysis	(オプションリスト。granularity=glyph の場合には不可) 表 10.11 に従った、高レベル内容分析とテキスト処理のためのサブオプション群のリスト。

表 10.10 TET_open_page()・TET_process_page() のページオプション一覧

オプション	説明
docstyle	<p>(キーワード) レイアウト検出エンジンがさまざまなパラメタを選択するために用いるヒント。これらのパラメタは、文書が以下の分類の1つに属する状況においてレイアウト分析を最適化します: 文書がこれらの分類の1つにあてはまることがわかっている場合には、このオプションに適切な値を与えればレイアウト検出結果は非常に向上します。このオプションは高度なレイアウト認識を有効にします (デフォルト: none):</p> <p>book 典型的な本</p> <p>business ビジネス文書</p> <p>cad 技術または建築図面。通常、非常に断片化しています。</p> <p>fancy 複雑なレイアウトによる装飾的なページ</p> <p>forms 構造化されたフォーム</p> <p>generic 特に特徴を指定しない最も一般的な文書分類です。</p> <p>magazines 雑誌記事</p> <p>none 特定の文書スタイルがわかっておらず、高度なレイアウト認識は無効にされます。</p> <p>native レイアウト検出を無効化して、内容を、ネイティブなページ内容順序のまま返します。これは、テキストがページ全体にわたって配置されており、列検出が望ましくなく、行ごとにテキスト抽出を行いたい、フォームのようなレイアウトに対して有用でしょう。</p> <p>papers 新聞</p> <p>science 科学記事</p> <p>searchengine アプリケーションは検索エンジンインデックス生成機能やそれに類似のアプリケーションであり、ページの単語一覧をなるべく速く取得することが主たる関心。表組・ページ構造認識は無効化されます。</p> <p>simpleline 単純化された1段組みページレイアウトを前提してテキストを個々の行として処理。表組検知とハイフン除去は無効化されます。これは単行指向レイアウトを持つ請求書などの文書に対して役立つでしょう。このdocstyleはgranularityとは無関係です。</p> <p>spacegrid 視覚レイアウトがスペースキャラクタ群を用いて生成される、リスト指向のレポート (メインフレームシステムで生成されることが多い)。この種の文書に対しては、影付き検出や洗練された単語境界検出といった多くのヒューリスティックは必要ないので、このオプションによってテキスト抽出を高速化できます。</p>
emptycheck	<p>(論理値) true の場合、通常の内容抽出が無効化されます。そのかわりに、includebox オプションで与えられた枠を用いて、その枠が何らかのテキストか画像かベクトルグラフィックを内容として持っているかどうかチェックされます (ただ1個のincludeboxにのみ対応)。includebox オプションが与えられていない場合には、クリッピング領域全体がチェックされます。これを活用すると空ページを識別できます。以下のオプションは無視されます: granularity・engines・fontsize-range。クリッピングオペレータ群は無視されます。</p> <p>このチェックの結果は、TET_get_text() を呼び出すと、ページ内容ではなく文字列 empty か notempty のいずれか一方を返しますので、それを用いてチェックできます。デフォルト: false</p>
excludebox	<p>(矩形のリスト) 指定した矩形を合わせた領域を、テキストと画像の抽出から除外します。デフォルト: 空</p>
fontsize-range	<p>(float 2 個のリスト、または float とキーワード) テキストの最小・最大文字サイズを指定した2個の数値。この区間を外れたサイズのテキストは無視されます。最大値にキーワード unlimited を指定すると、上限なしという意味になります。デフォルト: { 0 unlimited }</p>

表 10.10 TET_open_page()・TET_process_page() のページオプション一覧

オプション	説明
granularity	(キーワード) TET_get_text() が返すテキスト断片の粒度。glyph 以外のすべてのモードで単語検出機能が有効になります。詳しくは 90 ページの「テキストの粒度」を参照してください (デフォルト: word) :
glyph	各断片はそれぞれ 1 個のグリフの結果を内容として持ちますが、それが複数のキャラクタになる場合もあります (合字の場合など)。
word	各断片はそれぞれ、単語検出機能によって決定された 1 個の単語を内容として持ちます。
line	各断片はそれぞれテキスト 1 行を、ないしはそれにできるだけ似たものを内容として持ちます。連続する 2 個の単語の間には単語区切りキャラクタが挿入されます。
page	各断片はそれぞれ 1 個のページを内容として持ちます。単語・行・段落区切りキャラクタが適宜挿入されます。
ignore-artifacts	(論理値) ページ装飾として標識されているテキストと画像を無視します。これを利用すると、ページ装飾として標識されている、本文外のページ内容をスキップできます。タグ付きでない文書の中でも、内容がページ装飾として標識されていることがあります。デフォルト: false
ignore-invisibletext	(論理値) true の場合には、表現モード 3 (不可視) のテキストは無視されます。デフォルト: false (不可視テキストは、スキャンされたページとその OCR テキストを内容として持つ画像 + テキスト PDF で主に使用されているからです)
image-analysis	(オプションリスト) 表 10.13 に従った、高レベル画像処理を制御するためのサブオプション群のリスト。
includebox	(矩形のリスト) テキストと画像の抽出を、指定した矩形を合わせた領域に限定します。デフォルト: 切り抜き領域全体
layers	(キーワード) レイヤー内部 (オプション内容としても知られます) のページ内容の扱い。使えるキーワード (デフォルト: visible) :
all	レイヤーにかかわらずすべてのページ内容を抽出。ページ上の複数のレイヤーの内容が重なり合うと、テキストが意味不明になったり、画像連結が失敗したりすることもあります。
invisible	デフォルトで不可視のすべてのレイヤーの内容を抽出し、その他のすべてのレイヤーを無視。
visible	デフォルトで可視のすべてのレイヤーの内容を抽出し、その他のすべてのレイヤーを無視。
layout-analysis	(オプションリスト。granularity=glyph の場合には不可) 表 10.12 に従った、レイアウト検出機能を制御するためのサブオプション群のリスト。
layouteffort	(キーワード) レイアウト認識の品質 / パフォーマンスのトレードオフを制御します。レイアウト認識は、努力を増せば向上できますが、これによって操作は遅くなるおそれがあります。このレイアウト認識努力を、キーワード none・low・medium・high・extra で制御できます。デフォルト: low

表 10.10 TET_open_page()・TET_process_page() のページオプション一覧

オプション	説明
layouthint	(オプションリスト) 特定のページレイアウト要素の存在についてレイアウト認識エンジンに通知します: subsummary (キーワード) サブサマリ (傍注) の存在について、指定によってはその位置とともにエンジンに知らせます。使えるキーワード (デフォルト: none): auto サブサマリ検出なし。 left ページの左脇にサブサマリ検出を試みます。 none 自動的にサブサマリ検出を試みます。 right ページの右脇にサブサマリ検出を試みます。 header (論理値) true の場合、エンジンはページヘッダの検出を試みます (デフォルト: false)。 footer (論理値) true の場合、エンジンはページフッタの検出を試みます (デフォルト: false)。
maxvector-count	(float) ベクトルグラフィックエンジンに考慮させたいベクトルオブジェクトの最大数。デフォルト: 500
minvectorsize	(float) ベクトルグラフィックエンジンに考慮させたいベクトルオブジェクトの最小寸法。ベクトルオブジェクトの寸法は、その外接枠の対角線の長さをポイント単位で表したものです。デフォルト: 5
structure-analysis	(オプションリスト。granularity=glyph の場合には不可) 表 10.14 に従った、ページ構造分析を制御するためのサブオプション群のリスト。
topdown	(オプションリスト) 可視ページの左上隅に原点を持つ、y 座標が下方増加する座標系を指定します。そうでないなら、左下隅に原点を持つデフォルト座標系が用いられます。下向き座標を有効にすると、Acrobat で表示される座標系と同じにすることができます。使えるサブオプション: input (論理値) true の場合には、以下の項目に対して下向き座標が有効になります (デフォルト: false): ページオプション includebox・excludebox output (論理値) true の場合には、以下の項目に対して下向き座標が有効になります (デフォルト: false): TET_char_info: y・alpha・beta TET_image_info: y・alpha・beta TETML: Destination/@bottom、Destination/@top、 エレメント Cell・Box・Line・Table の属性 @lly・@ury・@uly・@lry、 エレメント Glyph・PlacedImage の属性 @y・@alpha・@beta。
vector-analysis	(オプションリスト。granularity=glyph に対しては不可) 表・レイアウト検出のためのベクトルグラフィックの解析を制御するための、表 10.15 に従ったサブオプション群。このオプションが存在する場合には、表・レイアウト解析のためにベクトルグラフィックが考慮されます。

表 10.11 TET_open_page()・TET_process_page() の contentanalysis オプションのサブオプション一覧

オプション	説明
bidirectional	(キーワード。granularity=glyph の場合には無視されます。右書きキャラクタがページ上に存在している場合にのみ効力を持ちます) 断片内の右書き・左書きテキストを並べ替える反転双方向アルゴリズムを制御します (デフォルト: logical):
visual	断片内の右書き・左書きキャラクタを視覚順に保ちます。すなわち、反転双方向アルゴリズムを適用しません。
logical	反転双方向アルゴリズムを適用して、断片内のキャラクタを論理順でもたらしめます。
bidirectionlevel	(キーワード) 反転双方向アルゴリズムに対するページのベースレベル (すなわちテキスト進行の主要向き) を指定します (デフォルト: auto):
auto	テキスト進行の主要向きを、内容に基づいてヒューリスティックに決定します。
ltr	テキスト進行の主要向きとして左書きを前提します (欧文文書など)
rtl	テキスト進行の主要向きとして右書きを前提します (ヘブライ文字・アラビア文字文書など)
dehyphenate	(論理値) true の場合には、ハイフン区切りされた単語が特定され、ハイフンを挟むテキスト断片どうしが連結されます。ハイフン自体は keephyphens オプションに従って扱われます。デフォルト: true
dropcapsize	(float) 大きなグリフがドロップキャップとして認識される最小サイズ。ドロップキャップは、区域の先頭の大きなキャラクタで、数行にわたってぶら下がっているものです。それらは、その区域の残りとして連結され、その区域内の最初の単語の一部を成します。デフォルト: 35
dropcapratio	(float) ドロップキャップと隣接テキストの文字サイズの最小比率。大きなキャラクタは、そのサイズが dropcapsize を超えており、かつ、その文字サイズ比率が dropcapratio を超えている場合にドロップキャップとして認識されます。言い換えれば、これはドロップキャップがわたるテキスト行数です。デフォルト: 4 (ドロップキャップは 3 行にわたるものが非常に多いですが、行間の分も考慮に入れる必要があります)
includebox-order	(整数) 複数の包含枠を与えている場合 (オプション includebox 参照)、このオプションは、枠の順序が単語検出機能に対しどのような効力を持つかを制御します (デフォルト: 0):
0	ページ内容を分析する際に、包含枠順序は無視します。結果は、あたかも包含枠群の外のテキストがすべて削除されたのと同じになります。これは、ほしくないテキスト (ヘッダ・フッタなど) を除去しつつ、単語検出機能には何の影響も与えないようにするために有用です。
1	包含枠順序を、単語と区域を生成する際には考慮に入れますが、区域順序を決定する際には考慮しません。1 個の単語が複数の枠に属することは決してありません。できた区域群は、論理順に並べ替わります。枠が重なりあっている場合には、そのテキストはリスト内で最も先に現れた枠に属します。それ以外では、オプションリスト内における包含枠の順序は考慮されません。この設定は、テキストをフォームから抽出する時や、テキストを表組から抽出する時や、複雑なレイアウトにおいて包含枠が重なりあっている場合に有用です。
2	包含枠順序を、すべての操作について考慮します。各包含枠の内容は他の枠とは独立に扱われ、できたテキストは包含枠の順序に従って連結されます。これは、フォームからテキストを特定の順序で抽出したい時や、雑誌レイアウト内の記事段組を定義済順序で抽出したい時に有用です。こうした場合には、包含枠を適切な順序で指定するために、そのページレイアウトに関する事前の知識が必要です。
keephyphen-glyphs	(論理値) true かつ dehyphenate=true の場合には、ハイフン除去された単語の各部分の間のハイフングリフは、TET_get_char_info() が返すグリフのリスト内と TETML 内の Glyph エレメントで温存されます。これは、ページ上のテキストを正確に置き換えたいなど、ハイフンの位置について詳しい情報を必要とするアプリケーションにおいて有用です。これは fold={[_dehyphenation remove]} とは異なることに留意してください。後者は、TET_get_text() が返す論理テキストからハイフンを除去するだけであり、グリフに対しては効力を持ちません。デフォルト: false

