

การตรวจสอบคำสะกดสามารถนำมาเพิ่มความถูกต้องผลลัพธ์ของ OCR ,ซึ่งจะใช้เวลามากสำหรับภาษาไทย เนื่องจากไม่มีขอบเขตที่แบ่งระหว่างแยกคำอย่างชัดเจน, การตรวจสอบคำสะกดจึงต้องทำการตรวจสอบทุกตัวอักษรที่ติดกัน และทุกคำที่เป็นไปได้ ซึ่งยังมีความคลุมเครือในการแบ่งแยกขอบเขตคำต่อเนื่องกันไป ในงานวิจัยนี้จะนำเสนอ โทเคนพาสซิง อัลกอริทึม, ซึ่งมักในปัญหาการรู้จำเสียงคำพูด, เข้ามาช่วยในการแก้ไขปัญหานี้ โดยจะใช้ผลลัพธ์จาก OCR ซึ่งประกอบด้วยตัวอักษรซึ่งมีค่าความน่าจะเป็นสูงที่สุด หัวตัว โทเคนจะถูกสร้างขึ้นมาจากตัวอักษรแต่ละตัวและส่งผ่านไปรวมกับตัวอักษรชุดต่อไป ในแต่ละครั้งที่โทเคนจะถูกส่งไป, จะทำการตรวจสอบตรวจสอบคำสะกดของแต่ละโทเคนด้วยพจนานุกรม, โทเคนที่มีคำซึ่งสะกดผิดจะถูกทิ้งไป ส่วนโทเคนซึ่งเป็นคำที่สมบูรณ์แล้วจะถูกใช้ในการสร้างกราฟของคำ, ซึ่งจะประกอบด้วยคำทั้งหมด ซึ่งมาจากตัวอักษรของแต่ละโทเคน ที่มีลำดับคะแนนสูงที่สุดห้าตัวอักษร โทเคนพาสซิง อัลกอริทึมจะถูกนำมาใช้อีกครั้งในระดับของคำในการเลือกประโยคที่มีความความน่าจะเป็นสูงที่สุด

ABSTRACT

TE138952

Spell checking can be used to improve OCR result, which is quite time consuming for Thai language. Since, there is no explicit word boundary, the spell checking has to go through all possible ambiguity characters and ambiguity word boundary. This paper proposed a Token Passing algorithm, often used in speech recognition, to this problem. The output of the OCR consists string of 5 most probable characters. The letter token are generated for each letters and passed to the next 5 characters. Each time the token is parsed, the dictionary is used to check for the correct spelling. The wrong spelling token are discarded. Tokens with complete word are used to construct words graph, which will be fully constructed when letter token reach the best five characters. Token passing Algorithm is used again in the word level to select the best possible sentence.