

การสร้างสเปซคุณลักษณะเด่นสำหรับการวิเคราะห์ข้อมูลเอฟเอ็มอาร์ไอ Feature Space Construction for fMRI Data Analysis

ปริญญญา เจริญวรเกียรติ¹ ลือพล พิพานเมฆาภรณ์² และ สุวัจชัย กมลสันติโรจน³
ภาควิชาวิทยาการคอมพิวเตอร์และสารสนเทศ คณะวิทยาศาสตร์ประยุกต์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
แขวงวงศ์สว่าง เขตบางซื่อ กรุงเทพมหานคร 10800
e-mail: khun_pariya@yahoo.com¹ luepol.p@sci.kmutnb.ac.th² suwatachai.k@sci.kmutnb.ac.th³

บทคัดย่อ

การวิเคราะห์ข้อมูลภาพถ่ายสมองซึ่งได้จากเครื่องสแกนเอ็มอาร์ไอมีประโยชน์อย่างยิ่งในการศึกษาความสัมพันธ์ระหว่างกิจกรรมที่เกิดขึ้นภายในสมองกับหน้าที่ต่างๆ ของสมอง ที่ผ่านมามีงานวิจัยจำนวนมากนำเสนอเทคนิคการวิเคราะห์ภาพถ่ายสมองโดยใช้หลักการเรียนรู้ของเครื่อง อย่างไรก็ตามการวิเคราะห์ข้อมูลเอฟเอ็มอาร์ไอก็ยังคงเป็นเรื่องที่ยากและท้าทาย เนื่องจากคุณลักษณะเฉพาะของข้อมูลชนิดนี้ซึ่งมีจำนวนข้อมูลน้อยแต่มีมิติข้อมูลที่สูงมาก บทความวิจัยฉบับนี้นำเสนอเทคนิคใหม่สำหรับการวิเคราะห์ข้อมูลเอฟเอ็มอาร์ไอ ซึ่งประกอบไปด้วย 3 ขั้นตอนหลัก ได้แก่ การเลือกจุดสมองที่น่าสนใจ การสร้างสเปซลักษณะเด่นจากการวิเคราะห์ความสัมพันธ์ระหว่างจุดสมอง และการสร้างตัวจำแนกเอฟเอ็มอาร์ไอจากลักษณะเด่นที่ได้ ผลการทดลองซึ่งมีวัตถุประสงค์ในการทำนายภาพทดสอบจากภาพเอฟเอ็มอาร์ไอยืนยันได้ว่าอัลกอริทึมที่นำเสนอจะให้ผลลัพธ์ที่ดีกว่าเทคนิคเอฟเอ็มอาร์ไอในปัจจุบัน โดยพบว่ามีเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการจำแนกเพิ่มขึ้นมากกว่า 20 เปอร์เซ็นต์

คำสำคัญ: การวิเคราะห์ภาพถ่ายสมอง เอฟเอ็มอาร์ไอ การสกัดลักษณะเด่น การเรียนรู้ของเครื่อง

Abstract

Analysis of fMRI data is very useful for studying relationship between neural activity and a variety of brain functions. For many years, a number of brain image analysis techniques using machine learning were proposed. However, this task is still challenging due to the unique characteristics of the brain data with very small samples but extremely high dimensionality, reducing generalization performance. This paper presents a novel analysis method for fMRI data. It consists of three major steps: (1) Identifying informative voxels (2) extracting feature space by analyzing semantic relationships among voxels and (3) learning fMRI classifier from the extracted features. Preliminary experimental results conducted on the task of image prediction from fMRI data confirmed that the proposed method achieves improvements of classification accuracy (more than 20% in mean accuracy) in comparing with current neuroimaging methods.

Keywords: Brain Imaging Analysis, fMRI, Feature Extraction, Machine learning


1. บทนำ

Functional magnetic resonance imaging (fMRI) หรือเอฟเอ็มอาร์ไอ [1] คือเทคนิคการตรวจวัดการเปลี่ยนแปลงของเซลล์ประสาทในสมองซึ่งตอบสนองต่อคลื่นแม่เหล็กไฟฟ้า โดยอาศัยการเปลี่ยนแปลงของกระแสเลือดและความสัมพันธ์ของระดับออกซิเจนของเลือดในสมอง จากนั้นนำมาแปลงเป็นภาพถ่ายสมองสามมิติ (3D image) การวิเคราะห์ภาพถ่ายเอฟเอ็มอาร์ไอถูกนำไปใช้ประโยชน์ในหลายๆ ด้าน ตัวอย่างเช่น การวินิจฉัยทางการแพทย์ [2] และการสร้างระบบเชื่อมต่อกับสมอง (Brain Computer Interface system) [3] เป็นต้น

ข้อมูลภาพถ่ายเอฟเอ็มอาร์ไอจะประกอบไปด้วยจุดสมอง (voxel) จำนวนมาก โดยที่แต่ละจุดสมองจะถูกแสดงเป็นปริมาตรทรงลูกบาศก์ขนาดเล็กขึ้นอยู่กับความละเอียดของการสแกนสมอง จำนวนจุดสมองในภาพจะอยู่ระหว่าง 20,000 ถึง 60,000 จุด [1][4] ที่ผ่านมามีงานวิจัยของเครื่อง (Machine learning) มักมีบทบาทสำคัญในการวิเคราะห์ภาพถ่ายเอฟเอ็มอาร์ไอเพื่อที่จะอธิบายความสัมพันธ์ระหว่างจุดสมองกับหน้าที่ต่างๆ ของสมอง [5][7][11-12][17] จากชุดข้อมูล ระหว่างเทคนิคเหล่านี้ General linear models (GLM) [5] มักถูกใช้เพื่อที่จะค้นหาความสัมพันธ์เชิงเส้นระหว่างเวลาและจุดสมองซึ่งถูกกระตุ้นอย่างมีนัยสำคัญ อย่างไรก็ตาม GLM ยังคงมีข้อจำกัดหลายๆ ด้าน โดยเฉพาะอย่างยิ่งการละเลยความจริงที่ว่าหลายจุดสมองอาจทำงานร่วมกันเพื่อแยกแยะข้อมูล [5][6]

