

หัวข้อคุณลักษณะ	การผสมผสานการจัดกลุ่มแบบฟัซซีกับเมตริกซ์การเกิดร่วมของระดับสีเทา
ผู้เขียน	นายยุทธนา มุลกลาง
ปริญญา	ปรัชญาดุษฎีบัณฑิต (วิศวกรรมคอมพิวเตอร์)
คณะกรรมการที่ปรึกษา	รศ. ดร. ศันสนีย์ เอื้อพันธ์วิริยะกุล อาจารย์ที่ปรึกษาหลัก รศ. ดร. นิพนธ์ ธีรอำพน อาจารย์ที่ปรึกษาร่วม ผศ. ดร. กานต์ ปทานุคม อาจารย์ที่ปรึกษาร่วม

บทคัดย่อ

พื้นผิวเป็นคุณสมบัติพื้นฐานที่สำคัญประการหนึ่งของรูปภาพ การวิเคราะห์พื้นผิวเป็นขั้นตอนที่สำคัญขั้นตอนหนึ่งในการนำไปใช้ในการรับรู้ภาพของคอมพิวเตอร์ โดยเฉพาะอย่างยิ่งการจำแนกพื้นผิวเป็นส่วนสำคัญในการวิเคราะห์ลักษณะของพื้นผิว ซึ่งเป็นปัญหาที่ยากเนื่องจากลักษณะของพื้นผิวมีลักษณะที่ไม่เหมือนกัน เช่น การหมุน มาตรการส่วนที่แตกต่างกัน และอื่น ๆ วิธีการสกัดลักษณะเด่นที่ดีของพื้นผิวจึงมีความจำเป็นต่อขั้นตอนของการวิเคราะห์เป็นอย่างดี

ในงานวิจัยนี้จึงได้นำเสนอวิธีการสกัดลักษณะเด่นของพื้นผิว โดยการผสมผสานการจัดกลุ่มแบบ Fuzzy C-Means (FCM) เข้ากับเมตริกซ์ของการเกิดร่วมของระดับค่าสีเทา (Gray Level Co-occurrence Matrix: GLCM) ซึ่งเมตริกซ์แบบฟัซซีของการเกิดร่วมของระดับค่าสีเทา (Fuzzy Co-Occurrence Matrix: FCOM) จะคำนวณมาจากค่าความเป็นสมาชิกในแต่ละกลุ่ม หลังจากนั้นเราสามารถทำการสกัดลักษณะเด่น 14 ค่า ประกอบด้วย contrast, correlation, energy, homogeneity, variance, sum average, sum variance, entropy, sum entropy, difference variance, difference entropy, information measure of correlation, maximal correlation coefficient จากแต่ละ FCOM ในการวิจัยนี้ได้ทำการทดสอบคุณลักษณะเด่นที่สกัดได้ด้วยวิธีฟัซซีพอร์ตเวกเตอร์แมชชีน กับฐานข้อมูลพื้นผิวชนิดสีเทาประกอบด้วย Brodatz, Kylberg, UIUC และ UMD ทั้งนี้ได้ทำการเปรียบเทียบผลการทดลองกับวิธีการสกัดลักษณะเด่นของพื้นผิวด้วยวิธีการสกัดแบบ GLCM ผลการจำแนกโดยอาศัยลักษณะเด่นของวิธีการที่นำเสนอจากชุดข้อมูลทดสอบคือ 100%, 100%, 100% และ 100% สำหรับฐานข้อมูล Brodatz, Kylberg, UIUC และ UMD ตามลำดับ ในขณะที่ผลการจำแนกโดยอาศัยลักษณะเด่นที่สกัดได้จากวิธีการ GLCM คือ 100%, 99.55%, 92% และ 99% ตามลำดับ จากผลการทดลองนี้ ลักษณะเด่น

