

# การหาความหมายภาพด้วยการวัดความคล้ายภาพด้วยเปรียบเทียบคู่ที่เหมาะสม

## Semantic Images by Similarity Measure Images with Appropriate Pairwise comparisons

นัชพ์ชานัน พินปัญช์ธนะ

Nutchanun Chinpanthana

วิทยาลัยนวัตกรรมด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจปันพิทย์ 110/1-4 ถ.ประชาชื่น เขตหลักสี่ กรุงเทพฯ 10210  
College of Innovative Technology and Engineering Dhurakij Pundit University 110/1-4 Prachachuen Rd. Laksi, Bangkok 10210,  
E-mail nutchanun.cha@dpu.ac.th, Tel. 02-954-7300

### บทคัดย่อ

การค้นคืนภาพและการจำแนกภาพกำลังเป็นปัญหาที่น่าสนใจสำหรับการประมวลผลภาพ โดยส่วนใหญ่จะทำการใช้คุณลักษณะที่เจือร์ที่ถูกสกัดออกมาร่วมกับวิธีการโครงข่ายประสาทเทียมแบบสังเคราะห์เพื่อทำมาปรับปรุงการทำงานให้มีความหมายภาพด้วยการใช้คำหลักที่ถูกแท็กลงในภาพ ซึ่งส่วนใหญ่ไม่เดลที่ถูกสร้างมานั้นมักจะนำพาด้วยความลับซึ่งคำหลักที่ถูกสกัดลงในภาพ ทำอย่างไม่สามารถแปลความหมายภาพได้อย่างแท้จริง ดังนั้นในงานวิจัยนี้พยายามแก้ปัญหาด้วยการวัดความคล้ายกันของภาพด้วยวิธีการเลือกคู่กราฟที่เหมาะสม โดยระบบหั่งหมวดประกอบด้วย 4 ส่วนคือ (1) การเตรียมข้อมูล (2) การใส่ข้อมูลภาพ (3) การวัดความคล้ายกันของภาพด้วยวิธีการเลือกคู่กราฟที่เหมาะสม (4) การวัดและการประเมินผลการทำงาน จากการทดลองได้ทำการเปรียบกับเครื่องมือเบรียบเทียบจำแนกภาพทั่วไป เช่น ชัพพอร์ตเวกเตอร์แมกซ์, โครงข่ายประสาทเทียมแบบหลายชั้น โครงข่ายประสาทเทียมแบบสังเคราะห์ และ โครงข่ายประสาทเทียมแบบบริเวณสังเคราะห์ ผลที่ได้จากการทดลองแสดงให้เห็นว่าวิธีการวัดความคล้ายกันของภาพที่นำเสนอสามารถจำแนกภาพที่มีความหมายได้มากกว่าด้วยค่าความถูกต้องที่สูงกว่าคำสำคัญ: การประมวลผลภาพ จับคู่กราฟ การค้นคืนภาพ ความหมายภาพ

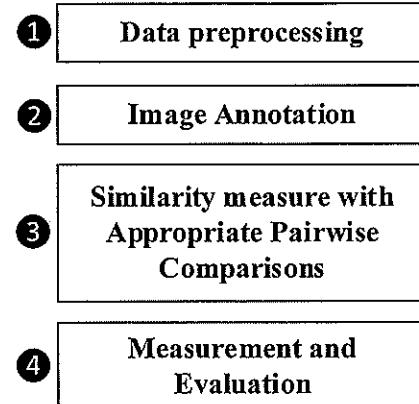
### Abstract

Recently, image retrieval and image classification are an active problem in digital image processing. Existing approaches typically focus on visual features extracted from an object-oriented convolutional neural network (CNN) and then improve semantic models by using keyword annotation. This model leads to an inadequate situation in the relation with keywords that are extracted from the images. It does not specific enough for representing the actual meaning. To overcome this problem, we suggest a new measure of similarity with appropriate pairwise comparisons (SAPC). The overall system process is divided into four steps: (1) data preprocessing; (2) image annotation; (3) similarity measure with appropriate pairwise comparisons and (4) measure and evaluation. The experiment is compared with traditional classification methods including Support Vector Machine Multiple Feedforward Neural Network, Convolutional Neural Networks, and Regions with Convolutional Neural Networks. The results show that our proposed approach offers significant performance improvements in the interpretation of semantic images, compared, with the higher accuracy.

