

【A6】Delphiテクニカルセッション



DEVELOPER CAMP

Delphi 2009ではじめるUnicodeアプリケーション - 既存コード移行のポイント -

有限会社 エイブル
富永 英明

アジェンダ



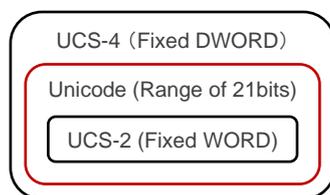
DEVELOPER CAMP

- Unicode の基礎知識
- 旧プロダクトからの移行 – Delphi 2007 へ –
- Delphi 2009 と Unicode
- 旧プロダクトからの移行 – Unicode アプリケーション –
- 資料

Unicode の基礎知識

Unicode の基礎知識

- 文字セット

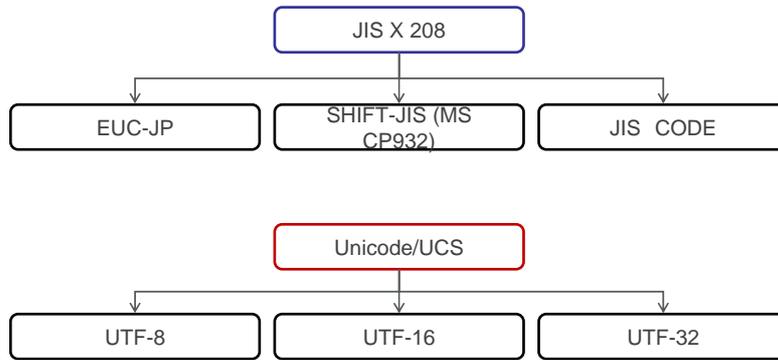


ANSI

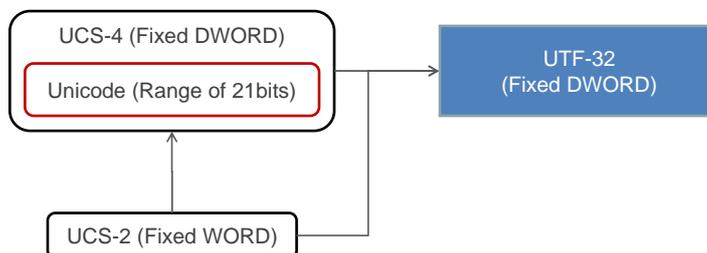
JIS X 208

⋮

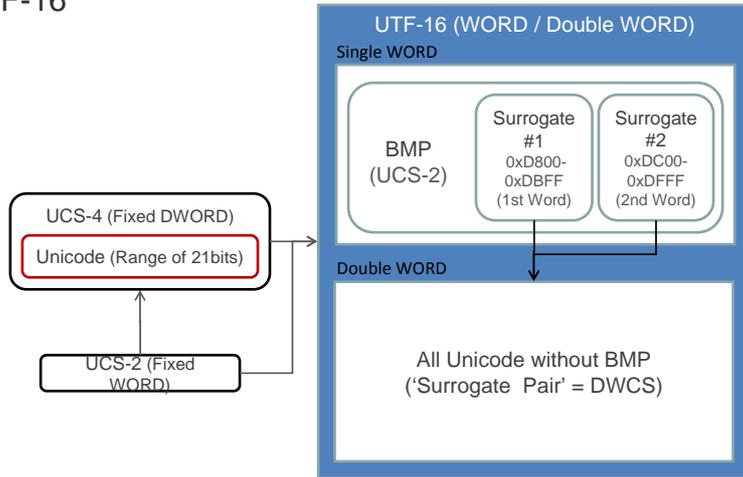
- 文字エンコーディング



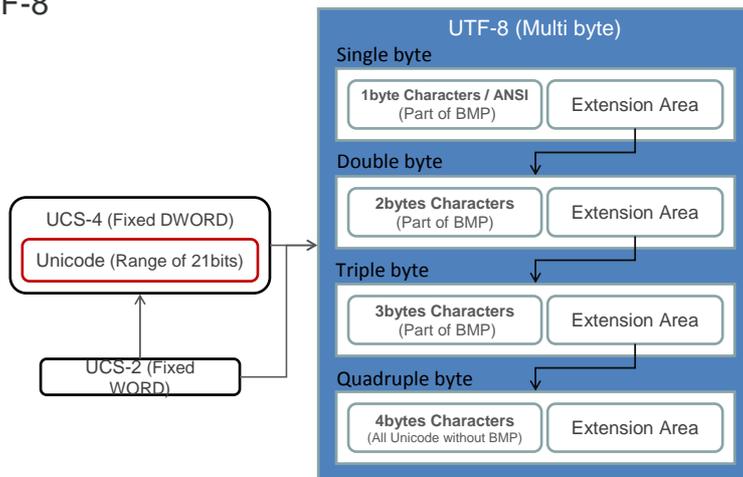
- UTF-32



• UTF-16



• UTF-8



- プレーン

Unicode			
Plane #0 (BMP=UCS-2) U+0000-U+FFFF			
Plane #1 (SMP) U+10000-U+1FFFF	Plane #2 (SIP) U+20000-U+2FFFF	Plane #3 (reserved) U+30000-U+3FFFF	Plane #4 (reserved) U+40000-U+4FFFF
Plane #5 (reserved) U+50000-U+5FFFF	Plane #6 (reserved) U+60000-U+6FFFF	Plane #7 (reserved) U+70000-U+7FFFF	Plane #8 (reserved) U+80000-U+8FFFF
Plane #9 (reserved) U+90000-U+9FFFF	Plane #10 (reserved) U+A0000-U+AFFFF	Plane #11 (reserved) U+B0000-U+BFFFF	Plane #12 (reserved) U+C0000-U+CFFFF
Plane #13 (reserved) U+D0000-U+DFFFF	Plane #14 (SSP) U+E0000-U+EFFFF	Plane #15 (PUP #A) U+F0000-U+FFFFF	Plane #16 (PUP #B) U+100000- U+10FFFF