เพื่อที่จะแก้ปัญหาดังกล่าว นักวิจัยจำนวนหนึ่งเริ่มที่จะพิจารณาหลักการวิเคราะห์รูปแบบของจุดสมองซึ่งถูกกระตุ้นหลายจุด (Multi Voxel Pattern Analysis: MVPA) [5] แนวคิดของ MVPA ก็คือการค้นหา รูปแบบเชิงพื้นที่ (spatial pattern) ของจุดสมองหลายจุดซึ่งตอบสนองต่อสิ่งกระตุ้น (stimuli) เหมือนกัน ตัวอย่างเช่น งานวิจัย [7] นำเสนอเทคนิคการเลือกจุดสมอง (voxel selection) ที่น่าสนใจ โดยการ train ตัวจำแนก regularize (ได้แก่ Elastic Net) ด้วยชุดข้อมูลเอฟเอ็มอาร์ไอ อย่างไรก็ตามผลที่ได้ไม่ง่ายในการแปลความหมาย (interpretation) เนื่องจากแต่ละจุดสมองอาจมีหน้าที่ในการแยกแยะข้อมูลได้หลากหลายรูปแบบ งานวิจัยจำนวนหนึ่งใช้ความรู้จากผู้เชี่ยวชาญ (expert) เพื่อวิเคราะห์เฉพาะบริเวณของสมองซึ่งมีผลต่อเงื่อนไขโดยตรง แทนที่การวิเคราะห์ทั้งสมองเพื่อลดข้อผิดพลาดและเวลาที่ใช้ในการ train ตัวจำแนก [8][9]

ไม่นานมานี้งานวิจัยจำนวนหนึ่งนำเสนออัลกอริทึมการสกัดลักษณะเด่นจากภาพถ่ายสมองโดยใช้เทคนิค searchlight [5] [10-12] แนวคิดของ searchlight ก็คือการค้นหาสารสนเทศในแต่ละจุดสมองโดยพิจารณาจุดรอบข้างผ่านกริดสามมิติ (3D grid) แสดงดังภาพที่ 1 ตัวอย่างเช่นงานวิจัย [10] นำเสนอการสร้างแผนที่สารสนเทศ (information map) บนภาพสมองโดยใช้ searchlight ขนาด 4 มิลลิเมตรและ 33 จุดรอบข้างของแต่ละจุดสมองและทำการเลือกจุดสมองทั้งหมดภายใน searchlights ที่น่าสนใจ งานวิจัย [11] [12] จะใช้ประโยชน์จากการทำ cross validation ของการ train ตัวจำแนกโบนารีคลาสในแต่ละ searchlight ขนาด 2 มิลลิเมตร และ 27 จุดรอบข้างเพื่อใช้คัดเลือกจุดสมองที่น่าสนใจ



ภาพที่ 1 ตัวอย่างของ Searchlight ขนาด 30 จุดรอบข้าง

ถึงแม้ว่า searchlight จะให้ผลที่น่าสนใจในการวิเคราะห์ภาพเอเอ็มอาร์ไอ อย่างไรก็ตามเทคนิคเหล่านี้มุ่งเน้นการใช้ searchlight เป็นเกณฑ์ในการคัดเลือกจุดสมองและลดมิติข้อมูลในภาพ ขณะที่สารสนเทศจากตัวจำแนกซึ่งถูก train ในแต่ละ searchlight โดยทำ cross-validation กับชุดข้อมูลภาพไม่ได้ถูกนำมาพิจารณาในเทคนิคเหล่านี้

เพื่อที่จะจัดการกับข้อมูลเอเอ็มอาร์ไอ บทความวิจัยฉบับนี้จะนำเสนออัลกอริทึมการสกัดลักษณะเด่นสำหรับข้อมูลเอเอ็มอาร์ไอ แนวคิดก็คือการวิเคราะห์ความสัมพันธ์เชิงความหมายระหว่างจุดสมองในภาพ จากนั้นนำความสัมพันธ์ดังกล่าวมาใช้ในการสร้างสเปซคุณลักษณะเด่น (feature space) สำหรับอธิบายข้อมูลเอเอ็มอาร์ไอ เพื่อที่จะวิเคราะห์ความสัมพันธ์ดังกล่าว งานวิจัยนี้จะนำเสนอการใช้เทคนิคโครงข่ายประสาทเทียม (artificial neural network) ซึ่งจะ learn ความสัมพันธ์เหล่านี้จากสารสนเทศในแต่ละจุดสมอง จากการทดลองพบว่าลักษณะเด่นที่ได้จากเทคนิคที่นำเสนอจะมีความแม่นยำเฉลี่ยในการจำแนกข้อมูลเอเอ็มอาร์ไอมากกว่า เมื่อเปรียบเทียบกับเทคนิคเอเอ็มอาร์ไอในปัจจุบัน

2. วิธีการนำเสนอ (Proposed method)

