

# Unicodeを扱う際の小細工色々覚書

2023-09-02 IDSの正規化とか方法が思いつかなかったのでパス  
2023-08-28 最後といったな？あれは嘘だ  
2023-08-26 一応これが最終形になります  
2023-08-25 もう少し整理しようやと手直し  
2023-08-24 結合文字まで入れたので公開

## 前提

Java11で実行。

仕事で色々やりそうな感じがあったので自分のリファレンス用で品質関係は二の次。  
OSS等で公開されたライブラリは使わない（多分使わせてくれないだろうからな）

## 用意したクラス

- UTF-16な文字列を1文字単位に分解する。サロゲートペア表現になる文字も対象。異字体セレクタを伴う文字も対象。
- 結合文字も扱うけど、平仮名 片仮名用に限定。全部なんてやってらんない[u+200D? 知らない子ですね...]
- 分解結果は文字で扱わずUnicodeのコードポイントで取得する。

```
List<Integer> codepoints = new ArrayList<Integer>();
Integer codepoint;
// String targetStr;
for(Integer idx = 0; idx < targetStr.length(); idx++) {
    codepoint = targetStr.codePointAt(idx);
    codepoints.add(codepoint);
    if (codepoint > 65535) idx++; // サロゲートペア上位コード位置なので下位コード位置に補正しておく
}
```

戻す場合はコードポイントから文字に戻す。

```
StringBuilder sb = new StringBuilder();
String targetStr;
// List<Integer> codepoints;
for(Integer idx = 0; idx < codepoints.size(); idx++) {
    sb.appendCodePoint(codepoints.get(idx)); // コードポイントから文字に戻す
}
targetStr = sb.toString();
```

例えば文字列 “ 叱 野家葛 ” を与えたら、以下の形に分解する。

List要素	1文字のList要素	格納するコードポイント	説明
0	0	u+53f1	叱

List要素	1文字のList要素	格納するコードポイント	説明
1	0	u+20bb7	
2	0	u+91ce	野
3	0	u+5bb6	家
4	0	u+845b	葛
	1	u+e0100	

JSON風イメージだところかな。なおJSONだと16進数は使えないしコメントも書けない。

```
"codepoints": [  
  [ 0x53f1 ],           // 叱  
  [ 0x20bb7 ],         //  
  [ 0x91ce ],          // 野  
  [ 0x5bb6 ],          // 家  
  [ 0x845b, 0xe0100 ] // 葛  
]
```

あと、結合文字が理解できないソフトウェアは結構危険で、Macで作ったファイルをWindowsに持ってきた時にこの問題にぶつかる事が多い。片仮名 平仮名の処理はやっておいた方が無難。

## java.text.Normalizerつかえや？

片仮名 平仮名の正規化ならjava.text.Normalizer使えるやろ？と言われるけど、それ以外がねー。

なんか弄ってほしくないものまで弄られちゃうんで、ちょっと使うのが難しいかな...

NFC	NFKC
-----	-----
Str : □□¼□2□□□□□□	Str : □□¼□2□□□□□□
StrLen : 10	StrLen : 10
convedStr : □□¼□2□□□□□□	convedStr : (有)(株)1 / 412 (五)六
convedLen : 10	convedLen : 18
Normalize : NFC	Normalize : NFKC
Pos 0 : □ u+3232	Pos 0 : ( u+28
Pos 1 : □ u+3231	Pos 1 : 有 u+6709
Pos 2 : ¼ u+bc	Pos 2 : ) u+29
Pos 3 : □ u+2460	Pos 3 : ( u+28
Pos 4 : 2□ u+32, u+20e3	Pos 4 : 株 u+682a
Pos 5 : □ u+24f7	Pos 5 : ) u+29
Pos 6 : □ u+2779	Pos 6 : 1 u+31
Pos 7 : □ u+3224	Pos 7 : □ u+2044
Pos 8 : □ u+3285	Pos 8 : 4 u+34
-----	Pos 9 : 1 u+31
Str : パ`ピ`プ`へ`ホ`	Pos 10 : 2□ u+32, u+20e3
StrLen : 10	Pos 11 : □ u+24f7
convedStr : パ`ピ`プ`へ`ホ`	Pos 12 : □ u+2779
convedLen : 10	Pos 13 : ( u+28
Normalize : NFC	Pos 14 : 五 u+4e94
Pos 0 : ハ u+ff8a	Pos 15 : ) u+29
Pos 1 : □ u+ff9f	Pos 16 : 六 u+516d
Pos 2 : ヒ u+ff8b	-----
Pos 3 : □ u+ff9e	Str : パ`ピ`プ`へ`ホ`
Pos 4 : フ u+ff8c	StrLen : 10
Pos 5 : □ u+ff9f	convedStr : パピプベポ
Pos 6 : ヘ u+ff8d	convedLen : 5
Pos 7 : □ u+ff9e	Normalize : NFKC
Pos 8 : ホ u+ff8e	Pos 0 : パ u+30d1
Pos 9 : □ u+ff9f	Pos 1 : ビ u+30d3
-----	Pos 2 : プ u+30d7
Str : は`ひ`ふ`へ`ほ`	Pos 3 : ベ u+30d9
StrLen : 10	Pos 4 : ポ u+30dd
convedStr : ぱびぷべぼ	-----
convedLen : 5	Str : は`ひ`ふ`へ`ほ`
Normalize : NFC	StrLen : 10
Pos 0 : ぱ u+3071	convedStr : ぱびぷべぼ
Pos 1 : ひ u+3073	convedLen : 5
Pos 2 : ふ u+3077	Normalize : NFKC
Pos 3 : べ u+3079	Pos 0 : ぱ u+3071
Pos 4 : ぼ u+307d	Pos 1 : ひ u+3073
	Pos 2 : ふ u+3077
	Pos 3 : べ u+3079
	Pos 4 : ぼ u+307d