表 10.11 TET_open_page()・TET_process_page() の contentanalysis オプションのサブオプション一覧

オプション	説明
<i>linespacing</i>	(キーワード) 段落内のテキスト行どうしの間典型的な縦間隔を指定します: small・medium・large のいずれかです (デフォルト: medium)
<i>maxwords</i>	(整数かキーワード) ページ上の単語の数が、指定した数以下のときは (キーワード unlimited を指定すると上限なしになります)、ページ上で検出された区域群は適切に連結され並べ替えされます。ページ上の単語の数が、指定した数を超過しているときは、区域は一切作成されず、単語群はページ内容の読み順で抽出されます。後者の場合には処理はより速くなりますが、抽出される単語群の順序は最適ではなくなるおそれがあります。新聞のような、多くの単語を含む大きなページに対しては、このオプションを unlimited に設定することを推奨します。デフォルト: 5000
<i>merge</i>	(整数) ストリップと区域の連結を制御します (デフォルト: 2): <ul style="list-style-type: none"> 0 ストリップ作成後の連結なし。これはかなり処理速度を向上させますが、最適未満の出力を生成するおそれがあるほか、影によっては正しく検出されないおそれがあります。 1 単純な、ストリップを区域へ入れ込む連結: ストリップは、それが区域に重なっており、それでいて、次のストリップ以外のストリップと重なり合っていない場合に (影なしの場合における区域の重なり合いを避けるため)、この区域内へ連結されます。 2 順序破りなテキストのための高度な区域連結: merge=1 に加えて、複数の重なり合う区域は、両区域のテキスト内容が重なり合わないならば、結合されて 1 個の区域になります。
<i>numeric-entities</i>	(キーワード) 数値・分数・時刻のような数値実体に対する単語境界検出を制御します (デフォルト: keep): <ul style="list-style-type: none"> <i>split</i> その実体を、punctuationbreaks サブオプションに従って分割します。 <i>keep</i> その実体を、単語まるごととして温存します。
<i>shadow-detect</i>	(論理値) true の場合には、影付きや偽ボールドテキストを作り出している、重なり合うテキスト断片群の冗長なインスタンスは検出され除去されます。デフォルト: true
<i>punctuation-breaks</i>	(論理値。granularity=word の場合のみ) true の場合には、文字のそばに配置されている約物キャラクタは単語境界として扱われ、そうでない場合にはそれは隣接する単語内へ含まれます。たとえば、このオプションは URL とメールアドレスを取り扱う際に有用でしょう。デフォルト: true
<i>superscript</i>	(整数) 下付き・上付き検出を制御します (デフォルト: 2): <ul style="list-style-type: none"> 0 下付き・上付き検出なし 1 単純な下付き・上付き検出 2 下付き・上付き検出のための高度なアルゴリズム
<i>useclasses</i>	(論理値) true の場合、単語境界を決定するために Unicode 分類が考慮されます。デフォルト: true
<i>usemetrics</i>	(論理値) true の場合、単語境界を決定するために、グリフ間の間隔が、空白グリフの幅と比較されます。デフォルト: true

表 10.12 TET_open_page()・TET_process_page() の layoutanalysis オプションのサブオプション一覧

オプション	説明
<i>layout-astable</i>	(論理値) true の場合には、レイアウト認識はページ上の区域群を 1 個ないし複数の表組として扱います。連なりが表組と見なされるために必要な最小の列数は、文書のスタイルに依存します。false の場合には、スーパー表組認識は無効化されます (デフォルト: true)。

表 10.12 TET_open_page()・TET_process_page()の layoutanalysis オプションのサブオプション一覧

オプション	説明
layout-columnhint	(キーワード) このオプションは、複雑なレイアウトにおける区域読み順検出を向上させる可能性があります。使えるキーワード (デフォルト : multicolumn) : multicolumn ページは多段組テキストを含んでいます。区域は段組から段組へ並べ替えされます。 none ヒントは何も得られません。区域順序はページ内容順序によって決定されます。 singlecolumn ページは1段組テキストを含んでいます。区域は行から行へ並べ替えされます。このキーワードは layouteffort=low とともに用いるべきです。
layoutdetect	(整数) 再帰的レイアウト認識の深度を指定します (デフォルト : 1) : 0 レイアウト認識なし。 1 ページ全体に対するレイアウト認識。ほとんどの文書がこれで充分です。 2 レベル1の結果に対するレイアウト認識。これは、さまざまな多段組副レイアウトを持つレイアウトや、ページ上のさまざまな箇所タイトルがあるレイアウトや、複数段落表組に対して必要です。 3 レベル2の結果に対するレイアウト認識。これは非常に複雑なレイアウトに対してのみ必要です。
layoutrowhint	(オプションリスト) レイアウト行処理を制御します。使えるオプション (デフォルト : none) : full レイアウト行処理を有効にします。 none レイアウト行処理を無効化します。 separation (キーワード) レイアウト行処理を有効にしますが、レイアウト認識がスーパー表組と推測した場合には無効化します。以下のサブオプションが使えます : preservecolumns 区域どうし間の視覚関係に基づいて縦の段組を保つことを試みます。段組内の区域どうしが大きく引き離されている場合 (画像がはさまっているなどして) にはこれを推奨します。 thick 隣り合う区域どうしを連結して、それを同じレイアウト行内に配置しようと試みます。これによって、レイアウト行の数は少なくなり、一つ一つは大きくなります。段組内の段落どうしが互いに文字サイズよりも引き離されている雑誌や新聞のような複雑なレイアウトや、いくつかの多段組記事が縦に並んでいるレイアウトにはこれを推奨します。 thin 隣り合う区域どうしを引き離し、それらを別々のレイアウト行に配置しようと試みます。これによって、レイアウト行の数は多くなり、一つ一つは小さくなります。 例 : layoutanalysis = {layoutrowhint={full separation=thick}}
mergetables	(整数) 表行1個だけの表組は、表組認識中にスキップされ、通常の区域として扱われます。2個の連続する区域が表組である場合には (表行1個だけであっても)、それらは結合することもできます (デフォルト : none) : down 下方へのみ結合します。 none 結合しません。 up 上方へのみ結合します。 updown 双方向に結合します。

表 10.12 TET_open_page()・TET_process_page() の layoutanalysis オプションのサブオプション一覧

オプション	説明
splithint	(キーワードかオプションリスト) 2 ページ見開きスプレッド (ないしはさらなるスプレッドから成るページも) の特別な扱いを有効にします。ページを縦または横に、2 個以上のセクションに分割することができます。キーワード includebox を指定すると、分割領域群は includebox オプションによって定義されます。これに換えて、以下のオプションを与えることもできます： <i>x</i> (float) <i>x</i> 軸に関する除数。例：0.5 なら 2 ページ見開きスプレッド、0.33 なら 3 ページスプレッド。 <i>y</i> (float) <i>y</i> 軸に関する除数。
standalone-fontsize	(float) 巨大グリフに対する最小文字サイズ。巨大グリフは 1 グリフストリップを形成し、かつ、他の区域とは結合されません (デフォルト：70)。
supertable-columns	(整数。layoutastable=true の場合のみ) 区域の連なりをスーパー表組と見なすためのレイアウト行内の最小の段組数。表組が段落群から作成される時、これらの段組は結合されずに、別々の区域として認識されます。この結果として、レイアウト認識はこれらの区域の連なりを表組として特定することができます (デフォルト：4)。
tabledetect	(整数) 再帰的表組認識の深度を指定します (デフォルト：1)： 0 位置に基づく表組認識なし。vectoranalysis オプションのサブオプション structures=usevectoronly が設定されている場合には、セル枠を持つ表組は依然検出されます。 1 各区域に対する表組認識。 2 レベル 1 で検出された各表セルに対する表組認識。これは、ネストされた表組のために、また、複数行にわたるセルの解決のために必要です。 3 向上した表行結合検出を用いた表組認識。

表 10.13 TET_open_page()・TET_process_page() の imageanalysis オプションのサブオプション一覧

オプション	説明
heightrange	(正の整数 2 個のリスト、または正の整数とキーワード) 抽出される画像群の最小と最大の高さをピクセル単位で。画像の高さと、そのマスク (もしあれば) の高さが、指定した区間の外にある場合、その画像は無視されます。最大値をキーワード unlimited を用いて指定することもでき、その場合は上限なしを意味します。デフォルト：sizerange の値
merge	(オプションリスト) 画像連結を制御します。この処理は、合わせて 1 個の大画像を形成できる隣接画像群を結合します。これは、PDF 内に個々のストリップが温存されているマルチストリップ画像に対して、また、多数の微小画像に分解されている背景画像に対して有用です。使えるオプション： disable (論理値) true の場合には、画像連結は無効化されます。デフォルト：false gap (float) 連結対象と見なさせたい 2 個の画像の間隔または重なり。この値は、ポイント単位の絶対間隔として、また、ピクセル数としても解釈されます。デフォルト：1.0

表 10.13 TET_open_page()・TET_process_page() の imageanalysis オプションのサブオプション一覧

オプション	説明
sizerange	(正の整数 2 個のリスト、または正の整数とキーワード) 抽出される画像群の辺の最小と最大の長さをピクセル単位で。画像の少なくとも一辺が、指定した区間の外にある場合、その画像は無視されます。最大値をキーワード unlimited を用いて指定することもでき、その場合は上限なしを意味します。この sizerange オプションは、heightrange と widthrange の両方を同じ値に設定するためのショートカットです。デフォルト : {20 unlimited}
smallimages	非推奨。heightrange/sizerange/widthrange を使用してください
widthrange	(正の整数 2 個のリスト、または正の整数とキーワード) 抽出される画像群の最小と最大の幅をピクセル単位で。画像の幅と、そのマスク (もしあれば) の幅が、指定した区間の外にある場合、その画像は無視されます。最大値をキーワード unlimited を用いて指定することもでき、その場合は上限なしを意味します。デフォルト : sizerange の値