- サロゲートペア

- UTF-16 で U+10000 以降のコードポイントの文字は 2ワード で表す。
- SHIFT-JIS のように、第 2 文字構成要素が 1 ワード文字の範囲と重複する事はないため、文字検索やデリミタの判別は容易となる。
- 第 1 文字構成要素と第 2 文字構成要素の範囲も重複しない。
- UTF-8 / UTF-32 にサロゲートペアの概念はないが、Windows の Unicode は UTF-16 なので、サロゲートペアを考慮せずに変換した場合に影響が出る。例えば、UTF-8 の 4バイト文字は U+10000 以降のコードポイントの文字を表すので、4バイト文字が不正になってしまう。
- サロゲートペアを考慮しないと、Unicode 1.0 (UCS2) アプリケーションしか作れない。
- サロゲートペアで表される文字はコードポイントからすれば、Unicode 全体の 16/17 となる。
- 詳細は <http://dn.codegear.com/jp/article/38811> で。

● 結合文字列

- “見た目の1文字”を複数のコードポイントで表すのが結合文字列。
- 結合文字列は“基底文字”+“結合文字”の並び。
- 例えば、基底文字“か”と結合文字“ゝ”の組み合わせで“が”という結合文字列となる。
- これとは別に、“が”という単独のコードポイントの文字も存在する。これは合成文字とよばれる。
- 結合文字列から合成文字へ変換する事を“合成”、逆に合成文字から結合文字列へ変換する事を“分解”という。
- 10を超えるコードポイントで構成される結合文字列が存在する。
- 結合文字列の“が”と合成文字の“が”は見た目では判断できない。
- 文字列検索の際には、結合文字列と合成文字を同一視しなくてはならない場合があり、前処理として“正規化(Normalize)”を行う必要がある。
- 詳細は <http://dn.codegear.com/jp/article/38816> で。

● その他の注意点

- エンコードによってはファイルの先頭に BOM(バイト・オーダー・マーク) と呼ばれるバイトオーダーを調べるためのマーカが付加される事がある。
- U+FEFF (“ZERO WIDTH NO-BREAK SPACE”) のように、幅0の文字が存在する。
- Unicode では 文字の半角/全角サイズを文字構成要素数では判断できない。

