பைத்தான் வழி தமிழ் இயல்மொழி ஆய்வுகள் - ஓப்பன் தமிழ்

வழங்குவது - திரு. முத்தையா அண்ணாமலை

எழில் மொழி அறக்கட்டளை, கலிபோர்னியா

மினஞ்சல்: ezhillang@gmail.com

இடம்: ஜனவரி 18ஆம் நாள் 2020, ரொறன்ரோ பல்கலைக்கழகம், ஸ்கார்பரோ.

ஓப்பன் தமிழ் நிரல் தொகுப்பைக் கொண்டு எப்படி தமிழ் இயல் மொழி ஆய்வுகளுக்கான சேவைகளை செயல்படுத்தலாம் என்று பார்க்கலாம்

பங்களிப்பாளர்கள் பட்டியலில் காணவும்: https://github.com/Ezhil-Language-Foundation/open-tamil/blob/master/CREDITS

உரிமம் : MIT திறமூல உரிமம்

சுட்டி: https://pypi.org/project/Open-Tamil/ வரிசை எண்: 0.96

Library
UNIVERSITY OF TORONTO
SCARBOROUGH

Digital Tamil Studies - எண்ணிமத் தமிழியல்

© 2020, எழில் மொழி அறக்கட்டளை.

¶˝ ∞∂È ï Ω• º±∂Â!

பங்களிப்பு - வளர்ச்சி - நிறுவுதல்

- 2013-அளவில் எழில் மொழி வழி
- கிட் https://github.com/Ezhil-Language-Foundation/open-tamil
- மாதிரி வலைதளம் http://Tamilpesu.us

நிறுவுதல் - Installation

- Python3 setup required
- $ pip install –upgrade open-tamil>=0.9

இணையத்தில் பரிசோதிப்பது

Google CoLab – இணையம் வழி நிரல்களை பழகுதல்

என்ன :

கூகிள் நிறுவனம் CoLab – Code-Laboratory என்ற ஒரு சேவையை பெரும்பாலும் பைத்தான் வழி செயற்கையறிவு நிரல்களை (TensorFlow கொண்டு) உருவாக்க பொதுமக்களுக்கு வழ்ங்கியுள்ளது. ஆனால் இதனை தமிழ் கணிமைக்கு பயன்படுத்தலாமா ? ஆம்.