表 10.14 TET_open_page()・TET_process_page() の structureanalysis オプションのサブオプション一覧

オプション	説明
bullets	(オプションリストのリスト。list=true の場合にのみ意味を持ちます) リスト内でビュレットキャラクタとして用いられる Unicode キャラクタとフォント名の組み合わせ。使えるサブオプション:
bulletchars	(Unicode 値のリスト) ビュレットキャラクタのための 1 個ないし複数の Unicode 値。このサブオプションを与えない場合には、指定した fontname を用いているキャラクタすべてがビュレットキャラクタとして扱われます。デフォルト : ビュレットとして広く使われているキャラクタ数十種類を内容としたリスト
fontname	(文字列) ビュレットキャラクタを使うフォントの名前。このサブオプションを与えない場合には、bulletchars サブオプションで指定したキャラクタはつねにビュレットキャラクタとして扱われます。
例 :	
	bullets={{fontname=ZapfDingbats}}
	bullets={{bulletchars={U+2022}}}
	bullets={{fontname=KozGoPro-Medium bulletchars={U+2460 U+2461 U+2462 U+2463 U+2464}}}
list	(論理値) TETML 出力のためのリスト認識を有効にします (デフォルト : false)。false の場合には、リスト構造に関する情報は何も決定されません。
overpagelists	(キーワード) リストの一部である可能性のある物が複数ページにわたっている場合の処理。使えるキーワード (デフォルト : ascending) :
ascending	ページ群がギャップなしに正順に処理されている場合にのみ、複数ページにわたっている情報を保管する。
always	ページ処理の順序にかかわらずつねに、複数ページにわたっている情報を保管する。
never	複数ページにわたっている情報を一切保管しない。すなわち、検出されるリストは同一ページ内に限られ、番号付きリストは必ずしも 1 から始まりません。

表 10.15 TET_open_page()・TET_process_page() の vectoranalysis オプションのサブオプション一覧

オプション	説明
closetablearea	(論理値) true の場合、表組の枠がまったく存在していなくても、解析のために表組の枠を生成。デフォルト : false

表 10.15 TET_open_page()・TET_process_page() の vectoranalysis オプションのサブオプション一覧

オプション	説明
ignorelines	(キーワード) どの直線を解析から除外するかを指定。使えるキーワード (デフォルト : none) : horizontal 水平の直線を無視。 none 直線を無視しない。 vertical 垂直の直線を無視。
pagesizelines	(論理値) true の場合、ページ寸法とほぼ同じ長さの、大きな直線を考慮。デフォルト : false
splitsequence	(論理値) true の場合、垂直の直線 (あるいは回転されたテキストに対しては水平の直線) がテキストの列を分割することを許容。デフォルト : false
structures	(キーワード) 表組検出のためにベクトルグラフィックを解釈するためのアルゴリズムを指定。使えるキーワード (デフォルト : unions) :
tables	拡張された unions モード : このアルゴリズムはさらに、集合体が表組ネットを形成しているかどうかをチェックします。もしそうなら、その結果は 1 個の表組領域として扱われます。
unions	このアルゴリズムは、直線群から部分レイアウト集合体の構築を試みます。そのような集合体が構築された場合には、それは完全な部分レイアウト実体として。すなわち、内包されているテキスト領域群はすべてその部分レイアウトに帰属するものとして扱われます。
usevectoronly	このアルゴリズムは、表組検出の際に、テキストの位置を無視し、ベクトルグラフィックのみを使用します。このアルゴリズムは高速であり、単純な表組に対してはうまくいきますが、表行・表列結合を扱いません。これは、セル枠が完全にある表組、すなわちベクトルグラフィックを使って各表セルを正しく識別できる表組に対して推奨されます。このようは表組については、layoutanalysis オプションのサブオプション tabledetect=0 を用いて検出することも可能です。デフォルト : false
vectoriterative	このアルゴリズムは、ベクトルグラフィックのみを使用し、表行・表列結合を識別するために反復的に動作します。これは、より長い時間を要し、複数の表行または表列にわたる表セルを含む複雑な表レイアウトに対して推奨されます。

C++ Java C# **void close_page(int page)**

Perl PHP **close_page(long page)**

C **void TET_close_page(TET *tet, int page)**

ページハンドルと、関連するすべてのリソースを解放します。

page TET_open_page() で得られた有効なページハンドル。

詳細 TET_close_document() を呼び出すと、その文書の開いているページはすべて自動的に閉じられます。とはいえ、ページが必要なくなった時点で明示的に閉じるのが良いプログラミング習慣です。閉じられたページハンドルは、その後はいかなる関数呼び出しにおいても使用してはいけません。

10.5 テキスト・グリフ詳細抽出関数

C++ Java C# `String get_text(int page)`

Perl PHP `string get_text(long page)`

C `const char *TET_get_text(TET *tet, int page, int *len)`

ページの内容から、次のテキスト断片を得ます。

`page` `TET_open_page()` で得られた有効なページハンドル。

`len` (C 言語バインディングのみ) 返される文字列の長さを、`TET_set_option()` の `outputformat` オプションに応じて保持する変数へのポインタ :

`outputformat=utf8` の場合、長さは Unicode キャラクタの数として報告されます。ヌル終端文字列のバイト数 (これは 8 ビットコードユニットの数に等しいです) は `strlen()` 関数で求められます。

`outputformat=utf16` の場合、長さは 16 ビットコードユニットの数として報告されます。サロゲートペアは 2 個のコードユニットとしてカウントされます。文字列のバイト数は `2*len` です。

`outputformat=utf32` の場合、長さは 32 ビットコードユニットの数として報告されます (これは Unicode キャラクタの数に等しいです)。文字列のバイト数は `4*len` です。

戻り値 ページ上の、次のテキスト断片を内容として持つ文字列。この断片の長さは、`TET_open_page()` の `granularity` オプションによって決定されます。`granularity=glyph` の場合であっても、この文字列は複数のキャラクタを内容として持つ場合があります (103 ページの 7.1 「Unicode のさまざまな重要概念」を参照)。

ページ上のテキストがすべて取得されていた場合には、空文字列かヌルオブジェクトが返されます (後述)。この場合には、テキストがもうない理由はページ上のエラーによるものなのか、それともページの末尾に到達したからなのかを知るために、`TET_get_errnum()` を呼び出すべきです。

詳細 ページオプション `ignoreartifacts` が指定されている場合には、ページ装飾として標識されているテキストは無視されます。ページオプション `ignoreinvisibletext` が指定されている場合には、テキスト表現モード 3 (不可視) を用いているテキストは無視されます。

バインディング C 言語バインディング : 結果は、`TET_set_option()` の `outputformat` オプションに従って、ヌル終端 UTF-8 (デフォルト) か UTF-16/UTF-32 のいずれかの文字列で提供されます。i5/iSeries と zSeries では、EBCDIC 符号化された UTF-8 を選択することもでき、かつこれがデフォルトで有効になっています。テキストがそれ以上得られないときは、NULL ポインタと `*len=0` が返されます。

C++・COM : 結果は、UTF-16 形式 (C++ では `wstring`) の Unicode 文字列として提供されます。テキストがそれ以上得られないときは、空文字列が返されます。

Java・.NET・Objective-C : 結果は、Unicode 文字列として提供されます。テキストがそれ以上得られないときは、ヌル (Objective-C では `nil`) オブジェクトが返されます。

Perl・PHP : 結果は、`TET_set_option()` の `outputformat` オプションに従って、UTF-8 (デフォルト) か UTF-16/UTF-32 の文字列として提供されます。テキストがそれ以上得られないときは、空文字列が返されます。

Python : 結果は、`TET_set_option()` の `outputformat` オプションに従って、UTF-8 (デフォルト) か UTF-16/UTF-32 の文字列として提供されます。Python 3 では、UTF-16/UTF-32 の結果はバイト列として返されます。テキストがそれ以上得られないときは、`None` が返されます。

Ruby : 結果は、`TET_set_option()` の `outputformat` オプションに従って、UTF-8 (デフォルト) か UTF-16/UTF-32 の文字列として提供されます。テキストがそれ以上得られないときは、`nil` オブジェクトが返されます。

RPG 言語バインディング : 結果は Unicode 文字列として提供されます。テキストがそれ以上得られないときは、`NULL` が返されます。

C++ `const TET_char_info *get_char_info(int page)`

C# Java `int get_char_info(int page)`

Perl PHP `object get_char_info(long page)`

C `const TET_char_info *TET_get_char_info(TET *tet, int page)`

最近のテキスト断片内の、次のグリフに対する詳しい情報を得ます。

`page` `TET_open_page()` で得られた有効なページハンドル。

注記 この関数の名前は付け間違いです。ページ上の視覚的なグリフについての情報を報告する関数であって、それに対応する Unicode キャラクタについて報告するのではないのですから、`TET_get_glyph_info()` という名前にしておくべきでした。

戻り値 `TET_get_text()` が返した最近のテキスト断片について、グリフがそれ以上得られないときは、バインディング依存の値が返されます。詳しくは後述の**バインディング**の項を参照してください。

詳細 この関数は、`TET_get_text()` の後に 1 回ないし複数回呼び出すことができます。これは、与えられたページハンドルに関連付けられているカレントテキスト断片において、次のグリフへ進み (グリフがもうないときは何も返しません)、そしてそのグリフについての詳しい情報を提供します。グリフを N 個持ち、論理キャラクタを M 個持つテキスト断片に対しては、この関数への呼び出しが複数回成功します。 N と M の関係は粒度に依存します :

- ▶ **granularity=glyph** の場合、各テキスト断片はそれぞれただ 1 個のグリフに対応します。すなわち $N=1$ です。1 個のグリフは多くの場合、1 個のキャラクタに対応します。すなわち $M=1$ です。ただし、合字グリフの場合には、1 個のグリフが複数のキャラクタを生成しますので、 $M>1$ であり、`TET_get_char_info()` を複数回呼び出す必要があります。
- ▶ **glyph** 以外の粒度の場合には、グリフ列はキャラクタ列を生成し、ここで各グリフがそれぞれ生み出すキャラクタは $0 \cdot 1 \text{ 個} \cdot \text{複数}$ のいずれでもありえます。このグリフ列は、Unicode キャラクタ列の原料となるわけです。言い換えれば、 N と M の間の関係は事前に確定しません。 N と M の間の関係は、内容分析 (ハイフン除去処理でハイフンが除去されるなど) や Unicode 後処理 (字形統合によってキャラクタが追加されたり削除されたりするなど) によって影響を受ける可能性があります。

glyph 以外の粒度の場合には、この関数は、`TET_get_text()` への最近の呼び出しが返したテキスト断片を構成する次のグリフへ進みます。これによって、単語検出機能が有効など

