


การสกัดความรู้เกี่ยวกับสรรพคุณทางยาของพืชสมุนไพรไทยจากเอกสารภาษาไทยเพื่อ
สนับสนุนระบบการตอบคำถามอัตโนมัติ
บทนำ

1. ความเป็นมาของปัญหา

ระบบศูนย์บริการความรู้อัตโนมัติ (Automatic Knowledge Service Center System) ในปัจจุบันมีปัญหาในด้านการให้บริการความรู้เชิงบรรยายแบบอัตโนมัติได้อย่างมีประสิทธิภาพ โดยเฉพาะอย่างยิ่งความรู้เกี่ยวกับคุณสมบัติหรือสรรพคุณต่างๆของเอนติตี้ (Entity)ที่เป็นวัตถุ (Object) มีอยู่จริง (เช่น โหระพา กระเพรา ขมิ้น ขิง ข่า พลู มะนาว เป็นต้น ซึ่งคือพืช สมุนไพรไทย) ความรู้เกี่ยวกับการเตรียมยาสมุนไพร และความรู้วิธีการใช้ยาสมุนไพรไทย เป็นต้น ความรู้เหล่านี้ถือว่าเป็นความรู้ที่มีประโยชน์อย่างมากสำหรับประชาชนทั่วไปเพื่อนำไปใช้บำรุงรักษาสุขภาพของตนเองด้วยการตอบคำถามความรู้เกี่ยวกับสมุนไพรไทยผ่านทางระบบอัตโนมัติของศูนย์บริการความรู้ด้วยคำถามประเภทต่างๆ เช่น “อะไร(What-question)” “อย่างไร(How-question)” “ทำไม(Why-question)” “ที่ไหน(Where-question)” “เมื่อไร(When-question)” เป็นต้น นอกจากนี้(Takahashi K., et. al., 2004; Metzler D. and Croft W.B., 2005) ได้แบ่งคำถาม “อะไร(What-question)” ออกเป็นประเภทต่างๆเช่น ประเภทลิสต์(List)/รายการ ประเภทเอนติตี้ ประเภทนิยาม ประเภทเวลา เป็นต้น ตัวอย่างเช่นเช่น “ใบโหระพามีสรรพคุณทางยาอะไรบ้าง” “พืชสมุนไพรอะไรมีสรรพคุณขับลม” “สมุนไพรคืออะไร” “ควรใช้ยาสมุนไพรเมื่อไร” เป็นต้น ทั้งนี้จะทำให้ประชาชนทั่วไปมีความรู้ได้โดยไม่ต้องทำการสืบค้นและอ่านจากเอกสารต่างๆ ซึ่งทำให้เสียเวลามาก ดังนั้นระบบศูนย์บริการความรู้อัตโนมัติ ดังกล่าวซึ่งแสดงในรูปที่1 ควรประกอบด้วยสี่ส่วนหลักคือ

- 1) การสกัดความรู้เรื่องสรรพคุณทางยาของสมุนไพรไทย (Medicinal Property Knowledge Extraction) เก็บลงในฐานความรู้
- 2) การแทนความรู้เรื่องสรรพคุณทางยาของสมุนไพรไทย (Medicinal Property Knowledge Representation)
- 3) การวิเคราะห์คำถาม (Question Analysis)
- 4) การหาคำตอบ (Answer Determination)



รูปที่1 แสดงกรอบงานของระบบศูนย์บริการความรู้อัตโนมัติ

สำหรับงานวิจัยครั้งนี้จะเป็นการศึกษาเฉพาะการสกัดความรู้เรื่องสรรพคุณทางยาของสมุนไพรไทย และระบบการตอบคำถามเกี่ยวกับสรรพคุณทางยาของสมุนไพรไทยซึ่งจะเป็นคำถาม “อะไร/what” ประเภทลิสต์ (เช่น ...สรรพคุณอะไรบ้าง) ประเภทเอนติตี้ (เช่น...สมุนไพรอะไร) นอกจากนี้ความรู้เรื่องสรรพคุณของสมุนไพรไทยปรากฏ

