

## การออกแบบและพัฒนาเครื่องมือการจัดกลุ่มยีนโดยใช้ข้อมูลการแสดงออกของยีน และข้อมูลของส่วนหน้าของยีน\*

### A Design and Development of Clustering Tool Using Gene Expression and Upstream Region Data

วัฒน์วิมูลย์ แพรมงคล<sup>1</sup>, อันันต์ ทองทา<sup>2</sup>, ดวงดาว วิชาดาภุล<sup>3</sup>

<sup>1</sup> หลักสูตรชีวสารสนเทศ, คณะเทคโนโลยีสารสนเทศและคณะเทคโนโลยีชีวภาพและเทคโนโลยี  
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

<sup>2</sup> คณะเทคโนโลยีชีวภาพและเทคโนโลยีชีวภาพและเทคโนโลยีมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี

<sup>3</sup> หน่วยชีวสารสนเทศ ศูนย์พันธุวิศกรรมและเทคโนโลยีชีวภาพแห่งชาติ

**บทคัดย่อ –** เทคโนโลยีไมโครอเรียได้มีบทบาทในงานวิจัยทางด้านเทคโนโลยีชีวภาพในปัจจุบันเป็นอย่างมาก ไม่ว่าจะเป็นในด้านการศึกษาหน้าที่ของยีน (Gene function) การศึกษาโครงสร้างการควบคุมการแสดงออกของยีน (Gene regulatory networks) และการค้นหาไข่ใหม่ เป็นต้น ข้อมูลที่ได้จากไมโครอเรย์นั้นเป็นข้อมูลของการแสดงออกของยีน (Gene expression data) ทั้งหมดภายในเซลล์ซึ่งข้อมูลดังกล่าวจะสามารถนำร้าไปสู่ความเข้าใจการทำงานระดับของเซลล์ภายในสิ่งแวดล้อมที่นักชีววิทยาต้องการศึกษา โดยการจัดการข้อมูลของการแสดงออกของยีนนั้นโดยทั่วไปแล้วจะทำการจัดกลุ่มของยีนเข้าด้วยกันโดยคูเพียงความคล้ายคลึงของรูปแบบของการแสดงออกของยีนท่านั้น ซึ่งเครื่องมือที่ใช้ในการจัดกลุ่มข้อมูลของการแสดงออกของยีนในปัจจุบันส่วนใหญ่ใช้เพียงข้อมูลของการแสดงออกของยีน ซึ่งการใช้ชุดของข้อมูลเพียงรูปแบบของการแสดงออกของยีนนั้นอาจไม่เพียงพอ เนื่องจากข้อมูลการแสดงออกของยีนนักกิจกรรมกวนจากลิ่งแวดล้อม และการแสดงออกของยีนที่มีรูปแบบคล้ายคลึงกันที่เป็นตัวบ่งชี้ที่ไม่ชัดเจนที่จะสรุปได้ว่ายีนเหล่านั้นควรจะอยู่ในกลุ่มเดียวกัน ดังนั้นหากเราทำการเพิ่มข้อมูลอื่นๆ ลงไปร่วมกับข้อมูลการแสดงออกของยีน ก็จะทำให้การจัดกลุ่มของยีนทำได้ถูกต้องมากขึ้น โดยข้อมูลที่นำมาเพิ่มนั้นก็คือข้อมูลของส่วนหน้าของยีน (Upstream regions data) ซึ่งเป็นส่วนควบคุมการแสดงออกของยีน โดยเชื่อว่าหากยีนที่มีส่วนหน้าของยีนที่คล้ายคลึงกัน ก็จะมีคุณสมบัติแสดงออกในระบบของเมดานอลิซึมเดียวกัน การจัดกลุ่มแบบ naïve Bayes (Naïve Bayes classification) ถูกนำมาใช้ในการจัดกลุ่มของ 2 ชุดข้อมูล และนำผลจากการจัดกลุ่มของทั้ง 2 ชุดข้อมูลมาซ้อนกัน (Overlapping- algorithm) โดยจะทำให้ผลลัพธ์การทับซ้อนของข้อมูลมีประสิทธิภาพมากขึ้น

**คำสำคัญ –** การจัดกลุ่มของยีน (Gene clustering), การจัดกลุ่มแบบ naïve Bayes (Naïve Bayes classification), การแสดงออกของยีน (Gene expression), บริเวณส่วนหน้าของยีน (Upstream regions)