เทคนิคที่นำเสนอในงานวิจัยนี้จะประกอบไปด้วย 3 ขั้นตอนหลัก ได้แก่ ขั้นตอนแรกคือการสร้าง searchlight สำหรับแต่ละจุดสมองในภาพ ขั้นตอนที่สองคือการเลือกจุดสมองที่น่าสนใจ (informative voxels) โดยอาศัยแผนที่ searchlight เพื่อที่จะลดมิติข้อมูล และขจัดสิ่งรบกวน (noise voxel) ในภาพสมอง ขั้นตอนที่สามจะเป็นการสกัดลักษณะเด่นในภาพสมองโดยการใช้สารสนเทศเชิงพื้นที่ (spatial information) ร่วมกับสารสนเทศเชิงรูปแบบ (pattern information) ผ่านกระบวนการเรียนรู้

ของโครงข่ายประสาทเทียม สุดท้ายจะนำลักษณะเด่นที่ได้ไปสร้างตัวจำแนกเอเอ็มอาร์ไอ (fMRI classifier) ผ่านอัลกอริทึม machine learning สำหรับรายละเอียดในแต่ละขั้นตอนจะถูกอธิบายแต่ละหัวข้อย่อยถัดไป

2.1 Searchlight บนจุดสมอง

กำหนดให้จุดสมองในภาพเอเอ็มอาร์ไอถูกแสดงในรูปเซต $V = \{v_j\}_{j=1...m}$ โดยที่ v_j หมายถึงจุดสมองลำดับที่ j และ m หมายถึงจำนวนจุดสมองทั้งหมดในภาพ ดังนั้นบริเวณจุดสมองรอบข้างของ v_j สามารถถูกนิยามได้ว่าเป็นเซตย่อย S_j

$$S_j = \{v \in V, d(v, v_j) \leq \hat{d}\}$$

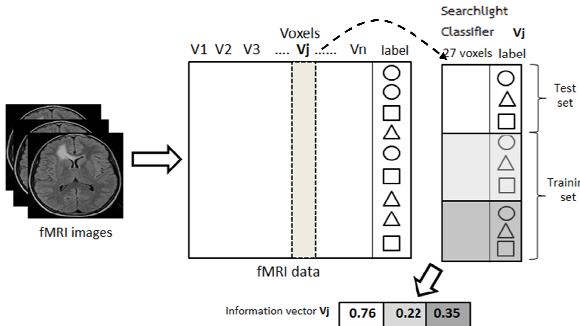
โดยที่ $d(v, v_j)$ จะหมายถึงระยะทางยูคลีเดียน (Euclidean distance) ระหว่าง v_j และ v และ \hat{d} คือรัศมี (radius) ของ searchlight เนื่องจาก S_j ควรจะมีขนาดที่เล็กเพียงพอสำหรับการค้นหาสารสนเทศใน v_j และเพื่อลดเวลาการ train ตัวจำแนก searchlight ในงานวิจัยนี้กำหนดรัศมี \hat{d} เท่ากับ 3 หน่วย (ถูกแนะนำในงานวิจัย [10]) ซึ่งจะทำให้ขนาดของแต่ละ searchlight จะเท่ากับ $3 \times 3 \times 3 = 27$ จุดรอบข้าง

2.2 เวกเตอร์สารสนเทศของจุดสมอง (voxel pattern vector)

ภาพเอเอ็มอาร์ไอประกอบไปด้วยจุดสมองจำนวนมาก ระหว่างจุดสมองเหล่านี้หลายจุดไม่มีประโยชน์และอาจส่งผลให้ประสิทธิภาพของตัวจำแนกเอเอ็มอาร์ไอลดลง ที่ผ่านมามีงานวิจัยนำเสนอเทคนิคการคัดเลือกจุดสมองที่น่าสนใจสอดคล้องกับความสามารถในการแยกแยะข้อมูลที่แตกต่างระหว่างสองคลาสใดๆ [11] [12] อย่างไรก็ตามข้อเสียของเทคนิคเหล่านี้ก็คือหากจำนวนคลาสในชุดข้อมูลมีมากจะส่งผลให้กระบวนการคัดเลือกทำได้ยากมากขึ้น เนื่องจากต้องมีการสร้างตัวจำแนกโบนารี (binary classifiers) จำนวนมาก เช่นหากจำนวนคลาสข้อมูลเท่ากับ 100 ในการประเมินแต่ละจุดสมอง จะต้อง train ตัวจำแนกทั้งหมดเท่ากับ $C(100, 2) = 4,950$ ตัว เพื่อสร้างเวกเตอร์สารสนเทศของจุดสมอง ยิ่งไปกว่านั้นหากจำนวนข้อมูล train ในแต่ละคลาสไม่มากเพียงพอการประเมินความแม่นยำของตัวจำแนกเหล่านี้ก็อาจไม่ถูกต้อง

เพื่อที่จะแก้ปัญหาดังกล่าว งานวิจัยนี้นำเสนอเทคนิคในการสร้างเวกเตอร์สารสนเทศจุดสมอง โดยการทำ K cross validation กับชุดข้อมูลเอเอ็มอาร์ไอ เริ่มต้นจะแบ่งชุดข้อมูลออกเป็น K กลุ่มๆ เท่ากัน ด้วยวิธีการสุ่มตัวอย่าง (random) โดยที่ K หมายถึงจำนวนคลาสของข้อมูล แต่ละกลุ่มจะประกอบไปด้วยข้อมูลที่ถูกรandomมาจากทุกๆ คลาสในสัดส่วนที่เท่ากัน แต่ละ searchlight ของจุดสมอง v_j จะทำ K cross validation โดยจะใช้ชุดข้อมูล K-1 กลุ่มสำหรับ train และที่เหลือสำหรับ test วนซ้ำจนกระทั่งครบทุกกลุ่ม ผลลัพธ์จากการทำ cross validation นี้ก็คือ

เวกเตอร์สารสนเทศ (information vector) ขนาด K มิติ โดยที่แต่ละมิติ จะแทนความแม่นยำในการจำแนก (classification accuracy) ในแต่ละ กลุ่มข้อมูลทดสอบ ภาพที่ 2 แสดงตัวอย่างการสร้างเวกเตอร์สารสนเทศ สำหรับ v_j ด้วยวิธีการของ K cross validation