ที่เข้ามาช่วยการค้นคืนความหมายภาพ แต่ผลลัพธ์ที่ได้จะเป็นกลุ่มของคำหลักที่เกิดขึ้นบนภาพเป็นส่วนใหญ่

มีกิจกรรมวิจัยอธิบายโครงสร้างความหมายในรูปแบบลำดับในเชิงการมองเห็น (semantic hierarchy for vision) [8] เพื่อนำเสนอความสัมพันธ์วัตถุภายในภาพเพื่อสร้างความสัมพันธ์ และทำความสัมพันธ์ของภาพจากคำหลักภายใน ความสอดคล้องกันด้วยการเรียนรู้ทำให้ครอบคลุมรูปแบบการค้นคืนภาพ บางกลุ่มใช้กราฟเพื่อสร้างความสัมพันธ์ของกราฟ ระหว่างข้อมูลสำหรับการจำแนกที่ดีขึ้นและยังไม่สามารถได้ความหมายที่ถูกต้อง ปัจจุบันงานวิจัยพยายามที่จะสร้างความสัมพันธ์ภายในภาพ [9] เช่น (girl, on, horse) หรือ (man, eat, apple) เพื่อตอบสนองการแปลความหมายภาพที่มีความซับซ้อนขึ้น บางวิจัยของได้นำเสนอวิธีการที่ทำการจับคู่วัตถุและหัวเรื่องและความสัมพันธ์ระหว่างกัน [10] ตัวอย่างเช่น ภาพที่ประกอบด้วยบุคคล (person), มอเตอร์ไซด์ (motorcycle) และหมวกกันน็อก (helmet) สามารถสร้างความสัมพันธ์ได้เป็น (person - on - motorcycle), (person - wear - helmet) หรือ (motorcycle - has - wheel) แต่ในความเป็นจริงแล้วการวัดความคล้ายกันของภาพนั้นการใส่ความหมายวัตถุด้วยคำหลักเกิดความข้อข้องกันเนื่องจากการให้ความหมายของคำหลักมีความหมายเหมือนกัน (Synonym) เช่น “stone” กับ “rock” มีความหมายคล้ายกันคือคน “people” กับ “human” มีความหมายคล้ายกันคือ คน , “kid” กับ “child” มีความหมายคล้ายกันคือเด็ก หรือ “hat” กับ “cap” มีความหมายคือหมวก เป็นต้น ดังนั้นจะเห็นว่าการพยายามใช้คำหลักแทนที่ของต้นนั้นยังเกิดข้อผิดพลาดซึ่งบางภาพอาจมีความหมายที่ตรงกันแต่การใช้คำหลักที่แตกต่างกันที่เป็นได้ดังนั้นการสร้างกลุ่มคำที่มีความเหมือนกันหรือกลุ่มคำที่มีความสัมพันธ์กับตามลำดับออนไลโนโลเจี้ย (Ontology) [11][12] เป็นโครงสร้างหนึ่งที่มีหลายกลุ่มวิจัยใช้ในการแทนรูปแบบการเชื่อมโยงของกลุ่มคำในรูปแบบกราฟลำดับขึ้นเพื่อให้ง่ายต่อการสร้างความเชื่อมโยงตามกลุ่มคำที่สัมพันธ์กัน เช่น “horse” กับ “camel” ตามลำดับขึ้นที่ถูกเชื่อมโยงกัน แต่อย่างไรก็ตาม

การหาความสัมพันธ์ของลำดับขึ้นที่เหมือนกันตามกลุ่มคำ หลักบนภาพ ยากที่จะเกิดความสัมพันธ์ ดังนั้นในงานวิจัยนี้



รูปที่ 2 ขั้นตอนการประมวลผลข้อมูลภาพ

จึงสร้างรูปแบบความสัมพันธ์ของความหมายภาพจากการวัดความคล้ายด้วยการเปรียบเทียบจากการจับคู่วัตถุที่เหมาะสม (similarity measure with appropriate Pairwise comparisons) เพื่อทำการจำแนกข้อมูลภาพให้ได้ตามกลุ่มความหมายอย่างแท้จริง

