"urumARRi": Online Unicode Conversion of TSCII web page - A Server Side Approach

Sathish Kumar Nithianandam*, Sudhakar Balakrishnan & (Late) Arun Prasath Egambaram
New York, USA

Introduction

This paper addresses needs of Unicode platform users to view TSCII pages without browser setup or font download. Paper provides a solution for TSCII web page publishers to support Unicode users.

"உருமாற்றி" converts TSCII based web page to Unicode page and serves it to the userís browser from Server Side. TSCII web page publishers can add a "urumARRi" location link in their URL for automatic Unicode conversion.

"உருமாற்றி" can also do the reverse, i.e., convert Unicode pages to TSCII web pages for users who are on Unicode non-compatible operating systems like Microsoft Windows 95 and Windows 98.

TSCII web page publishers can extend their support to Unicode users by adding a urumARRi location link with their URL to their pages. Tamil Unicode web page publishers and bloggers can extend their support to TSCII users.

A snapshot of our TSCII to Unicode implementation is showin in **Fig. 1**: User's browser using "urumARRi" script to view TSCII web page from www.kalkiweekly.com[1] (in Unicode page with Latha Font)

Key Features

* View TSCII web pages without any browser setup or font download in Unicode enabled browsers.
* TSCII web page publishers can extend their support to Unicode users by adding a urumARRi location link with their URL to their pages.
* Enables Search Engines to index TSCII web pages as Unicode pages.
* Multiple online access methods
*   urumARRi Homepage (URL Input box in the page).
* Direct Input URL (type www.urumARRi.com/convert?http://www.infitt.org in browser address bar).
  * Using Bookmarklet / Favlet.

[1] www.kalkiweekly.com was chosen to illustrate the parsing of complex HTML by urumARRi.

- "tamizpaTTai"[2] Internet Explorer tool bar.

- Simple implementation, once hosted it is accessible to whole community.
- Server Side solution implemented using Perl v5.8.4 which adds portability and flexibility.
- Highly efficient, low memory foot print code.
- Open source solution for extendibility by Tamil community.
- Tested extensively on Project Madurai TSCII releases & www.infitt.org TSCII web pages.

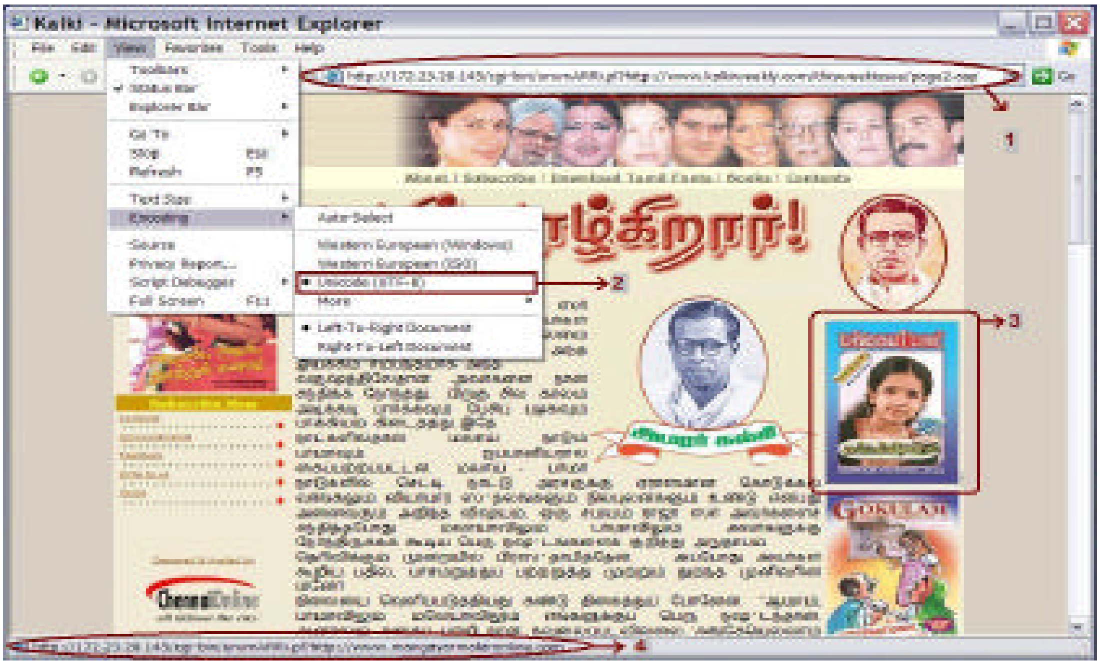

1. "urumARRi" script on a server serving a TSCII web page, Direct Input URL method is used.; 2. The output web page is identified as Unicode (UTF-8) by Microsoft Internet Explorer browser; 3 & 4. New modified link composed of "உருமாற்றி" location with the selected link has been shown.