ภาพที่ 2 เวกเตอร์สารสนเทศสำหรับจุดสมอง v_j โดยตัวจำแนก K-ways

จากภาพที่ 2 สมมติว่าชุดข้อมูลเอ็เอ็มอาร์ไอจำนวน 9 ตัวอย่างจาก 3 คลาส ได้แก่ \bigcirc , \square , \triangle เพื่อที่จะได้รับเวกเตอร์สำหรับจุดสมอง v_j ตัว จำแนก searchlight ของ v_j ซึ่งประกอบ 27 จุดรอบข้าง v_j ในทุกๆ คลาสจะถูกสร้างและทำ cross validation สุดท้ายค่าความแม่นยำจะถูก คำนวณจากความถูกต้องในการจำแนกแต่ละกลุ่มข้อมูลทดสอบและถูก แสดงในรูปแบบของเวกเตอร์สารสนเทศเพื่อประเมินคุณภาพของ v_j ใน งานวิจัยนี้เลือก Multiclass SVM [13] สำหรับตัวจำแนก searchlight

เพื่อที่จะเลือกจุดสมองที่น่าสนใจ เราเรียงลำดับจุดสมองสอดคล้องกับ ค่าเฉลี่ยความแม่นยำในแต่ละมิติซึ่งหากมีค่ามากกว่าหรือเท่ากับค่าเทรช โยล (threshold) ก็จะถูกเลือกเพื่อที่จะนำไปวิเคราะห์ต่อไป (ในงานวิจัยนี้ กำหนดค่าเทรชโยลเท่ากับ 0.6 เนื่องจากให้ผลที่ดีที่สุดในการชุดข้อมูลทดลอง)

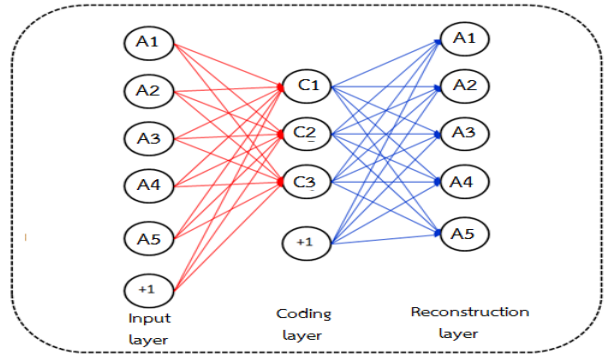
ข้อดีของวิธีการนี้ก็คือประสิทธิภาพของตัวจำแนก searchlight ที่อาจ เพิ่มขึ้น ซึ่งเป็นผลมาจากจำนวนข้อมูลในชุดข้อมูล train มีมากขึ้น ยิ่งไป กว่านั้นช่วยลดเวลาในการ train ข้อมูลเนื่องจากตัวจำแนก searchlight แบบ K ways จะมีจำนวนน้อยกว่าตัวจำแนกแบบโบนารีมาก

2.3 การเรียนรู้รูปร่างเชิงความหมาย (Learning Semantic Space)

ถึงแม้ว่าการเลือกจุดสมองที่น่าสนใจโดยใช้ information จากการ จำแนกข้อมูลในแต่ละคลาสจะช่วยลดจำนวนจุดสมองในภาพถ่ายสมองได้ อย่างไรก็ตามจำนวนจุดสมองก็อาจยังคงมีมากและบางจุดสมองก็อาจมีการ ทำงานร่วมกันภายใต้บางเงื่อนไข

เพื่อที่จะสร้างตัวจำแนก fMRI อย่างมีประสิทธิภาพ เทคนิคการลดมิติ ข้อมูล เช่น Singular Value Decomposition (SVD) และ Linear Discriminate Analysis (LDA) [13] บ่อยครั้งถูกนำมาใช้ในการแก้ปัญหา นี้ โดยการสร้างสเปซลักษณะเด่น (feature space) ซึ่งมีมิติต่ำกว่าข้อมูล ต้นฉบับ อย่างไรก็ตามเทคนิคเหล่านี้เป็นเทคนิคเชิงสถิติซึ่งสเปซที่ได้อาจไม่ เหมาะ (fit) กับข้อมูลและจะใช้ได้ดีในการลดมิติข้อมูลที่มีลักษณะเชิงเส้น (linear data) งานวิจัยนี้จะนำเสนอเทคนิคการสร้าง feature space

สำหรับเอ็เอ็มอาร์ไอ การใช้โครงข่ายประสาทเทียม Autoencoder [15][16] ซึ่งจะลดมิติข้อมูลโดยการเข้ารหัส (encoder) ของ information ในจุดสมอง ข้อดีของโครงข่ายประสาทเทียมชนิดนี้ก็คือความสามารถใน การสร้างรหัสเชิงความหมาย (semantic coding) สำหรับอธิบายข้อมูลที่ ซับซ้อนอย่างมีประสิทธิภาพ ภาพที่ 3 แสดงโครงสร้างของโครงข่าย ประสาทเทียม autoencoder



ภาพที่ 3 โครงสร้างของโครงข่ายประสาทเทียม autoencoder

จากภาพที่ 3 โครงข่ายประสาทเทียม autoencoder ประกอบไป ด้วย 3 ชั้นข้อมูล ได้แก่ชั้นอินพุต (input layer) ชั้นเข้ารหัส (coding layer) และชั้นสร้างข้อมูล (reconstruction layer) โดยที่จำนวนโหนด (node) ในชั้นอินพุตและชั้นสร้างข้อมูลจะมีจำนวนเท่ากัน ขณะที่จำนวน โหนดในชั้นเข้ารหัสจะมีจำนวนน้อยกว่า เพื่อจุดประสงค์ในการสร้าง semantic codesสำหรับอธิบายชุดข้อมูล