\* งานวิจัยนี้ได้รับทุนสนับสนุนจากศูนย์พันธุวิศกรรมและเทคโนโลยีชีวภาพแห่งชาติ

## 1. บทนำ

ปัจจุบันงานวิจัยในด้านโพสต์โจนิมิก (Post-genomic) กำลังเป็นที่สนใจแก่นักชีววิทยาระดับโมเลกุล โดยเครื่องมือหนึ่งที่มีความสำคัญต่อการศึกษางานวิจัยด้านนี้คือ ไมโครอาร์ทีอีนเอซึ่งเป็นเครื่องมือที่ทำให้นักวิจัยสามารถศึกษาการแสดงออกของยีนจำนวนหลายพันยีน โดยทำการทดลองเพียงครั้งเดียว จึงทำให้การศึกษางานวิจัยด้านโพสต์โจนิมิกทำได้รวดเร็ว และได้ข้อมูลที่ถูกต้องมากขึ้น วิธีการที่จะจัดการกับข้อมูลการแสดงออกของยีนโดยทั่วไปนิยมที่จะจัดกลุ่มของยีนเข้าด้วยกัน โดยการหาความคล้ายคลึงกันของรูปแบบการแสดงออกของยีน (Pattern of gene expression) [1] ซึ่งเครื่องมือที่ใช้ในการจัดกลุ่มของยีนในปัจจุบันมีอยู่num-many เท่าน Cluster (Eisen), SAM (Stanford), GeneCluster (MIT) และ J-Express (Molmine) [1,2,3,4] แต่เครื่องมือที่ใช้ในการจัดกลุ่มยีนในปัจจุบัน จะทำการพิจารณาข้อมูลการแสดงออกของยีนเพียงข้อมูลเดียว ด้วยการคูณรูปแบบการแสดงออกของยีนเป็นหลัก หากยีนใดมีรูปแบบของการแสดงออกของยีนที่คล้ายคลึงกัน ก็จะจัดกลุ่มยีนเหล่านั้นเข้าด้วยกัน อย่างไรก็ตามการพิจารณาข้อมูลการแสดงออกของยีนเพียงอย่างเดียวนั้น อาจไม่เพียงพอที่จะแสดงว่ายีนที่ถูกจัดกลุ่มเข้าด้วยกันมีความสัมพันธ์ไปในทางเดียวกันหรือไม่ เนื่องจากข้อมูลการแสดงออกของยีนจากไมโครอาร์ทีอีกเกิดสิ่งรบกวนต่อตัวข้อมูลได้มาก และการที่ยีนมีรูปแบบของการแสดงออกของยีนที่เหมือนกันก็ไม่ได้เป็นตัวบ่งชี้ที่เด่นชัดว่ายีนเหล่านั้นควรจะถูกจัดอยู่ในกลุ่มเดียวกัน [5] ด้วยข้อจำกัดของข้อมูลดังกล่าว เราจึงเสนอที่จะเพิ่มข้อมูลทางชีววิทยาอีกหนึ่งข้อมูลของการแสดงออกของยีนเพื่อช่วยในการจัดกลุ่มยีน โดยหวังว่าการเพิ่มข้อมูลนี้จะช่วยให้สามารถเพิ่มประสิทธิภาพในการจัดกลุ่มของยีนได้ดีขึ้น ข้อมูลทางชีววิทยาที่เราเลือกเข้ามาร่วมด้วยในการจัดกลุ่มยีนนั้นคือ ข้อมูลของส่วนหน้าของยีน ด้วยเหตุผลที่ว่า ในกระบวนการทางชีววิทยาระดับเซลล์ส่วนใหญ่นั้นจะถูกควบคุมพอดีกับกระบวนการแสดงออกในระดับการถอดรหัสพันธุกรรมของดีเอ็นเอ (Transcription) ด้วยการที่ Transcription factor จะเข้าไปปัจจัยกับตำแหน่งของดีเอ็นเอ(Motif) ที่จำเพาะกับโปรตีนนั้นๆ ซึ่งอยู่บนตำแหน่งที่ไม่สามารถถอดรหัสพันธุกรรม (Non-coding region) โดยตำแหน่งที่ไม่สามารถถอดรหัสพันธุกรรมจะเป็นไกด์ทั้งส่วนหน้าของยีน ส่วนหลังของยีน และแฟรงค์อยู่ในส่วนที่สามารถถอดรหัสพันธุกรรมของยีนคนละชนิดซึ่งพบในยูคาริโอต ในงานวิจัยนี้เลือกใช้ส่วนหน้าของยีนเนื่องจาก เป็นส่วนที่พื้นที่ในไมโครอาร์ทีอี และยูคาริโอต ที่สำคัญในส่วนหน้าของยีนนี้เป็นส่วนที่มีบทบาทอย่างมากในการควบคุม