## 2. ขั้นตอนการประมวลผล

การเตรียมข้อมูลภาพเพื่อเข้าสู่กระบวนการประมวลผลจะแบ่งขั้นตอนวิธีการดำเนินงานวิจัย ออกเป็น 4 ส่วนหลักสามารถอธิบายดังรูปที่ 2 ดังนี้ (1) ขั้นตอนการเตรียมข้อมูล (Data preprocessing) (2) การใส่ข้อมูลภาพ (Image annotation) (3) การวัดความคล้ายกันของภาพด้วยวิธีการเลือกคู่กราฟที่เหมาะสม (Similarity measure with Appropriate Pairwise Comparisons) (4) การวัดและการประเมินผลการทำงาน (Measurement and Evaluation)

2.1 ขั้นตอนการเตรียมข้อมูล เริ่มจากคัดเลือกข้อมูลภาพดิจิทัลที่มีวัตถุบนภาพที่เด่นชัด มีวัตถุภาพพื้นหลังภาพที่ถูกคัดเลือกเข้ามานั้น เป็นภาพที่มีความหมายภาพชัดเจน ภาพที่ถูกคัดเลือกออกไปไม่นำมาใช้ทดลองจะเป็นภาพที่มีลักษณะผิดปกติ (outlier) คุณลักษณะวัตถุไม่ชัดคุณลักษณะ มีขนาดวัตถุขนาดเดียวกันไปไม่สามารถปะชี้ชื่อวัตถุได้ ภาพถ่ายระยะใกล้ (close up) ทำให้ต้องมีการคัด

$$S_{ij} = \begin{cases} e^{-\frac{\|g_i - g_j\|_2^2}{\sigma^2}} & \text{if } g_i \in N_k(\tilde{I}_j), g_j \in N_k(g_i), \\ 0 & \text{otherwise} \end{cases} \quad (2)$$

เมื่อกำหนดให้  $\sigma$  หือจำนวนพารามิเตอร์ และ  $\tilde{g}_i$  เป็นจำนวนระดับการเรียนรู้ของฟีเจอร์จากการวนชักก่อนหน้าในการเรียนรู้ทั้งหมด และ  $N_k(\tilde{g}_i)$  แทนด้วยชุดข้อมูลของ K-nearest neighbors ของ  $\tilde{g}_i$

กำหนดให้ ลาบลัสกราฟ (Graph Laplacian)  $L = D - S$ , เมื่อ  $D$  แทนเมตริกซ์ diagonals (Diagonal Matrix) ที่กำหนดให้มีอิติเมต์เป็น  $D_{ii} = \sum_j S_{ij}$ , จากสมการที่ (1) สามารถเขียนใหม่เป็น

$$P_\delta = \text{tr}(G^T L G), \quad (3)$$

$$\frac{\partial P_\delta}{\partial G} = 2LG. \quad (4)$$

การเขียนสมการใหม่เพื่อลดตอนสมการบางตัวที่ไม่จำเป็น และบางโครงสร้างถูกสืบทอดมาและอยู่ใน การเรียนรู้ของทั้งระบบแล้ว

## 5. การวัดและประเมินผลการทำงาน

การวัดและประเมินผลการทำงาน (Measurement and Evaluation) จะเป็นการทดสอบการจำแนกความหมายภาพที่มีวัตถุในภาพเป็นหลักจากฐานข้อมูลจาก PASCAL action และ [13]

### 5.1 ข้อกำหนดและฐานข้อมูล

สำหรับข้อมูลภาพที่ใช้ในการทดสอบทั้งหมด 1,500 ภาพ คัดเลือกฐานข้อมูลภาพแอ็คชันจาก PASCAL action [13] ข้อมูลภาพประกอบด้วย 12 วัตถุดังนี้ bike, bird, boat, car, cat, chair, table, dog, horse, person, plant และ sofa ภาพที่มีการไฟก์ระยะใกล้ ข้อมูลภาพที่มีความซ้ำซ้อน หรือไม่สอดคล้องกันจะไม่ถูกนำมาพิจารณา และจำแนกข้อมูลภาพให้อยู่ในหมวดหมู่ตามความหมายภาพ เช่น “birthday party”, “leisure”, “couple love”, “sport racing”, “office working”, “playground”, “graduation ceremony”, “city” เป็นต้น