Try out the NoteBook https://bit.ly/2Ru90y9

சேவைகள் - தமிழ்பேசு வலைதளம்

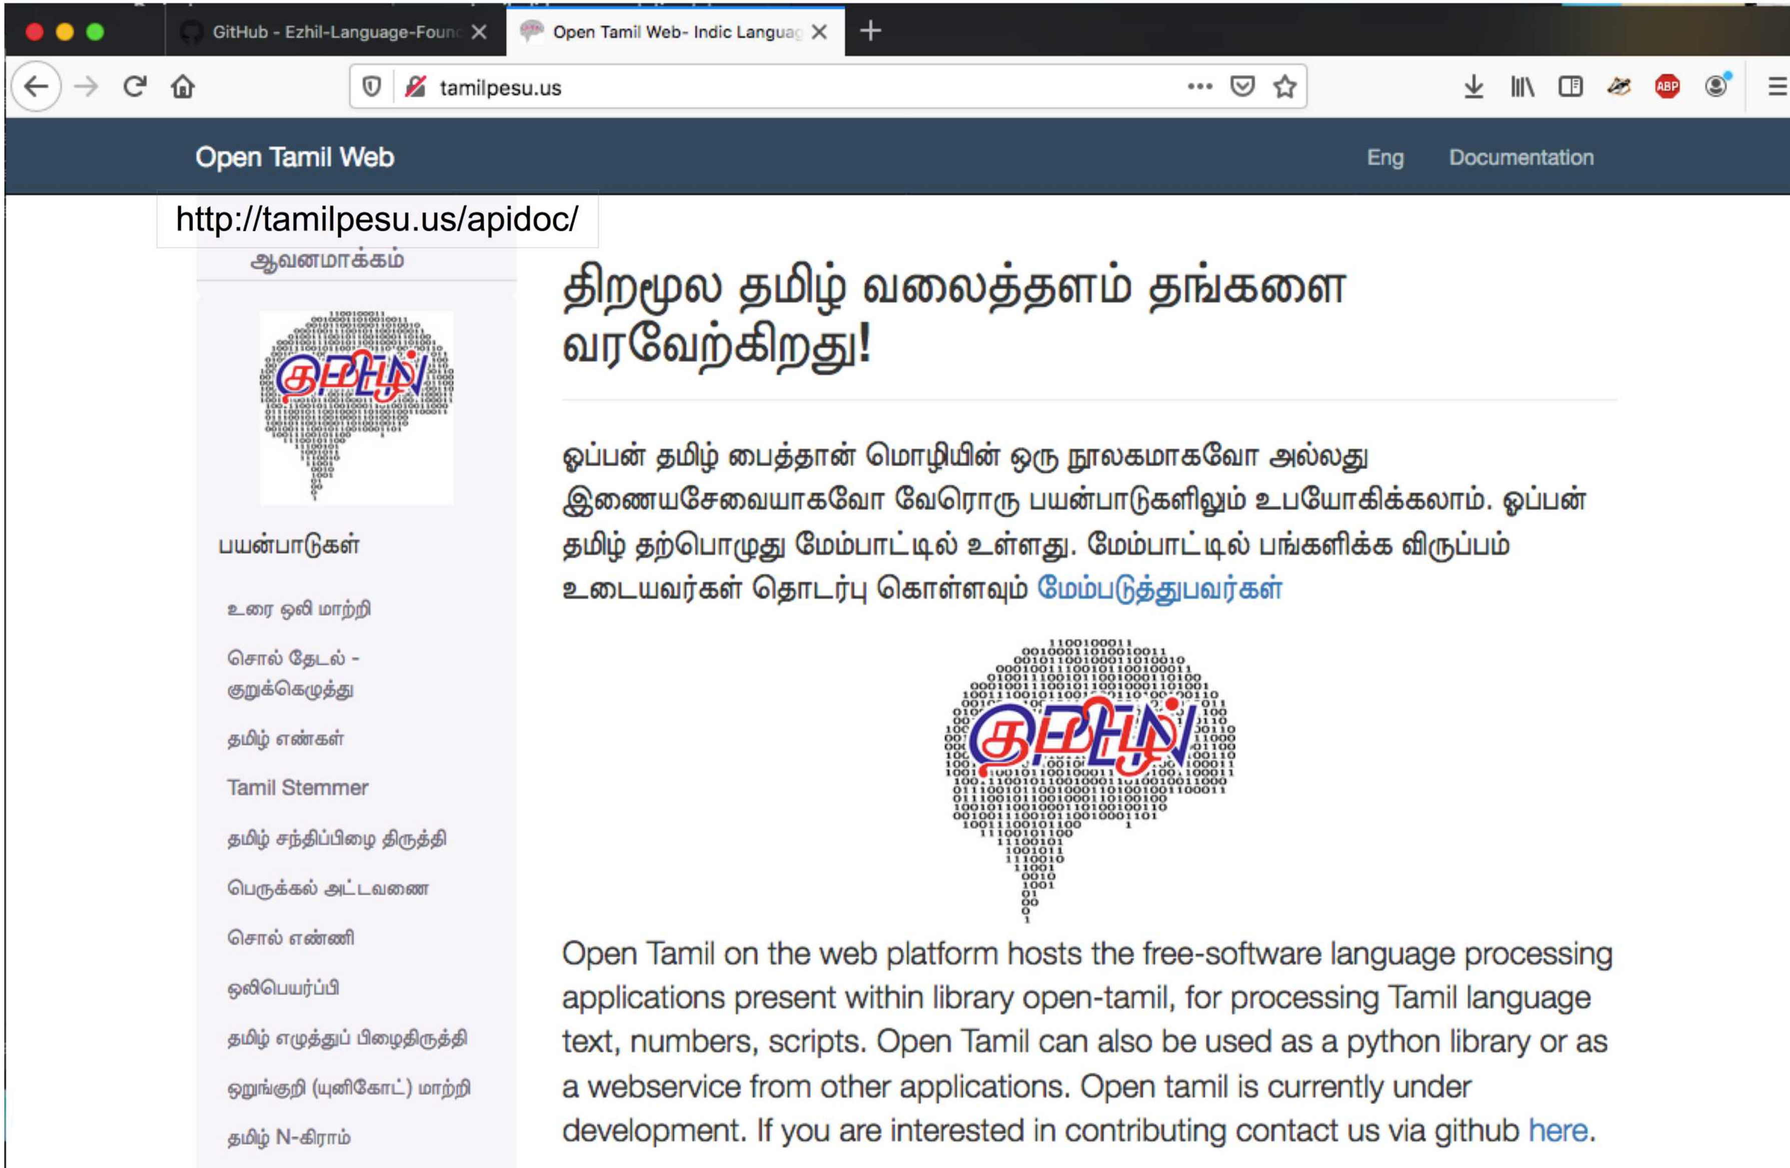

ஓப்பன் தமிழ் நிரல்தொகுப்பு

பைத்தான் வழி தமிழ் இயல்மொழி ஆய்வுகள் - ஓப்பன் தமிழ்

- 2012-இல் இருந்து பொது வெளியில் இருக்கின்றது
- இயல் மொழி உரை ஆய்வுகளுக்கு பயன்படுத்தலாம்
- 6-ஆண்டுகளாக தொடர்ந்து களப்பணி.
- பலர் பங்களிப்புகளுடன் தொலைவில் இணையம் வழி குழுவாக செயல்படும் திட்டம்.
- ஏரக்குறைய 30-ஆயிரம் வரி பைத்தான் நிரல் அளவு.
- அனைத்தும் பரிசோதிக்கப்பட்ட அல்கோரிதங்கள்.
- பயனாளர்கள்: எழில், பைதமிழ்,

எழுத்தின் குறியீடு

- என்கோடிங் - குறியீட்டு வித்தியாசத்தில் தமிழ் உரைகள்
- எழுத்துரு சம்பந்தப்பட்ட குறியீடுகள்
    - அவற்றின் தேடல்; எ.கா: பயனருக்கு அறிமுகமில்லாத குறியீடை (மென்பொருள் அரு அறிந்தவரை, தேடி பதில் அளிக்கும்.