Normalizer.Form.NFC, Normalizer.Form.NFD, Normalizer.Form.NFKC, Normalizer.Form.NFKD とあるので、それぞれ自分で試してみるといいと思うよ！

```
package myKanjiDemos;

import java.text.Normalizer;
import java.util.EnumSet;
import java.util.List;
```

```
import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyKanjiDemo01 {

    public static void main(String[] args) {

        String Str0 = "□□¼□2□□□□□";
        String Str1 = "ハ°ヒ°フ°ヘ°ホ°";
        String Str2 = "は °ひ °ふ °へ °ほ °"; // 濁音 半濁音記号の結合文字入り

        CharDisp(Str0, Normalizer.Form.NFC);
        CharDisp(Str1, Normalizer.Form.NFC);
        CharDisp(Str2, Normalizer.Form.NFC);

        CharDisp(Str0, Normalizer.Form.NFKC);
        CharDisp(Str1, Normalizer.Form.NFKC);
        CharDisp(Str2, Normalizer.Form.NFKC);
    }

    public static void CharDisp(String str, Normalizer.Form normalize)
    {
        // java.text.Normalizer でノーマライズして
        String convedStr = Normalizer.normalize(str, normalize);

        // 1文字毎に分解
        List<List<Integer>> chars =
MyStringToChars.parseToCodepoint(convedStr,
EnumSet.of(CharsNormalize.NONE));

        // 分解結果の表示
        System.out.println("-----");
        System.out.println("Str      : " + str);
        System.out.println("StrLen   : " + str.length());
        System.out.println("convedStr : " + convedStr);
        System.out.println("convedLen : " + convedStr.length());
        System.out.println("Normalize : " + normalize);

        StringBuilder sbChars = new StringBuilder();
        StringBuilder sbCodeStr = new StringBuilder();

        for(Integer pos = 0; pos<chars.size(); pos++)
        {
            List<Integer> cs = chars.get(pos);
            sbChars.setLength(0);
            sbCodeStr.setLength(0);

            for(Integer idx = 0; idx<cs.size(); idx++)
            {
                sbChars.appendCodePoint(cs.get(idx));
                if (idx != 0) sbCodeStr.append( ", " );
            }
        }
    }
}
```

```
        sbCodeStr.append( "u+" + Integer.toHexString(cs.get(idx)) );
    }

    System.out.println("Pos " + pos + "      : " + sbChars.toString()
+ " " + sbCodeStr.toString());
}
}
}
```

## デモコード

コード中のdemo\_Normalizeにオプションを渡して変化を確認します。以下に示しているものはオプション指定なし(正規化指定なし)の状態。

### MyKanjiDemo02

サロゲートペア、異字体セレクタ、結合文字を混ぜ込んだ文字列のデモ

```
package myKanjiDemos;

import java.util.EnumSet;

import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyKanjiDemo02 {

    public static void main(String[] args) {

        String Str0 = "伊藤";           // 通常
        String Str1 = "叱 家 ; "       // サロゲートペア混在
        String Str2 = "葛葛 葛 ; "     // 通常+異字体セレクタ
        String Str3 = "                // サロゲートペア+異字体セレクタ

        EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.NONE);
        // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.HALF2FULL_KANA);
        // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA);
        // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA,
CharsNormalize.HALF2FULL_KANA);

        MyDemoMethod.charDisp(Str0, demo_Normalize);
        MyDemoMethod.charDisp(Str1, demo_Normalize);
        MyDemoMethod.charDisp(Str2, demo_Normalize);
        MyDemoMethod.charDisp(Str3, demo_Normalize);

    }
}
```

}

## MyKanjiDemo03

カナと濁音 半濁音記号混在の文字列のデモ

```
package myKanjiDemos;

import java.util.EnumSet;

import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyKanjiDemo03 {

    public static void main(String[] args) {

        String Str0 = "ハフハホヒフヘホ" ; // 半
        角カタカナ
        String Str1 = "ハ `ヒ `フ `ハ `ホ "` ; // 半角カ
        タカナに結合文字の濁音 半濁音記号を付与
        String Str2 = "ハフ ヒフ フフ ヘホ ホフ ハフヒフフフヘホ" ; // 片仮名に濁音 半
        濁音記号付与
        String Str3 = "はフ ひフ ふフ へホ ほフ はフひフふフへホ" ; // 平仮名に濁音 半
        濁音記号付与
        String Str4 = "ぱびふべぽバビブベボ"; // カナに濁音 半濁音
        記号付き
        String Str5 = "は `ひ `ふ `へ `ほ `ハ `ヒ `フ `へ `ホ `";
        // カナに結合文字の濁音 半濁音記号付与

        EnumSet<CharsNormalize> demo_Normalize =
        EnumSet.of(CharsNormalize.NONE);
        // EnumSet<CharsNormalize> demo_Normalize =
        EnumSet.of(CharsNormalize.HALF2FULL_KANA);
        // EnumSet<CharsNormalize> demo_Normalize =
        EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA);
        // EnumSet<CharsNormalize> demo_Normalize =
        EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA,
        CharsNormalize.HALF2FULL_KANA);

        MyDemoMethod.charDisp(Str0, demo_Normalize);
        MyDemoMethod.charDisp(Str1, demo_Normalize);
        MyDemoMethod.charDisp(Str2, demo_Normalize);
        MyDemoMethod.charDisp(Str3, demo_Normalize);
        MyDemoMethod.charDisp(Str4, demo_Normalize);
        MyDemoMethod.charDisp(Str5, demo_Normalize);

    }
}
```

## MyKanjiDemo04

半角 全角カナを混在した文字列のデモ

```
package myKanjiDemos;

import java.util.EnumSet;

import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyKanjiDemo04 {
    public static void main(String[] args) {

        String Str0 = "み ゜み ゜ミ ゜ミ ゜ミ ゜ミ `伊 藤 `"; // 濁音 半濁
        音記号の組み合わせが無いカナに結合文字で濁音 半濁音記号を付与
        String Str1 = "み ゜み ゜ミ ゜ミ ゜ミ ゜ミ `伊 藤 `"; // 濁音 半濁音記号の組み合わ
        せが無いカナに濁音 半濁音記号を付与
        String Str2 = "み ゜み ゜ミ ゜ミ ゜ミ ゜ミ `伊 藤 `"; // 濁音 半濁音記号
        の組み合わせが無いカナに半角濁音 半濁音記号を付与

        EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.NONE);
        // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.HALF2FULL_KANA);
        // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA);
        // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA,
CharsNormalize.HALF2FULL_KANA);

        MyDemoMethod.charDisp(Str0, demo_Normalize);
        MyDemoMethod.charDisp(Str1, demo_Normalize);
        MyDemoMethod.charDisp(Str2, demo_Normalize);

    }
}
```