Script Logic

- Retrieves and parses the input HTML from the given URL.
- Converts all TSCII v1.7 characters into Unicode characters (100% accuracy), simple approach. Coverts all Unicode characters into TSCII characters for Unicode to TSCII coversion.
- Changes META tag http-equiv argument char-set value from ìx-user-definedî to ìutf-8î to hint the browser about the served page type.
- Changes all links in the web page as follows:
- Converts links to other HTML pages to have the script location with the link.
- Converts links to frames to support conversion of other frames inside it.
- Images and links to images are retained as in the original page.
- Converts relative links to absolute links.
- Retains English characters as it is.

[2] Refer to adjoining paper "tamizpaTTai"

A snapshot of our Unicode to TSCII implementation is shown in **Fig.2** : User's browser using urumARRi script to view TSCII web page from www.thoughtsintamil.blogspot.com (in TSCII page with TSC_Avarangal Font)

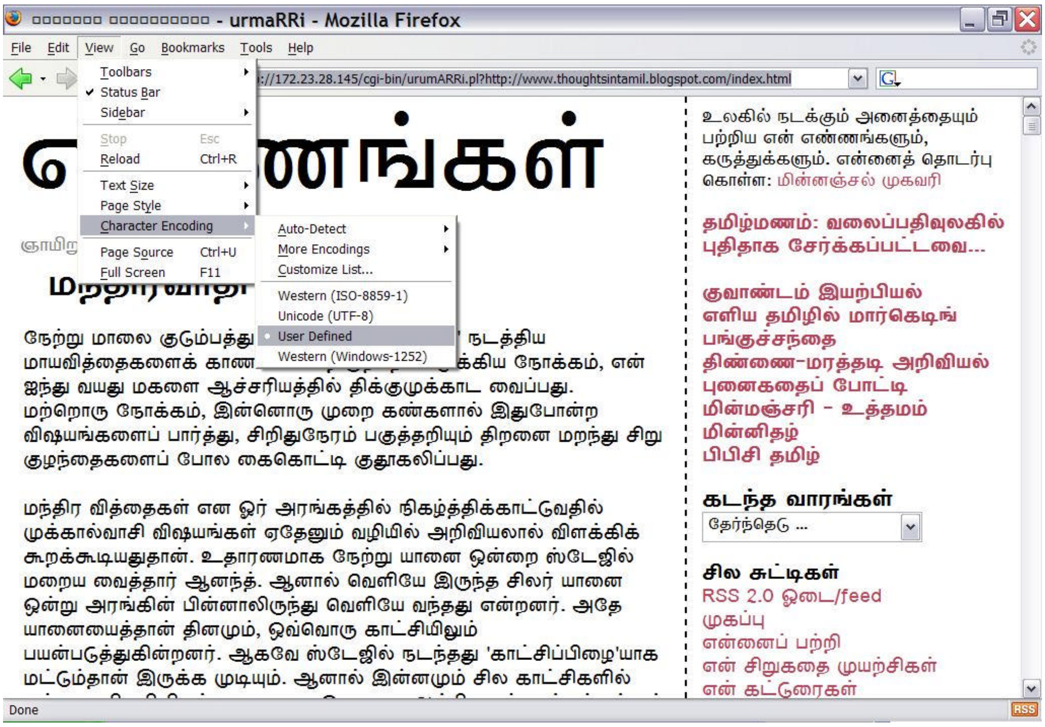

://172.23.28.145/cgi-bin/urumARRi.pl?http://www.thoughtsintamil.blogspot.com/index.html

எ ணங்கள்

ஞாயிறு

மந்திரவாதி

நேற்று மாலை குடும்பத்து ' நடத்திய மாயவித்தைகளைக் காண க்கிய நோக்கம், என் ஐந்து வயது மகளை ஆச்சரியத்தில் திக்குமுக்காட வைப்பது. மற்றொரு நோக்கம், இன்னொரு முறை கண்களால் இதுபோன்ற விஷயங்களைப் பார்த்து, சிறிதுநேரம் பகுத்தறியும் திறனை மறந்து சிறு குழந்தைகளைப் போல கைகொட்டி குதூகலிப்பது.

மந்திர வித்தைகள் என ஓர் அரங்கத்தில் நிகழ்த்திக்காட்டுவதில் முக்கால்வாசி விஷயங்கள் ஏதேனும் வழியில் அறிவியலால் விளக்கிக் கூறக்கூடியதுதான். உதாரணமாக நேற்று யானை ஒன்றை ஸ்டேஜில் மறைய வைத்தார் ஆனந்த். ஆனால் வெளியே இருந்த சிலர் யானை ஒன்று அரங்கின் பின்னாலிருந்து வெளியே வந்தது என்றனர். அதே யானையைத்தான் தினமும், ஒவ்வொரு காட்சியிலும் பயன்படுத்துகின்றனர். ஆகவே ஸ்டேஜில் நடந்தது 'காட்சிப்பிழை'யாக மட்டும்தான் இருக்க முடியும். ஆனால் இன்னமும் சில காட்சிகளில்

உலகில் நடக்கும் அனைத்தையும் பற்றிய என் எண்ணங்களும், கருத்துக்களும். என்னைத் தொடர்பு கொள்ள: மின்னஞ்சல் முகவரி

தமிழ்மணம்: வலைப்பதிவுலகில் புதிதாக சேர்க்கப்பட்டவை...