ในเอกสารพีชสมุนไพรรไทยในรูปแบบของหลายๆ EDU (Elementary Discourse Unit, คือประโยคง่ายๆ ธรรมดาไม่ซับซ้อน, Carlson and et. al, 2003) ดังตัวอย่างต่อไปนี้

- EDU1: กระเทียมเป็นยาขับลมในลำไส้
 - EDU2: [กระเทียม]แก้ไอ
 - EDU3: [กระเทียม]ขับเสมหะ
 - EDU4: [กระเทียม] ช่วยย่อยอาหาร
 - EDU5: [กระเทียม]รักษากลาก เกื้อน
- หมายเหตุ: สัญลักษณ์ '['..]' หมายถึงการละคำ

ดังนั้นจากตัวอย่างเอกสารพีชสมุนไพรรไทยต่อไปนี้

พริกไทย (Piper nigrum Linn.)

สรรพคุณ เปลือกของพริกไทยมีน้ำย่อยสำหรับย่อยไขมัน ด้วยเหตุนี้ตำราโบราณจึงเชื่อกันว่าพริกไทยสามารถลดความอ้วนได้. พริกไทยช่วยกระตุ้นปฏิกิริยาขับถ่าย เพื่อให้อาหารย่อยง่ายขึ้น. พริกไทยมีรสเผ็ดร้อน เมื่อรับประทานเข้าไปจะรู้สึกอุ่นวาบที่ท้อง ช่วยขับลม ขับเหงื่อ ขับปัสสาวะ แก้ท้องอืดท้องเฟ้อ แก้ไข้มาลาเรีย แก้หวัด โรค, ใช้กันพริกไทย 10 กรัม บดให้ละเอียดแล้วคั้นกับน้ำ 8 แก้ว ใช้เป็นยาถ่ายท้องที่อันตราย, สารพิเพอรินในพริกไทยสามารถใช้เป็นยาฆ่าแมลง ซึ่งไม่เป็นอันตรายต่อมนุษย์โดยนำผลพริกไทยมาทุบให้แตกแล้วใช้โรยบริเวณตู้เสื้อผ้าหรือบริเวณที่ต้องการ

จากตัวอย่างเอกสารสมุนไพรรไทยข้างต้นส่วนที่ขีดเส้นใต้คือสรรพคุณหรือคุณสมบัติของพีชสมุนไพรร “พริกไทย” ดังนั้นปัญหาในส่วนของการสกัดความรู้เกี่ยวกับคุณสมบัติของเอนิตีโดยเฉพาะเรื่องสรรพคุณทางยาของสมุนไพรรไทยจากเอกสารภาษาไทย ประกอบด้วยสามปัญหาคือ ปัญหาการระบุเอนิตีสมุนไพรรไทย ปัญหาการระบุสรรพคุณทางยาของสมุนไพรรไทย ปัญหาการหาขอบเขตของ EDUs สรรพคุณทางยาของสมุนไพรรไทย

ส่วนปัญหาจากระบบสอบถามเกี่ยวกับคุณสมบัติของเอนิตีสมุนไพรรไทย ประกอบด้วยปัญหาการวิเคราะห์ “คำถามอะไร” ปัญหาการระบุโฟกัส (Focus)ของคำถาม และปัญหาการหาคำตอบจากความรู้เกี่ยวกับคุณสมบัติของเอนิตีที่ได้สกัดมา