## MyKanjiDemo05

濁音 半濁音記号で構成した文字列のデモ

```
package myKanjiDemos;

import java.util.EnumSet;

import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyKanjiDemo05 {
```

```

public static void main(String[] args) {
    StringBuilder sb2 = new StringBuilder();

    sb2.appendCodePoint(0x3099);
    sb2.appendCodePoint(0x309A);

    String Str0 = "□□"; // 濁音 半濁音記号を連続
    String Str1 = "□□"; // 濁音 半濁音記号を連続
    String Str2 = sb2.toString(); // 濁音記号の結合文字を連続
    String Str3 = "は゜ ひ゜ ふ゜ へ゜ "; // 濁音 半濁音記号を連続
    String Str4 = "は゜ ひ゜ ふ゜ へ゜ "; // 濁音 半濁音記号を連続
    String Str5 = "ハ゜ ヒ゜ フ゜ ヘ゜ "; // 濁音 半濁音記号を連続
    String Str6 = " ゝん "; // 濁音 半濁音記号を連続
    String Str7 = " ゝん "; // 濁音 半濁音記号を連続

    EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.NONE);
    // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.HALF2FULL_KANA);
    // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA);
    // EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA,
CharsNormalize.HALF2FULL_KANA);

    MyDemoMethod.charDisp(Str0, demo_Normalize);
    MyDemoMethod.charDisp(Str1, demo_Normalize);
    MyDemoMethod.charDisp(Str2, demo_Normalize);
    MyDemoMethod.charDisp(Str3, demo_Normalize);
    MyDemoMethod.charDisp(Str4, demo_Normalize);
    MyDemoMethod.charDisp(Str5, demo_Normalize);
    MyDemoMethod.charDisp(Str6, demo_Normalize);
    MyDemoMethod.charDisp(Str7, demo_Normalize);

}
}

```

## MyKanjiDemo06

記号 絵文字を含む文字列のデモ

```

package myKanjiDemos;

import java.util.EnumSet;

import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyKanjiDemo06 {
    public static void main(String[] args) {

```

```
String Str0 = "□□□□□□"; // 半角記号
String Str1 = "(株)4567 2 (五) "; // 記号
String Str2 = "□"; // 絵文字

EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.NONE);
// EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.HALF2FULL_KANA);
// EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA);
// EnumSet<CharsNormalize> demo_Normalize =
EnumSet.of(CharsNormalize.COMBININGVOICEMARK_KANA,
CharsNormalize.HALF2FULL_KANA);

MyDemoMethod.charDisp(Str0, demo_Normalize);
MyDemoMethod.charDisp(Str1, demo_Normalize);
MyDemoMethod.charDisp(Str2, demo_Normalize);

}
}
```

## 実行結果

### MyKanjiDemo02の実行結果

呼び出し結果。サロゲートペアに異字体セレクタがついてもとりあえず分解できた。

実行結果。

NONE	HALF2FULL_KANA	COMBININGVOICEMARK_KANA	COMBININGVOICEMARK_KANA + HALF2FULL_KANA
<pre> Str      : 伊藤 StrLen   : 2 RebuildStr : 伊藤 RebuildLen : 2 parseOption : [NONE] Pos      0 : 伊 u+4f0a Pos      1 : 藤 u+85e4                     </pre>	<pre> Str      : 伊藤 StrLen   : 2 RebuildStr : 伊藤 RebuildLen : 2 parseOption : [HALF2FULL_KANA] Pos      0 : 伊 u+4f0a Pos      1 : 藤 u+85e4                     </pre>	<pre> Str      : 伊藤 StrLen   : 2 RebuildStr : 伊藤 RebuildLen : 2 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 : 伊 u+4f0a Pos      1 : 藤 u+85e4                     </pre>	<pre> Str      : 伊藤 StrLen   : 2 RebuildStr : 伊藤 RebuildLen : 2 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 : 伊 u+4f0a Pos      1 : 藤 u+85e4                     </pre>
<pre> Str      : 叱 家 StrLen   : 6 RebuildStr : 叱 家 RebuildLen : 6 parseOption : [NONE] Pos      0 : 叱 u+53f1 Pos      1 :   u+20bb7 Pos      2 : 家 u+5bb6 Pos      3 :   u+20b9f                     </pre>	<pre> Str      : 叱 家 StrLen   : 6 RebuildStr : 叱 家 RebuildLen : 6 parseOption : [HALF2FULL_KANA] Pos      0 : 叱 u+53f1 Pos      1 :   u+20bb7 Pos      2 : 家 u+5bb6 Pos      3 :   u+20b9f                     </pre>	<pre> Str      : 叱 家 StrLen   : 6 RebuildStr : 叱 家 RebuildLen : 6 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 : 叱 u+53f1 Pos      1 :   u+20bb7 Pos      2 : 家 u+5bb6 Pos      3 :   u+20b9f                     </pre>	<pre> Str      : 叱 家 StrLen   : 6 RebuildStr : 叱 家 RebuildLen : 6 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 : 叱 u+53f1 Pos      1 :   u+20bb7 Pos      2 : 家 u+5bb6 Pos      3 :   u+20b9f                     </pre>
<pre> Str      : 葛葛 葛 StrLen   : 7 RebuildStr : 葛葛 葛 RebuildLen : 7 parseOption : [NONE] Pos      0 : 葛 u+845b Pos      1 : 葛 u+845b, u+e0109 Pos      2 : 葛 u+845b, u+e0100                     </pre>	<pre> Str      : 葛葛 葛 StrLen   : 7 RebuildStr : 葛葛 葛 RebuildLen : 7 parseOption : [HALF2FULL_KANA] Pos      0 : 葛 u+845b Pos      1 : 葛 u+845b, u+e0109 Pos      2 : 葛 u+845b, u+e0100                     </pre>	<pre> Str      : 葛葛 葛 StrLen   : 7 RebuildStr : 葛葛 葛 RebuildLen : 7 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 : 葛 u+845b Pos      1 : 葛 u+845b, u+e0109 Pos      2 : 葛 u+845b, u+e0100                     </pre>	<pre> Str      : 葛葛 葛 StrLen   : 7 RebuildStr : 葛葛 葛 RebuildLen : 7 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 : 葛 u+845b Pos      1 : 葛 u+845b, u+e0109 Pos      2 : 葛 u+845b, u+e0100                     </pre>
<pre> Str      : StrLen   : 10 RebuildStr : RebuildLen : 10 parseOption : [NONE] Pos      0 :   u+26e40 Pos      1 :   u+26e40, u+e0103 Pos      2 :   u+26e40, u+e0102                     </pre>	<pre> Str      : StrLen   : 10 RebuildStr : RebuildLen : 10 parseOption : [HALF2FULL_KANA] Pos      0 :   u+26e40 Pos      1 :   u+26e40, u+e0103 Pos      2 :   u+26e40, u+e0102                     </pre>	<pre> Str      : StrLen   : 10 RebuildStr : RebuildLen : 10 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 :   u+26e40 Pos      1 :   u+26e40, u+e0103 Pos      2 :   u+26e40, u+e0102                     </pre>	<pre> Str      : StrLen   : 10 RebuildStr : RebuildLen : 10 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 :   u+26e40 Pos      1 :   u+26e40, u+e0103 Pos      2 :   u+26e40, u+e0102                     </pre>