### 5.2 วิธีการวัดประสิทธิภาพ

การประเมินด้วยการวัดประสิทธิภาพของการจำแนกภาพด้วย ชั้พพอร์ตเวกเตอร์แมกซิน (Support Vector Machine : SVM) [15][16][17], โครงข่ายประสาทเทียมแบบหลายชั้น (Multiple Feedforward Neural Network : MLPN) โครงข่ายประสาทเทียมแบบลังวัตนา ก า ร (Convolutional Neural Networks : CNN) [18][19][20] โครงข่ายประสาทเทียมแบบบริเวณสังวัตนา ก า ร (Regions with Convolutional Neural Networks: RCNN) และ นำเสนอวิธีการวัดความคล้ายกันของภาพด้วยวิธีการเลือกถูกต้องที่เหมาะสม (Similarity measure with Appropriate Pairwise Comparisons: SAPC) ก า ร พิจารณาเป็นค่าของความถูกต้องของแต่ละกลุ่มข้อมูลซึ่งจะประกอบด้วย การวัดค่าความแม่นยำ ค่าความระลึก ค่าความถูกต้อง และ ค่าเฉลี่ยของความแม่นยำ

1. ค่าความแม่นยำ (False positive rate / Precision: Pr.) เป็นอัตราส่วนของการค้นพบภาพที่ถูกต้องจากจำนวนภาพทั้งหมดที่ทำการค้นหาได้

$$Pr = \varepsilon / \partial \quad (5)$$

เมื่อกำหนดให้  $\varepsilon$  แทนจำนวนข้อมูลที่เกี่ยวและถูกต้องออกมาก ได้อย่างถูกต้อง และ  $\partial$  แทนจำนวนข้อมูลที่ถูกต้องออกมาก ทั้งหมด

2. ค่าความระลึก (True positive rate / Recall: Re) เป็น อัตราส่วนของการค้นพบภาพที่ถูกต้องจากจำนวนภาพที่ถูกต้องทั้งหมด

$$Re = \varepsilon / \sigma \quad (6)$$

เมื่อ  $\sigma$  แทนจำนวนข้อมูลที่เกี่ยวข้องทั้งหมด

3. ค่าเฉลี่ยของความแม่นยำ (mean average precision: MAP) เป็นค่าเฉลี่ยความแม่นยำของคำหลักค้นหารายคำที่เกี่ยวข้องกัน (relevance) และนำไปจัดอันดับ โดยมีความสัมพันธ์กับคิวรี่ (query) ค่าเฉลี่ยของความแม่นยำเมื่อกำหนดค่าสูงสุดของ  $k$  ที่มีความเกี่ยวข้องกับข้อมูลภายในที่ถูกค้นคืน สามารถเขียนเป็นกลุ่มของเขตของข้อมูลที่

ตารางที่ 3 การจำแนกความหมายภาพด้วยความสัมพันธ์ของวัตถุด้วย Data Set I

Categories/Method	SVM		MLPN		CNN		RCNN		SAPC	
	Prec.	Recall								
office working	54.0	50.5	65.3	65.3	71.6	69.4	75.7	75.0	83.0	85.6
city	51.5	46.8	65.7	65.0	75.8	70.6	70.1	75.8	79.2	82.4
birthday party	49.5	46.7	67.0	67.0	71.4	69.4	70.6	72.0	77.6	78.4
couple love	48.2	52.0	65.1	67.6	65.8	70.9	71.2	73.3	78.4	76.0
grad. ceremony	46.7	42.2	62.1	54.0	72.5	71.8	71.4	70.7	79.1	65.5
playground	46.1	47.5	67.4	62.6	63.2	67.7	73.2	71.0	69.5	75.3
family time	49.0	51.5	66.3	67.0	65.1	65.1	75.3	70.2	76.9	79.5
sport game	42.7	50.0	58.1	67.3	73.3	72.5	77.2	76.5	76.6	78.8
Accuracy	48.37		64.49		69.67		73.05		77.48	