งานวิจัยที่เกี่ยวข้องสามารถแบ่งออกเป็นสองส่วนหลักคือ ส่วนการสกัดและแทนความรู้เกี่ยวกับคุณสมบัติของเอนิตี และส่วนการตอบคำถามของคำถามประเภท“อะไรบ้าง” กล่าวคือมีการใช้เทคนิคต่างๆ สกัดความรู้เกี่ยวกับคุณสมบัติของเอนิตีจากงานวิจัยที่เกี่ยวข้องเช่น Weeber M. and Vos. R., 1998; Fang et al.,2008; และ PaSca M., 2008 โดย Weeber M. and Vos. R.(1998)ได้กล่าวถึงคุณสมบัติของฤทธิ์ยาจำเป็นต้องคำนึงถึง 3 เรื่องหลักคือ ยา(A) ผลที่แสดงออกทางกายภาพ (Physiological Effect)(B) และ โรค (C) และความสัมพันธ์ระหว่าง 3 เรื่องดังกล่าวเป็น A -> B , B -> C , ทำให้ได้ A -> C ดังนั้น Weeber M. and Vos. R.(1998) เสนอการสกัดความรู้ทางการแพทย์โดยการหาความสัมพันธ์ระหว่างคำ(ซึ่งอยู่ในรูปของนามวลี) A, B, และ C จากเอกสารทางการแพทย์โดยใช้แนวทางสถิติด้วยการความสัมพันธ์ชนิดAssociationระหว่างคำที่อยู่รอบๆ Side-Effect Words ภายใต้กรอบหน้าต่างขนาด 64 คำ Expert I ได้ recall = 0.19 precision = 0.14 Expert II ได้ recall = 0.24 precision = 0.07

Fang et al.,(2008) ได้ค้นพบความสัมพันธ์(Association Discovery) ระหว่างคำนามต่างๆที่เป็นชื่อยาสมุนไพรจีน โรค พันธุกรรม ผลกระทบ (Side Effect) ของยาสมุนไพรจีน และส่วนผสม โดยการวิเคราะห์การเกิดร่วมกัน (Collocation Analysis) จากเอกสารที่มีการกำกับ และมีการนำเอา IE (Information Extraction) และแบบจำลอง Swanson's ABC (A -> B และ B -> C ทำให้ได้ ความสัมพันธ์แบบการส่งผ่าน (Transitive Association) คือ A -> C) มาประยุกต์ใช้ โดยกำหนดให้ A คือพันธุกรรม B คือ ส่วนผสมที่สามารถควบคุม A และ C คือ ยาสมุนไพรจีน เพื่อการบอกเป็นนัยของ A -> C เมื่อ A -> B และ B -> C ปรากฏขึ้นในเอกสารอย่างมีนัยสำคัญ ผลการวิจัยของ Fang et al.,(2008) ได้ precision =0.91 อย่างไรก็ตามวิธีของ Fang et al.,(2008)อยู่บนพื้นฐานของการใช้แต่เพียงนามวลี

PaSca M. (2008) ระบุความรู้ที่เป็นจริงเกี่ยวกับคลาสวัตถุ (Object Class) ต่างๆได้โดยการใช้ อีสะแพทเทิร์น (Is-A pattern) กับการสอบถามหรือคิวรี (Query) ที่มีคีย์เวิร์ด (Key Word) อยู่ด้วยทำการสกัดคุณสมบัติต่างๆที่อยู่ในรูปนามวลี จากเอกสารบนเว็บและจากส่วนบันทึกคิวรี (Query Log) ด้วยค่า precision of 0.8 สำหรับ 100 คลาสที่สามารถระบุได้ จาก 5 คุณสมบัติหรือ แอททริบิวท์ (Attribute) ที่ สกัดได้

อย่างไรก็ตาม วิธีดังกล่าว(Weeber M. and Vos. R., 1998; Fang et al.,2008; PaSca M., 2008) ไม่เหมาะสำหรับงานวิจัยนี้ในส่วนของการสกัดความรู้เกี่ยวกับสรรพคุณทางยาของเอนตีตี้พืชสมุนไพรไทยจากเอกสารภาษาไทย เพราะสรรพคุณเหล่านี้จะแสดงอยู่ในรูปของกริยาวลี และหลายๆกริยาวลีอยู่ต่อเนื่องกันต่อเนื่องกันต่อหนึ่งเอนตีตี้สมุนไพรซึ่งจะอยู่ในรูปของนามวลีที่ส่วนใหญ่มักจะละ