## MyKanjiDemo03の実行結果

かなと濁音 半濁音記号の組み合わせ。

実行結果。

NONE	HALF2FULL_KANA	COMBININGVOICEMARK_KANA	COMBININGVOICEMARK_KANA + HALF2FULL_KANA
------	----------------	-------------------------	---



# MyKanjiDemo04の実行結果

めったにない組み合わせの確認。大丈夫そう。

実行結果。

NONE	HALF2FULL_KANA	COMBININGVOICEMARK_KANA	COMBININGVOICEMARK_KANA + HALF2FULL_KANA
<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [NONE] Pos      0 : み u+307f, u+309a Pos      1 : み u+307f, u+3099 Pos      2 : ゐ u+30df, u+309a Pos      3 : ゐ u+30df, u+3099 Pos      4 : ゑ u+ff90, u+309a Pos      5 : ゑ u+ff90, u+3099 Pos      6 : 伊 u+4f0a, u+3099 Pos      7 : 藤 u+85e4, u+309a </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [HALF2FULL_KANA] Pos      0 : み u+307f, u+309a Pos      1 : み u+307f, u+3099 Pos      2 : ゐ u+30df, u+309a Pos      3 : ゐ u+30df, u+3099 Pos      4 : ゑ u+30df, u+309a Pos      5 : ゑ u+30df, u+3099 Pos      6 : 伊 u+4f0a, u+3099 Pos      7 : 藤 u+85e4, u+309a </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 : み u+307f, u+309c Pos      1 : ゐ u+30df, u+309b Pos      2 : ゐ u+30df, u+309c Pos      3 : ゑ u+30df, u+309b Pos      4 : ゑ u+ff90, u+309c Pos      5 : ゑ u+ff90, u+309b Pos      6 : 伊 u+4f0a, u+309b Pos      7 : 藤 u+85e4, u+309c </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 : み u+307f, u+309c Pos      1 : ゐ u+30df, u+309b Pos      2 : ゐ u+30df, u+309c Pos      3 : ゑ u+30df, u+309b Pos      4 : ゑ u+30df, u+309c Pos      5 : ゑ u+30df, u+309b Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>
<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [NONE] Pos      0 : み u+307f, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゐ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+ff90, u+309b Pos      5 : ゑ u+ff90, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [HALF2FULL_KANA] Pos      0 : み u+307f, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゐ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+30df, u+309b Pos      5 : ゑ u+30df, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 : ゐ u+30df, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゑ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+ff90, u+309b Pos      5 : ゑ u+ff90, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 : ゐ u+30df, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゑ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+30df, u+309b Pos      5 : ゑ u+30df, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>
<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [NONE] Pos      0 : ゐ u+30df, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゑ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+ff90, u+309b Pos      5 : ゑ u+ff90, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [HALF2FULL_KANA] Pos      0 : ゐ u+30df, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゑ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+30df, u+309b Pos      5 : ゑ u+30df, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [COMBININGVOICEMARK_KANA] Pos      0 : ゐ u+30df, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゑ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+ff90, u+309b Pos      5 : ゑ u+ff90, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>	<pre> Str      : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ StrLen   : 16 RebuildStr : み み ゐ ゑ ゑ ゑ ゑ 伊藤     : み み ゐ ゑ ゑ ゑ ゑ RebuildLen : 16 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos      0 : ゐ u+30df, u+309b Pos      1 : ゐ u+30df, u+309c Pos      2 : ゑ u+30df, u+309b Pos      3 : ゑ u+30df, u+309c Pos      4 : ゑ u+30df, u+309b Pos      5 : ゑ u+30df, u+309c Pos      6 : 伊 u+4f0a, u+309c Pos      7 : 藤 u+85e4, u+309b </pre>

# MyKanjiDemo05の実行結果

濁音 半濁音記号単体の時の処理。

実行結果。



# MyKanjiDemo06の実行結果

記号 絵文字の時の処理。

実行結果。

NONE	HALF2FULL_KANA	COMBININGVOICEMARK_KANA	COMBININGVOICEMARK_KANA + HALF2FULL_KANA
<pre> Str      : □□□□□□ StrLen   : 6 RebuildStr : □□□□□□ RebuildLen : 6 parseOption : [NONE] Pos 0 : □ u+ffe9 Pos 1 : □ u+ffeb Pos 2 : □ u+ffea Pos 3 : □ u+ffec Pos 4 : □ u+ffed Pos 5 : □ u+ffee                     </pre>	<pre> Str      : □□□□□□ StrLen   : 6 RebuildStr : ←→↑↓■○ RebuildLen : 6 parseOption : [HALF2FULL_KANA] Pos 0 : ← u+2190 Pos 1 : → u+2192 Pos 2 : ↑ u+2191 Pos 3 : ↓ u+2193 Pos 4 : ■ u+25a0 Pos 5 : ○ u+25cb                     </pre>	<pre> Str      : □□□□□□ StrLen   : 6 RebuildStr : □□□□□□ RebuildLen : 6 parseOption : [COMBININGVOICEMARK_KANA] Pos 0 : □ u+ffe9 Pos 1 : □ u+ffeb Pos 2 : □ u+ffea Pos 3 : □ u+ffec Pos 4 : □ u+ffed Pos 5 : □ u+ffee                     </pre>	<pre> Str      : □□□□□□ StrLen   : 6 RebuildStr : ←→↑↓■○ RebuildLen : 6 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos 0 : ← u+2190 Pos 1 : → u+2192 Pos 2 : ↑ u+2191 Pos 3 : ↓ u+2193 Pos 4 : ■ u+25a0 Pos 5 : ○ u+25cb                     </pre>
<pre> Str      : □𑄎𑄎 2 (𑄎) StrLen   : 12 RebuildStr : □𑄎𑄎 2 (𑄎) RebuildLen : 12 parseOption : [NONE] Pos 0 : □ u+3231 Pos 1 : 𑄎 u+bc Pos 2 : 𑄎 u+332b Pos 3 : □ u+2460 Pos 4 : 2□ u+32, u+20e3 Pos 5 : □ u+24f7 Pos 6 : □ u+2779 Pos 7 : □ u+3224 Pos 8 : □ u+3285 Pos 9 : □ u+24d3 Pos 10 : □ u+24a8                     </pre>	<pre> Str      : □𑄎𑄎 2 (𑄎) StrLen   : 12 RebuildStr : □𑄎𑄎 2 (𑄎) RebuildLen : 12 parseOption : [HALF2FULL_KANA] Pos 0 : □ u+3231 Pos 1 : 𑄎 u+bc Pos 2 : 𑄎 u+332b Pos 3 : □ u+2460 Pos 4 : 2□ u+32, u+20e3 Pos 5 : □ u+24f7 Pos 6 : □ u+2779 Pos 7 : □ u+3224 Pos 8 : □ u+3285 Pos 9 : □ u+24d3 Pos 10 : □ u+24a8                     </pre>	<pre> Str      : □𑄎𑄎 2 (𑄎) StrLen   : 12 RebuildStr : □𑄎𑄎 2 (𑄎) RebuildLen : 12 parseOption : [COMBININGVOICEMARK_KANA] Pos 0 : □ u+3231 Pos 1 : 𑄎 u+bc Pos 2 : 𑄎 u+332b Pos 3 : □ u+2460 Pos 4 : 2□ u+32, u+20e3 Pos 5 : □ u+24f7 Pos 6 : □ u+2779 Pos 7 : □ u+3224 Pos 8 : □ u+3285 Pos 9 : □ u+24d3 Pos 10 : □ u+24a8                     </pre>	<pre> Str      : □𑄎𑄎 2 (𑄎) StrLen   : 12 RebuildStr : □𑄎𑄎 2 (𑄎) RebuildLen : 12 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos 0 : □ u+3231 Pos 1 : 𑄎 u+bc Pos 2 : 𑄎 u+332b Pos 3 : □ u+2460 Pos 4 : 2□ u+32, u+20e3 Pos 5 : □ u+24f7 Pos 6 : □ u+2779 Pos 7 : □ u+3224 Pos 8 : □ u+3285 Pos 9 : □ u+24d3 Pos 10 : □ u+24a8                     </pre>
<pre> Str      : □# StrLen   : 3 RebuildStr : □# RebuildLen : 3 parseOption : [NONE] Pos 0 : □ u+1f40e Pos 1 : # u+270c                     </pre>	<pre> Str      : □# StrLen   : 3 RebuildStr : □# RebuildLen : 3 parseOption : [HALF2FULL_KANA] Pos 0 : □ u+1f40e Pos 1 : # u+270c                     </pre>	<pre> Str      : □# StrLen   : 3 RebuildStr : □# RebuildLen : 3 parseOption : [COMBININGVOICEMARK_KANA] Pos 0 : □ u+1f40e Pos 1 : # u+270c                     </pre>	<pre> Str      : □# StrLen   : 3 RebuildStr : □# RebuildLen : 3 parseOption : [HALF2FULL_KANA, COMBININGVOICEMARK_KANA] Pos 0 : □ u+1f40e Pos 1 : # u+270c                     </pre>