เพื่อที่จะเข้ารหัส information ในจุดสมอง เราวัดความเหมือนระหว่าง จุดสมอง โดยใช้ information vector ซึ่งได้จากการทำ k cross validation ของตัวจำแนก searchlight ในงานวิจัยนี้ใช้ตัววัดความ เหมือนเชิงมุม (cosine similarity) เพื่อที่จะคำนวณความเหมือนระหว่าง จุดสมอง v_i และ v_j ซึ่งถูกนิยามดังนี้

$$\cos(v_i, v_j) = \frac{\sum_{d=1}^k v_{id} \times v_{jd}}{\sqrt{\sum_{d=1}^k (v_{id})^2} \times \sqrt{\sum_{d=1}^k (v_{jd})^2}} \quad (1)$$

โดยที่ k หมายถึงจำนวนมิติของ information vector ในการทำ searchlight และความเหมือนเชิงมุมจะมีค่าอยู่ระหว่าง 0 ถึง 1

สำหรับทุกๆ คู่ของจุดสมอง v_i และ v_j ในภาพเอ็เอ็มอาร์ไอ เมตริกซ์ S จะแสดงค่าความเหมือนของจุดสมอง

	V1	V2	V5	Vm
V1	1.000	0.844	0.657	0.742
V2	0.844	1.000	0.380	0.823
V5	0.657	0.380	1.000	0.496
.....
Vm	0.742	0.122	0.675	1.000

ภาพที่ 4 เมตริกซ์ S ซึ่งได้จากการวัดความเหมือนระหว่างจุดสมอง

ขั้นตอนถัดไปก็คือการ train โครงข่ายประสาทเทียมเพื่อเข้ารหัสความเหมือนระหว่างจุดสมอง ในงานนี้จะใช้เมตริกซ์ความเหมือนของจุดสมอง S เป็นอินพุตและเอาท์พุตของโครงข่ายประสาทเทียมโดยที่โครงสร้างของโครงข่ายประสาทเทียมจะเป็นแบบ fully connected และถูกกำหนดค่าไว้ ดังนี้

1. จำนวนโหนดในชั้นอินพุตและชั้นสร้างข้อมูลใหม่จะมีค่าเท่ากับจำนวนคอลัมน์ m ของเมตริกซ์ S
2. จำนวนชั้นซ่อนจะถูกกำหนดให้เท่ากับ z โดยที่ $z \ll m$
3. ฟังก์ชันกระตุ้น (activation function) ของแต่ละโหนดในชั้น coding และชั้นสร้างข้อมูลใหม่จะใช้ฟังก์ชันกระตุ้นเชิงเส้น (linear activation function)

อัลกอริทึม Gradient Descent จะถูกใช้สำหรับกระบวนการ train โครงข่ายประสาทเทียม โดยนิยามฟังก์ชันเป้าหมาย (objective function) J ดังนี้

$$J(\theta) = \underset{\theta}{\operatorname{argmin}} \left\{ \frac{1}{m} \sum_i^m \|\hat{v}_i - v_i\|^2 + \frac{\lambda}{2} \|\theta\|_2^2 \right\}$$

- โดยที่ m คือจำนวนแถวของเมตริกซ์ S
- v_i คือเวกเตอร์ลักษณะเด่นของจุดสมอง v_i
- \hat{v}_i คือเวกเตอร์ลักษณะเด่นของจุดสมอง v_i ซึ่งได้จากโครงข่ายประสาทเทียม
- λ คือค่าพารามิเตอร์ regularization และ
- θ คือเวกเตอร์พารามิเตอร์ในโครงข่ายประสาทเทียม

ผลที่ได้จากการ train โครงข่ายประสาทเทียมนี้ก็คือเมตริกซ์ C_z ซึ่งจะแสดง latent code ของแต่ละจุดสมอง ในงานวิจัยนี้เราใช้ autoencoder neural network บน Matlab ซอฟต์แวร์ [16]

เพื่อที่จะได้รับ semantic representation สำหรับข้อมูลเอฟเอ็มอาร์ไอ เราสร้างแมปฟังก์ชัน $\varphi: X \rightarrow R_z$ ซึ่งแปลงชุดข้อมูลเอฟเอ็มอาร์ไอต้นฉบับ X เข้าไปอยู่ในเมตริกซ์ R_z ซึ่งจะมีมิติเท่ากับ z โดยที่ $z \ll m$ โดยการฉายภาพ (projection) ข้อมูลจากเมตริกซ์ต้นฉบับของชุดข้อมูลเอฟเอ็มอาร์ไอ X ดังนี้

$$\varphi(X) = X \cdot C_z^T = R_z$$

- โดยที่ R_z หมายถึงเมตริกซ์เอฟเอ็มอาร์ไอแปลง (Transformed fMRI matrix)
- C_z^T หมายถึงเมตริกซ์ทรานสโพส (Transposed matrix) ของเมตริกซ์ C_z

อัลกอริทึมด้านล่าง จะแสดงขั้นตอนการสร้าง feature space สำหรับเอฟเอ็มอาร์ไอ

Algorithm fMRI_Feature_Extractor

Input: informative voxel set V , fMRI matrix X and Number of z code dimensions

Output: fMRI transformed matrix R_z

1. For each voxel $v_i, v_j \in V$ do
2. compute cosine similarity w.r.t. their informational vector
3. End for
- 4.
5. Generate matrix S from the voxel similarities;
6. Learn code matrix C_z for each voxel by semantic autoencoder;
7. Transform matrix X with the mapping $\varphi(X) \rightarrow R_z$;
8. Return R_z ;

