

Abstract (บทคัดย่อ)

Project Code : MRG5580030

(รหัสโครงการ)

**Project Title : Knowledge Generalization from Causality Knowledge Extracted from
Texts for Answering Why- Question Expressed by Text and Image**

(ชื่อโครงการ) การหาความรู้โดยรวมจากความรู้เหตุและผลที่สกัดได้จากเอกสาร
ภาษาไทยสำหรับการตอบคำถามเหตุและผลโดยอาศัยคำถามจาก
ข้อความและภาพ

Investigator : Assoc. Prof. Chaveevan Pechsiri (Dhurakij Pundit University)

(ชื่อนักวิจัย) รองศาสตราจารย์ ดร. จวีวรรณ เพ็ชรศิริ (มหาวิทยาลัยธุรกิจบัณฑิตย์)

E-mail Address : itdpu@hotmail.com

Project Period : July 2012 – July 2014

(ระยะเวลาโครงการ) กรกฎาคม 2555 – กรกฎาคม 2557

Abstract

The research aims to extract and generalize the causality knowledge for supporting a Why Question Answering (QA) system integrated with image processing (called the Embedded-Image Why-QA system) for providing the knowledge used in the problem diagnosis, especially in plant diseases. The image expression is applied on the Why-question part for providing Why-question contents (i.e. plant symptoms) that are difficult to be explained by text. There are three main problems involved with this current research. The first problem of the causality knowledge extraction, especially the effect boundary determination problems, is confronted after applying the verb-pair (a causative verb and an effect verb) rules to identify the causality. Then, the research applies Maximum Entropy, Supported Vector Machine, and Naïve Bayes for the comparative study of the effect boundary determination, having the effect verb concepts from the effect EDUs as the features. The second problem is the knowledge generalization problems which come from the extracted causality knowledge containing the uncertainty nuance expression and the incompleteness knowledge. Thus, the research proposes applying the basic linguistic rules to solve the uncertainty problems and the Monte Carlo simulation technique to solve incompleteness problems by imputation of the effect unit. And then, we apply the fuzzy function right after the imputation to determine the generality value of each effect event expressed by the effect verb concept feature of the effect EDU from several documents having the same cause concept. The third problem is from the Embedded-Image Why-QA system which consists of how to determine the Why-question type from the text part of the question, how to determine the Why-question contents from the image part of the question, and how to determine the corresponding answer to the Why-question from the extracted causality. Therefore, the research applies a Why-question cue set to solve the Why-question type, a Bag-of-Visual-Words to solve the Why-question contents, and determining the corresponding answers by ranking the similarity scores between the question content and the extracted causality knowledge including the symptom generality value. Then, the results of this research have shown that the effect boundary determination based on ME has the highest correctness 92% on average and the extracted causality can support the embedded image Why-QA system by answering correctly at 78% correctness at the first rank.

Keywords: Generality value, effect boundary, Embedded-Image Why-QA system, visual word, Why-question cue

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์สําคัญและหาความรู้เหตุและผลโดยรวม เพื่อสนับสนุนระบบการตอบคำถามเหตุและผล ที่ได้นํารวมการกับการประมวลผลภาพเข้าไว้ (เรียกระบบคำถามนี้ว่า ระบบเอมเบดเดด-อิมเมจวอยคิวเอ Embedded-Image Why-QA system) ทั้งนี้เพื่อกําหนดความรู้ให้ซึ่งใช้ในการวินิจฉัยปัญหา โดยเฉพาะปัญหาโรคพืช การนํารวมมาประยุกต์ใช้ในระบบการตอบคำถามเหตุและผลนี้ก็เพื่อง่ายต่อการอธิบายลักษณะอาการของโรค ซึ่งบางครั้งยากที่จะอธิบายด้วยข้อความ ปัญหาสำหรับงานวิจัยนี้ประกอบด้วยสามปัญหาหลักดังนี้ ปัญหาแรกเป็นปัญหาด้านการสําคัญความรู้เหตุและผล โดยเฉพาะเรื่องการหาขอบเขตของผลหลังจากที่ได้ใช้กฎคู่กริยา (Verb-Pair Rule, กริยาเหตุและกริยาผล) ระบุนความรู้เหตุและผล ฉะนั้นงานวิจัยนี้จึงทำการประยุกต์ใช้แมกซ์ิมเอนโทรปีหรือเอ็มอี (Maximum Entropy, ME) :ซัพพอร์ตเวกเตอร์แมชชีนหรือเอสวีเอ็ม (Support Vector Machine, SVM) และเนย์บ์เบย์หรือเอนบี (Naive Bayes, NB) เพื่อศึกษาการเปรียบเทียบการหาขอบเขตของผล โดยมีฟีเจอร์ (Feature) ที่ใช้คือกริยาผล ปัญหาที่สองเป็นปัญหาเกี่ยวกับการหาความรู้โดยรวม ซึ่งเกิดจากรู้เหตุและผลที่สําคัญได้นั้นพบปัญหาเกี่ยวกับ ความไม่แน่นอนของนูนแอนซ์ (Nuance) ที่แสดงอาการโรค ปัญหาความไม่สมบูรณ์ของข้อมูลที่สําคัญได้ ดังนั้นงานวิจัยนี้ขอเสนอกฎทางภาษาศาสตร์ แก่ปัญหาเกี่ยวกับความไม่แน่นอนของนูนแอนซ์ และใช้เทคนิคการจำลอง มอนติคาร์โล(Monte Carlo Simulation Technique) ทำการเติมเต็มข้อมูลเพื่อแก้ปัญหาคความไม่สมบูรณ์ของข้อมูล ก่อนที่จะทำการหาความรู้โดยรวมด้วยฟังก์ชันฟัซซี (Fuzzy Function) สําหรับหาค่าเจเนอรัลลิตี้ (Generality Value) ของแต่ละกริยาผลที่มาจกสาเหตุเดียวกัน ปัญหาที่สามเป็นปัญหาเกี่ยวกับระบบเอมเบดเดด-อิมเมจวอยคิวเอ ที่ประกอบด้วยปัญหาการระบุประเภทคำถามเหตุและผลจากส่วนที่เป็นข้อความของคำถาม ปัญหาการหาเนื้อหาคำถามจากส่วนที่เป็นภาพของคำถาม และปัญหาการหาคําตอบจากรู้เหตุและผลที่สําคัญได้พร้อมด้วยค่าเจเนอรัลลิตี้ ดังนั้นงานวิจัยนี้จึงประยุกต์ใช้ชุดประเภทคำถามเหตุและผล (Why-question cue set) ระบุนประเภทคำถามเหตุและผล ใช้ถุงของวิซวลเวิร์ด (Bag of Visual Word) หาเนื้อหาคำถาม และใช้การจัดลำดับคะแนนความคล้าย ระหว่างเนื้อหาคำถามกับความรู้เหตุและผล ที่สําคัญได้มาทำการหาคําตอบจากการทดลองของงานวิจัยนี้ ได้แสดงให้เห็นว่า การหาขอบเขตของผลด้วยวิธีเอ็มอีให้ความถูกต้องเฉลี่ยสูงสุดคือ 92% และความรู้เหตุและผลที่สําคัญได้สามารถใช้ตอบคำถามได้ถูกต้อง 78% ที่ลำดับที่1 (Rank1)

คําสําคัญ: Generality value, effect boundary, Embedded-Image Why-QA system, visual word, Why-question cue