## 作成した文字列分解クラス

1文字毎に切り出してコードポイントのリストを返すクラスをでっちあげる。異字体セレクトがあればこれもまとめる。  
 分解処理を提供するメソッド `parseToCodepoints()` を用意。

半角(HALFWIDE)□全角(FULLWIDE)に関わらず、濁音と半濁音記号は直前の文字に紐づくものとして扱う。ただし、直前の文字が濁音と半濁音記号だった場合は別の文字として扱う。\*MyKanjiDemo05のあたり。

前々回より、不明瞭だった仕様が明確になりました。

### MyStringToChars.java

```

package myKanjiDemos;

import java.util.ArrayList;
import java.util.EnumSet;
import java.util.HashMap;
import java.util.List;
import java.util.Map;

public class MyStringToChars {
                    
```

```
// 文字列分解時のオプション
public enum CharsNormalize
{
    // ダミー
    NONE,
    // 半角カナを全角カナへ変換する
    HALF2FULL_KANA,
    // 文字と濁音 半濁音記号を1文字に統合する
    COMBININGVOICEMARK_KANA
};

// 1文字リストの内容から文字列を生成する
public static String makeStringFromList(List<List<Integer>>
parsedList)
{
    StringBuilder sbRebuild = new StringBuilder();

    sbRebuild.setLength(0);
    for(int pos=0; pos < parsedList.size(); pos++) {
        for(int idx = 0; idx < parsedList.get(pos).size(); idx++) {
sbRebuild.appendCodePoint(parsedList.get(pos).get(idx));
        }
    }

    return sbRebuild.toString();
}

// 文字列を1文字ずつ分解してリストにする
public static List<List<Integer>> parseToCodepoints(String str,
EnumSet<CharsNormalize> normalize)
{
    List<List<Integer>> ans = new ArrayList<List<Integer>>();

    Integer currentCodepoint;
    Integer codepoint;

    for(int idx = 0; idx<str.length(); idx++) {
        currentCodepoint = codepoint = str.codePointAt(idx);

        if(isDiacriticalMarksSymbols(codepoint)) { // 異字体セレクトに対応
            appendCharCodepoint(ans, codepoint);
        }
        else if ( isVariationSelectors(codepoint) ) { // 記号用ダイアク
リティカルマーク処理
            appendCharCodepoint(ans, codepoint);
        }
        else { // 通常

            if(normalize.contains(CharsNormalize.HALF2FULL_KANA)) {
```

```
// カナのFULLWIDE化
        codepoint = normalizationHalf2FullKana(codepoint);
    }

    if(normalize.contains(CharsNormalize.COMBININGVOICEMARK_KANA)) { // 濁音
半濁音記号正規化处理
        if (isSoundmarkKana(codepoint)) { // 濁音 半濁音記号処理
            concatCharAndSoundmarkKana(ans, codepoint);
        }
        else {
            appendChar(ans, codepoint);
        }
    }
    else { // 通常!!!!
        if (isSoundmarkKana(codepoint)) {
            mergeCharAndSoundmarkKana(ans, codepoint);
        }
        else {
            appendChar(ans, codepoint);
        }
    }
}

// 入力文字列ではサロゲートペアの上位コードを指しているので
if(currentCodepoint > 65535) idx++;

}

return ans;
}

// 記号用ダイアクリティカルマーク判定
private static boolean isDiacriticalMarksSymbols(int codepoint)
{
    boolean ans = false;

    if( (codepoint >= 0x20D0)&& (codepoint <= 0x20FF) ) ans = true;

    return ans;
}

// 異字体セレクタ判定
private static boolean isVariationSelectors(int codepoint)
{
    boolean ans = false;

    if ( ((codepoint>=0xe0100)&&(codepoint<=0xe01ef)) ||
        ((codepoint>=0xef00 )&&(codepoint<=0xef0f )) ) {
        ans = true;
    }
}
```

```
    }

    return ans;
}

// 濁音半濁音記号判定
private static boolean isSoundmarkKana(int soundmarkCodepoint)
{
    boolean ans = false;

    if(mapVoicemarkKana.containsKey(soundmarkCodepoint)) {
        ans = true;
    }

    return ans;
}

// かな濁音半濁音記号付き判定
private static boolean isKanaWithSoundmark(int kanaCodepoint)
{
    boolean ans = false;

    if(mapKanaWithJudgeVoicemark.containsKey(kanaCodepoint)) {
        ans = !mapKanaWithJudgeVoicemark.get(kanaCodepoint);
    }

    return ans;
}

// 半角カナを全角カナへ正規化する
private static Integer normalizationHalf2FullKana(int
kanaCodepoint)
{
    Integer ans = kanaCodepoint;

    if(mapHalf2FullKana.containsKey(kanaCodepoint)) {
        ans = mapHalf2FullKana.get(kanaCodepoint);
    }

    return ans;
}

// 結合文字の濁音 半濁音記号を正規化する
private static Integer normalizationSoundmarkKana(int
soundmarkCodepoint)
{
    Integer ans = soundmarkCodepoint;

    if(mapVoicemarkKana.containsKey(soundmarkCodepoint)) {
        ans = mapVoicemarkKana.get(soundmarkCodepoint);
    }
}
```

```
    }

    return ans;
}

// 文字の構成コードポイントを追加する
private static void appendCharCodepoint(List<List<Integer>>
charlist, int codepoint)
{
    if(charlist != null) {

        if (charlist.size()==0) {
            charlist.add(new ArrayList<Integer>());
        }

        charlist.get(charlist.size()-1).add(codepoint);
    }
}

// 文字を追加する
private static void appendChar(List<List<Integer>> charlist, int
codepoint)
{
    if(charlist != null) {
        charlist.add(new ArrayList<Integer>());
        charlist.get(charlist.size()-1).add(codepoint);
    }
}

// 濁音 半濁音記号を直前の文字の構成コードポイントとして追加する
private static void mergeCharAndSoundmarkKana(List<List<Integer>>
charlist, int soundmarkCodepoint)
{
    List<Integer> targetChar;
    int kanaCodepoint;

    if(charlist.size()==0) { // 統合先の文字がないので単体のまま
        charlist.add( new ArrayList<Integer>() );
        charlist.get(0).add(normalizationSoundmarkKana(soundmarkCodepoint));
        return;
    }

    targetChar = charlist.get(charlist.size()-1);
    kanaCodepoint = targetChar.get(targetChar.size()-1);

    if (isSoundmarkKana(kanaCodepoint)) { // 統合先の文字が濁音 半濁音記
号なら単体文字追加にする
        charlist.add( new ArrayList<Integer>() );
    }
}
```

```