ที่สกัดได้จากวิธีการที่นำเสนอให้ผลของการจำแนกที่ดีกว่าลักษณะเด่นที่สกัดได้จากวิธีการ GLCM ในทำนองเดียวกัน

ลำดับต่อมาได้ทำการทดสอบระบบตรวจความผิดปกติของภาพถ่ายเต้านมแบบอัตโนมัติด้วยลักษณะเด่นที่สกัดได้จากวิธีการ FCOM บนฐานข้อมูลสาธารณะ mini-MIAS ซึ่งประกอบด้วยความผิดปกติ calcification (CALC), well-defined/circumscribed masses (CIRC), speculated masses (SPIC) และ architectural distortion (ARCH) ซึ่งได้ทำการเปรียบเทียบผลของการตรวจจับความผิดปกติกับชุดลักษณะเด่นที่สกัดได้จาก GLCM โดยผลของการตรวจพบความผิดปกติชนิด ARCH, CALC, CIRC และ SPIC ด้วยชุดลักษณะเด่นของ FCOM คือ 100% ค่าผิดพลาดเชิงบวกต่อรูปภาพ (false positive per image: FPI) 9.46, 100% ที่ 3.39 FPI, 81.25% ที่ 18 FPI และ 90% ที่ 13.72 FPI ซึ่งผลการตรวจจับความผิดปกติที่ได้จากชุดลักษณะเด่นที่สกัดได้จาก GLCM คือ 100% ที่ 9.46 FPI, 89.47% ที่ 10.81 FPI, 68.75% ที่ 6.78 FPI และ 70% ที่ 4.45 FPI ตามลำดับ จากผลการตรวจจับความผิดปกติข้างต้นวิธีการที่นำเสนอได้ผลดีสำหรับความผิดปกติชนิด ARCH และ CALC ส่วนความผิดปกติประเภทอื่น ๆ ให้ผลการจำแนกที่ใกล้เคียงกันกับวิธีการจำแนกอื่น ๆ แต่วิธีที่นำเสนอไม่มีการปรับปรุงภาพเบื้องต้นใด ๆ และไม่มีการเลือกขอบเขตของพื้นที่ก่อนการจำแนก

นอกจากการทดลองที่กล่าวมาแล้วนั้น ได้ทดสอบระบบเพื่อทำการจำแนกประเภทของพาหนะยานเกราะจากฐานข้อมูล MSTAR ด้วยชุดลักษณะเด่นที่สกัดได้จากวิธีการที่นำเสนอ วิธีการจำแนกประเภทของพาหนะยานเกราะจากภาพถ่ายทางอากาศเป็นปัญหาที่มีการวิจัยกันอย่างกว้างขวางเนื่องจากรูปภาพที่ได้จากสัญญาณเรดาร์แตกต่างจากภาพที่มองเห็นได้ด้วยสายตา ฐานข้อมูล MSTAR ประกอบด้วยพาหนะยานเกราะ 3 ประเภท คือ รถถัง T72 รถลำเลียงพล BMP2 และรถลำเลียงพล BRT70 ในการจำแนกประเภทนี้จะใช้ตัวจำแนก MSVM และ RBF network นอกจากนี้ได้ทำการหลอมรวมผลลัพธ์จากการจำแนกด้วยตัวจำแนกทั้งสอง ด้วยวิธีการ ensemble average ผลการจำแนกที่ดีที่สุดจากชุดข้อมูลทดสอบคือ 97.94% จากการหลอมรวมจาก 20 ตัวจำแนกที่ดีที่สุดที่ได้มาจากตัวจำแนก RBF network 10 ชุด จากระยะห่างของระดับคู่สี่เทาที่ 5 และอีก 10 ชุด จากระยะห่างของระดับคู่สี่เทาที่ 10 ส่วนผลการจำแนกจากการหลอมรวมจากตัวจำแนก MSVM คือ 95.37% ซึ่งได้มาจากตัวจำแนก 10 ชุดจากระยะห่างของระดับคู่สี่เทาที่ 5 และอีก 10 ชุดจากระยะห่างของระดับคู่สี่เทาที่ 10 โดยทำการเปรียบเทียบกับผลลัพธ์ที่ได้จากการสกัดคุณลักษณะเด่นจาก GLCM ซึ่งผลลัพธ์ของการจำแนกที่ได้จากชุดลักษณะเด่นที่ได้จาก FCOM ให้ผลดีกว่าในทุก ๆ ผลการจำแนก