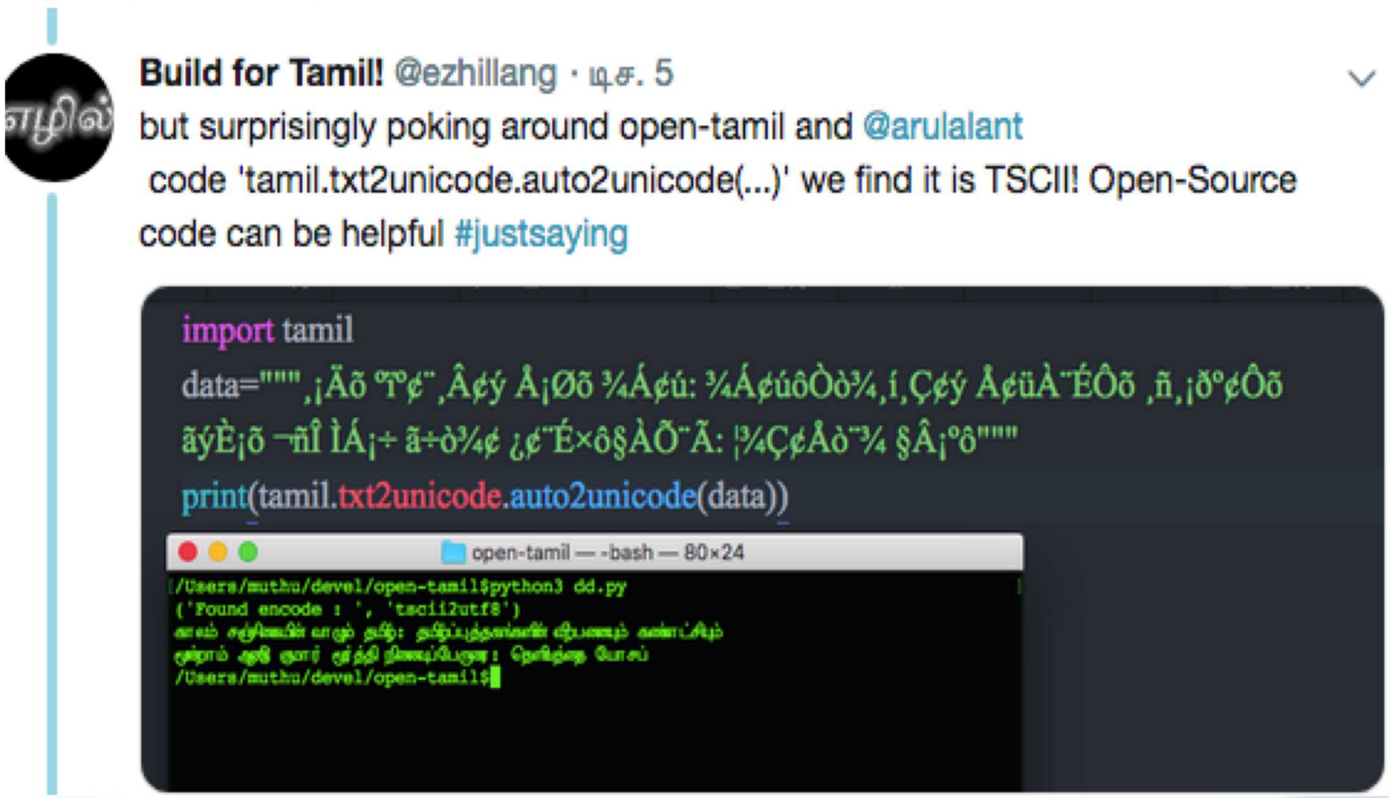

பொது எழுத்துணரும் சேவைக

- நேக்கு : ஏதேனும் ஒரு குறியீட்டில் இருந்து ஒருங்குறி-UTF-8இல் ஆய்வுகள் நடத்தப்படும்.
- தமிழ் அகரமுதலி : உயிர், மெய், உயிர்மெய் எழுத்துக்கள், தமிழ் எண், மரபின் பால் உள்ள சில் குறியீடுகளும் இருக்கு.
- தமிழ் உரை சொற்களை எழுத்து வரிசைகளாக பிரிக்கலாம்!
- விவரங்கள் அடுத்த காட்சியில்

tamil

open-tamil provides Python package 'tamil' with ability to,

1. map unicode code-points to Tamil letters - basic but important parsing - in a routine called get_letters from a Tamil word `tamil.utf8.get_letters` and `tamil.utf8.get_letters_iterable` API return the Tamil letters from the unicode points of a normalized unicode string. These routines are written with efficiency in mind, and tested for accuracy.
2. work with vowels (uyir) and consonants (mei), compound, uyir-mei letters
3. reverse letters in Tamil word

பொது எழுத்துணரும் சேவைக

Open-tamil ச|வா|வால்|வாசல்|சவால்

- Generate Anagrams
- Generate Combinations of words
- Partial words
- Check if word is a palindrome

```
import tamil
from solthiruthi.dictionary import *
TVU_dict = DictionaryBuilder.create(TamilVU)
word = u'சவால்'
q=list(tamil.wordutils.combinagrams(word,TVU_dict))
print(u'|'.join(q))
```

which gives you the output, ச|வா|வால்|வாசல்|சவால்

உரை சுருக்கி

- அசோக் இராமசந்திரணின் உத்தி - https://github.com/AshokR/TamilNLP
- தமிழில் நிறுத்தச் சொற்கள் பட்டியல் வழங்கினார். Summarization அல்கோரிதங்கள்.

உள்ளீடு அளவு: 72 சொற்கள், வெளியீடு அளவு: 8 சொற்கள். சுருக்கம் 9.

தமிழ் பேசு.us - ஓபன் தமிழ் உரை சுருக்கம்

தமிழ் பேசு.us இருந்தபோதிலும் இலக்கணம் தெரிந்து எழுதினால் சந்திப்பிழைகள் நேராது.

