

.Deb

銀河系唯一のDebian専門誌

2015年5月23日

特集：自然言語処理チームとパッケージ




下 ビア ア シ 勉強 会

目次		nlp-ja) とパッケージ	5
1	事前課題	4.1 NOTICE	5
1.1	野島	4.2 pkg-nlp-ja	5
1.2	wskoka	4.3 管理パッケージ	5
1.3	koedoyoshida	4.4 その他の NLP パッケージ	5
1.4	dictoss	4.5 何ができるか	5
1.5	yy-y-ja-jp	4.6 応用例	6
1.6	myokoym	4.7 動作原理	6
2	Debian Trivia Quiz	4.8 解析の手がかり	6
3	最近の Debian 関連のミーテ ィング報告	4.9 アルゴリズム	6
3.1	第 125 回東京エリア Debian 勉強会	4.10 辞書探索	7
4	自然言語処理チーム (pkg-	4.11 トライ (Trie)	7
		4.12 Double Array	7
		4.13 辞書	7
		4.14 単語の追加: KAKASI	8
		4.15 単語の追加: ChaSen	8
		4.16 単語の追加: MeCab	8
		4.17 参考	8

1 事前課題

野島 貴英



今回の事前課題は以下です:

1. 本日、何の作業をやるかを宣言ください。
2. (オプション) どこで今回の勉強会の開催を知りましたか?
3. (オプション) 何について聞きたい/参加者と話をしたいですか?

この課題に対して提出いただいた内容は以下です。

1.1 野島

1. Q.hack time に何をしますか?
A. Nook HD+ をそろそろ debian に。
2. (オプション)Q. 何について聞きたい/参加者と話をしたいですか?
A. ソフトウェア自由を守り通す事に対して、何が出来るかについて。

1.2 wskoka

1. Q.hack time に何をしますか?
A. MIPS Debian の移植
2. (オプション)Q. どこで今回の勉強会の開催を知りましたか?
A. その他

1.3 koedoyoshida

1. Q.hack time に何をしますか?
A. DDTSS,PyconJP 関連
2. (オプション)Q. どこで今回の勉強会の開催を知りましたか?
A. 友達や知り合いから直接

DDTSS: <http://ddtp.debian.net/ddtss/index.cgi/ja>

1.4 dictoss

1. Q.hack time に何をしますか?
A. kFreeBSD の IPsec 関連を調べる

2. (オプション)Q. どこで今回の勉強会の開催を知りましたか?
A. Debian JP のメーリングリスト

1.5 yy-y-ja-jp


1. Q.hack time に何をしますか?
A. DDTSS
2. (オプション)Q. どこで今回の勉強会の開催を知りましたか?
A. その他
3. (オプション)Q. 何について聞きたい/参加者と話をしたいですか?
A. DDTSS

1.6 myokoym

1. Q.hack time に何をしますか?
A. Groonga のビルドをしながら、Debian で英語の形態素解析する方法を調べます。
2. (オプション)Q. どこで今回の勉強会の開催を知りましたか?
A. Twitter (@tokyodebian)
3. (オプション)Q. 何について聞きたい/参加者と話をしたいですか?
A. 英語の形態素解析のパッケージについて聞きたいです。

2 Debian Trivia Quiz

野島 貴英



Debian の昨今の話題についての Quiz です。

今回の出題範囲は `debian-devel-announce@lists.debian.org` や `debian-news@lists.debian.org` に投稿された内容などからです。

問題 1. Jessie が無事リリースされました。いつだったでしょうか？

- A 2015/4/11
- B 2015/4/18
- C 2015/4/25

問題 2. Jessie で初めて追加されたものではないものが混ざっています。どれ？

- A Debian Games Blend
- B OpenJDK
- C androidsdk-tools

問題 3. Debian GNU/Hurd 2015 も 2015/4/30 にリリースされました。心臓部の GNU Mach のバージョンはいくつ？

- A 1.6
- B 1.5
- C 1.4

問題 4. 2015 年の GSoC に採択された、Debian MIPS ports についての開発内容は次のどれ？

- A 多数のビルド出来ないパッケージを、ちゃんとビルドできるようにする。
- B 新しい MIPS CPU への対応
- C 新しい MIPS CPU 搭載製品への対応

問題 5. 遂に `http.debian.net` が `debian.org` のインフラに移動となりました。新しい URL はどれ？


- A `http://http.debian.org/debian`
- B `http://httpredir.debian.org/debian`
- C `http://www.debian.org/`

問題 6. debian への `libdvdcss/ZFS` パッケージ搭載の件について、2015/5 の Bit From DPL で報告された状況は以下のどれ？

- A DPL がいろいろ議論して回っている状況
- B 搭載日確定した
- C 搭載を諦めた

3 最近の Debian 関連のミーティング報告

野島 貴英




3.1 第 125 回東京エリア Debian 勉強会

- 場所はスクウェア・エニックスさんのセミナールームをお借りしての開催でした。
- 参加者は 13 名でした。
- セミナ内容はまえだこうへいさんによる「.deb から Python パッケージへの変遷」でした。
- 残りの時間で hack time を行い、成果発表をしました。
- 宴会の代わりに、「祥龍房 新宿イーストサイドスクエア店」で夕食会をやりました。