charlist.get(charlist.size()-1).add(normalizationSoundmarkKana(soundmarkCodepoint));
    return;
}

    if (isKanaWithSoundmark(kanaCodepoint)) { // 統合先の文字が濁音 半濁音記号付きなら単体文字追加にする
        charlist.add( new ArrayList<Integer>() );
charlist.get(charlist.size()-1).add(normalizationSoundmarkKana(soundmarkCodepoint));
        return;
    }

    // 統合先の文字の構成要素に構成コードポイントを追加
    targetChar.add(normalizationSoundmarkKana(soundmarkCodepoint));
}

    // 濁音 半濁音記号付きの文字に正規化する
    private static void concatCharAndSoundmarkKana(List<List<Integer>> charlist, int soundmarkCodepoint)
    {
        List<Integer> targetChar;
        int kanaCodepoint;
        int newsoundmark;

        if(charlist.size()==0) { // 統合先の文字がないので単体のまま
            charlist.add( new ArrayList<Integer>() );
charlist.get(0).add(normalizationSoundmarkKana(soundmarkCodepoint));
            return;
        }

        targetChar = charlist.get(charlist.size()-1);
        kanaCodepoint = targetChar.get(targetChar.size()-1);

        if (isSoundmarkKana(kanaCodepoint)) { // 統合先の文字が濁音 半濁音記号なら単体文字追加にする
            charlist.add( new ArrayList<Integer>() );
charlist.get(charlist.size()-1).add(normalizationSoundmarkKana(soundmarkCodepoint));
            return;
        }

        if (isKanaWithSoundmark(kanaCodepoint)) { // 統合先の文字が濁音 半濁音記号付きなら単体文字追加にする
            charlist.add( new ArrayList<Integer>() );
charlist.get(charlist.size()-1).add(normalizationSoundmarkKana(soundmarkCodepoint));
            return;
        }

        // 統合先の文字のが濁音 半濁音記号を付与可能な場合は文字の差し替え
```

```
newsoundmark = mapVoicemarkKana.get(soundmarkCodepoint);

switch(newsoundmark)
{
    case 0x309B:
        if (map309B.containsKey(kanaCodepoint)) {
            targetChar.remove(targetChar.size()-1);
            targetChar.add(map309B.get(kanaCodepoint));
        }
        else {
            targetChar.add(newsoundmark);
        }
        break;

    case 0x309C:
        if (map309C.containsKey(kanaCodepoint)) {
            targetChar.remove(targetChar.size()-1);
            targetChar.add(map309C.get(kanaCodepoint));
        }
        else {
            targetChar.add(newsoundmark);
        }
        break;

    default:
        targetChar.add(soundmarkCodepoint);
        break;
}
}

private static Map<Integer, Integer> mapVoicemarkKana = new
HashMap<Integer, Integer>()
{{
    put( 0x3099 , 0x309B ); // 結合文字濁音
    put( 0x309A , 0x309C ); // 結合文字半濁音
    put( 0x309B , 0x309B ); // 濁音
    put( 0x309C , 0x309C ); // 濁音
    put( 0xFF9E , 0x309B ); // ハーフワイド濁音
    put( 0xFF9F , 0x309C ); // ハーフワイド半濁音
}};

private static Map<Integer, Boolean> mapKanaWithJudgeVoicemark =
new HashMap<Integer, Boolean>()
{{
    put( 0x3094 , false); // づ
    put( 0x304C , false); // が
    put( 0x304E , false); // ぎ
    put( 0x3050 , false); // ぐ
    put( 0x3052 , false); // げ
    put( 0x3054 , false); // ご
    put( 0x3056 , false); // ざ
}}
```

```
put( 0x3058 , false); // じ  
put( 0x305A , false); // ず  
put( 0x305C , false); // ぜ  
put( 0x305E , false); // ぞ  
put( 0x3060 , false); // だ  
put( 0x3062 , false); // ぢ  
put( 0x3065 , false); // づ  
put( 0x3067 , false); // で  
put( 0x3069 , false); // ど  
put( 0x3070 , false); // ば  
put( 0x3071 , false); // ぱ  
put( 0x3073 , false); // び  
put( 0x3074 , false); // ぴ  
put( 0x3076 , false); // ぶ  
put( 0x3077 , false); // ぷ  
put( 0x3079 , false); // べ  
put( 0x307A , false); // ぺ  
put( 0x307C , false); // ぼ  
put( 0x307D , false); // ぽ  
put( 0x30F4 , false); // ヴ  
put( 0x30AC , false); // ガ  
put( 0x30AE , false); // ギ  
put( 0x30B0 , false); // グ  
put( 0x30B2 , false); // ゲ  
put( 0x30B4 , false); // ゴ  
put( 0x30B6 , false); // ザ  
put( 0x30B8 , false); // ジ  
put( 0x30BA , false); // ス  
put( 0x30BC , false); // ゼ  
put( 0x30BE , false); // ソ  
put( 0x30C0 , false); // ダ  
put( 0x30C2 , false); // チ  
put( 0x30C5 , false); // ツ  
put( 0x30C7 , false); // デ  
put( 0x30C9 , false); // ド  
put( 0x30D0 , false); // バ  
put( 0x30D1 , false); // パ  
put( 0x30D3 , false); // ビ  
put( 0x30D4 , false); // ぴ  
put( 0x30D6 , false); // ブ  
put( 0x30D7 , false); // ぷ  
put( 0x30D9 , false); // ベ  
put( 0x30DA , false); // ぺ  
put( 0x30DC , false); // ボ  
put( 0x30DD , false); // ぽ  
put( 0x30F7 , false); //  
put( 0x30F8 , false); //  
put( 0x30F9 , false); //  
put( 0x30FA , false); //  
put( 0x3046 , true ); // う  
put( 0x304B , true ); // か
```

```
put( 0x304D , true ); // き
put( 0x304F , true ); // く
put( 0x3051 , true ); // け
put( 0x3053 , true ); // こ
put( 0x3055 , true ); // さ
put( 0x3057 , true ); // し
put( 0x3059 , true ); // す
put( 0x305B , true ); // せ
put( 0x305D , true ); // そ
put( 0x305F , true ); // た
put( 0x3061 , true ); // ち
put( 0x3064 , true ); // つ
put( 0x3066 , true ); // て
put( 0x3068 , true ); // と
put( 0x306F , true ); // は
put( 0x3072 , true ); // ひ
put( 0x3075 , true ); // ふ
put( 0x3078 , true ); // へ
put( 0x307B , true ); // ほ
put( 0x30A6 , true ); // ウ
put( 0x30AB , true ); // カ
put( 0x30AD , true ); // キ
put( 0x30AF , true ); // ク
put( 0x30B1 , true ); // ケ
put( 0x30B3 , true ); // コ
put( 0x30B5 , true ); // サ
put( 0x30B7 , true ); // シ