ในงานวิจัยนี้ยังได้ทำการทดลองการจำแนกฐานข้อมูลพื้นผิวชนิดสี ประกอบด้วย Outex, USPTex, Biomass, MondialMarmi และ NewbarkTex ซึ่งลักษณะเด่นที่สกัดได้จะเกิดจากการรวมกันของการสกัดลักษณะเด่นในแต่ละแขนงของสี ในการทดลองนี้ได้ทำการเปรียบเทียบกับลักษณะเด่นที่สกัด

จากวิธีการ GLCM และ Fuzzy Color Level Co-occurrence Matrix (FCLCM) ซึ่งวิธีการของ FCLCM จะคำนวณมาจากผลการจัดกลุ่มแบบ FCM ของทุกเซนเนลสีพร้อมกัน นอกจากนั้นแล้วยังได้ทำการเปรียบเทียบผลการจำแนก จากชุดลักษณะเด่นที่ได้จากวิธีการ Color Level Co-occurrence Matrix (CLCM) ด้วย ผลการจำแนกโดยใช้ลักษณะเด่นที่สกัดได้จาก FCOM บนชุดข้อมูลทดสอบ คือ 91.91%, 97.03%, 100%, 100% และ 97.55% สำหรับฐานข้อมูลพื้นผิวชนิดสีข้างต้นตามลำดับ ในขณะที่ผลการจำแนกจากชุดลักษณะเด่นที่สกัดได้จาก GLCM คือ 97.06%, 98.86%, 100%, 100% และ 97.55% ตามลำดับ ส่วนผลการจำแนกจากชุดลักษณะเด่นที่สกัดได้จาก FCLCOM คือ 89.71%, 89.53%, 100%, 100% และ 90.80% ตามลำดับ และผลการจำแนกจากชุดลักษณะเด่นที่สกัดได้จาก CLCM คือ 96.32%, 96.51%, 100%, 100% และ 96.32% ตามลำดับ จากผลการทดลองดังกล่าว ผลการจำแนกจากชุดลักษณะเด่นที่สกัดได้จาก FCOM ให้ผลการจำแนกได้ดีเทียบได้กับวิธีการอื่น ๆ สำหรับชุดข้อมูลพื้นผิวชนิดสี



ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่
Copyright© by Chiang Mai University
All rights reserved

Dissertation Title	Incorporating Fuzzy Clustering into Gray Level Co-occurrence Matrix	
Author	Mr. Yutthana Munklang	
Degree	Doctor of Philosophy (Computer Engineering)	
Advisory Committee	Assoc. Prof. Dr. Sunsanee Auephanwiriyakul	Advisor
	Assoc. Prof. Dr. Nipon Theera-Umpon	Co-advisor
	Asst. Prof. Dr. Karn Patanukhom	Co-advisor

ABSTRACT

Texture is one of the most important image characteristics. Texture analysis is also one of the important steps in many computer vision applications. Particularly, texture classification, a major part in texture analysis, is not an easy problem since texture can be non-uniform due to many reasons, such as rotation and scaling. A good feature extraction method is, therefore, needed in order to help in this process.