การแสดงออกของยีน ดังนั้นเราจึงคาดว่ายีนที่ถูกควบคุมการทำงานร่วมกันนั้นจะมีรูปแบบของส่วนหน้าของยีนที่คล้ายคลึงกัน เพราะฉะนั้นชุดของข้อมูลของส่วนหน้าของยีนจึงเหมาะสมที่จะถูกเลือกเพื่อนำมาช่วยในการจัดกลุ่มยีน

ผลงานการวิจัยเพื่อเพิ่มประสิทธิภาพการจัดกลุ่มยีนโดยใช้ข้อมูลร่วม เราได้พัฒนาโปรแกรมที่มีชื่อว่า “ชู-คลัสเตอร์” (XU-Cluster) ที่สามารถจัดกลุ่มยีนโดยใช้ข้อมูลการแสดงออกของยีน และ ข้อมูลส่วนหน้าของยีน โดยชู-คลัสเตอร์ จะทำการเรียกโปรแกรม AutoClass [6] เพื่อจัดกลุ่มยีนสำหรับแต่ละชุดข้อมูล หลังจากนั้นชู-คลัสเตอร์จะนำกลุ่มยีนที่ผ่านการจัดกลุ่มโดย AutoClass มาหาข้อร่วม (yinที่พบทั้งในกลุ่มยีนที่ถูกจัดกลุ่มด้วยข้อมูลการแสดงออกของยีนและข้อมูลส่วนหน้าของยีน) ซึ่งกลุ่มยีนใหม่จากขั้นตอนการหาข้อร่วมนั้น เราเชื่อว่า จะเป็นกลุ่มยีนที่มีความละเอียด และมีความถูกต้องมากขึ้น นอกจากรูปแบบของชู-คลัสเตอร์ได้จัดเตรียมเครื่องมือที่เกี่ยวข้องกับการแสดงผลเป็นภาพชั้นประภากลุ่มด้วย การแสดงผลในรูปของเส้น และการแสดงผลในรูปของกราฟ เพื่อให้ผู้ใช้มีความสะดวก และง่ายต่อการแปลผลลัพธ์มากขึ้น

## 2. วิธีการศึกษา

### 2.1 ข้อมูลที่ใช้ในการทดลอง

งานวิจัยนี้ใช้ชุดข้อมูลทั้งหมด 3 ชุด โดยมีรายละเอียดดังต่อไปนี้

#### 2.1.1 ชุดข้อมูลของการแสดงออกของยีนจากไมโครอาร์ทีอี (Gene expression data)

ชุดข้อมูลนี้นำมาจากฐานข้อมูลในโครงการของสแตนฟอร์ด (genome-www5.stanford.edu) ในงานวิจัยนี้ได้เลือกชุดข้อมูลที่ทำการศึกษาเกี่ยวกับกระบวนการทำงานของส่วนหน้าของยีนในวัฏจักรเซลล์ และการเจริญของเส้นใยเทียมในยีสต์ (Two yeast forkhead genes regulate the cell cycle and- pseudohyphal growth) [7] โดยชุดข้อมูลนี้เป็นการทดลองแบบอนุกรมเวลา โดยมียีนทั้งหมด 5,171 ยีน และทำการทดลองทั้งหมด 26 การทดลอง (fkh1,2 alpha factor 0 – 210 นาที : 13 การทดลอง, cell cycle-alpha factor, fkh1, fkh2 0 - 180 นาที : 13 การทดลอง) ข้อมูลที่ได้จากฐานข้อมูลจะถูกนำมาจัดให้อยู่ในสภาวะบรรทัดฐานเดียวกัน (Normalization) ด้วย log<sub>2</sub> และทำการกรองยีนที่มีข้อมูลที่ขาดหายไป (Missing data) และยีนที่ไม่มีนัยสำคัญต่อการวิเคราะห์ ด้วยชุดเครื่องมือทางชีวสารสนเทศใน Matlab เวอร์ชัน 7 [8] โดยข้อมูลหลังจากการกรองแล้วเหลือ 731 ยีน ซึ่งจะถูกจัดเก็บในรูปของไฟล์ข้อความ (Text file)