put( 0x30B9 , true ); // ス
put( 0x30BB , true ); // セ
put( 0x30BD , true ); // ソ
put( 0x30BF , true ); // タ
put( 0x30C1 , true ); // チ
put( 0x30C4 , true ); // ツ
put( 0x30C6 , true ); // テ
put( 0x30C8 , true ); // ト
put( 0x30CF , true ); // ハ
put( 0x30D2 , true ); // ヒ
put( 0x30D5 , true ); // フ
put( 0x30D8 , true ); // ヘ
put( 0x30DB , true ); // ホ
put( 0x30EF , true ); // ワ
put( 0x30F0 , true ); // 𐄀
put( 0x30F1 , true ); // 𐄁
put( 0x30F2 , true ); // 𐄂
}};

private static Map<Integer, Integer> mapHalf2FullKana = new
HashMap<Integer, Integer>()
{{
    put( 0xFF9E , 0x309B ); // Voicemark
    put( 0xFF9F , 0x309C ); // Voicemark
}}
```

```
put( 0xFFE9 , 0x2190 ); // ←
put( 0xFFEA , 0x2191 ); // ↑
put( 0xFFEB , 0x2192 ); // →
put( 0xFFEC , 0x2193 ); // ↓
put( 0xFFE8 , 0x2502 ); // |
put( 0xFFED , 0x25A0 ); // ■
put( 0xFFEE , 0x25CB ); // ○
put( 0x0020 , 0x3000 ); // □
put( 0xFF64 , 0x3001 ); // □
put( 0xFF61 , 0x3002 ); // □
put( 0xFF62 , 0x300C ); // □
put( 0xFF63 , 0x300D ); // □
put( 0x003D , 0x30A0 ); // □
put( 0xFF67 , 0x30A1 ); // ア
put( 0xFF71 , 0x30A2 ); // ア
put( 0xFF68 , 0x30A3 ); // イ
put( 0xFF72 , 0x30A4 ); // イ
put( 0xFF69 , 0x30A5 ); // ウ
put( 0xFF73 , 0x30A6 ); // ウ
put( 0xFF6A , 0x30A7 ); // エ
put( 0xFF74 , 0x30A8 ); // エ
put( 0xFF6B , 0x30A9 ); // オ
put( 0xFF75 , 0x30AA ); // オ
put( 0xFF76 , 0x30AB ); // カ
put( 0xFF77 , 0x30AD ); // キ
put( 0xFF78 , 0x30AF ); // ク
put( 0xFF79 , 0x30B1 ); // ケ
put( 0xFF7A , 0x30B3 ); // コ
put( 0xFF7B , 0x30B5 ); // サ
put( 0xFF7C , 0x30B7 ); // シ
put( 0xFF7D , 0x30B9 ); // ス
put( 0xFF7E , 0x30BB ); // セ
put( 0xFF7F , 0x30BD ); // ソ
put( 0xFF80 , 0x30BF ); // タ
put( 0xFF81 , 0x30C1 ); // チ
put( 0xFF6F , 0x30C3 ); // ツ
put( 0xFF82 , 0x30C4 ); // ツ
put( 0xFF83 , 0x30C6 ); // テ
put( 0xFF84 , 0x30C8 ); // ト
put( 0xFF85 , 0x30CA ); // ナ
put( 0xFF86 , 0x30CB ); // ニ
put( 0xFF87 , 0x30CC ); // ヌ
put( 0xFF88 , 0x30CD ); // ネ
put( 0xFF89 , 0x30CE ); // ノ
put( 0xFF8A , 0x30CF ); // ハ
put( 0xFF8B , 0x30D2 ); // ヒ
put( 0xFF8C , 0x30D5 ); // フ
put( 0xFF8D , 0x30D8 ); // ヘ
put( 0xFF8E , 0x30DB ); // ホ
put( 0xFF8F , 0x30DE ); // マ
put( 0xFF90 , 0x30DF ); // ミ
```

```
    put( 0xFF91 , 0x30E0 ); // ム
    put( 0xFF92 , 0x30E1 ); // メ
    put( 0xFF93 , 0x30E2 ); // モ
    put( 0xFF6C , 0x30E3 ); // ヤ
    put( 0xFF94 , 0x30E4 ); // ヤ
    put( 0xFF6D , 0x30E5 ); // ユ
    put( 0xFF95 , 0x30E6 ); // ユ
    put( 0xFF6E , 0x30E7 ); // ヨ
    put( 0xFF96 , 0x30E8 ); // ヨ
    put( 0xFF97 , 0x30E9 ); // ラ
    put( 0xFF98 , 0x30EA ); // リ
    put( 0xFF99 , 0x30EB ); // ル
    put( 0xFF9A , 0x30EC ); // レ
    put( 0xFF9B , 0x30ED ); // ロ
    put( 0xFF9C , 0x30EE ); // ヲ
    put( 0xFF9C , 0x30EF ); // ワ
    put( 0xFF66 , 0x30F2 ); // ヲ
    put( 0xFF9D , 0x30F3 ); // ン
    put( 0xFF65 , 0x30FB ); // □
    put( 0xFF70 , 0x30FC ); // □
}};
```

```
    private static Map<Integer, Integer> map309C = new HashMap<Integer,
Integer>()
    {{
        put( 0x306F , 0x3071 ); // ば
        put( 0x3072 , 0x3074 ); // び
        put( 0x3075 , 0x3077 ); // ぶ
        put( 0x3078 , 0x307A ); // ぺ
        put( 0x307B , 0x307D ); // ぼ
        put( 0x30CF , 0x30D1 ); // パ
        put( 0x30D2 , 0x30D4 ); // ピ
        put( 0x30D5 , 0x30D7 ); // プ
        put( 0x30D8 , 0x30DA ); // ペ
        put( 0x30DB , 0x30DD ); // ポ
    }};
```

```
    private static Map<Integer, Integer> map309B = new HashMap<Integer,
Integer>()
    {{
        put( 0x309D , 0x309E ); // ズ
        put( 0x30FD , 0x30FE ); // ヴ
        put( 0x3046 , 0x3094 ); // づ
        put( 0x304B , 0x304C ); // が
        put( 0x304D , 0x304E ); // ぎ
        put( 0x304F , 0x3050 ); // ぐ
        put( 0x3051 , 0x3052 ); // げ
        put( 0x3053 , 0x3054 ); // ご
        put( 0x3055 , 0x3056 ); // ざ
    }};
```

```
    put( 0x3057 , 0x3058 ); // じ  
    put( 0x3059 , 0x305A ); // ず  
    put( 0x305B , 0x305C ); // ぜ  
    put( 0x305D , 0x305E ); // ぞ  
    put( 0x305F , 0x3060 ); // だ  
    put( 0x3061 , 0x3062 ); // ぢ  
    put( 0x3064 , 0x3065 ); // づ  
    put( 0x3066 , 0x3067 ); // で  
    put( 0x3068 , 0x3069 ); // ど  
    put( 0x306F , 0x3070 ); // ば  
    put( 0x3072 , 0x3073 ); // び  
    put( 0x3075 , 0x3076 ); // ぶ  
    put( 0x3078 , 0x3079 ); // べ  
    put( 0x307B , 0x307C ); // ぼ  
    put( 0x30A6 , 0x30F4 ); // ヴ  
    put( 0x30AB , 0x30AC ); // ガ  
    put( 0x30AD , 0x30AE ); // キ  
    put( 0x30AF , 0x30B0 ); // グ  
    put( 0x30B1 , 0x30B2 ); // ゲ  
    put( 0x30B3 , 0x30B4 ); // ゴ  
    put( 0x30B5 , 0x30B6 ); // ザ  
    put( 0x30B7 , 0x30B8 ); // ジ  
    put( 0x30B9 , 0x30BA ); // ス  
    put( 0x30BB , 0x30BC ); // ゼ  
    put( 0x30BD , 0x30BE ); // ソ  
    put( 0x30BF , 0x30C0 ); // タ  
    put( 0x30C1 , 0x30C2 ); // チ  
    put( 0x30C4 , 0x30C5 ); // ツ  
    put( 0x30C6 , 0x30C7 ); // デ  
    put( 0x30C8 , 0x30C9 ); // ド  
    put( 0x30CF , 0x30D0 ); // バ  
    put( 0x30D2 , 0x30D3 ); // ビ  
    put( 0x30D5 , 0x30D6 ); // ブ  
    put( 0x30D8 , 0x30D9 ); // ベ  
    put( 0x30DB , 0x30DC ); // ボ  
    put( 0x30EF , 0x30F7 ); //  
    put( 0x30F0 , 0x30F8 ); //  
    put( 0x30F1 , 0x30F9 ); //  
    put( 0x30F2 , 0x30FA ); //  
    }  
};  
}
```