ภาพที่ 5 อัลกอริทึมการสกัดลักษณะเด่นสำหรับข้อมูลเอฟเอ็มอาร์ไอ

หลังจากการสกัดลักษณะเด่นใหม่ให้กับข้อมูลเอฟเอ็มอาร์ไอ ขั้นตอนสุดท้ายก็คือการ train ตัวจำแนกโดยใช้ข้อมูลเอฟเอ็มอาร์ไอทั้งหมด Multiclass linear SVM จะถูกใช้ในการทดลองนี้สำหรับการสร้างตัวจำแนกเอฟเอ็มอาร์ไอ เนื่องจากผลการทดลองในงานวิจัย [17]

3. การทดลอง (Experiment)

หัวข้อนี้จะกล่าวถึงวิธีการทดลอง ในงานวิจัยนี้เราเลือกที่จะวัดประสิทธิภาพของเทคนิคที่น่าเสนอในงานการทำนายหมวดของภาพทดสอบ (Image category) จากภาพถ่ายเอฟเอ็มอาร์ไอซึ่งถูกบันทึกและเปรียบเทียบกับเทคนิคอื่นๆ

3.1 ข้อมูล (Data)

สำหรับชุดข้อมูลที่น่ามาใช้ในการทดลอง ได้แก่ชุดข้อมูลมาตรฐานของภาพเอฟเอ็มอาร์ไอ StarPlus จากมหาวิทยาลัย Canegie Mellon [18] ซึ่งถูกสร้างขึ้นเพื่อวัตถุประสงค์สำหรับการใช้ในการทดลองเกี่ยวกับ brain functionality โดยภาพเอฟเอ็มอาร์ไอ ชุดข้อมูลนี้ประกอบไปด้วยภาพถ่ายสมองเอฟเอ็มอาร์ไอจากอาสาสมัครจำนวน 9 คน (ได้แก่ P1 – P9) แบ่งออกเป็นผู้ชาย 4 และผู้หญิง 5 คน ซึ่งมีช่วงอายุระหว่าง 18 ถึง 32 ปี อาสาสมัครแต่ละคนจะถูกขอให้มองภาพทดสอบจำนวน 12 หมวด (category) โดยที่แต่ละหมวดจะมีภาพทดสอบจำนวน 5 ภาพซึ่งสัมพันธ์กับหมวดของมัน จำนวน 6 รอบ และเครื่องจะทำการอ่านภาพสมองขณะที่อาสาสมัครกำลังดูภาพถ่าย ดังนั้นอาสาสมัครแต่ละคนจะถูกบันทึกภาพสมองทั้งหมด 360 ภาพ โดยที่แต่ละภาพจะถูกแปลงให้อยู่ในรูปของเวกเตอร์จุดสมอง (voxel vector) ซึ่งจำนวนมิติโดยเฉลี่ยแต่ละคนจะอยู่ระหว่าง 17,000 ถึง 19,000 จุดสมอง [18]

3.2 หลักการเปรียบเทียบ (Baseline approach)

ในการทดลองนี้ เราเปรียบเทียบวิธีการที่นำเสนอกับเทคนิค searchlight ที่มีอยู่ในปัจจุบันทั้งหมด 3 วิธี ดังนี้

- Searchlight-based center selection วิธีนี้จะเลือกจุดสมองเฉพาะที่อยู่ตรงกลางเป็นตัวแทน searchlight ที่ให้ความแม่นยำเฉลี่ยสูง
- Searchlight-based full selection [10] วิธีนี้จะเลือกจุดสมองและบริเวณทั้งหมดภายใต้ searchlight ที่ให้ความแม่นยำเฉลี่ยสูง
- Pattern-based voxel selection [11] [12] จะเลือกจุดสมองจากรูปแบบของการถูกกระตุ้น และนำรูปแบบของจุดสมองที่ได้มาสร้างลักษณะเด่นสำหรับข้อมูลเอฟเอ็มอาร์ไอ

เพื่อที่จะเปรียบเทียบกับทุกๆ เทคนิค ในการทดลองนี้ ผู้วิจัยจะใช้ searchlight ขนาด $3 \times 3 \times 3 = 27$ จุด และใช้ Multiclass linear SVM เป็นตัววัดประสิทธิภาพในทุกๆ เทคนิคที่เปรียบเทียบกัน

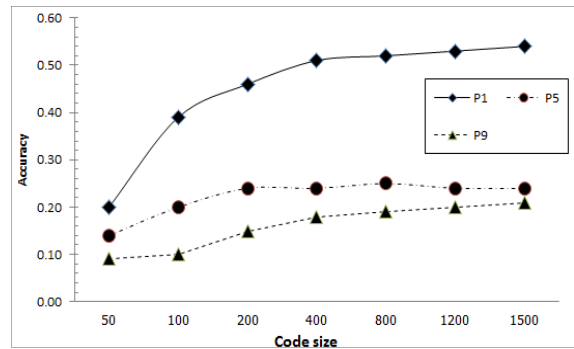
3.3 ขนาดของรหัส (code size)

พารามิเตอร์ที่สำคัญในเทคนิคที่นำเสนอคือขนาดของรหัส (code size) ของจุดสมอง ซึ่งจะกำหนดอย่างเหมาะสมสำหรับอาสาสมัครแต่ละคน ขนาดของรหัสที่สั้นเกินไปหรือยาวเกินไปอาจจะส่งกระทบต่อประสิทธิภาพตัวจำแนกเอฟเอ็มอาร์ไอ เพื่อที่จะได้รับขนาดของรหัสที่เหมาะสม เราทดลองปรับเปลี่ยนขนาดของรหัส ตามค่าดังนี้ 50 100 200 400 800 1,200 และ 1,500 และวัดประสิทธิภาพความแม่นยำในการจำแนกสำหรับแต่ละอาสาสมัคร ภาพที่ 6 แสดงตัวอย่างการหาขนาดของรหัสที่เหมาะสมสำหรับข้อมูล P1 P5 และ P9 ตามลำดับ