きにグリフの詳細を取得することができ、また、1 個のテキスト断片には複数のキャラクタが含まれる場合があります。カレントテキスト断片についてすべてのグリフの詳細を取得するには、この関数を、情報をもう返さなくなるまで繰り返し呼び出す必要があります。

構造またはプロパティ/フィールド内のグリフ詳細は、同じページハンドルで次に `TET_get_char_info()` か `TET_close_page()` を呼び出すまで有効です。グリフ情報プロパティ/フィールドのセットは、TET オブジェクトごとにただ 1 個しかありませんので、同じページについてであれ、別のページについてであれ、別の文書についてであれ、再び `TET_get_char_info()` を呼び出す前にクライアント側ですべてのグリフ情報を取得しておく必要があります。

バインディング C・C++ 言語バインディング：`TET_get_text()` が返した最近のテキスト断片について、グリフがそれ以上得られないときは、NULL ポインタが返されます。そうでないときは、1 個のグリフに関する情報を内容として持つ `TET_char_info` 構造へのポインタが返されます。このデータ構造のメンバについては表 10.16 で説明します。

COM・Java・.NET・Objective-C 言語バインディング：`TET_get_text()` が返した最近のテキスト断片について、グリフがそれ以上得られないときは、-1 が返されます。そうでないときは 1 が返されます。個々のグリフ情報は、表 10.16 に従った TET プロパティ/パブリックフィールドから取得することができます。関数が -1 を返したにもかかわらずプロパティ/フィールドの値を見た場合には、いずれも値 -1 をとります (`unknown` フィールドは `false` になります)。

Perl・Python 言語バインディング：`TET_get_text()` が返した最近のテキスト断片について、グリフがそれ以上得られないときは、0 が返されます。そうでないときは、表 10.16 に挙げるキー群を含むハッシュが返されます。個々のグリフ情報は、このハッシュ内のキーによって取得することができます。

PHP 言語バインディング：`TET_get_text()` が返した最近のテキスト断片について、グリフがそれ以上得られないときは、空 (ヌル) オブジェクトが返されます。そうでないときは、表 10.16 に挙げるフィールド群を内容として持つオブジェクトが返されます。個々のグリフ情報は、このオブジェクトのメンバフィールドから取得することができます。グリフ情報オブジェクト内の整数フィールドは、PHP 言語バインディングでは `long` として実装されています。

Ruby バインディング：グリフがそれ以上得られないときは、nil (ヌルオブジェクト) が返されます。そうでないときは、`TET_char_info` オブジェクトが返されます。

表 10.16 `TET_char_info` 構造のメンバ (C・C++・Ruby) と、同等の public フィールド (Java・PHP・Objective-C)・キー (Perl)・プロパティ (COM・.NET)、およびその型と意味の一覧。詳しくは 78 ページの 6.2 「ページとテキストの視覚情報」と 84 ページの 6.3 「テキストカラー」を参照。

プロパティ/ フィールド名 説明

uv (整数) カレントグリフの Unicode 値を UTF-32 形式で (outputformat オプションにかかわらず)。glyph 以外の粒度の場合、これは、最終テキスト断片とはまったく無関係な擬似値か、あるいは挿入された区切りキャラクタとなることがあります。granularity=glyph の場合、グリフに対する Unicode 値列は論理テキストに等しいですが、それ以外の粒度の場合には、それはさまざまな処理ステップによって変更されている可能性があります。

表 10.16 TET_char_info 構造のメンバ (C・C++・Ruby) と、同等の public フィールド (Java・PHP・Objective-C)・キー (Perl)・プロパティ (COM・.NET)、およびその型と意味の一覧。詳しくは 78 ページの 6.2 「ページとテキストの視覚情報」と 84 ページの 6.3 「テキストカラー」を参照。

プロパティ / フィールド名	説明
type	(整数) キャラクタの種別。以下の種別は、ページ上の実グリフを記述します。これ以外のすべてのプロパティ / フィールドの値は、対応するグラフによって決定されます： 0 (TET_CT_NORMAL) ちょうど 1 個のグリフに対応する通常のキャラクタ 1 (TET_CT_SEQ_START) キャラクタ列 (合字など) の先頭 以下の種別は、ページ上のどのグリフにも照応しない擬似キャラクタを記述します。x・y フィールドは、最近の実グリフの終了点を表し、width フィールドは 0 になり、これ以外の uv を除くすべてのフィールドは、いちばん最近の実グリフに対応する値をとります： 10 (TET_CT_SEQ_CONT) 合字などキャラクタ列のつづき 12 (TET_CT_INSERTED) 挿入された単語・行・段落区切りキャラクタ
attributes	(整数) グリフの属性をビットで表したものの組み合わせることもできます： (なし) (TET_ATTR_NONE) どのビットもセットされていない場合には、特殊グリフ属性は一切検出されていません。 ビット 0 (TET_ATTR_SUB) 視覚的または意味的な下付き ビット 1 (TET_ATTR_SUP) 視覚的または意味的な上付き ビット 2 (TET_ATTR_DROPCAP) ドロップキャップキャラクタ (段落先頭の大きいキャラクタ) ビット 3 (TET_ATTR_SHADOW) このグリフの、グリフまたは単語ベースの影重複は除去済 ビット 4 (TET_ATTR_DEHYPHENATION_PRE) グリフは、ハイフン区切り箇所直前のキャラクタを表す ビット 5 (TET_ATTR_DEHYPHENATION_ARTIFACT) contentanalysis={keeplyphenglyphs=true} が指定された場合以外において、除去されたハイフンキャラクタ。 ビット 6 (TET_ATTR_DEHYPHENATION_POST) グリフは、ハイフン区切り箇所直後のキャラクタを表す ビット 8 (TET_ATTR_ARTIFACT) グリフはページ装飾 (本文外の内容) を表す
unknown	(論理値。C・C++・Perl では整数) 通常は false (0) ですが、元のグリフが Unicode ヘマップできずに、unknownchar として指定されたキャラクタへ置き換えられた場合には true (1)。
x,y	(double) グリフの参照点の位置。この参照点は、横書きではグリフ枠の左下隅であり、縦書きでは上端中央の点です。擬似キャラクタについてはこの x・y 座標は、最近のキャラクタの終了点の座標になります。
width	(double) 対応するグリフの幅 (横書きでも縦書きでも)。擬似キャラクタ (すなわち type=12 の挿入された区切りキャラクタ、および属性ビット 5 がセットされたハイフン区切りキャラクタ) についてはこの幅は 0 になります。
height	(double) 縦書きの場合：照応するグリフの、そのフォントメトリック群とテキスト出力パラメータ群 (字間など) に従った高さ。この高さは、デフォルト座標系では正の値ですが、topdown 座標系の場合には負の値になります。等幅縦書きフォントにおいては、字間が適用されている場合を除き、すべてのグリフが fontsize を高さとして持ちます。擬似キャラクタ (区切りキャラクタなど) は高さ 0 を持ちます。 横書きの場合、そのグリフ高さの近似値が与えられます。この近似値は、フォント特性群から導出されますので、あるフォント内のすべてのグリフについて等しくなります。目に見えるグリフがここで与えられた値とちょうど同じ高さを持つ保証はありません。
alpha	(double) テキスト進行の向きを度単位で反時計回り (あるいは下向き座標の場合には時計回り) に測ったもの。横書きの場合にはこれはテキストのベースラインの向きであり、縦書きの場合にはこれは標準縦向きに対する角度です。この角度は範囲 $-180^\circ < \alpha \leq +180^\circ$ 内になります。標準的な横書きテキストでも、縦書きの標準的テキストでも、この角度は 0° になります。

表 10.16 TET_char_info 構造のメンバ (C・C++・Ruby) と、同等の public フィールド (Java・PHP・Objective-C)・キー (Perl)・プロパティ (COM・.NET)、およびその型と意味の一覧。詳しくは 78 ページの 6.2 「ページとテキストの視覚情報」と 84 ページの 6.3 「テキストカラー」を参照。

プロパティ / フィールド名 説明

beta (double) テキスト斜形化角度を度単位で反時計回り (あるいは下向き座標の場合には時計回り) に、alpha の垂線に対して測ったもの。この角度は、正立テキストについては 0° になり、斜体になった (斜形化された) テキストについては負 (あるいは下向き座標の場合には正) の値になります。この角度は範囲 $-180^\circ < \text{beta} \leq +180^\circ$ になりますが、ただし $\pm 90^\circ$ 以外の値をとりません。 $\text{abs}(\text{beta}) > 90^\circ$ なら、そのテキストはベースラインで反転されています。

fontid (整数) fonts[] 擬似オブジェクト内におけるフォントの番号 (pCOS パスリファレンス参照)。fontid が負になることはありません。

fontsize (double) 文字のサイズ (つねに正)。この値と、グリフの実際の高さとの比は固定ではなく、フォントデザインによって変動する可能性があります。多くのフォントでは、文字サイズは、すべてのアセンダ (アクセント付きキャラクタも含め) とディセンダを包含するよう選ばれています。

textrendering (整数) テキスト表現モード (ビット位置ではなく整数) :



0 (TET_TR_FILL) テキストを塗る



1 (TET_TR_STROKE) テキスト (輪郭) を描線 (アウトライン)



2 (TET_TR_FILLSTROKE) テキストを塗って描線

3 (TET_TR_INVISIBLE) 不可視テキスト (OCR テキスト用)



4 (TET_TR_FILL_CLIP) テキストを塗って、クリッピングパスに追加



5 (TET_TR_STROKE_CLIP) テキストを描線し、クリッピングパスに追加



6 (TET_TR_FILLSTROKE_CLIP) テキストを塗って描線し、クリッピングパスに追加



7 (TET_TR_CLIP) テキストをクリッピングパスに追加

Type 3 フォントのテキスト : textrendering=3・7 は不可視テキストになります。それ以外の値の textrendering は無意味であり無視されます。

colorid (整数) 塗り色・描線色・テキスト表現の組み合わせをあらわすテキストカラーの添字。ある文書内における同じ組み合わせの出現はすべて同一のカラー ID で表されます。異なる組み合わせは異なる ID で表されますので、複数のグリフの色が互いに同じかどうかを、そのカラー ID を比較することによってチェックすることが可能です。たとえば、連続するグリフの colorid 値を比較することによって、テキストカラーの切り替わりを識別することもできます。テキストを塗っている、および/または描線している正確な色空間と色要素群については、TET_get_color_info() を用いて取得できます。Separation・DeviceN カラーに対しては、文書オブション glyphcolor を用いて、Separation または DeviceN 色空間の代替色を要求することもできます。

C++ `const TET_color_info *get_color_info(int doc, int colorid, wstring optlist)`

C# `int get_color_info(int doc, int colorid, String optlist)`

Perl PHP `object get_color_info(long doc, long colorid, string optlist)`

C `const TET_color_info *TET_get_color_info(TET *tet, int doc, int colorid, const char *optlist)`