デモで使う表示メソッドを分離。

### MyDemoMethod.java

```
package myKanjiDemos;  
  
import java.util.EnumSet;  
import java.util.List;
```

```
import myKanjiDemos.MyStringToChars.CharsNormalize;

public class MyDemoMethod {

    public static void charDisp(String str, EnumSet<CharsNormalize>
normalize)
    {
        List<List<Integer>> chars =
MyStringToChars.parseToCodepoints(str, normalize);
        String rebuildStr = MyStringToChars.makeStringFromList(chars);

        System.out.println("-----");
        System.out.println("Str      : " + str);
        System.out.println("StrLen   : " + str.length());
        System.out.println("RebuildStr : " + rebuildStr);
        System.out.println("RebuildLen : " + rebuildStr.length());
        System.out.println("parseOption : " + normalize);

        StringBuilder sbChars = new StringBuilder();
        StringBuilder sbCodeStr = new StringBuilder();

        for(int pos=0; pos<chars.size(); pos++)
        {
            sbChars.setLength(0);
            sbCodeStr.setLength(0);

            for(int idx=0; idx<chars.get(pos).size(); idx++)
            {
                sbChars.appendCodePoint(chars.get(pos).get(idx));
                if (idx != 0) sbCodeStr.append( ", " );
                sbCodeStr.append( "u+" +
Integer.toHexString(chars.get(pos).get(idx)) );
            }

            System.out.printf("Pos %7d : %s %s\n", pos,
sbChars.toString(), sbCodeStr.toString());
        }
    }
}
```

From:

<https://wiki.hgotoh.jp/> - 努力したWiki

Permanent link:

<https://wiki.hgotoh.jp/documents/java/java-002>

Last update: **2024/11/01 16:30**