3.4 ผลการทดลอง

ตารางที่ 1 แสดงการเปรียบเทียบประสิทธิภาพความแม่นยำของตัวจำแนกเอฟเอ็มอาร์ไอในแต่ละเทคนิค จากตารางนี้จะเห็นว่าเทคนิคที่นำเสนอจะให้ความแม่นยำในการจำแนกข้อมูลเอฟเอ็มอาร์ไอสูงกว่าเทคนิคอื่นๆ โดยเฉพาะอย่างยิ่งเมื่อเปรียบเทียบกับเทคนิคการเลือกจุดสมองในงานวิจัย [11] ซึ่งจะเลือกจุดสมองสอดคล้องกับประสิทธิภาพตัวจำแนก searchlight ในแต่ละคู่ของคลาส พบว่าเทคนิคที่นำเสนอจะให้ผลลัพธ์ที่ดีขึ้นสำหรับอาสาสมัครส่วนใหญ่ (8 จาก 9 คน) ยกเว้น P1 ซึ่งมีเปอร์เซ็นต์ความแม่นยำลดลง 5.5 เปอร์เซ็นต์ สิ่งนี้แสดงให้เห็นว่าเทคนิคที่นำเสนอสามารถอธิบาย information ของจุดสมองได้ดีกว่า ยิ่งไปกว่านั้นผลลัพธ์นี้ยังแสดงให้เห็นถึงความสำคัญในการพิจารณาความสัมพันธ์ระหว่างจุดสมอง (voxel relations) ซึ่งไม่มีในเทคนิคอื่นสำหรับการจำแนกข้อมูลเอฟเอ็มอาร์ไออีกด้วย

ในการเปรียบเทียบกับเทคนิค center selection ซึ่งจะเลือกจุดสมองซึ่งสัมพันธ์กับ searchlight ที่ให้ความแม่นยำเฉลี่ยสูงกว่าค่าเทรชโฮล (≥ 0.6) จากตารางที่ 1 พบว่าเทคนิคของเรายังคงให้ประสิทธิภาพที่ดีกว่าในการทำนายหมวดภาพทดสอบจากข้อมูลเอฟเอ็มอาร์ไอ



ภาพที่ 6 แสดงประสิทธิภาพของตัวจำแนกเอฟเอ็มอาร์ไอสำหรับ P1 P5 และ P9 เมื่อมีการปรับเปลี่ยนขนาดของรหัส (code size)

สิ่งนี้สามารถอธิบายได้ว่า semantic information จากจุดสมองที่เกี่ยวข้องกัน (related voxels) จะช่วยเพิ่มความสามารถในการจำแนกข้อมูลเอฟเอ็มอาร์ไอ และการพิจารณาจุดสมองเพียงลำพังอาจทำให้ประสิทธิภาพการจำแนกลดลงได้ สิ่งนี้จะเห็นได้จากการเพิ่มขึ้นของเปอร์เซ็นต์ความแม่นยำเมื่อเปรียบเทียบกับเทคนิค full selection ซึ่งจะเลือกจุดสมองทั้งหมดที่อยู่ภายใน searchlight มาสร้างเป็น representation

อย่างไรก็ตามเทคนิค full selection อาจยังคงไม่ได้ผลที่น่าพึงพอใจเนื่องจากมาจากสองสาเหตุหลัก ได้แก่ (1) redundant information ซึ่งมาจากจุดสมองที่อยู่ใน searchlight ที่อยู่ในบริเวณซ้อนทับ ยิ่งไปกว่านั้นจำนวนจุดสมองที่เพิ่มมากขึ้นมีแนวโน้มที่จะลดประสิทธิภาพของตัวจำแนก และ (2) การละเลยที่จะพิจารณาความสัมพันธ์ระหว่างจุดสมองเหล่านี้ เทคนิคที่นำเสนอในงานวิจัยนี้แก้ปัญหาดังกล่าวโดยการเลือกจุดสมองที่สำคัญและใช้โครงข่ายประสาทเทียม autoencoder สำหรับการอธิบาย semantic information ซึ่งซ่อนอยู่ในจุดสมองเหล่านี้

4. สรุป

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาเทคนิคสำหรับการวิเคราะห์รูปแบบของจุดสมองแบบหลายจุด (multi-voxel pattern analysis) สำหรับภาพสมองซึ่งมาจากการถ่ายด้วยเทคนิคเอฟเอ็มอาร์ไอ เราพัฒนาอัลกอริทึมสำหรับการเลือกจุดสมองที่น่าสนใจเพื่อลดมิติข้อมูลของภาพ โดยการทำการ searchlight นอกจากนั้นผู้วิจัยยังนำเสนอเทคนิคใหม่ในการสร้าง semantic representation สำหรับแสดงภาพเอฟเอ็มอาร์ไอ โดยการประยุกต์ใช้โครงข่ายประสาทเทียม autoencoder ร่วมกับ spatial information และ searchlight information ในแต่ละจุดสมองที่น่าสนใจ เพื่อที่จะอธิบายความสัมพันธ์ระหว่างจุดสมองเหล่านี้

จากผลการทดลองเอฟเอ็มอาร์ไอซึ่งถูกสร้างขึ้นในงานวิจัยนี้เพื่อทดสอบการทำนาย (prediction) หมวดหมู่ของภาพเอฟเอ็มอาร์ไอทดสอบโดยอาสาสมัครจำนวน 9 คน ในชุดข้อมูล Starplus