ส่วนการตอบคำถามของคำถามประเภท“อะไรบ้าง” ได้มีการใช้เทคนิคต่างๆจากงานวิจัยที่เกี่ยวข้อง (Riloff E. and Thelen M.,2000; Quaresma P. and Rodrigues I., 2005; Fan S. et. al., 2008) โดย Riloff E. and Thelen M.(2000) ได้ใช้กฎเป็นพื้นฐาน (Rule Base)ต่างๆพร้อมกับการให้คะแนน สำหรับระบบตอบคำถามอย่างอัตโนมัติ ทั้งนี้เพื่อทดสอบความเข้าใจจากการอ่านบทความภาษาอังกฤษ โดยระบบอัตโนมัติหลังจากที่ได้ผ่านซอฟต์แวร์แจ่งประโยค “Sundance” วิธีการเลือกคำตอบโดยการให้คะแนนสำหรับประโยคที่มีค่าตรงกับคำในประโยคคำถาม ถ้าประโยคใดมีคะแนนสูงประโยคนั้นคือประโยคคำตอบ สำหรับการตอบคำถาม “What”ได้ความถูกต้องเป็น 0.31 สำหรับระบบอัตโนมัติ 0.28 สำหรับคนตอบ อย่างไรก็ตามกฎของ คำถาม “What”เหล่านั้นไม่สามารถใช้กับงานวิจัยนี้

Quaresma P. and Rodrigues I.(2005) ได้ เสนอระบบการตอบคำถามที่มีการใช้ซอฟต์แวร์แจ่งประโยค ภาษาโปรตุเกส (Portuguese Parser) กับเอกสารทางคดีความและประโยคคำถาม สำหรับสถาบันเกี่ยวกับความยุติธรรมของชาวโปรตุเกส เช่น ศาล สำนักงานทนายความ เป็นต้น โดยศึกษาคำถามเกี่ยวกับคดีความ โดยวิธี ยูนิไฟต์ (Unify) ด้วยโปรแกรมภาษาโปรล็อก (Prolog) ระหว่างประโยคในเอกสารทางคดีความกับคำถามหลังจากผ่านซอฟต์แวร์แจ่งประโยคได้ความถูกต้อง 25% จาก 200 คำถาม

Fan S. et. al., (2008) ได้เสนอแบบจำลอง CRF (Conditional Random Field Model) สำหรับระบบการตอบคำถามที่คำถามมีลักษณะซับซ้อนมาก โดยเขาแก้ไขปัญหสำหรับคำถามที่ซับซ้อนด้วยการให้มีการกำกับความหมายระดับก้อน (Chunk Semantic) ให้กับคำถาม ซึ่งคำถามนี้จะถูกนำไปหาค่าความคล้าย (Similarity) กับคำถามที่มีคู่คำตอบ (Question-Answer Pair) จากเว็บไซต์ภาษาจีน CRFคล้ายกับ Maximum Entropy(ME) เซตฟีเจอร์(Feature Set) ที่ใช้โดย CRFประกอบด้วยคำที่กำหนดความหมายไว้ , tag, Pattern, และKey word (ดูในหัวข้องานวิจัยก่อนหน้า) เพื่อให้หาค่าความคล้าย ซึ่งได้ค่าความถูกต้องเฉลี่ย 93.07% precision 93.07%recall

อย่างไรก็ตาม วิธีดังกล่าว(Riloff E. and Thelen M.,2000; Quaresma P. and Rodrigues I., 2005; Fan S. et. al., 2008) ไม่เหมาะสำหรับงานวิจัยนี้ในส่วนของการตอบคำถาม เนื่องจากคำถาม “what” ของงานวิจัยนี้เป็นประเภทลิสต์ ส่วนของ Riloff E. and Thelen M.(2000)และ Quaresma P. and Rodrigues I.(2005) เป็นประเภทอื่นที่ไม่ใช่ลิสต์ ฉะนั้นจะมีแพทเทิร์นที่ต่างกันออกไป และลักษณะภาษาไทยต่างจากภาษาอังกฤษและภาษาโปรตุเกส