- Windows と Unicode
 - Win9x の Unicode は UCS2
 - NT系の Windows の Unicode は UTF-16
 - Vista では 何も考えずに サロゲートペアを扱えるが、2000 / XP では多少の環境設定が必要となる。
 - “JIS X 0213:2004” の範囲の Unicode しか扱わないのであれば、フォントに “メイリオ” または IPAフォント(<http://ossipedia.ipa.go.jp/ipafont/>) が使える。
 - 単一のフォントで収録された文字が多いのは “MingLiU” または “SimSun”。
 - Office 2000 以降を持っているのであれば、“Arial Unicode MS” が使える。これは Unicode 2.1 規格のすべての文字を網羅する。
 - Vista と “JIS X 0213:2004” についての 資料は “JIS X 0213:2004 / Unicode 実装ガイド (Microsoft)” <http://go.microsoft.com/fwlink/?LinkId=78800> がある。

- Delphi 1
 - → Delphi 7 または Delphi 2007 へ
 - 32bit 化
- Delphi 2 ~ Delphi 5
 - → Delphi 7 へ
 - コンポーネントの修正 (dsgnintf → DesignIntf)
 - ネットワークコンポーネントの置換 (NetManage)
- Delphi 6 ~ Delphi 7
 - → Delphi 2007 へ
 - CLXコードの排除
- Delphi 2005 ~ Delphi 2006 (Turbo Delphi 含む)
 - → Delphi 2007 へ
 - XP / Vista 対応 (XPMan / VistaAltFix / FastMM の削除)

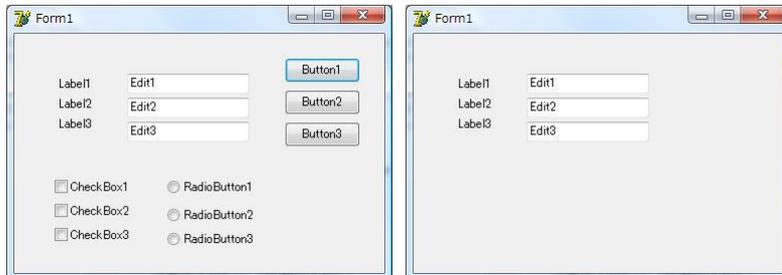
- DsgnIntf (~ Delphi5)
 - Dsgnintf を uses しているコンポーネントは、DesignIntf / DesignEditors を uses するように変更しなくてはならない。

```
// [旧]
uses
  ..., DsgnIntf, ...

// [新]
uses
  ..., DesignIntf, DesignEditors, VCLEditors, RTLConsts, ...
```

- FastMM (Option)
 - BDS2006 で採用された新しいメモリマネージャと同等のメモリマネージャ
 - http://sourceforge.net/project/showfiles.php?group_id=130631 からDL可能。
 - 詳細は以下のURLで
<http://dn.codegear.com/jp/article/33624>
<http://dn.codegear.com/jp/article/33696>

- Vista Alt Fix (～ BDS 2006)



Delphi 2007 以前のプロダクトでは、テーマに対応させたアプリケーションをVistaで動作させた場合、単にAltキーを押下するだけで、コントロールの一部が正しく描画されなくなってしまう。