`TET_get_char_info` を用いて取得したカラー ID のカラー詳細を取得します。

`doc` `TET_open_document*()` を用いて取得した有効な文書ハンドル。

`colorid` `TET_get_char_info()` の `colorid` メンバから取得した有効なカラー ID。

`optlist` 取得したい色の種類を表 10.17 に従って指定したオプションリスト。

表 10.17 TET_get_color_info() のオプション一覧

オプション	説明
<code>usage</code>	(キーワード) 色の用途 (デフォルト: fill)
<code>fill</code>	塗りに使用されている色
<code>stroke</code>	描線に使用されている色

戻り値 C/C++: 求められた色空間と色に関する詳細を持った構造へのポインタ。
Perl・Python・PHP・Ruby: 求められたカラー情報を内容とするハッシュまたはオブジェクト。
COM・Java・.NET・Objective-C: 固定値 1。

詳細 この関数は、`colorid` によって指定された色に関する詳細を返します。`usage` オプションによって、`colorid` に紐づいた塗り色か描線色が報告されます。

バインディング C・C++ 言語バインディング: 求められた色に関する情報を内容とする `TET_color_info` 構造へのポインタが返されます。このデータ構造のメンバの詳細を表 10.18 に挙げます。

COM・Java・.NET・Objective-C 言語バインディング: 表 10.18 に従った TET プロパティ / public フィールドから色情報を取得できます。

Perl・Python・PHP・Ruby 言語バインディング: 表 10.18 に挙げるキー / フィールド / メンバを内容とするハッシュまたはオブジェクトから色情報を取得できます。

表 10.18 TET_color_info 構造のメンバ (C・C++・Ruby) と、同等の public フィールド (Java・PHP・Objective-C)・キー (Perl)・プロパティ (COM・.NET)、およびその型と意味の一覧。詳しくは 84 ページの 6.3 「テキストカラー」を参照。

プロパティ / フィールド名	説明
<code>colorspaceid</code>	(整数) <code>colorspaces[]</code> 擬似オブジェクト内の色空間の添字 (pCOS パスリファレンス参照)、あるいは不可視テキスト (<code>textrendering=3</code>) などそのグリフに色が何も適用されていない場合は -1。
<code>patternid</code>	(整数) <code>patterns[]</code> 擬似オブジェクト内のパターンの添字 (pCOS パスリファレンス参照)、あるいはそのグリフにパターンが何も適用されていない場合は -1。
<code>components¹</code>	(double 値の配列) 色要素値群。 <code>colorspaceid</code> を用いてレポートされた色空間の中で解釈する必要があります。 C・C++ 言語バインディング: 必要な配列項目の数を <code>n</code> メンバで得られます。

表 10.18 TET_color_info 構造のメンバ (C・C++・Ruby) と、同等の public フィールド (Java・PHP・Objective-C)・キー (Perl)・プロパティ (COM・.NET)、およびその型と意味の一覧。詳しくは 84 ページの 6.3 「テキストカラー」を参照。

**プロパティ /
フィールド名 説明**

n^1 (整数。C・C++ 言語バインディングのみ) components メンバ内の配列項目の数

1. このメンバには、colorspaceid メンバが -1 でない場合にのみアクセスする必要があります。

10.6 画像抽出関数

C++ `const TET_image_info *get_image_info(int page)`

C# `int get_image_info(int page)`

Perl PHP `object image_info get_image_info(long page)`

C `const TET_image_info *TET_get_image_info(TET *tet, int page)`

ページ上の、次の画像に関する情報を取得します（ただしピクセルデータ本体は取得しません）。

`page` `TET_open_page()` で得られた有効なページハンドル。

戻り値 画像がそれ以上得られないときは、バインディング依存の値が返されます。そうでないときは、画像の詳細がバインディング依存の形で利用できます。詳しくは、後述の**バインディング**の項を参照してください。

詳細 この関数は、与えられたページハンドルに関連付けられている次の画像へ進み、その画像についての詳しい情報を提供します。ページ上に画像がもうないときは関数は `0`・`-1`・`NULL` のいずれかを返します。以下の種類の画像は無視されます：

- ▶ マスクとして使用されている画像は無視されます。pCOS とその *maskid* 擬似オブジェクトを通じてそれらを取得できます（139 ページの 8.5.2 「画像マスクとソフトマスク」を参照）。
- ▶ 連結処理によって消費されて連結されることにより 1 個の大きな画像を形成した画像（すなわち *mergetype=consumed*）は無視されます。
- ▶ 小画像フィルタによって除去された画像（137 ページの 8.4 「小画像・大画像フィルタリング」を参照）は無視されます。
- ▶ *clippingarea*・*excludebox*・*includebox* オプションによって指定された抽出領域の完全に外に位置している画像は無視されます。
- ▶ *ignoreartifacts* ページオプションが与えられている場合には、ページ装飾として標識されている画像はスキップされます。

構造またはプロパティ/フィールド内の画像詳細は、同じページハンドルで次に `TET_get_image_info()`・`TET_get_text_info()`・`TET_close_page()` のいずれかを呼び出すまで有効です。画像情報プロパティ/フィールドのセットは、TET オブジェクトごとにただ 1 個しかありませんので、同じページについてであれ、別のページについてであれ、再び `TET_get_image_info()` を呼び出す前にクライアント側ですべての画像情報を取得しておく必要があります。

バインディング C・C++ 言語バインディング：ページ上で画像がそれ以上得られないときは `NULL` ポインタが返され、そうでないときは、画像に関する情報を内容として持つ `TET_image_info` 構造へのポインタが返されます。このデータ構造のメンバについては表 10.19 で説明します。

COM・Java・.NET・Objective-C 言語バインディング：ページ上で画像がそれ以上得られないときは、`-1` が返されます。そうでないときは `1` が返されます。個々の画像情報は、表 10.19 に従った TET プロパティ/フィールドから取得することができます。関数が `-1` を返したにもかかわらずプロパティ/フィールドの値を見た場合には、いずれも値 `-1` をとります。

Perl・Python 言語バインディング：ページ上で画像がそれ以上得られないときは、0 が返されます。そうでないときは、表 10.19 に挙げるキー群を含むハッシュが返されます。個々の画像情報は、このハッシュ内のキーによって取得することができます。

PHP 言語バインディング：ページ上で画像がそれ以上得られないときは、空 (ヌル) オブジェクトが返されます。そうでないときは、型 `TET_image_info` のオブジェクトが返されます。個々の画像情報は、表 10.19 に従ってそのフィールドから取得することができます。画像情報オブジェクト内の整数フィールドは、PHP 言語バインディングでは `long` として実装されています。

Ruby バインディング：画像がそれ以上得られないときは、nil (ヌルオブジェクト) が返されます。そうでないときは、`TET_image_info` オブジェクトが返されます。

表 10.19 `TET_image_info` 構造のメンバ (C・C++・Ruby) と、同等のパブリックフィールド (Java・PHP・Objective-C)・キー (Perl)・プロパティ (COM・.NET)、およびその型と意味の一覧。詳しくは 127 ページの 8.1 「画像抽出の基本」を参照。

プロパティ / フィールド名	説明
<code>x, y</code>	(double) 画像の参照点の位置。参照点は画像の左下隅です。
<code>width, height</code>	(double) ページ上の画像の幅と高さをポイント単位で、画像の辺に沿って測ったもの。
<code>alpha</code>	(double) ピクセル行の向き。この角度は範囲 $-180^\circ < \alpha \leq +180^\circ$ 内になります。正立画像については <code>alpha</code> は 0° になります。
<code>beta</code>	(double) ピクセル列の向きを、 <code>alpha</code> の垂線に対して測ったもの。この角度は範囲 $-180^\circ < \beta \leq +180^\circ$ になりますが、ただし $\pm 90^\circ$ 以外の値をとりません。正立画像については <code>beta</code> は $-90^\circ < \beta < +90^\circ$ になります。 $\text{abs}(\beta) > 90^\circ$ なら、その画像はベースラインで反転されています。
<code>imageid</code>	(整数) pCOS 擬似オブジェクト <code>images[]</code> 内における画像の番号。この擬似オブジェクト内のエントリ群を通じて、詳細な画像とマスクのプロパティを取得することができます (pCOS パスリファレンス参照)。
<code>attributes</code>	(整数) 画像の属性群をビットとして表現したもの。これらのビットを組み合わせることも可能です。以下のビットが定義されています (最下位ビットがビット 0)： <code>bit 8</code> (TET_ATTR_ARTIFACT) 画像はページ装飾 (ページ外的内容) を表現しています。ページ装飾画像群が結合されてきた合成画像もページ装飾として標識されます。 <code>bit 9</code> (TET_ATTR_ANNOTATION) 注釈 (体裁ストリーム) から抽出された画像。 <code>bit 10</code> (TET_ATTR_PATTERN) パターンから抽出された画像。 <code>bit 11</code> (TET_ATTR_SOFTMASK) グラフィック状態内のソフトマスク (透過グループ XObject 内で定義された) から抽出された画像。

C++ Java C# `int write_image_file(int doc, int imageid, String optlist)`

Perl PHP `long write_image_file(long doc, long imageid, string optlist)`

C `int TET_write_image_file(TET *tet, int doc, int imageid, const char *optlist)`

画像データをディスクへ書き出します。

`doc` `TET_open_document*()` で得られた有効な文書ハンドル。

imageid 画像の pCOD ID。この ID は、`TET_get_image_info()` を呼び出して成功した後に `imageid` フィールドから、あるいは、`images` 擬似オブジェクト内のすべてのエントリをなめる（この配列内には `length:images` エントリがあります）ことによって取得することができます。

optlist 表 10.20 に従って画像関連オプション群を指定したオプションリスト。右記のオプションが使えます：

dpi · **filename** · **keepiccprofile** · **keepxmp** · **typeonly** · **validatejpeg**。

他の関数の下記のオプションも、生成される画像出力に影響を与えます：

- ▶ `TET_open_document*()` : `allowjpeg2000` · `spotcolor` (表 10.8 参照)
- ▶ `TET_open_page/TET_process_page()` : `imageanalysis` (表 10.10 · 表 10.13 参照)

戻り値 エラー時には -1、そうでないなら 0 より大きな値。-1 が返された場合には、`TET_get_errmsg()` を呼び出してエラーの詳細を知ることが推奨します。エラーの場合には何の画像出力も生成されません。戻り値が -1 以外の場合には、その戻り値が示すファイル形式でその画像を抽出できることを示します：

- ▶ 10 (TET_IF_TIFF) : TIFF (`.tif`) として抽出された画像
- ▶ 20 (TET_IF_JPEG) : JPEG (`.jpg`) として抽出された画像
- ▶ 31 (TET_IF_JP2) : プレーン JPEG 2000 (`.jp2`) として抽出された画像
- ▶ 32 (TET_IF_JPF) : 拡張 JPEG 2000 (`.jpf`) として抽出された画像
- ▶ 33 (TET_IF_J2K) : 生 JPEG 2000 コードストリーム (`.j2k`) として抽出された画像
- ▶ 50 (TET_IF_JBIG2) : JBIG2 (`.jbig2`) として抽出された画像

形式 `TET_IF_JP2` · `TET_IF_JPF` · `TET_IF_J2K` は、`allowjpeg2000=true` の場合にのみ生成されます。そうでない場合にはが生成されません。