ซึ่งมีการใช้ “Question Mark, ?” เป็นตัวระบุประโยคคำถาม ในขณะที่ภาษาไทยไม่มี นอกจากนี้คู่คำถามคำตอบเกี่ยวกับสรรพคุณสมุนไพรไทยบนเว็บไซต์มีไม่มากเหมือนของจีนฉะนั้นวิธีของ Fan S. et. al.(2008) ไม่สามารถนำมาประยุกต์ใช้กับงานวิจัยนี้

ดังนั้นในส่วนของการสกัดความรู้เกี่ยวกับสรรพคุณทางยาของเอนตีตี้พืชสมุนไพรไทยจากเอกสารภาษาไทย งานวิจัยนี้จึงขอเสนอการใช้แพทเทิร์น ทางภาษาศาสตร์คือ NP1 V_{mp} NP2 (เมื่อ NP1 คือเซตความคิดนามวลีหรือ Noun Phrase Concept เกี่ยวกับเอนตีตี้ เช่นพืชสมุนไพร(Herb) และสาร(Substance)ของสมุนไพร NP2 คือเซตความคิดนามวลีเกี่ยวกับอาการ (Symptom) โรค(Disease) เชื้อ(Pathogen) และ V_{mp} คือเซตความคิดกริยาที่แสดงให้เห็นสรรพคุณทางยา(Medicinal-Property Verb Concept) ดังนี้

$np1_i = \text{part} + \text{TopicName}$ เมื่อ $i=1,2,...,m$

$\text{part} \in \{\text{null}, \text{ใบ}, \text{ดอก}, \text{ราก}, \text{ต้น}, \text{เมล็ด}, \text{ผล}, \dots\}$

$\text{TopicName} \in \{\text{“โหระพา/basil” “กระเพรา/sweet basil” “กระเทียม/garlic” “พริกไทย/pepper” “พริก/chili” “ขิง/ginger” “ข่า/galangal” “ตะไคร้/lemon grass” “ว่านหางจระเข้/aloe” “กานพลู/cinnamon” “พลู/betel”}\}$

$NP1 = \{np1_1, np1_2, \dots, np1_m\}$

$NP2 = \{\text{“[อาการ] ปวดท้อง/abdominal pain”, “[อาการ] คลื่นไส้/nausea”, “[อาการ] อาเจียน/vomit”, “[อาการ] เวียนศีรษะ/dizziness” , “ไข้/fever”, “[อาการ] ปวดศีรษะ /headache”, “[อาการ] [แผล] อักเสบ/inflame”, “[อาการ] ภูมิแพ้/allergy”, “[อาการ] ท้องเสีย/diarrhea” , “ปัสสาวะ/urine”, “ลม/gas”, “กรดในกระเพาะ/stomach acid”, “โรคผิวหนัง/skin disease”, “โรคหัวใจ/heart disease”, “ความดัน/blood pressure”...}\}$

$V_{mp} = \{\text{“รักษา/cure” “บรรเทา/relieve” “แก้/stop, prevent” “ขับ/release” “ลด/reduce” “เพิ่ม/increase” ...}\}$

มาทำการระบุความรู้เกี่ยวกับสรรพคุณทางยาของเอนตีตี้พืชสมุนไพรไทย โดยที่ความคิดนามวลี และความคิดกริยาได้จากสารานุกรมไทย เวอร์ดเน็ต (Wordnet) และ www.longdo.com นอกจากนี้ขอเสนอ คู่ความคิดกริยาที่เกี่ยวข้องสรรพคุณทางยาและอยู่ต่อเนื่องกันภายในหนึ่งกรอบหน้าต่างที่เคลื่อนไปด้วยระยะทางหนึ่ง EDU เพื่อใช้หาขอบเขตของสรรพคุณทางยาของเอนตีตี้พืชสมุนไพรนั้นด้วยการใช้Naive Bayesทดสอบ Hypothesis นอกจากนี้ความรู้ที่สกัดได้จะอยู่ในรูปของเมตริกซ์เวกเตอร์(V) ของความคิดกริยาแสดงสรรพคุณยาของพืชสมุนไพร(V_i) ดังนี้