セミナはまえださんにより、Python パッケージのローカル Debian CI に関する発表と、Python に関する Debian 公式パッケージの考察が行われました。大統一 Debian 勉強会から、毎年発表のはや 3 年越しのシリーズものとなります。昨今の言語関係の流行りや事情から、言語のパッケージを Debian のパッケージ化を検討した方が良い場合と、あまり向かない場合がある状況とのことです。会場に Haskell の詳しい人、Perl に詳しい人がおり、様々に議論がなされました。

4 自然言語処理チーム (pkg-nlp-ja) とパッケージ

野首 貴嗣



4.1 NOTICE

私は専門家ではありません。

4.2 pkg-nlp-ja

Debian における自然言語処理パッケージの管理 <https://alioth.debian.org/projects/pkg-nlp-ja/>

4.3 管理パッケージ

- ChaSen
 - dirtts (Double Array 実装)
- 辞書
 - ipadic
 - naist-jdic
 - unidic

4.4 その他の NLP パッケージ

- 解析
 - MeCab
 - Juman
 - 変換
 - Anthy (pkg-anthy)
 - KAKASI
 - mozc
- * 変換については pkg-ime で管理

4.5 何ができるか

形態素解析

- 形態素 (単語) を調べる
- 単語の属性情報を得る
 - － 品詞・読み等
 - * 辞書に依存

ChaSen, MeCab, Juman ref:<http://www.phontron.com/nlptools.php?lang=ja>

4.6 応用例

- 検索エンジン
 - － 転地インデックスの作成
 - － Groonga, Namazu 等
- 音声合成 (Text-to-Speech)
 - － open-jtalk
- n
- 分かち書き
 - － word2vec の下処理
- かな漢字変換

4.7 動作原理

- 解析対象を確からしい単位で分割
 - － 例: 「東京都府中市」
 - * x 「東」「京都」「府」「中」「市」
 - * o 「東京」「都」「府中」「市」
 - － 単純なルールでは処理できない

4.8 解析の手がかり

- － マッチする単語の長さ
 - * 最長一致 (KAKASI)
- ref: KAKASI の実装と課題
- － 品詞情報の利用
 - * 前後に来やすい品詞のつながり
 - * 単語のつながり
 - * 単語の頻度/スコア
- － 確率
 - * 出現率、接続確率

4.9 アルゴリズム

- － コスト最小法
 - * ChaSen
 - － CRF (条件付き確率場)
 - * MeCab
- ref: 日本語形態素解析入門 (pdf)

4.10 辞書探索

Common Prefix Search

- 同じ接頭語を持つデータを高速に検索

アルゴリズム

- トライ
 - パトリシアトライ
- Double Array
 - darts パッケージ

4.11 トライ (Trie)

文字単位の木構造

漢-->字-->化

```
|      |
|      +-->語
+-->音
```

ref: <http://ja.wikipedia.org/wiki/基数木>

4.12 Double Array

トライ構造を 2 つの配列で表現

- BASE 配列 (子ノード番号へのオフセット)
- CHECK 配列 (親ノード番号)
 - 単純な状態遷移表だと疎な配列になる
 - 構築に計算が必要
 - * 配列の空き要素を見つける必要がある
 - * 動的な更新には向かない

ref: ダブル配列の実装方法

4.13 辞書

- KAKASIDIC(kanwadic)
 - SKKDIC ベース
- ipadic
 - ChaSen, MeCab
- naist-jdic
 - ChaSen, MeCab
- jumandic
 - MeCab, JUMAN

4.14 単語の追加: KAKASI

辞書ファイルの作成 (EUC-JP)

```
# よみ [空白] 漢字  
けいさんしょう 経産省  
けいざいさんぎょうしょう 経済産業省
```

kakasi コマンドの引数に辞書のパスを追加

```
$ echo '日本の経産省' | kakasi -w -iutf8 -outf8 ./extdic  
日本 の 経産省  
$ echo '日本の経産省' | kakasi -w -iutf8 -outf8  
日本 の 経産省
```

4.15 単語の追加: ChaSen

- ipadic のソースを取得
- 追加したい単語の意味に近いものを探す
- そのエントリーをコピーし、スコアはそのまま単語を修正する
- ./configure && make

注: スコアを計算するツールが付属していない

4.16 単語の追加: MeCab

1. ChaSen と同じ方法
 - 活用のある品詞はすべて開く必要がある
2. mecab-cost-train で正確なコストを算出
 - 元となるコーパスを用意する必要がある
 - cf: mecab-ipadic-neologd
 - MeCab の IPA 辞書を再学習させてみる
 - MeCab の辞書をカスタマイズする

4.17 参考

自然言語処理ツール

<http://www.phontron.com/nlptools.php?lang=ja>

日本語で読める自然言語処理のチュートリアルスライドまとめ

<http://blog.unnono.net/2015/04/nlp-tutorial.html>



Debian 勉強会資料

2015年5月23日 初版第1刷発行

東京エリア Debian 勉強会 (編集・印刷・発行)