In this research, we incorporated the Fuzzy C-Means (FCM) clustering into the Gray Level Co-occurrence Matrix (GLCM). In particular, we computed the Fuzzy Co-Occurrence Matrices (FCOM) from the result of FCM for each cluster. There are fourteen features, i.e. contrast, correlation, energy, homogeneity, variance, sum average, sum variance, entropy, sum entropy, difference variance, difference entropy, information measure of correlation, and maximal correlation coefficient, computed from each FCOM. We then tested our features with the multiclass support vector machine (one-versus-all strategy) on the Brodatz, Kylberg, UIUC, and the UMD gray levels texture data sets. We also compared the classification result using the same set of feature extracted from the GLCM. The best validation set using the features computed from our FCOM are 100%, 100%, 100%, and 100% on the Brodatz, Kylberg, UIUC, and UMD, respectively, whereas those on the same data sets using the features from the GLCM were 100%, 99.55%, 92%, and 99%, respectively. The experimental results

showed that the features extracted from our FCOM provided a better classification performance than those from the regular GLCM.

Next, we developed a breast abnormalities detection system using the feature extracted from FCOM on the mini-MIAS public data set. The abnormalities considered were calcification (CALC), well-defined/circumscribed masses (CIRC), speculated masses (SPIC), and architectural distortion (ARCH). The feature set computed from the GLCM was also used for the purpose of comparison. The best blind test data set results of the ARCH, CALC, CIRC, and SPIC detection from the feature set computed from our FCOM were 100% with 9.46 false positives per image (FPI), 100% with 3.39 FPI, 81.25% with 18 FPI, and 90% with 13.72 FPI, respectively. The results of the same abnormalities detection from the feature set extracted from the GLCM were 100% with 9.46 FPI, 89.47% with 10.81 FPI, 68.75% with 6.78 FPI, and 70% with 4.45 FPI, respectively. From the experimental results, our system provided better performance than other existing methods in ARCH and CALC detection. Our results from our system were similar to the results from those methods used in SPIC and CIRC detection. However, our system did not require any preprocessing or region of interest (ROI) selection at all.

We also implemented our FCOM texture features in the synthetic aperture radar (SAR) automatic target recognition (ATR) on MSTAR public release data set. The SAR image classification is one of the most challenging problems because of the difficult characteristics of SAR images. The MSTAR consists of three types of military vehicles, i.e., T72 tank, BMP2 armored personnel carriers (APCs), and BTR70 APCs. In classification task, we used MSVM and the radial basis function (RBF) network as classifiers. Moreover, we implemented the ensemble average as a fusion tool. The best recognition result was at 97.94% correct detection from the fusion of the 20 best FCOM with RBF network models (the 10 best RBF network models at $d = 5$ and the other 10 best RBF network models at $d = 10$) while the best fusion result of FCOM with MSVM was at 95.37% correct detection (the 10 best MSVM models at $d = 5$ and the other 10 best MSVM models at $d = 10$). We also compared the fusion detection result using the same set of features extracted from the GLCM. The experimental results from FCOM were better than those from GLCM in all cases.

Finally, we also evaluated our features on the Outex, USPTex, Biomass, MondialMarmi, and NewBarkTex color texture data sets. In this case, the feature was combined from each color channel. We also compared the classification result using the same set of feature extracted from the GLCM and Fuzzy Color Levels Co-occurrence Matrix (FCLCOM). The FCLCOM was computed from the result of FCM where it clustered all color channels altogether. Furthermore, we also compared the classification result using the feature extracted from the Color Levels Co-occurrence Matrix (CLCM). The best validation set classification results using the features computed from our FCOM were 91.91%, 97.03%, 100%, 100%, and 97.55% on the color texture data sets, respectively. The results on the same data sets using the features extracted from the GLCM were 97.06%, 96.86%, 100%, 100%, and 97.55%, respectively. The same data sets using the features extracted from the FCLCOM were 89.71%, 89.53%, 100%, 100%, and 90.80%, respectively, whereas those on the same data sets using the features extracted from the CLCM were 96.32%, 96.51%, 100%, 100%, and 96.32%, respectively. Therefore, we concluded that the features extracted from our FCOM yielded good classification performance comparable to the other methods on the color texture.