これを回避するのが、"VistaAltFix (<http://cc.codegear.com/item/24282>)"。

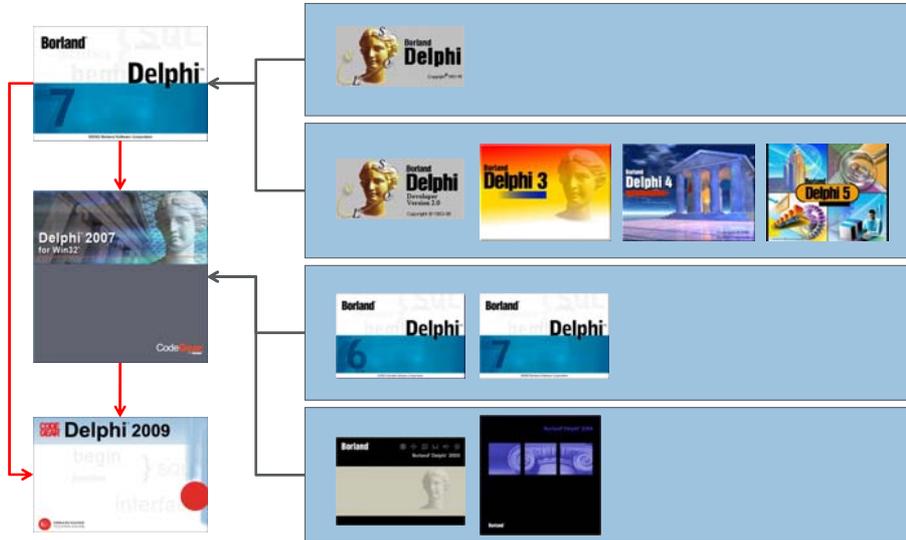
※Delphi 2007 / Delphi 2009 には不要。

- Delphi 2007 でやるべき事

- コンポーネント (パッケージ) / ライブラリの整備
- XP / Vista 対応
- BDE の代替
- レポートツールの精査
- (できれば) Delphi 2009 互換機能の実装

- ステップアップグレードのススメ

- 16bit Windows 専用 → Delphi (1)
- Win9x対応最終版 → Delphi 7
- Ansi対応最終版 → Delphi 2007
- Unicode 対応版 → Delphi 2009
- 必要に応じて、Delphi 2009 からのバックポート



• IDE (1)

- コードエディタ から オブジェクトインスペクタ に至るまで、完全に Unicode 化されている。サロゲートペアも正しく表示できる。



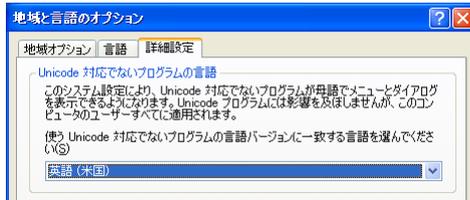
• IDE (2)

- Windows 2000 / XP ではシステムフォント“Tahoma”の影響で、サロゲートペアを正しく表示できない。



- IDE (3)

- Unicode化により、IDE がシステムのコードページに影響されなくなった。



上: Delphi 2007
下: Delphi 2009



- RTL

- RTL は Unicode を扱うための関数/クラスが強化されている。
 - ファイル入出力には TEncoding クラス を利用可能(後述)。
 - RTL は 基本的に W系API を呼び出す。

- VCL

- VCL も Unicode をサポートするが、IDE 同様、一部の VCL でシステムフォントの影響を受けてしまい、2000 / XP では正しくフォントを設定していても、サロゲートペアを正しく表示できない事がある。



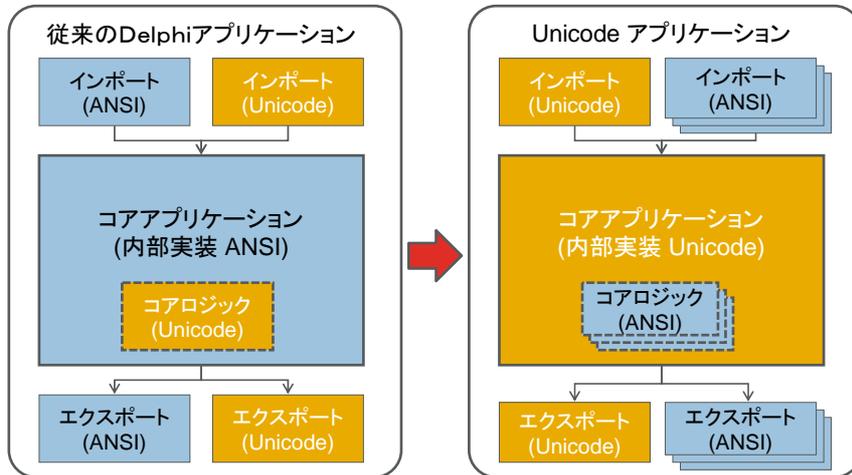
RibbonGroup のキャプションが
□で表示されている(設計時/QCあり)