詳細 この関数は、指定した pCOD ID を持つ画像に対するピクセルデータを、いくつかの画像形式の 1 つへ変換し、その結果をディスクファイルへ書き出します。`typeonly` オプションを与えた場合は、画像の種別だけが返され、画像ファイルは生成されません。

バインディング C · C++ : 戻り値のためのマクロが `tetlib.h` 内で得られます。

表 10.20 `TET_write_image_file()` · `TET_get_image_data()` のオプション一覧

オプション	説明
compression	(キーワード。非推奨)
dpi	(非負 float 値 1 個か 2 個のリスト) 水平・垂直方向の画像解像度をインチあたりピクセル数で表した 1 個か 2 個の値。値を 1 個だけ与えた場合には両方の方向に対して用いられます。与えた値は、生成される TIFF 画像の中に記録されます。これらは、画像内のピクセル数を変更しません (すなわちダウンサンプリングなし)。画像解像度の決定について詳しくは 134 ページの「画像解像度」を参照してください。1 個か 2 個の値がゼロの場合には解像度エントリは一切書き込まれません。デフォルト : 72
filename ¹	(文字列。typeonly を与えていないかぎり必須) ディスク上の画像ファイルの名前。この filename に、画像ファイル形式を示す接尾辞が追加されます。 TET コマンドラインツールでオプション <code>--imageloop resource</code> を用いたときに用いられるファイル命名規則は、TETML 内のものと一致しています (19 ページの「画像ファイル名」を参照)。抽出された画像を TETML とともに使用する場合には、これと同じファイル名パターンを使用することを推奨します。

表 10.20 TET_write_image_file()・TET_get_image_data()のオプション一覧

オプション	説明
<i>keepicprofile</i>	(論理値) true の場合、かつ ICC プロファイルが画像に割り当てられている場合には、抽出された TIFF・JPEG 画像の中へその ICC プロファイルが埋め込まれます。このオプションを false に設定すると、画像を小さくできる可能性があります、カラーマネジメントが犠牲になります。デフォルト : true
<i>keepxmp</i>	(論理値) true の場合、かつ、その画像が PDF 内で関連付けられた XMP メタデータを持っている場合には、抽出される TIFF・JPEG 画像内にそのメタデータが埋め込まれます。デフォルト : true
<i>preferredtiff-compression</i>	(キーワード。非推奨)
<i>typeonly</i> ¹	(論理値) 与えたオプションに従って画像種別が決定されますが、画像ファイルは書き出されません。TET_get_image_data() 自体は画像種別を返さないの、これは、それが返した画像の種別を決定するために有用です。デフォルト : false
<i>validatejpeg</i>	(論理値) true の場合、抽出された JPEG 画像を検証することによって、つねに正しい画像出力を行います。false にすると、処理は若干速いですが、無効な JPEG データが変更されることなく生成画像ファイルへ複製されます。デフォルト : true

1. TET_write_image_file() のみ

C++ **const char *get_image_data(int doc, size_t *length, int imageid, wstring optlist)**

C# Java **final byte[] get_image_data(int doc, int imageid, String optlist)**

Perl PHP **string get_image_data(long doc, long imageid, string optlist)**

C **const char *TET_get_image_data(TET *tet, int doc, size_t *length, int imageid, const char *optlist)**

画像データをメモリへ書き込みます。

doc TET_open_document*() で得られた有効な文書ハンドル。

length (C・C++ 言語ポインティングのみ) 返されるデータの長さがバイト単位で格納されるメモリ位置への C スタイルポインタ。

imageid 画像の pCOS ID。この ID は、TET_get_image_info() を呼び出して成功した後に **imageid** フィールドから、あるいは、**images** pCOS 配列内のすべてのエントリをなめる (この配列内には **length:images** エントリがあります) ことによって取得することができます。

optlist 表 10.20 に従って画像関連オプション群を指定したオプションリスト。右記のオプションが使えます : **keepxmp**。

戻り値 指定したオプション群に従って画像を表現したデータ。エラーの場合には、C・C++ では NULL ポインタが返され、それ以外の言語ポインティングでは空データが返されます。エラーが発生した場合には、TET_get_errmsg() を呼び出してエラーの詳細を知ることを推奨します。

詳細 この関数は、指定した pCOS ID を持つ画像に対するピクセルデータを、いくつかの画像形式の 1 つへ変換し、そのデータをメモリ内で利用可能にします。

バインディング COM : 多くのクライアントプログラムでは、Variant 型を用いて画像データを保持します。

C・C++ 言語バインディング：返されたデータバッファは、次にこの関数を呼び出すまで使えます。

10.7 TET マークアップ言語 (TETML) 関数

C++ Java C# `int process_page(int doc, int pagenumber, String optlist)`

Perl PHP `long process_page(long doc, long pagenumber, string optlist)`

C `int TET_process_page(TET *tet, int doc, int pagenumber, const char *optlist)`

ページを処理して TETML 出力を生成します。

doc `TET_open_document*()` で得られた有効な文書ハンドル。

pagenumber 処理したいページの物理的番号。最初のページをページ番号 1 とします。総ページ数は、`TET_pcos_get_number()` と pCOS バス `length:pages` で取得できます。`trailer=true` の場合、この `pagenumber` 引数は 0 にすることもできます。

optlist 以下のグループ内のオプション群を指定したオプションリスト：

- ▶ 表 10.10 に従った一般的なページ関連オプション(これらは `pagenumber=0` の場合には無視されます)：`clippingarea`・`contentanalysis`・`excludebox`・`fontsize`・`granularity`・`ignoreinvisibletext`・`imageanalysis`・`includebox`・`layoutanalysis`
- ▶ 表 10.21 に従った TETML 詳細を指定するオプション：`tetml`

表 10.21 TET_process_page() の追加オプション

オプション	説明
tetml	(オプションリスト) TETML の詳細を制御します。以下のオプションが使えます：
elements	(オプションリスト) オptional な TETML エレメントを指定します：
line	(論理値。granularity=word の場合のみ) true の場合、TETML 出力は、Paragraph と Word レベルの間に Line エレメントを含みます。デフォルト： false
glyphdetails	(オプションリスト。granularity=glyph・word の場合のみ) 各 Glyph エレメントに対して、どの属性が報告されるかを指定します (すべてのサブオプションのデフォルト： false)：
all	(論理値) すべての属性サブオプションを有効にします
dehyphenation	(論理値) 属性 dehyphenation を出力することによって、ハイフン区切りされた単語を示します。
dropcap	(論理値) 属性 dropcap を出力することによって、単語の先頭の大きなキャラクターを示します。
font	(論理値) 属性 font・fontsize・textrendering・unknown を出力します。
geometry	(論理値) 属性 x・y・width・alpha・beta を出力します。
sub	(論理値) 属性 sub を出力することによって、下付きを示します。
sup	(論理値) 属性 sup を出力することによって、上付きを示します。
shadow	(論理値) 属性 shadow を出力することによって、影付きまたは擬似太字テキストを示します。
textcolor	(論理値) グリフカラーに対する属性 fill・stroke (textrendering に従って) と、照応する Color エレメントを出力します。
trailer	(論理値) true の場合には、文書トレーラデータが、すなわち最終ページの後のデータが出力されます (これ以前に出力されたページ固有データにこれを連結する必要があります)。このオプションは、トレーラデータを出力するために、この関数を最後に呼び出す際に必要です。pagenumber=0 の場合には、トレーラデータのみが (ページ固有データなしで) 出力されます。trailer=true を与えた後は、その同じ文書に対してはもう TET_process_page() を呼び出してはいけません。デフォルト： false

戻り値 この関数はつねに 1 を返します。PDF の問題は TETML の *Exception* エレメントの中でレポートされます。オプションリストの解析に関連する問題に対しては例外が発生します。

詳細 この関数はページを開き、*TET_open_document*()* に与えた形式関連オプション群に従って TETML 出力を生成して、ページを閉じます。生成されたデータは、*TET_get_tetml()* で取得することができます。

この関数は、対応する *TET_open_document*()* への呼び出しでオプション *tetml* を与えた場合にのみ呼び出す必要があります。ヘッダデータは、すなわち、先頭ページの前の文書固有データは、*TET_open_document*()* によって、先頭ページデータの前に生成されます。これは、*TET_process_page()* を初めて呼び出す前に *TET_get_tetml()* を呼び出すことによって別個に取得することもできますし、ページ関連データと組み合わせて取得することもできます。

トレーラデータ、すなわち、最終ページの後の文書固有データは、文書に対してこの関数を最後に呼び出す際に *trailer* サブオプションで要求する必要があります。トレーラデータは、最終ページの後に別個の呼び出しを行なって生成することもできますし (*pagenumber=0*)、最終ページと一緒に生成することもできます (*pagenumber* は 0 以外)。ページ群は任意の順序で抽出することができ、また、文書のページ群の任意の部分集合を抽出することができます。

トレーラを取得せずに *TET_close_document()* を呼び出すとエラーになります。トレーラを取得した後に *TET_process_page()* を呼び出してもエラーになります。

C++ **const char *get_tetml(int doc, size_t *length, wstring optlist)**

C# Java **final byte[] get_tetml(int doc, String optlist)**

Perl PHP **string get_tetml(long doc, string optlist)**

C **const char *TET_get_tetml(TET *tet, int doc, size_t *length, const char *optlist)**

TETML データをメモリから取得します。

doc *TET_open_document*()* で得られた有効な文書ハンドル。

length (C・C++ 言語バインディングのみ) 返される文字列の長さをバイト単位で保持する変数へのポインタ。*length* は終端ヌルバイトを勘定しません。

optlist (現在、使えるオプションはありません。)

戻り値 次のデータ断片を内容として持つバイト配列。バッファが空の場合には、空文字列か *null* が返されます (C では NULL ポインタかつ **len=0*)。

詳細 この関数は、*TET_open_document*()* と、1 回ないし複数回の *TET_process_page()* への呼び出しによって生成された TETML データを取得します。TETML データは、*outputformat* オプションにかかわらず、つねに UTF-8 で符号化されています。内部バッファはこの呼び出しによってクリアされます。*TET_process_page()* を呼び出すたびに *TET_get_tetml()* を呼び出す必要はありません。クライアント側では、1 個ないし複数のページに対する、ないし文書全体に対するデータをバッファ内に蓄積しておくことが可能です。

TETML モードでは、*TET_close_document()* の前にこの関数を少なくとも 1 回呼び出す必要があります。でないとデータは利用できなくなってしまう。 *TET_get_tetml()* をちょうど 1 回だけ呼び出す場合には (そのようなただ 1 回呼び出しは、*TET_process_page()* への最後の呼び出しと *TET_close_document()* との間に行う必要があります)、バッファは文書全体に対する整形形式 TETML 文書を内容として持っていることが保証されます。

この関数は、`TET_open_document*()` の `tetml` オプションに `filename` サブオプションを与えた場合には呼び出してはいけません。

バインディング C・C++ 言語バインディング：結果は、ヌル終端 UTF-8 として提供されます。i5/iSeries・zSeries では、EBCDIC 符号化された UTF-8 が返されます。返されたデータバッファは、次に `TET_get_tetml()` を呼び出す時まで使えます。

