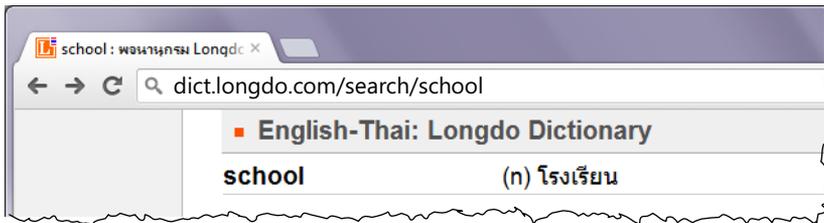


## โปรแกรมแปลคำอังกฤษเป็นไทย

บริการแปลคำอังกฤษเป็นไทย หรือคำไทยเป็นอังกฤษมีอยู่หลายที่ในอินเทอร์เน็ต (ผู้อ่านสามารถค้นวลี “English Thai Dictionary” ด้วยกูเกิลดู) ในหัวข้อนี้จะขอใช้บริการของเว็บไซต์ LONGDO Dict<sup>2</sup> โดยจะเขียนโปรแกรมที่รับคำอังกฤษจากผู้ใช้ทางแป้นพิมพ์ จากนั้นตัวโปรแกรมจะเรียกใช้บริการที่ <http://dict.longdo.com> ได้หน้าเว็บคำแปลเป็นภาษาไทยกลับคืนมา ค้นหาบริเวณที่เก็บคำแปลในหน้าเว็บ แล้วนำคำแปลที่พบแสดงทางจอภาพ คำถามที่ตามมาคือ จะเขียนโปรแกรมต่อกับเว็บไซต์ได้อย่างไร จะส่งคำที่ต้องการหาคำแปลได้อย่างไร และผลที่ได้กลับมาเป็นอย่างไร คำแปลที่ได้อยู่ที่ไหน ?

เริ่มที่สองคำถามแรกก่อน ถ้าอยากทราบว่า “school” แปลว่าอะไร ก็ให้เปิดเว็บเบราว์เซอร์ แล้วไปที่ <http://dict.longdo.com/search/school> จะได้ผลดังรูปที่ 5-7 หากต้องการคำแปลของ “scrape” ต้องไปที่ <http://dict.longdo.com/search/scrape> ดูสองตัวอย่างนี้แล้ว ผู้อ่านจะได้หรือยังว่า ถ้าต้องการหาคำอื่นจะไปทีใด ปัญหาคือจะให้โปรแกรมของเราไปที่เว็บเพจที่ต้องการได้อย่างไร ? ไม่ยาก ใช้ Scanner เช่นเคย แต่แทนที่จะส่ง System.in เพื่ออ่านจากแป้นพิมพ์หรือส่ง new File(...) เพื่ออ่านจากแฟ้ม คราวนี้ส่ง new URLStream(url) เพื่ออ่านจากเว็บที่ตำแหน่ง url แทน<sup>3</sup> ดังตัวอย่างในรหัสที่ 5-18 เป็นการเชื่อมเพื่ออ่านเว็บเพจคำแปลของคำอังกฤษที่เก็บในตัวแปร word เมื่อสร้างตัวอ่านเว็บชื่อ web เสร็จ ก็สามารถใช้เมทอด web.nextLine() ของ Scanner อ่านออกมาทีละบรรทัดเช่นที่เคยทำมา



รูปที่ 5-7 ตัวอย่างการให้บริการแปลคำอังกฤษเป็นไทยด้วย LONGDO

```
String site = " http://dict.longdo.com/search/";
String url = site + word;
Scanner web = new Scanner(new URLStream(url), "UTF-8");
...
```

รหัสที่ 5-18 ส่วนของโปรแกรมอ่านเว็บเพจ

<sup>2</sup> เหตุผลที่เลือกเว็บไซต์นี้ไม่มีอะไรนอกจากความง่ายในการเขียนโปรแกรมเพื่อส่งคำไป และตีความคำแปลที่ได้กลับมา และต้องขอเน้นว่าเนื่องจากโปรแกรมนี้อาศัยเว็บไซต์ภายนอกเครื่องที่สั่งทำงาน ดังนั้นจึงต้องเชื่อมต่อกับอินเทอร์เน็ตก่อนใช้งาน และก็ไม่แน่ว่าจะทำงานได้ เพราะเว็บไซต์อาจไม่พร้อมให้บริการก็เป็นได้