Button の Hint が
□で表示されている。

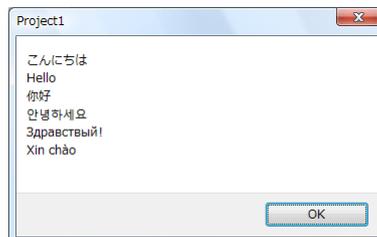
- Hint や Form の Caption は [デスクトップ | プロパティ | デザイン | 詳細設定] にてフォントを変更する事により対処可能。

• ANSIアプリケーション と Unicodeアプリケーション



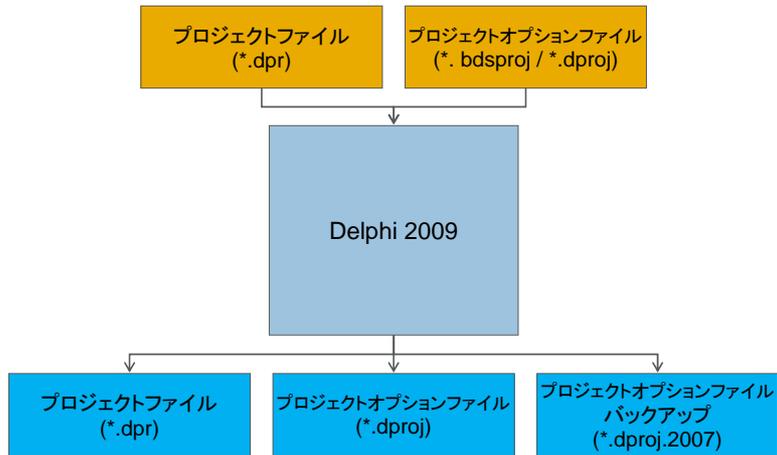
• アプリケーションを Unicode化することのメリット

- 多言語を同時に表示可能。

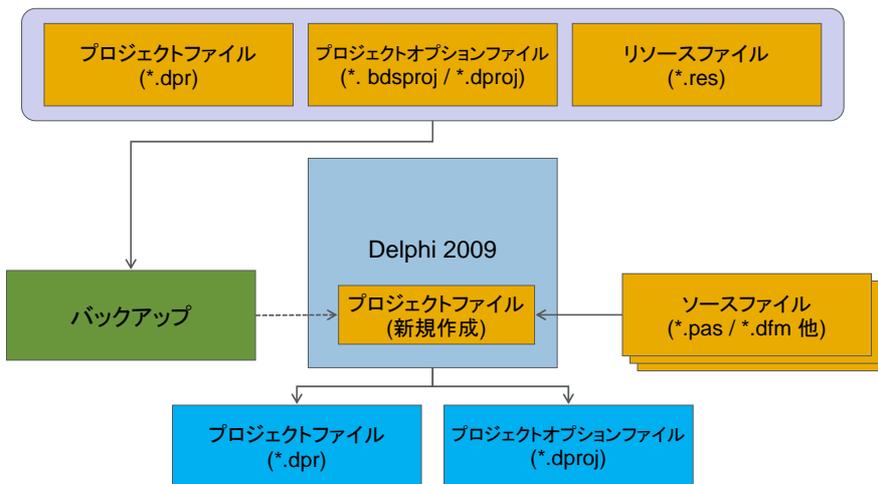


- 日本でよく使われる文字に限定しても、利用可能な文字が増える。
© ® ™ m³ 高 etc...
- 入出力ファイルに多くのANSIコードページが利用可能。
- アプリケーションのローカライズが比較的簡単に。
- 煩雑なマルチバイト処理から解放される。

• プロジェクトファイルの移行 (自動)



• プロジェクトファイルの移行 (手動)



- 新しいプロジェクトで不要なユニット / コンポーネントの除去
 - XPMan
プロジェクトオプションで指定
 - FastMM
標準のメモリマネージャと同等
 - VistaAltFix
Delphi 2007 からは不要
- 新しいプロジェクトファイルに指定できるもの
 - ReportMemoryLeaksOnShutdown (BDS 2006 ~)
アプリケーション終了時にメモリークをレポート
 - Application.MainFormOnTaskbar (Delphi 2007 ~)
メインフォームをタスクバーへ格納
 - Application.DefaultFont (Delphi 2009)
“ParentFont := True” の **フォーム** 用デフォルトフォントの指定
 - Screen.MessageFont (Delphi 2009)
メッセージボックス用デフォルトフォントの指定