Java・.NET バインディング：結果は、UTF-8 データを内容として持つバイト配列として提供されます。

COM:多くのクライアントプログラムは、Variant 型を用いて UTF-8 データを保持します。

PHP 言語バインディング：結果は、UTF-8 文字列として提供されます。

Python：結果は、8ビット文字列 (Python 3 : *bytes*) として返されます。

RPG 言語バインディング：結果は、ヌル終端 EBCDIC UTF-8 として返されます。

10.8 pCOS 関数

PDF からオブジェクトデータを取得するための完全な pCOS 文法が使えます。詳しい説明は、別の文書としてある pCOS パスリファレンスを参照してください。

C++ Java C# **double pcos_get_number(int doc, String path)**

Perl PHP **float pcos_get_number(int doc, string path)**

C **double TET_pcos_get_number(TET *tet, int doc, const char *path, ...)**

数値型か論理型の pCOS パスの値を得ます。

doc *TET_open_document**() で得られた有効な文書ハンドル。

path 数値または論理値オブジェクトへの完全 pCOS パス。

追加引数 (C 言語バインディングのみ) 任意の数の追加引数を、**key** 引数がそれに対応するプレースホルダを含んでいる場合には (文字列には **%s**、整数には **%d**、**%%** とするとパーセント記号 1 個)、与えることができます。これらの引数を利用すれば、可変の数値や文字列値を含む複雑なパスを明示的に組み立てる手間が省けます。プレースホルダの数と型が、与える追加引数と一致するようにするのは、クライアント側の役割です。

戻り値 pCOS パスによって特定されたオブジェクトの数値。論理値の場合は、それが **true** ならば 1 が返され、そうでないなら 0 が返されます。

C++ Java C# **String pcos_get_string(int doc, String path)**

Perl PHP **string pcos_get_string(int doc, string path)**

C **const char *TET_pcos_get_string(TET *tet, int doc, const char *path, ...)**

名前型・数値型・文字列型・論理型のいずれかの pCOS パスの値を得ます。

doc *TET_open_document**() で得られた有効な文書ハンドル。

path 文字列・名前・論理値のいずれかのオブジェクトへの完全 pCOS パス。

追加引数 (C 言語バインディングのみ) 任意の数の追加引数を、**key** 引数がそれに対応するプレースホルダを含んでいる場合には (文字列には **%s**、整数には **%d**、**%%** とするとパーセント記号 1 個)、与えることができます。これらの引数を利用すれば、可変の数値や文字列値を含む複雑なパスを明示的に組み立てる手間が省けます。プレースホルダの数と型が、与える追加引数と一致するようにするのは、クライアント側の役割です。

戻り値 pCOS パスによって特定されたオブジェクトの値を持つ文字列。論理値の場合は、文字列 **true** か **false** が返されます。

詳細 この関数は、pCOS がフルモードで動作しておらず、かつオブジェクトが文字列型の場合には、例外を発生させます。ただし、オブジェクト */Info/** (文書情報キー群) は制限 pCOS モードでも **nocopy=false** か **plainmetadata=true** ならば取得することができ、また、**bookmarks[...]/Title**、および、**pages[...]/annots[...]/** で始まるあらゆるパスは、制限 pCOS モードでも **nocopy=false** ならば取得できます。

この関数は、PDF 文書から取得する文字列がテキスト文字列であると前提しています。バイナリデータを内容として持つ文字列オブジェクトは、これに換えて、データにいかなる変更も加えない **TET_pcos_get_stream()** で取得するべきです。

パインディング C 言語バインディング: 文字列は、BOMなしの UTF-8 形式 (zSeries・i5/iSeries では EBCDIC-UTF-8) で返されます。返される文字列は、最大 10 エントリを持つリングバッファ内に格納されます。10 個を超える文字列が取得されたときには、バッファは再利用されますので、10 個を超える文字列を同時に利用したい場合には、クライアント側でその文字列を複製しておく必要があります。たとえば、`printf()` 文の引数ではこの関数を最大 10 回まで呼び出すことができます。同時に 10 個を超える文字列が使用されないならば、その戻り文字列は互いに独立であることが保証されているからです。

C++ 言語バインディング: 文字列は、C++ ラップのデフォルトの `wstring` 設定では `wstring` として返されます。zSeries・i5/iSeries の `string` 互換モードでは、結果は BOMなし EBCDIC-UTF-8 で返されます。

Java・.NET バインディング: 結果は、Unicode 文字列として提供されます。テキストがそれ以上得られないときは、ヌルオブジェクトが返されます。

Perl・PHP・Python・Ruby 言語バインディング: 結果は、UTF-8 文字列として提供されます。テキストがそれ以上得られないときは、ヌルオブジェクトが返されます。

RPG 言語バインディング: 結果は、EBCDIC-UTF-8 文字列として提供されます。

C++ `const unsigned char *pcos_get_stream(int doc, int *length, string optlist, wstring path)`

C# Java `final byte[] pcos_get_stream(int doc, String optlist, String path)`

Perl PHP `string pcos_get_stream(int doc, string optlist, string path)`

C `const unsigned char *TET_pcos_get_stream(TET *tet, int doc, int *length, const char *optlist, const char *path, ...)`

`stream` 型・`fstream` 型・文字列型のいずれかの pCOS パスの値を得ます。

`doc` `TET_open_document*()` で得られた有効な文書ハンドル。

`length` (C・C++ 言語バインディングのみ) 返されるストリームデータの長さをバイト単位で受け取る変数へのポインタ。

`optlist` 表 10.22 に従ってストリーム取得オプション群を指定したオプションリスト。

`path` ストリームまたは文字列オブジェクトへの完全 pCOS パス。

追加引数 (C 言語バインディングのみ) 任意の数の追加引数を、`key` 引数がそれに対応するプレースホルダを含んでいる場合には (文字列には `%s`、整数には `%d`、`%%` とするとパーセント記号 1 個)、与えることができます。これらの引数を利用すれば、可変の数値や文字列値を含む複雑なパスを明示的に組み立てる手間が省けます。プレースホルダの数と型が、与える追加引数と一致するようにするのは、クライアント側の役割です。

戻り値 ストリームまたは文字列の中に含まれた非暗号化データ。ストリームまたは文字列が空の場合、あるいは、暗号化されていない文書の中の暗号化された添付の内容がクエリされてその添付パスワードが与えられていない場合には、返されるデータは空になります (C・C++ では NULL)。

オブジェクトが `stream` 型の場合には、`keepfilter=true` でないかぎり、すべてのフィルタがストリーム内容から除去されます (すなわち、生データ本体が返されます)。オブジェクトが `fstream` 型か文字列型の場合には、PDF ファイル内で見つかったとおりのデータがそのまま届けられますが、ただし例外として ASCII85・ASCIIHex フィルタは除去されます。

データの解凍と ASCII フィルタの除去に加えて、**convert** オプションに従ってテキスト変換が適用される場合もあります。

JPX 圧縮されたストリームは以下のように扱われます：要素あたり 1～8 ビットの画像データは、要素あたり 8 ビットで返されます。要素あたり 9～16 ビットの画像データは、要素あたり 16 ビットで返されます。PDF 色空間が一切存在していない場合、かつ、JPX 圧縮されたストリームが内部カラーパレットを内容として持っている場合には、圧縮されていないストリームデータを返す前にこのパレットを適用することによって、レポートされている色空間と要素数にそのピクセルデータが必ず一致するようにします。なお、PDF 色空間 *Indexed* が存在している場合にはパレットは適用されません。

詳細 この関数は、pCOS がフルモードで動作していないときには例外を発生させます (pCOS パスリファレンス参照)。例外として、オブジェクト */Root/Metadata* は制限 pCOS モードでも *nocopy=false* か *plainmetadata=true* ならば取得することができます。パスが *stream* 型・*fstream* 型・*文字列型*のいずれかのオブジェクトを指し示していない場合にも、例外が発生します。

この関数は、その名前にもかかわらず、*文字列型*のオブジェクトを取得するために使うこともできます。オブジェクトをテキスト文字列として扱う *TET_pcos_get_string()* と違って、この関数は、返されたデータに対していかなる変更も加えません。バイナリ文字列データは PDF 内でめったに用いられませんので、自動的に検出できません。文字列オブジェクトをバイナリデータとして取得するか、それともテキストとして取得するのかが決めるのは、したがってユーザ側の役割です。

バインディング COM：多くのクライアントプログラムは、Variant 型を用いてストリーム内容を保持します。COM による JavaScript は、返されたバリエーション配列の長さを取得することを許しません (しかしこれは他の言語と COM では動作します)。

C・C++ 言語バインディング：返されたデータバッファは、次にこの関数を呼び出すまで使えます。

Python：結果は、8 ビット文字列として返されます (Python 3：*bytes*)。

注記 この関数を利用すると、PDF に埋め込まれているフォントデータを取得することができます。ユーザは、フォントは各フォントベンダの使用許諾の対象であり、それぞれの知的所有権保有者の明示的許諾なしでは再利用してはならないという事実にご留意してください。お使いのフォントベンダに連絡して、関連するライセンス契約を協議してください。

表 10.22 TET_pcos_get_stream() のオプション一覧

オプション	説明
convert	(キーワード。非対応フィルタで圧縮されているストリームに対しては無視されます) 文字列またはストリーム内容が変換されるかどうかを制御します (デフォルト：none)：
none	内容をバイナリデータとして扱い、何の変換も行いません。
unicode	内容をテキストデータとして (すなわち、TET_pcos_get_string() におけるのと全く同じに) 扱い、Unicode へ正規化します。Unicode 非対応言語バインディングでは、これは、データは BOM なし UTF-8 形式へ変換されることを意味します。このオプションは、めったに用いられない PDF 内のデータ型「テキストストリーム」(たとえばこれは JavaScript のために用いられる場合がありますが、JavaScript のほとんどはストリームオブジェクトでなく文字列オブジェクト内に入っています) のために必要です。

表 10.22 TET_pcos_get_stream() のオプション一覧

オプション	説明
<i>keepfilter</i>	(論理値。画像データストリームに対してのみ推奨されます。非対応フィルタで圧縮されているストリームに対しては無視されます) true の場合には、ストリームデータは、その画像の <i>filterinfo</i> 擬似オブジェクト内で指定されているフィルタで圧縮されたままになります (pGOS パスリファレンス参照)。false の場合には、ストリームデータは解凍されます。デフォルト : すべての非対応フィルタに対して true、それ以外には false

A TETライブラリクイックリファレンス

以下の表に、すべての TET API 関数の概観を示します。頭に (C) が付いているものは、関数の C プロトタイプであり、Java 言語バインディングでは利用できないことを意味します。

セットアップ

関数プロトタイプ	ページ
(C) <i>TET *TET_new(void)</i>	178
<i>void delete()</i>	178

オプション処理

関数プロトタイプ	ページ
<i>void set_option(String optlist)</i>	175

PDFlib 仮想ファイルシステム (PVF)