மீதி இரண்டு வல்லின ஒற்றெழுத்துக்களான ட், ற் ஆகிய இரண்டால் சந்திப்பிழை நேராது. எனவே இவை பற்றிக் கவலைப்பட வேண்டாம். வல்லினம் மிகும் இடங்களையும் மிகா இடங்களையும் தெரிந்து கொண்டால் சந்திப்பிழை அல்லது ஒற்றுப்பிழை நேராது. பெரிய எழுத்தாளர்களைக் கூட ஏமாறச் செய்யும் பிழை சந்திப்பிழை. பற்றி அதிகம் கவலைப்படத் தேவையில்லை என்று சொல்லுவோரும் உள்ளனர். இப்பிழையைச் சரிவரப் பார்க்கவில்லையென்றால் பொருள் கூட மாறுபடக்கூடும். நம்மில் சிலருக்கு இலக்கணம் தெரியாது என்றாலும் சந்திப்பிழையில்லாமல் எழுதிவிடுகிறோம். எழுதும்போது க், ச், த், ப் மிகும் இடங்களில் அழுத்தி உச்சரித்துப் படித்துப் பார்த்தால் பிழையைத் தவிர்க்கலாம். இருந்தபோதிலும் இலக்கணம் தெரிந்து எழுதினால் சந்திப்பிழைகள் நேராது.

அழி | சுருக்கம்

எண் -> எழுத்து மாற்றி

- tamil.numeral module
- இந்திய இயல்வழி
- அமெரிக்க இயல்வழி
- எழுத்தினை ஒலிக்கவும் சில ஒலிமாற்றிகள்
    - ஆண்/பெண் குரல்களில்

numeral - convert a given number (integer) into a numeral in Indian or American based system. e.g. following call will return the string

```
>> tamil.numeral.num2tamilstr_american( long(1e7) )
u"பத்து மில்லியன்",
```

தமிழ் சொல்திருத்தி

- spell, solthiruthi module
- ஆய்வு நிலையில் ஒரு சொல்திருத்தி
- அதன்வழி வந்த தகவல்-தரவமைப்புகள் (data structures)