- 文字欠損の検索
 - “暗黙的文字列キャスト(W1057)”
“暗黙的文字列キャストによるデータ喪失の可能性(W1058)”
“set 式で WideChar がバイト文字に変換されました(W1050)”
をワーニングからエラーに昇格させる。

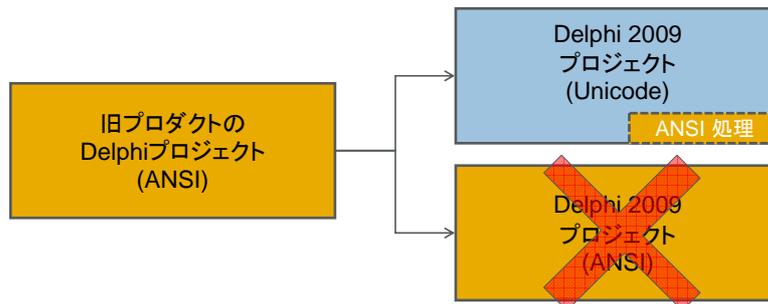
```
{ $WARN IMPLICIT_STRING_CAST ERROR }  
{ $WARN IMPLICIT_STRING_CAST_LOSS ERROR }  
{ $WARN WIDECCHAR_REDUCED ERROR }
```

- Set式を CharInSet() で置き換える。

```
if (S[i] in ['A'..'Z']) then  
  ↓  
if CharInSet(S[i], ['A'..'Z']) then
```

- ANSI文字列の部分使用

- ANSI文字列で内部実装してはいけない。局所的な使用に留めるべき。
- String は AnsiString に置換。
- 文字列操作関数の引数と戻り値、関数内の String は RawByteString に。
- PChar は PAnsiChar に置換。
- AnsiStrings 名前空間を uses した際の副作用の把握。



- メモリリーク検出とデバッグ

- 移行するプロジェクトには、
“ReportMemoryLeaksOnShutdown := True;”
を指定し、メモリリーク箇所を調べる。
- 経験上、PChar 等のメモリ確保/解放部分にバグが潜んでいる事が多い。

- コントロール文字列の4桁化

- 2桁のコントロール文字列は、意図しない ANSI->Unicode 変換を避けるためにすべて4桁化する (#\$0D#\$0A → #\$000D#\$000A)。

- 入出力するファイルのチェック

- SHIFT-JIS でなくてはならないのか？Unicode でいいのか？
- Iniファイルは それを利用する Unicode アプリケーションに合わせて、Unicode(UTF-16) で入出力するようにすべき。

- TEncoding (1)

- TEncoding を利用して Unicode形式ファイルを入出力可能。

```
procedure TForm1.Button1Click(Sender: TObject);
var
  SL: TStringList;
begin
  SL := TStringList.Create;
  try
    SL.Add(' あいうえお ');
    // ファイル保存
    SL.SaveToFile(' C:\Unicode.txt', TEncoding.Unicode);           // UTF-16LE
    SL.SaveToFile(' C:\UTF-16BE.txt', TEncoding.BigEndianUnicode); // UTF-16BE
    SL.SaveToFile(' C:\UTF-8.txt', TEncoding.UTF8);                // UTF-8
    SL.SaveToFile(' C:\UTF-7.txt', TEncoding.UTF7);                // UTF-7
  finally
    SL.Free;
  end;
end;
```

- TEncoding (2)

- TEncodingクラスを利用できるメソッドは以下の通り。
 - ComCtrls.TOutlineNode.WriteNode
 - ComCtrls.TOutlineNode.LoadFromFile
 - ComCtrls.TOutlineNode.LoadFromStream
 - ComCtrls.TOutlineNode.SaveToFile
 - ComCtrls.TOutlineNode.SaveToStream
 - ComCtrls.TOutlineNode.WriteNode
 - Classes.TStrings.LoadFromFile
 - Classes.TStrings.LoadFromStream
 - Classes.TStrings.SaveToFile
 - Classes.TStrings.SaveToStream
 - Classes.TStringStream.Create
 - Classes.TStreamReader.Create
 - Classes.TStreamWriter.Create