<sup>3</sup> URLStream เป็นคลาสพิเศษของ JLab มีชื่อเต็มว่า jlab.URLStream

คำถามถัดมาคือ ข้อมูลที่อ่านได้จากตัวอ่านเว็บมีรูปแบบเช่นไร รูปที่ 5-8 แสดงบรรทัดต้น ๆ ของข้อมูลในเว็บเพจที่อ่านได้ เมื่อไปหาคำแปลของคำว่า “school” (เครื่องหมาย ... ในรูปแทนข้อมูลมากมายที่ขอไม่แสดงให้ครบ) ข้อมูลเหล่านี้อยู่ในรูปแบบที่เรียกว่า HTML (HyperText Markup Language) <sup>4</sup> ประกอบด้วยเนื้อหาของเอกสาร การกำกับเนื้อความเพื่อบอกความหมาย ลักษณะการนำเสนอในเว็บเบราว์เซอร์ และอื่น ๆ อีกมากมาย

```
<html xmlns:og="http://opengraphprotocol.org/schema/"
xmlns:fb="http://www.facebook.com/2008/fbml">
<head>
  <meta property="og:title" content="คำศัพท์ school: พจนานุกรม Longdo ... />
  <meta http-equiv="Content-Type" content="text/html; charset=utf-8"/>
  ...
</head>
...
HREF="search/school"><b>school</b></A></td><td>[N] โรงเรียน, <b>See also
...
```

รูปที่ 5-8 ตัวอย่างข้อความที่อ่านได้เมื่อต่อไปยังเว็บเพจของ longdo

และก็มาถึงคำถามสุดท้ายคือ แล้วคำแปลอยู่ที่ใด ? สำหรับเว็บไซต์ LONGDO Dict ผู้เขียนได้ศึกษาข้อมูลทีอ่านกลับมา พบว่า คำแปลจะอยู่ในบรรทัดที่มีข้อความ HREF="search/ ตามด้วยคำศัพท์ (ดูบรรทัดก่อนสุดท้ายในรูปที่ 5-8) โดยคำแปลจะพบที่ตำแหน่งหลัง "<td>" และจบที่ตำแหน่งก่อนเครื่องหมายจุลภาค , (เนื่องจากอาจมีคำแปลหลายแบบ <sup>5</sup> เพื่อความง่าย จึงขอค้นและแสดงคำแปลแรกที่พบก็พอ) ภาระส่วนใหญ่ของการเขียนโปรแกรมนี้ก็คือ การหาคำแปลที่ปรากฏในบรรทัดที่มีรูปแบบที่ได้อธิบายมานี้เอง <sup>6</sup>

รหัสที่ 5-19 แสดงโปรแกรมสมบูรณ์เพื่อแปลคำอังกฤษเป็นคำไทย เริ่มด้วยการรับคำจากผู้ใช้ จากนั้น (บรรทัดที่ 9) ใช้ trim เพื่อขจัดช่องว่างซ้ายและขวา ตามด้วยการเปลี่ยนเป็นตัวเล็ก บรรทัดที่ 10 สร้างชื่อของเว็บเพจที่มีคำแปล แล้วสร้างตัวอ่านเว็บ ขอให้สังเกตที่ท้ายคำสั่ง มีการส่งสตริง "UTF-8" ไปด้วย ตรงนี้หมายความว่า เว็บเพจที่จะอ่านนี้มีการเข้ารหัสแบบที่เรียกว่า UTF-8 (ถ้าดูที่ปลายบรรทัดที่ 5 ของรูปที่ 5-8 จะพบข้อความ charset=utf-8 เป็นการระบุว่าเอกสารนี้เข้ารหัสข้อความแบบ UTF-8) ก่อนเข้าวงวนค้นคำแปลในเอกสาร มีการเตรียมตัวแปร thai ให้มีค่าเริ่มต้นเป็น "" และตัวแปร pattern เก็บข้อความที่เราต้องการค้นในเอกสาร