### 2.1.2 ชุดข้อมูลของส่วนหน้าของยีน (Upstream sequence data)

ข้อมูลของส่วนหน้าของยีนนี้ได้มาจากการ Regulatory Sequence Analysis Tools [9] ซึ่งเป็นเครื่องมือที่ใช้ในการคึงของข้อมูลของส่วนหน้าของยีน และงานวิจัยนี้ได้เลือกส่วนของหน้าเขินที่ตั้งแต่ -800 ถึง -1 เป็นจำนวน 800 นิวคลีโอไทด์ จากนั้นทำการจัดเก็บข้อมูลในรูปของไฟล์ข้อความ (Text file) ในรูปแบบของ FASTA

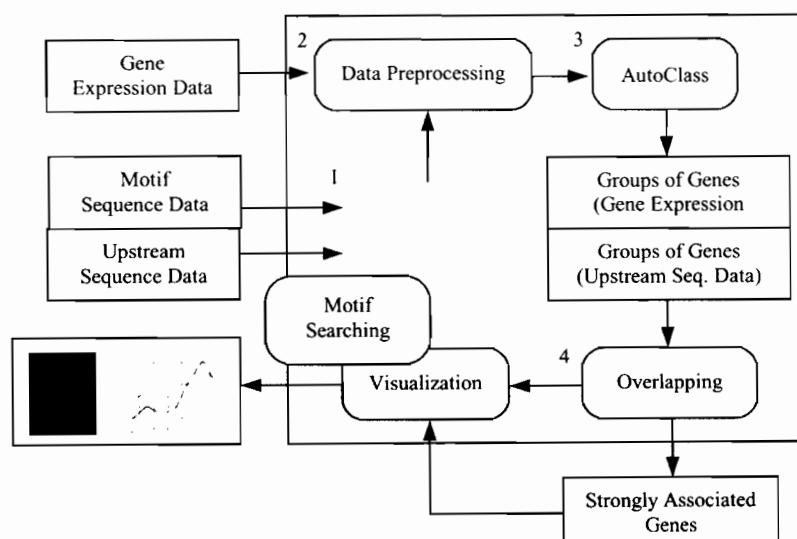
### 2.1.3 ชุดข้อมูลของโมโนฟี (Motif sequence data)

ชุดข้อมูลโมโนฟีในงานวิจัยนี้นำมาจาก 2 ฐานข้อมูล คือ ฐานข้อมูลของส่วนส่งเสริมการทำงานของยีน (Promoter region) ในชีสต์ (The Promoter Database of *Saccharomyces cerevisiae* : SCPD[10]) และ ฐานข้อมูลของโปรตีนที่จับสนับสนุนที่ไม่สามารถอ่านรหัสพันธุกรรมได้ (TRANSFAC® 6.0 – Public [11]) ในงานวิจัยนี้ผู้วิจัยได้ทำการเลือกชุดของโมโนฟีที่เกี่ยวข้องกับการทำงานของวัฏจักรเซลล์เนื่องจาก

วัฏจักรเซลล์เป็นกระบวนการทำงานที่สำคัญของสิ่งมีชีวิตจึงน่าจะเป็นที่สนใจของนักวิทยาศาสตร์ นอกจากนี้ชุดของโมโนฟีที่เกี่ยวข้องกับวัฏจักรเซลล์มีผู้ทำการทดลองมาก many เราจึงสามารถเลือกชุดของโมโนฟีได้มากกว่าเมื่อเปรียบเทียบกับชุดของโมโนฟีชุดอื่นๆ สำหรับความバラของโมโนฟีนั้นผู้วิจัยได้เลือกความバラที่อยู่ระหว่าง 6 – 10 เบส โดยไฟล์ของข้อมูลนี้มีลักษณะเป็นไฟล์ข้อความที่ประกอบด้วยชื่อโมโนฟีรูปแบบของโมโนฟี และตำแหน่งที่พบบนส่วนหน้าของยีน

## 2.2 โครงสร้างการทำงานของชู-คลัสเตอร์

ชู-คลัสเตอร์ประกอบด้วย 5 ส่วนหลัก คือ 1) ส่วนการค้นหาโมโนฟีบนส่วนหน้าของยีน 2) ส่วนการเตรียมข้อมูลเพื่อการประมวลผล 3) ส่วนการประมวลผลโดยโปรแกรม AutoClass 4) ส่วนการหาเชิงร่วม และ 5) ส่วนแสดงผลด้วยภาพ ดังรูปที่ 1