- TEncoding (3)

- TEncoding.GetEncoding() を利用するにはインスタンスの破棄が必要。
- CP_UTF8 を指定する事によって BOM なし UTF-8ファイル扱える。

```
procedure TForm1.Button1Click(Sender: TObject);
var
  SL: TStringList;
  Enc: TEncoding;
begin
  SL := TStringList.Create;
  Enc := TEncoding.GetEncoding(CP_UTF8); // UTF-8(CP_UTF8/CP65001)
  try
    SL.Add('あいうえお');
    SL.SaveToFile('C:\UTF-8N.txt', Enc);
  finally
    Enc.Free;
    SL.Free;
  end;
end;
```

- 移行後のブラッシュアップ

- 今時の Unicode アプリケーションを作るのなら、それなりのブラッシュアップが必要。
- フォント変更UIの追加
 - すべての Unicode 文字を網羅したフォントは存在しない。
 - アプリケーションで指定したフォントを相手を持っているとは限らない。
- サロゲートペアへの対応
 - サロゲートペアは特殊文字ではない。
 - 詳細は <http://dn.codegear.com/jp/article/38811> で。
- 結合文字列への対応
 - “文字列検索” や “データベースへのデータ格納” の処理を行う際には、前処理として正規化(Normalize)を行う必要がある。
 - 詳細は <http://dn.codegear.com/jp/article/38816> で。

• Unicode 関連

- Delphi Unicodeワールド /パートI
<http://dn.codegear.com/jp/article/38781>
- Delphi Unicodeワールド /パートII
<http://dn.codegear.com/jp/article/38698>
- Delphi Unicodeワールド /パートIII
<http://dn.codegear.com/jp/article/38699>
- Delphi 2009 と Unicode : Part I
<http://dn.codegear.com/jp/article/38781>
- Delphi 2009 と Unicode : Part II
<http://dn.codegear.com/jp/article/38783>
- Delphi 2009 と Unicode : Part III
<http://dn.codegear.com/jp/article/38786>
- Delphi 2009 と Unicode : 番外編 (サロゲートペア)
<http://dn.codegear.com/jp/article/38811>
- Delphi 2009 と Unicode : 番外編 (結合文字列)
<http://dn.codegear.com/jp/article/38816>
- The Unicode Consortium
<http://unicode.org/>

● Delphi 2009 関連

- CodeGear Delphi 2009 および C++Builder 2009 のインストール ノート
<http://dn.codegear.com/jp/article/38484>
- CodeGear Delphi 2009 および C++Builder 2009 のリリース ノート
<http://dn.codegear.com/jp/article/38489>
- Delphi/C++Builder/RAD Studio2009 のアンインストール
<http://support.codegear.com/jp/article/38836>
- Delphi 2009 機能評価ガイド
<http://dn.codegear.com/jp/article/38817>
- Delphi 2009 と 文字列型
<http://dn.codegear.com/jp/article/38791>
- Delphi 2009 のIDE設定
http://homepage1.nifty.com/ht_deko/tech020.html
- リファレンスマニュアル
<http://docs.codegear.com/>
- Quality Central (Delphi 2009 関連)
<http://qc.codegear.com/wc/qcmain.aspx?search=1&proj=10&vers=12.0>
- QualityCentral の Tips
<http://dn.codegear.com/jp/article/38793>

● その他

- Delphi の製品情報
http://www.geocities.jp/ht_deko/Delphi/index.html
- InstallAware を使って配布モジュールを作成する
<http://dn.codegear.com/jp/article/34383>
- InstallAware に関する Tips
http://homepage1.nifty.com/ht_deko/tech023.html
- 今更ながら BDE (Borland Database Engine)
http://homepage1.nifty.com/ht_deko/tech024.html
- MECSUtils
<http://cc.codegear.com/item/26061>
- MECSUtils リファレンス
http://homepage1.nifty.com/ht_deko/tech021.html
- Vista Alt Fix
<http://dn.codegear.com/jp/article/38791>
- FastMM4
http://sourceforge.net/project/showfiles.php?group_id=130631
- QuickReport Standard
<http://www.quickreport.co.uk/stanlegacy.html>

- MEMO