ตารางที่ 1 แสดงประสิทธิภาพความแม่นยำในการจำแนก (classification accuracy) ของตัวจำแนก SVM สำหรับเอฟเอ็มอาร์ไอในแต่ละเทคนิค

Method / participant	P1	P2	P3	P4	P5	P6	P7	P8	P9	AVG
Our proposed method	0.51	0.40	0.35	0.48	0.24	0.30	0.33	0.26	0.21	0.342
Baseline (Voxel Selection) [11] [12]	0.54	0.34	0.33	0.42	0.15	0.19	0.22	0.21	0.16	0.284
Baseline (Searchlight-based full Selection) [10]	0.42	0.31	0.30	0.38	0.14	0.22	0.21	0.20	0.14	0.258
Baseline (Searchlight-based Center Selection)	0.40	0.29	0.27	0.37	0.13	0.16	0.20	0.18	0.13	0.237
Baseline (use all voxels)	0.30	0.21	0.19	0.27	0.13	0.09	0.14	0.13	0.15	0.179
#Best Code Size	800	400	800	400	200	800	1,200	400	1,200	688.88

แสดงให้เห็นว่าเทคนิคการสกัดลักษณะเด่นที่นำเสนอประสบความสำเร็จในการเพิ่มประสิทธิภาพของตัวจำแนกเอฟเอ็มอาร์ไอ เปรียบเทียบกับเทคนิคเอฟเอ็มอาร์ไอที่ใช้ในปัจจุบัน โดยมีเปอร์เซ็นต์ความแม่นยำในการจำแนกเพิ่มขึ้น 20.70 เปอร์เซ็นต์ ผู้วิจัยเชื่อว่าเทคนิคที่นำเสนอในงานวิจัยนี้จะเป็นแนวทางใหม่สำหรับการวิเคราะห์ภาพเอฟเอ็มอาร์ไอ สำหรับงานในอนาคตก็คือการสำรวจแอปพลิเคชันต่างๆ ของเอฟเอ็มอาร์ไอซึ่งจะประยุกต์ใช้เทคนิคนี้ เช่นการวินิจฉัยทางการแพทย์โดยภาพเอฟเอ็มอาร์ไอ [2] หรือระบบอินเตอร์เฟซกับสมอง [3] เป็นต้น

เอกสารอ้างอิง

- [1] Poldrack, Russell A., Jeanette A. Mumford, and Thomas E. Nichols. Handbook of functional MRI data analysis. Cambridge University Press, 2011.
- [2] Long, Jinyi, et al. "Prediction of post-earthquake depressive and anxiety symptoms: a longitudinal resting-state fMRI study." Scientific reports 4 (2014).
- [3] Daly, Janis J., and Jane E. Huggins. "Brain-Computer Interface: Current and Emerging Rehabilitation Applications." Archives of physical medicine and rehabilitation 96.3 (2015): S1-S7.
- [4] Friston, Karl J., et al. "Statistical parametric maps in functional imaging: a general linear approach." Human brain mapping 2.4 (1994): 189-210.
- [5] Norman, Kenneth A., et al. "Beyond mind-reading: multi-voxel pattern analysis of fMRI data." Trends in cognitive sciences 10.9 (2006): 424-430.
- [6] Chou, Chun-An, et al. "Voxel Selection Framework in Multi-Voxel Pattern Analysis of fMRI Data for Prediction of Neural Response to Visual Stimuli." Medical Imaging, IEEE Transactions on 33.4 (2014): 925-934.
- [7] Carroll, Melissa K., et al. "Prediction and interpretation of distributed neural activity with sparse models." NeuroImage 44.1 (2009): 112-122.
- [8] Weiner, Kevin S., and Kalanit Grill-Spector. "Sparsely-distributed organization of face and limb activations in human ventral temporal cortex." Neuroimage 52.4 (2010): 1559-1573.
- [9] Kim, Junsuk, et al. "A multi-voxel pattern analysis of neural representation of vibrotactile location." Control, Automation and Systems (ICCAS), 2013 13th International Conference on. IEEE, 2013.
- [10] Kriegeskorte, Nikolaus, Rainer Goebel, and Peter Bandettini. "Information-based functional brain mapping." Proceedings of the National Academy of Sciences of the United States of America 103.10 (2006): 3863-3868.
- [11] Pereira, Francisco, and Matthew Botvinick. "Classification of functional magnetic resonance imaging data using informative pattern features." Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining. ACM, 2011.
- [12] Pereira, Francisco, and Matthew Botvinick. "A systematic approach to extracting semantic information from functional MRI data." Advances in Neural Information Processing Systems. 2012.
- [13] Franc, Vojtech, and Václav Hlaváč. "Statistical pattern recognition toolbox for Matlab." Prague, Czech: Center for Machine Perception, Czech Technical University (2004).
- [14] Wall, Michael E., Andreas Rechtsteiner, and Luis M. Rocha. "Singular value decomposition and principal component analysis." A practical approach to microarray data analysis. Springer US, 2003. 91-109.
- [15] Vincent, Pascal, et al. "Extracting and composing robust features with denoising autoencoders." Proceedings of the 25th international conference on Machine learning. ACM, 2008.
- [16] Ng, Andrew. "Sparse autoencoder." CS294A Lecture notes 72 (2011).
- [17] Pereira, Francisco, Tom Mitchell, and Matthew Botvinick. "Machine learning classifiers and fMRI: a tutorial overview." Neuroimage 45.1 (2009): 199-209.
- [18] Mitchell, Tom M., et al. "Predicting human brain activity associated with the meanings of nouns." science 320.5880 (2008): 1191-1195.