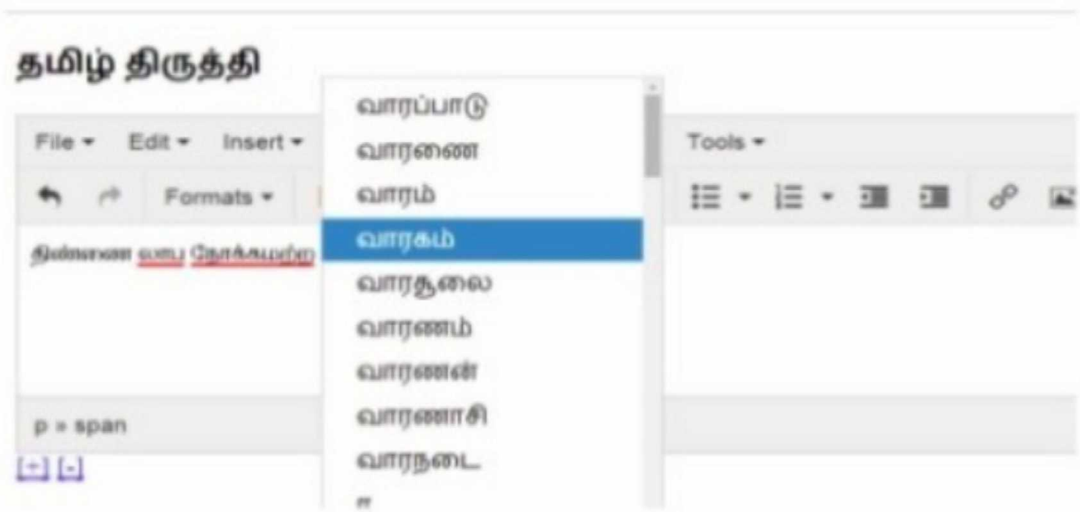

Integration of solthiruthi spell-checker from open-tamil with TinyMCE web editor

Work in progress

வேர்சொல் பகுப்பு - stemmer

- தாமோதரன் அவரது நிரலை ஓப்பன் தமிழில் இணைத்ததன் வழி வந்த உத்தி
- வதிகள் வழி உறுவாக்கப்பட்ட வேர்சொல் பகுப்பாய்வு
- http://www.kaniyam.com/releasing-tamil-stemmer-using-open-tamil/

```
from tamilstemmer import TamilStemmer


wordlist = [u'மலைகள்',u'பாடுதல்',u'ஓடினான்']
#expected = [u'மலை',u'பாடு', u'ஓடி']


ta_stemmer = TamilStemer()


for word in wordlist:
  ta_stemmer.stemWord(word)
```

தமிழ் சந்திப்பிழை திருத்தி

- நித்தியா - சீனிவாசன் உருவாக்கிய உத்தி.
- https://github.com/nithyadurai87/tamil-sandhi-checker

```
# -*- coding: utf-8 -*-
# Test for sandhi rules
#
# This file is part of 'tamil-sandhi-rules' package tests
#

# setup the paths
from sandhitests import PYTHON3, unittest
from tamilsandhi.sandhi_checker import safe_splitMeiUyir, check_sandhi, sandhi_checker_file_IO, Results
import tamil.utf8 as utf8
import codecs
import os


if PYTHON3:
    class long(int):
        pass

class SandhiTest(unittest.TestCase):
    def test_integration(self):
        golden = u"அங்குக் கண்டான் அந்த பையன். எத்தனைப் பழங்கள்? கண்டவாறு சொன்னான், ஐந்து சிறுவர்கள், கத்தியோடு நின்றான்,கத்திகொண்டு குத்தினா
        source =u"அங்குக் கண்டான் அந்த பையன். எத்தனை பழங்கள்?  கண்டவாறு சொன்னான், ஐந்து சிறுவர்கள், கத்தியோடு  நின்றான்," \
                 u"கத்திகொண்டு குத்தினான், வீட்டிலிருந்து  சென்றான், கை குழந்தை,  கற்று கொடுத்தான், குரங்கு குட்டி, விறகு கடை, பொது பணி,  தேர்வு
                 u"எனக்கு கொடு, வீட்டினின்று வெளியேறினான், வர சொன்னான், என்னுடைய புத்தகம், எனது புத்தகம், குறிஞ்சி தலைவன், தேங்காய் சட்னி,  த
        fixed,res = check_sandhi(source)
        fixed_string = u" ".join(fixed)
        #import pprint
        #pprint.pprint(u"%s"%fixed_string)
        self.assertEqual(fixed_string,golden)
        self.assertTrue(isinstance(res,Results))
        self.assertEqual(res.counter,46)
```

எங்களது பயனாளர்கள்

- Tamil NLP
    - அசோக் இராமசந்திரன்
- Pytamil
    - தமிழில் பைத்தன் மொழி நிரல் எழுதலாம்!
- சந்திப்பிழை திருத்தி
- ஏழில் - தமிழ் கணினி மொழி
- தமிழ்பேசு - tamilpesu.us

மேலும் பார்க்க

- தமிழா குழுமம் : கிட் https://github.com/thamizha
- எழில் வலைப்பூ: https://ezhillang.blog
- கணியம் அறக்கட்டளை: www.kaniyam.com
- 2018 INFITT Conference presentation, “Growth and Evolution of Open-Tamil,”. Link: https://www.slideshare.net/ezhillang/growth-and-evolution-of-opentamil
- ஓப்பன்-தமிழ் INFITT (உத்தமம்) மாநாடு வழங்கல்கள், மற்றும் ஆய்வுக்கட்டுரைகள்
- https://github.com/Ezhil-Language-Foundation/open-tamil/tree/master/conference-publications
  - 2019, “Algorithms for certain classes of Tamil spelling correction”
  - 2018, “Growth and evolution of Open-Tamil”
  - 2017, “Open-Source Landscape – opportunities and challenges”
  - 2016, “Developments in Open-Tamil”
  - 2014, “Open-Tamil project”

நன்றி

பங்களிபாளர்கள் சந்திப்பு (2018)