$V_i = \{v_{i1}, v_{i2}, \dots, v_{ik}\}$ สำหรับพืชสมุนไพรหนึ่งชนิด และ $v_{ik} \in V_{mp}$ (v_{ik} คือ $v_{mp_at_ik}$ และ V_i คือ V_{mp})

$V = \{V_i\}$ where $i=1..n$

ส่วนการตอบคำถามเกี่ยวกับสรรพคุณทางยาของสมุนไพรไทยงานวิจัยนี้จึงขอเสนอการใช้แพทเทิร์นของคำถาม (Question Word) “what” ประเภทลิสต์“อะไรบ้าง” และประเภทเอนตีตี้ “x อะไร” (เมื่อ x คือเอนตีตี้) ร่วมกับ NP1, NP2, และ V_{mp} มาทำการระบุประเภทคำถามและระบุโฟกัสของคำถาม เพื่อหาคำตอบจากความรู้ที่สกัดได้นั้น

2. วัตถุประสงค์

2.1 ศึกษาวิธีการสกัดความรู้เกี่ยวกับสรรพคุณทางยาของเอนตีตี้พืชสมุนไพรไทยจากเอกสารภาษาไทย

2.2 ศึกษากระบวนการสอบถามเกี่ยวกับสรรพคุณทางยาของสมุนไพรไทยด้วยคำถามประเภท “อะไรบ้าง(What-question)”

3. สมมติฐาน

3.1 คู่ความคิดระหว่างนามวลี NP1กับนามวลีNP2 และความคิดกริยาVmp จากแพทเทิร์นทางภาษาศาสตร์NP1 Vmp NP2 สามารถระบุว่าเป็นEDUอธิบายสรรพคุณทางยา

3.2 คู่ความคิดกริยาที่เกี่ยวกับสรรพคุณทางยาและอยู่ต่อเนื่องกันภายในหนึ่งกรอบหน้าต่าง ขนาด 2 EDUs แสดงว่าขอบเขตของ EDUs สรรพคุณทางยาของสมุนไพรไทยยังไม่สิ้นสุด

4. นิยามคำศัพท์

Medicinal Effect: ผลทางยาซึ่งเป็นคุณสมบัติของยา (Medicinal Property) หรือเรียกว่าสรรพคุณทางยา
EDU: Elementary Discourse Unit คือประโยคง่าย ๆ ธรรมดาไม่ซับซ้อน

QA System: Question Answering Systemคือระบบการตอบคำถาม

What-question: คำถามประเภทอะไร

NP:Noun Phrase Conceptคือความคิดนามวลี

V:Verb Concept คือความคิดกริยา

Question Word: คำที่ใช้แสดงคำถาม

Key Word:คำสำคัญ

5. ขอบเขตของการวิจัย

5.1 สามารถสกัดความรู้เกี่ยวกับสรรพคุณทางยาของเอนิตีพืชสมุนไพรไทยจากเอกสารภาษาไทย

5.2 สามารถสอบถามเกี่ยวกับสรรพคุณทางยาของสมุนไพรไทยด้วยคำถามประเภท “อะไรบ้าง(What-question)”ได้อย่างอัตโนมัติ

5.3 การวิจัยนี้จะเป็นการตอบคำถาม “อะไร(what-question)”ประเภทลิสต์ “อะไรบ้าง” และประเภทเอนิตี “x อะไร” เมื่อ x คือเอนิตีที่เท่านั้น