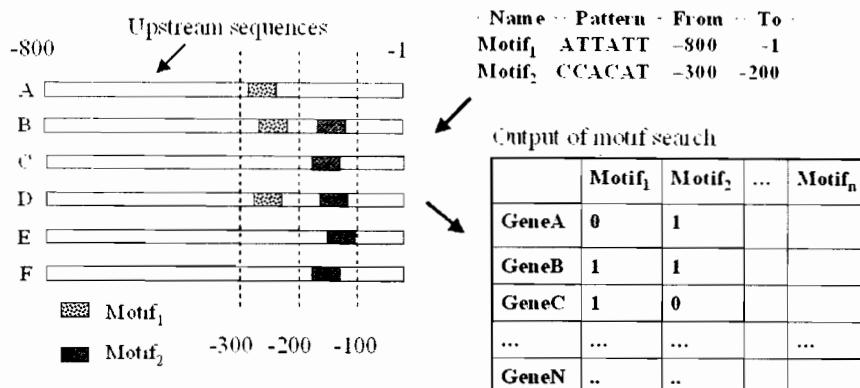


รูปที่ 1. แสดงโครงสร้างการทำงานของชู-คลัสเตอร์

### 2.2.1 ส่วนการค้นหาโมโนฟีบนส่วนหน้าของยีน

ข้อมูลที่ใช้ในขั้นตอนนี้คือ ข้อมูลโมโนฟี และข้อมูลส่วนหน้าของยีน โดยที่ไฟล์ของชุดโมโนฟีจะถูก拿来ไปตรวจสอบเพื่อคุ้ว่าพบรูปแบบของโมโนฟีเหล่านั้นบนส่วนหน้าของยีนหรือไม่ หากพบโปรแกรมจะทำการให้คะแนนเป็น 1 แต่หากไม่พบรูปแบบของโมโนฟีนั้นๆ บนส่วนหน้าของยีน โปรแกรมจะให้คะแนนเป็น 0 โดยตำแหน่งของโมโนฟีสามารถระบุตำแหน่งที่ชัดเจนหากเราทราบข้อมูลที่แน่นอนของโมโนฟีนั้นๆ

และหากไม่ทราบตำแหน่งที่ชัดเจนเราสามารถระบุตำแหน่งของข้อมูลอย่างกว้างๆ ได้ ขั้นตอนการค้นหาโมโนฟีบนส่วนหน้าของยีนแสดงดังรูปที่ 2



รูปที่ 2. แสดงส่วนการค้นหาโน้มที่พบในส่วนหน้าของยีน

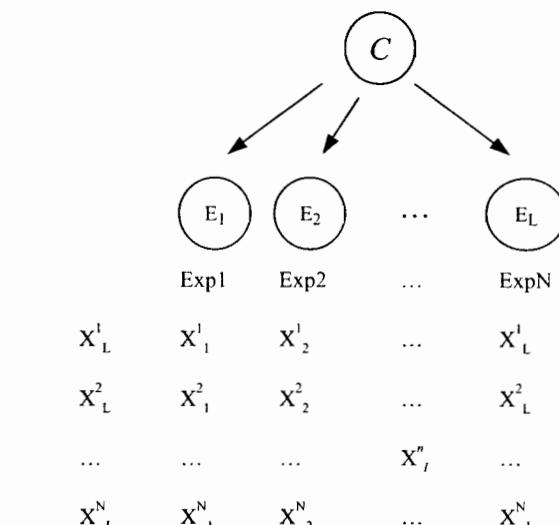
ผลลัพธ์จากส่วนค้นหาโน้มที่ฟ และ ชุดของข้อมูลการแสดงออกของยีน จะถูกส่งไปยังส่วนของการเรียนรู้ในรูปแบบที่ โปรแกรม AutoClass [6] ต้องการ ซึ่งไฟล์ดังกล่าวประกอบด้วย ไฟล์ข้อมูล (Data file), ไฟล์ส่วนหัวของข้อมูล (Header file), โนแมลไฟล์ (Model file), ไฟล์พารามิเตอร์ของการจัดกลุ่ม (Search parameter file) และ ไฟล์พารามิเตอร์ของการสร้างรายงาน (Report parameter file) ซึ่งสามารถคุยกับอิมพอร์ตของไฟล์ข้อมูลได้ใน (<http://ic.arc.nasa.gov/ic/projects/bayes-group/autoclass/>)