குவாண்டம் இயற்பியல்
எளிய தமிழில் மார்கெடிங்
பங்குச்சந்தை
திண்ணை-மரத்தடி அறிவியல்
புனைகதைப் போட்டி
மின்மஞ்சரி - உத்தமம்
மின்னிதழ்
பிபிசி தமிழ்

கடந்த வாரங்கள்

தேர்ந்தெடு ...

சில சுட்டிகள்

RSS 2.0 ஓடை/feed
முகப்பு
என்னைப் பற்றி
என் சிறுகதை முயற்சிகள்
என் கட்டுரைகள்

A snapshot of our Unicode to TSCII implementation for web page publishers using urumARRi script on the same server is shown in **Fig. 3**: User's browser using urumARRi script to view Unicode web page from www.sathish.net with a link to dynamically convert into TSCII for TSCII users.

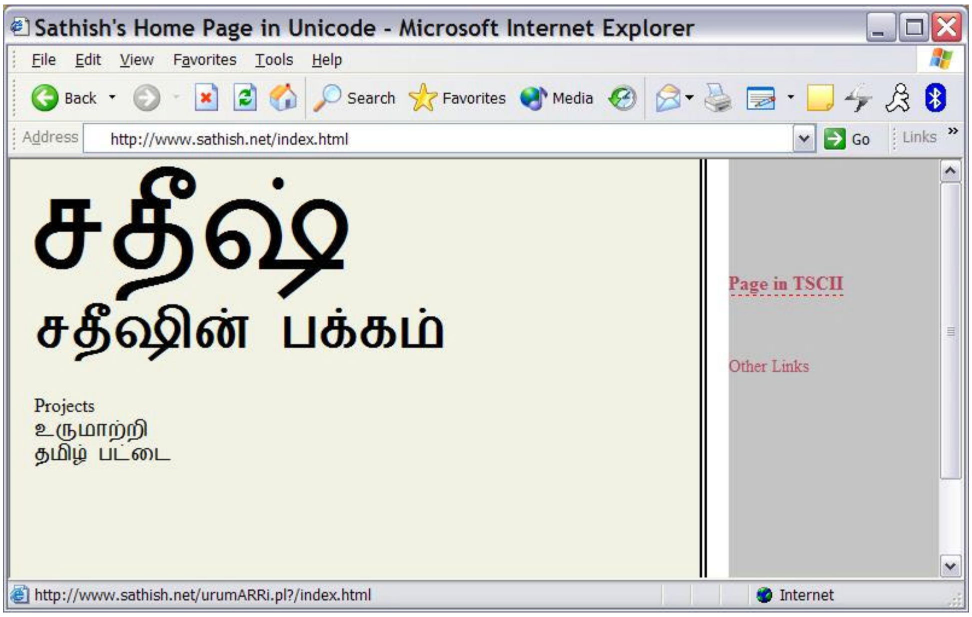
Sathish's Home Page in Unicode - Microsoft Internet Explorer
File Edit View Favorites Tools Help
Back
Search
Favorites
Media
Address
Go
Links
Internet

http://www.sathish.net/index.html

சதீஷ்

சதீஷின் பக்கம்

Projects
உருமாற்றி
தமிழ் பட்டை

Page in TSCII

Other Links

http://www.sathish.net/urumARRi.pl?/index.html

Configurable Options

- Convert HTML pages in current server dynamically without changing any relative links (All options including U2T & T2U are currently environment variables).
- Disable changing links to other domains.
- Batch run the script to bulk convert HTML pages in local machine..

Future Scope

This implementation converts TSCII v1.7 to Unicode, can be extended to the other Tamil encodings TAB and TAM.

Limitations

- Web pages from sites with security feature like cookies and https cannot be converted. Due to privacy concerns, form input/POST requests and server side session management are not implemented.
- Rendering of Unicode pages is slower compared to TSCII pages, as Unicode uses more space and memory.

References

TSCII & Unicode standards
http://www.tamil.net/tscii/
http://www.unicode.org/

Conversion Charts
http://www.tamil.net/tscii/faq5.html
http://www.geocities.com/Athens/5180/tscii4.html
http://www.infitt.org/minmanjari/issue2_1/mm-muthu.html

Tested on TSCII web pages
http://www.projectmadurai.org (http://www.tamil.net/projectmadurai/)
http://www.infitt.org/