関数プロトタイプ	ページ
<i>void create_pvf(String filename, byte[] data, String optlist)</i>	179
<i>int delete_pvf(String filename)</i>	180
<i>int info_pvf(String filename, String keyword)</i>	180

Unicode 変換

関数プロトタイプ	ページ
<i>String convert_to_unicode(String inputformat, byte[] input, String optlist)</i>	182

例外処理

関数プロトタイプ	ページ
<i>String get_apiname()</i>	184
<i>String get_errmsg()</i>	184
<i>int get_errnum()</i>	184

文書

関数プロトタイプ	ページ
<i>int open_document(String filename, String optlist)</i>	187
(C) <i>int TET_open_document_callback(TET *tet, void *opaque, tet_off_t filesize, size_t (*readproc)(void *opaque, void *buffer, size_t size), int (*seekproc)(void *opaque, tet_off_t offset), const char *optlist)</i>	194
<i>void close_document(int doc)</i>	195

ページ

関数プロトタイプ	ページ
<i>int open_page(int doc, int pagenumber, String optlist)</i>	196
<i>void close_page(int page)</i>	205

テキスト・グリフ詳細抽出

関数プロトタイプ	ページ
<i>String get_text(int page)</i>	206
<i>int get_char_info(int page)</i>	207
<i>int get_color_info(int doc, int colorid, String optlist)</i>	211

画像抽出

関数プロトタイプ	ページ
<i>int get_image_info(int page)</i>	213
<i>int write_image_file(int doc, int imageid, String optlist)</i>	214
<i>final byte[] get_image_data(int doc, int imageid, String optlist)</i>	216

TET マークアップ言語 (TETML)

関数プロトタイプ	ページ
<i>int process_page(int doc, int pagenumber, String optlist)</i>	218
<i>final byte[] get_tetml(int doc, String optlist)</i>	219

pCOS

関数プロトタイプ	ページ
<i>double pcos_get_number(int doc, String path)</i>	221
<i>String pcos_get_string(int doc, String path)</i>	221
<i>final byte[] pcos_get_stream(int doc, String optlist, String path)</i>	222

B 更新履歴

本マニュアルの更新履歴

日付	変更点
2019年7月18日	▶ <i>TET 5.2</i> に合わせて更新
2017年6月20日	▶ <i>TET 5.1</i> に合わせて更新
2016年5月19日	▶ <i>TET 5.0</i> に合わせて更新
2015年1月27日	▶ <i>TET 4.4</i> に合わせて更新
2014年5月26日	▶ <i>TET 4.3</i> に合わせて更新
2013年5月17日	▶ <i>TET 4.2</i> に合わせて更新
2012年4月04日	▶ <i>TET 4.1p1</i> に合わせて更新
2012年2月20日	▶ <i>TET 4.1</i> に合わせて更新
2010年9月22日	▶ <i>TET 4.op2</i> に合わせて更新
2010年7月27日	▶ <i>TET 4.0</i> に合わせて更新
2009年2月01日	▶ <i>TET 3.0</i> に合わせて更新
2008年1月16日	▶ <i>TET 2.3</i> に合わせてマニュアル更新
2007年1月23日	▶ <i>TET 2.0</i> に合わせた小幅追補
2005年12月14日	▶ <i>TET 2.1.0</i> に合わせて追加・修正。 <i>PHP・RPG</i> 言語バインディングに関する記述を追加
2005年6月20日	▶ <i>TET 2.0.0</i> に合わせてマニュアルを拡張・再構成
2003年10月14日	▶ <i>TET 1.1</i> に合わせてマニュアル更新
2002年11月23日	▶ <i>TET 1.0.2</i> に合わせて <i>TET_open_doc_callback()</i> の説明とページサイズ決定のコードサンプルを追加
2002年4月4日	▶ <i>TET 1</i> に合わせて第1版

索引

あ

アウトラインテキスト 210
アセンダ 82
アラビア文字 88
暗号化文書 63
色
 テキストの 84
色空間 138
インストール
 TET の 7
インチ 78
オプションリスト 167
オプションリスト文法 167

か

回転済みグリフ 87
影付き除去 92
画像
 色再現性 138
 解像度 134
 視覚情報 133
 種別を知る 128
 小画像除去 137
 抽出 127
 ディスクまたはメモリへ抽出 127
 配置画像 130
 文書内の画像数 130
 ページベースの抽出ループ 131
 リソース 130
 リソースベースの抽出ループ 132
 連結 135
 XMP メタデータ 128
キーワード
 オプションリスト内の 172
擬似太字除去 92
キャップハイト 82
キャラクタとグリフ 103
キャラクタ列 105
クオートされていない文字列値
 オプションリスト内の 170
矩形
 オプションリスト内の 172
組文字 105
クラシック .NET バインディング 36
グリフ 103

グリフ規則 125
グリフメトリック 79
グリフリスト 124
権限/パスワード 63
合字 105
互換分解 113
コマンドラインツール 17
コンコーダンス (XSLT サンプル) 163

さ

サブレット 33
最適化
 速度の 69
索引 (XSLT サンプル) 165
作成例
 XSLT 163
座標系 78
サロゲート 104
サンプルコード 14
シーケンス 105
しおり 75
視覚情報
 画像の 133
字形統合 109
終了点
 グリフと単語の 82
シュラッグ機能 63
小画像除去 137
所有者パスワード 63
数値
 オプションリスト内の 172
スキーマ 151
スポットカラー 138
正規化 116
正準分解 112
双方向テキスト 88
速度を最適化 69

た

タグ付き PDF 76
縦書き 86
単位 78
単語境界検出 91
単語検出機能 91
注釈 75
ディセンダ 82

テキストカラー 84
テキスト抽出ステータス 63
テキストのフィルタリング 106
テキストの前処理 106
テキストフィルタリング 106
添付パスワード 63

な

内容分析 90
生テキスト抽出 (XSLT サンプル) 166
日中韓 (日本語・中国語・韓国語) 12, 86
 互換形 87
 設定 7
 単語境界 86
ネストされたオプションリスト 168

は

配置画像 130
ハイフン除去 92
ハイライト 82
パスワード 63
パッケージ 76
表意文字テキスト
 単語境界 86
評価版 7
表組検出 97
表組抽出 (XSLT サンプル) 165
ファイル検索 66
ファイル添付 76
フォームフィールド 75
フォント統計 (XSLT サンプル) 164
フォントの使用箇所を検索 (XSLT サンプル)
 164
フォントフィルタリング (XSLT サンプル) 163
不可視テキスト 210
プログラミングサンプル 14
分解 112
文書情報項目 73
文書スタイル 94
文書領域 73
文法
 オプションリストの 167
ページ装飾
 タグ付き PDF 内の 198
ページベースの画像抽出ループ 131
ページ装飾 (タグ付き PDF 内の)
 TET_char_info 構造 209
ヘブライ文字 88
ポートフォリオ 76
ポイント 78

ま

マスタパスワード 63
マップ不能グリフ 119
ミリメートル 78
文字列
 オプションリスト内の 169

や

ユーザパスワード 63

ら

ライセンスキー 8
リガチャ 105
リスト検出 98
リスト値
 オプションリスト内の 168
リソースカテゴリ 65
リソースのコンフィギュレーション 65
リソースベースの画像抽出ループ 132
粒度 90
領域
 テキスト抽出の 78
例
 テキスト抽出ステータス 63
例外処理 25
 C の場合 27
レイヤー 77, 198
レスポンスファイル 21
ログ記録 185
論理値
 オプションリスト内の 172

A

API リファレンス 167

B

BMP (基本多言語面) 104
BOM (Byte Order Mark) 104

C

C++ バインディング 30
C バインディング 27
codelist 122
COM バインディング 32
CSV 形式 165

D

DeviceN 色空間 138
Dispose() 178

F

float ・ 整数値
オプションリスト内の 172
FontReporter Plugin 12, 121

G

glyphlist 124
glyphrule 125
granularity 90

H

HTML コンバータ (XSLT サンプル) 165

I

ICC プロファイル 138
IFilter
Microsoft 製品用 57

J

J2EE アプリケーションサーバ 33
Java バインディング 33
Javadoc 34
JBIG2 127
JPEG 127
JPEG 2000 127

L

Lucene 検索エンジン 50

M

MediaWiki 61

N

.NET Core バインディング 35
.NET バインディング 35

O

Objective-C バインディング 38
Oracle Text 54

P

pCOS
クックブック 15
API 関数 221
PDF のバージョン 11
Perl バインディング 40
PHP バインディング 41
PUA (私用領域) 104, 110, 120
Python バインディング 43

R

resourcefile パラメタ 68
RPG バインディング 46
Ruby バインディング 44

S

searchpath 66
Separation 色空間 138
Solr 検索サーバ 53

T

TET_CATCH() 184
TET_close_document() 195
TET_close_page() 205
TET_convert_to_unicode() 182
TET_create_pvf() 179
TET_delete_pvf() 180
TET_delete() 178
TET_EXIT_TRY() 27, 184
TET_get_apiname() 184
TET_get_char_info() 207
TET_get_errmsg() 184
TET_get_errnum() 184
TET_get_image_data() 216
TET_get_image_info() 213
TET_get_tetml() 219
TET_get_text() 206
TET_info_pvf() 180
TET_new() 178
TET_open_document_callback() 194
TET_open_document() 187
TET_open_page() 196
TET_pcos_get_number() 221
TET_pcos_get_stream() 222
TET_pcos_get_string() 221
TET_RETHROW() 184
TET_set_option() 175
TET_TRY() 184
TET_write_image_file() 214
tet.upr 67
TET クックブック 15
TET コネクタ
Lucene 用 50
MediaWiki 用 61
Microsoft 製品用 57
Oracle 用 54
Solr 用 53
TIKA 用 59
TET コマンドラインツール 17
TET の機能 11
TET プラグイン
Adobe Acrobat 用 49
TET マークアップ言語 (TETML) 141
TETML 141

スキーマ 151
TETRESOURCEFILE 環境変数 67
TeX 文書 72
TIFF 127
TIKA ツールキット 59
ToUnicode CMap 123

U

Unichar 値
 オプションリスト内の 170
Unicode
 後処理 109
 オプションリスト内の 170
 概念 103
 正規化 116
 符号化形式 104
 符号化スキーム 104
 分解 112
 前処理 106
 BOM 104
Unicode 字形統合 109
Unicode 対応言語/バインディング 173
UPR ファイル形式 65
UTF-32 118
UTF 形式 104

X

x ハイット 82
XFA フォーム 11, 157
XMP メタデータ 74
 画像の 128
 XSLT サンプル 165
XSD スキーマ
 TETML の 151
XSLT 160
 サンプル 15, 163

PDFlib GmbH

Franziska-Bilek-Weg 9
80339 München, Germany
www.pdflib.com

電話 +49・89・452 33 84-0
fax +49・89・452 33 84-99

疑問があたりの際は、PDF メーカーリストと、
tech.groups.yahoo.com/group/pdflib のアーカイブをチェックしてください

ライセンスに関するお問い合わせ
sales@pdflib.com

サポート
support@pdflib.com (お使いのライセンス番号をお書きください)