### 2.2.3 ส่วนการประมวลผลโดยโปรแกรม AutoClass

หลังจากได้ไฟล์จากขั้นเรียนรู้ข้อมูล ไฟล์เหล่านี้จะถูกส่งไปประมวลผล AutoClass โดย AutoClass จะทำการจัดกลุ่มของชุดข้อมูล และกำหนดจำนวนกลุ่มที่เหมาะสมแก่ชุดข้อมูลทั้งสอง โดยใช้หลักการของการจัดกลุ่มแบบไม่ต้องผ่านการรู้จำ (Unsupervised cluster) อัลกอริทึมที่ถูกใช้คือ การจัดกลุ่มแบบนาอีฟ เมบ์

#### 2.2.3.1 โนเมล นาอีฟ เมบ์ สำหรับข้อมูลการแสดงออกของยีน (Naïve Bayes Model For Gene Expression Data)

กราฟโนเมลถูกนิยมใช้เป็นโครงสร้างของระบบ Stochastic ซึ่งมีความสามารถในการเรียนรู้ความสัมพันธ์ระหว่างตัวแปรที่มีความซับซ้อนได้เป็นอย่างดี [12] นาอีฟ เมบ์ โนเมล เป็นกราฟโนเมลเพื่อฐานชนิดหนึ่ง ซึ่งในงานวิจัยนี้จะนำโนเมลชนิดนี้มาประยุกต์ใช้ในการจัดกลุ่มชุดข้อมูลการแสดงออกของยีนในไตรอะเรย์น์ถูกแสดงในรูป 3



รูปที่ 3. แสดงโนเมลนาอีฟ เมบ์ สำหรับข้อมูลการแสดงออกของยีน [12]

จากรูป C เป็น Hidden classification ในแต่ละ  $E_i$  แสดงถึงระดับของการแสดงออกของยีนในการทดสอบที่  $l$  และ  $x_l^n$  แสดงถึงค่าระดับการแสดงออกของยีนที่  $n$  ในการทดสอบที่  $l$  ในกรณีที่  $E_i$  เป็นโนเมลนาอีฟ เมบ์ ที่เราใช้ในการจัดกลุ่มยีนอยู่ในสมการที่ 1

$$P(X_L^n | C_k) = P(C_k) \prod_{l=1}^L P(x_l^n | C_{k,l}) \quad (1)$$

ในที่นี่ AutoClass จะหา Posterior probability ที่สูงที่สุด (Maximum of posterior probability) โดยที่  $P(C_k)$  เป็น Prior probability ของกลุ่มที่  $k$

และ  $\sum_{k=1}^K P(C_k) = 1$  และ  $0 \leq P(C_k) \leq 1$  เราใช้ Conditional

probability distribution (CPD)  $P(x_l^n | C_{k,l})$  โดยสมมติให้มีการ

กระจายของข้อมูลเป็นการกระจายข้อมูลแบบปกติ (Gaussian distribution)

$$P(x_l^n | C_{k,l}) = \frac{1}{\sqrt{2\pi\sigma_{k,l}}} \exp\left(-\frac{1}{2} \frac{(x_l^n - \mu_{k,l})^2}{\sigma_{k,l}^2}\right) \quad (2)$$

### 2.2.3.2 โมเดล นาอีฟ เบย์ สำหรับข้อมูลส่วนหน้าของยีน (Naïve Bayes Model For Upstream Sequence Data)

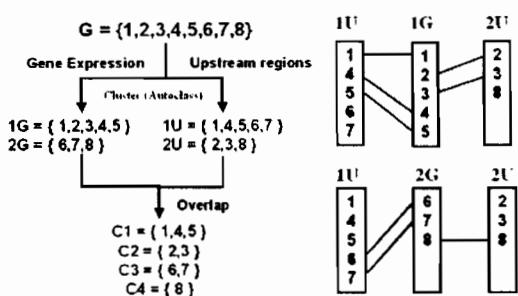
โมเดล นาอีฟ เบย์ ที่ใช้สำหรับส่วนหน้าของยีนนั้น ได้แสดงในสมการที่ 3