<sup>4</sup> หลังจากใช้เบราว์เซอร์ไปที่เว็บเพจแล้ว หากต้องการดูข้อมูล HTML ที่บรรยายหน้านั้น ให้คลิกเมาส์ปุ่มขวาที่หน้าเอกสาร แล้วเลือกเมนู View Source

<sup>5</sup> รูปที่ 5-7 ไม่ได้แสดงเบราว์เซอร์เต็มจอภาพ แต่ถ้าผู้อ่านลองต่อเว็บไปดูที่หน้านี้ จะพบว่า มีรายละเอียดคำแปลมากกว่าหนึ่งความหมายในหน้านี้

<sup>6</sup> เนื่องจากเว็บเพจถูกออกแบบมาเพื่อนำเสนอเนื้อหาให้คนดู แต่เราต้องการเขียนโปรแกรมให้ “เลือกดู” ส่วนที่สนใจในเว็บเพจ ซึ่งต้องอาศัยการค้นหาข้อมูลในเว็บเพจ เรียกกลวิธีแบบนี้ว่า การขูดเว็บ (web scraping)

การค้นดำเนินไปเรื่อยๆ ๓รอบเท่าที่ยังไม่พบบรรทัดที่มีคำแปล (thai ยังเป็น "") และตัวอ่านเว็บยังอ่านไม่หมด (web.hasNext() เป็นจริง) เมื่ออ่านบรรทัดใหม่เข้ามา ก็ค้นด้วย indexOf ว่ามี pattern หรือไม่ (บรรทัดที่ 18) ถ้ามี ก็ค้น "<td>" ต่อ (บรรทัดที่ 21) โดยเริ่มค้นต่อจากที่พบ pattern และถ้าพบ "<td>" ก็ค้นเครื่องหมาย , ต่ออีกในบรรทัดที่ 24 ถ้าพบอีก คำแปลก็คือสตริงย่อยที่อยู่หลัง "<td>" ไปจนถึงก่อน , ที่พบ (บรรทัดที่ 25) หากไม่พบในบรรทัดที่เพิ่งอ่านมา ก็วนกลับไปอ่านบรรทัดถัดไป โดยที่ thai ยังเป็น "" เมื่อหลุดจากวงวนโดย thai ไม่ใช่ "" แสดงว่า thai เก็บคำแปล ก็แสดงคำแปลนั้นทางจอภาพ (บรรทัดที่ 30) ไม่เช่นนั้นให้แจ้งให้ผู้ใช้ทราบว่าจะไม่พบคำแปล

```
01 import java.util.Scanner;
02 import jlab.URLStream;
03 // โปรแกรมแปลคำอังกฤษเป็นไทย
04 public class English2Thai {
05     public static void main(String[] args) {
06         Scanner kb = new Scanner(System.in);
07         System.out.print("คำ = ");
08         String eng = kb.nextLine();
09         eng = eng.trim().toLowerCase();
10         String url = "http://dict.longdo.com/search/" + eng;
11         Scanner web = new Scanner(new URLStream(url), "UTF-8");
12         String pattern = ("href=\"search/" + eng).toLowerCase();
13         String thai = "";
14         while (thai.equals("") && web.hasNext()) {
15             // href="search/target ... <td>[N] จุดมุ่งหมาย,
16             String t = web.nextLine();
17             t = t.toLowerCase();
18             int j = t.indexOf(pattern, 0);
19             if (j >= 0) {
20                 j += pattern.length();
21                 j = t.indexOf("<td>", j);
22                 if (j >= 0) {
23                     j += "<td>".length();
24                     int k = t.indexOf(",", j);
25                     if (k >= 0) thai = t.substring(j, k);
26                 }
27             }
28         }
29         if (thai != null) {
30             System.out.println("แปลว่า " + thai.trim());
31         } else {
32             System.out.println("ไม่พบคำแปล");
33         }
34     }
35 }
```