ตารางที่ 4 การจำแนกความหมายภาพด้วยความสัมพันธ์ของวัตถุด้วย Data Set II

Categories/Method	SVM		MLPN		CNN		RCNN		SAPC	
	Prec.	Recall								
office working	54.2	52.7	68.4	65.0	73.5	72.0	74.7	72.4	80.8	83.2
city	53.8	55.4	68.5	63.0	70.4	69.0	70.7	70.0	81.0	81.0
birthday party	53.6	48.6	68.7	68.0	70.6	72.7	72.0	71.3	75.3	77.7
couple love	50.0	51.4	64.8	69.3	69.4	75.0	71.2	73.1	79.6	78.0
grad. ceremony	45.7	41.6	65.2	58.6	75.3	70.0	73.0	72.3	78.7	66.1
playground	42.7	40.6	63.1	65.7	74.7	70.3	71.2	74.0	69.1	76.0
family time	49.5	50.0	65.4	68.7	69.9	72.0	75.3	73.0	78.7	73.3
sport game	43.3	52.0	64.2	69.3	72.8	75.0	77.5	79.0	75.9	84.2
Accuracy	49.09		65.96		72.00		73.14		77.26	

เปรียบเทียบ การจำแนกด้วยวิธีการ ได้ค่าความถูกต้องเพียง 48.37%, 64.49%, 69.67% และ 73.05% ด้วยวิธีการ SVM, MLPN, CNN และ RCNN และด้วยวิธีนำเสนอการวัดค่าความแตกต่างด้วยกราฟ SAPC สามารถได้ค่าเฉลี่ยความถูกต้องสูงถึง 77.48% ในชุดข้อมูล Data Set I และ เช่นเดียวกัน การจำแนกด้วย SAPC สามารถจำแนกได้ค่าความถูกต้องเฉลี่ยสูงถึง 77.26% กับชุดข้อมูล Data Set II และแสดงให้เห็นว่าการใช้ความสัมพันธ์ของวัตถุที่เกิดขึ้นภายในภาพ และการวัดค่าความแตกต่างมีผลต่อประสิทธิภาพใน การจำแนกข้อมูลตามความหมายภาพ แต่ถ้ามีการนำมาใช้ เพียงจำแนกวัตถุจะได้ค่าความถูกต้องที่น้อยกว่าอย่างเด่นชัด

จากการทดลองที่ใช้ชุดข้อมูลเดียวกันแต่มีการแยกตามกลุ่มวัตถุ และ กลุ่มความหมายของภาพด้วยการวัดประสิทธิภาพเดียวกัน SVM, MLPN, CNN และ RCNN และ ด้วยวิธีนำเสนอการวัดค่าความแตกต่างด้วยกราฟ SAPC จะเห็นว่าเมื่อมีการแทนข้อมูลภาพด้วยกราฟและใช้การวัดประสิทธิภาพด้วย SAPC จะเห็นว่าได้ค่าความถูกต้องที่สูงกว่าถึง 77.48%, 77.26% ในชุดข้อมูล Data set I และ Data set II ตามลำดับ

## 7. สรุป

งานวิจัยนี้ได้นำเสนอรูปแบบของการแทนข้อมูลภาพ ด้วยความสัมพันธ์ของข้อมูลวัตถุภายในภาพ และ การสร้างรูปแบบความสัมพันธ์ของความหมายภาพจากการ

- [14] Hanwang Zhang, Zawlin Kyaw, Shih-Fu Chang, Tat-Seng ChuaVisual. (2017). Translation Embedding Network for Visual Relation Detection. Conference: Conference: 2017 IEEE Conference on Computer Vision and Pattern: 5532-5540.
- [15] B. Schölkopf and A. Smola. (2002). Learning with Kernels: Support Vector Machines, Regularization, Optimization and Beyond. MIT Press, Cambridge. MA.
- [16] O. Chapelle, P. Haffner, and V. Vapnik. (1999). Support vector machines for histogram-based image classification. *NN*.
- [17] S. Melacci and M. Belkin. (2011). Laplacian support vector machines trained in the primal. *Journal of Machine Learning Research*. 12: 1149–1184.
- [18] Joachims, T. (1998). Text categorization with support vector machines—learning with many relevant features. In *Proceedings of the 10th European Conference on Machine Learning*. Chemnitz. Germany. (Berlin: Springer): 137–142.
- [19] Y. Tsuruoka, J. Tsujii, S. Ananiadou. (2009). Stochastic gradient descent training for  $\ell_1$ -regularized log-linear models with cumulative penalty. In *Proceedings of the AFNLP/ACL*.
- [20] Ren, S., He, K., Girshick, R., Sun, J. (2015). Faster r-cnn: Towards real-time object detection with region proposal networks. In: *Advances in neural information processing systems*: 91-99.