$$P(U_M^n | C_k) = P(C_k) \prod_{m=1}^M P(u_m^n | C_{k,m}) \quad (3)$$

โดยที่  $u_m^n$  เป็น Discrete value ที่แสดงถึงการพบหรือไม่พบโน้มที่พื้นส่วนหน้าของยีน จะสังเกตได้ว่าโมเดลนี้มีลักษณะคล้ายกันกับโมเดลที่ใช้กับการแสดงออกของยีน แต่จะที่แตกต่างกันคือ การกระจายตัวของข้อมูล โดยการกระจายตัวของข้อมูลส่วนหน้าของยีนเป็นการกระจายตัวแบบไม่ต่อเนื่อง (Discrete distribution) ในขณะที่การกระจายตัวของข้อมูลการแสดงออกของยีนเป็นแบบต่อเนื่อง (Continuous distribution) ดังนั้น  $P(u_m^n | C_{k,m})$  ที่แสดงถึง CPD ของข้อมูลส่วนหน้าของยีนจะใช้การกระจายแบบ Multinomial distribution

### 2.2.4 ส่วนการหาขีนร่วม (Overlapping)

เมื่อได้กลุ่มของยีนจากการจัดกลุ่มโดย AutoClass โดยใช้ชุดของข้อมูลที่ต่างกันคือ การแสดงออกของยีน และส่วนหน้าของยีน กลุ่มนี้ของชุดข้อมูลเหล่านั้นจะถูกนำมาหาขีนร่วมระหว่างสองกลุ่มข้อมูล ด้วยการจับคู่ของยีนแล้วดึงส่วนของยีนที่พับทั้งใน 2 กลุ่มข้อมูล ซึ่งเชื่อว่า หลังจากการทำการหาขีนร่วมแล้ว ยีนที่ถูกจัดเป็นกลุ่มใหม่น่าที่จะมีความสัมพันธ์มากยิ่งขึ้น แนวความคิดในการหาขีนร่วมได้ในรูปที่ 4



รูปที่ 4. แสดงส่วนการหาขีนร่วม (Overlapping)

จากรูปที่ 4 เป็นชุดของยีนทั้งหมดที่เราต้องการจัดกลุ่ม ประกอบด้วย 1, 2, 3, 4, 5, 6, 7 และ 8 หลังจากนั้นยีนชุดนี้จะถูกนำไปจัดกลุ่มด้วยโปรแกรม AutoClass โดยใช้ข้อมูลของการแสดงออกของยีน และ ชุดข้อมูลส่วนหน้าของยีน จากการจัดกลุ่มจะพบว่าชุดข้อมูลการแสดงออกของยีนถูกแบ่งออกเป็น 2 กลุ่มคือ 1G = {1,2,3,4,5} และ 2G = {6,7,8} และชุดข้อมูลส่วนหน้าของยีนถูกแบ่งออกเป็น 2 กลุ่มเช่นกัน คือ 1U = {1,4,5,6,7} และ 2U = {2,3,8} ขั้นตอนต่อมาเป็นส่วนที่จะทำการหาขีนร่วมระหว่างยีนในกลุ่มข้อมูลการแสดงออกของยีน และ กลุ่มข้อมูลส่วนหน้าของยีน กลุ่มใหม่ที่เป็นผลลัพธ์จากการหาขีนร่วม คือ C1 = {1,4,5}, C2 = {2,3}, C3 = {6,7} และ C4 = {8}

### 2.2.5 ส่วนการแสดงผลด้วยภาพ (Visualization)

เพื่อให้ง่ายต่อการศึกษาความหมายของผลลัพธ์ ชุดคลัสเตอร์ได้เตรียมฟังก์ชันของการแสดงผลในรูปของเส้นและกราฟ

#### 2.2.5.1 การแสดงผลในรูปเส้น

การศึกษาการแสดงออกของยีนนั้น โดยทั่วไปเป็นการศึกษาถึงการทำงานของยีนว่ายีนใด มีการแสดงออกของยีนเพิ่มขึ้น (Up-regulated) หรือลดลง (Down-regulated) อย่างไร เมื่อเทียบกับการทดลองอ้างอิง โปรแกรมจะกำหนดให้เส้นเพื่อแสดงการแสดงออกของยีน ก่อตัวคือ เสียง แสดงถึงการที่ยีนมีการแสดงออกของยีนมากกว่าตัวอ้างอิง ยีนเดียว และแสดงถึงการที่ยีนมีการแสดงออกของยีนน้อยกว่าตัวอ้างอิง ระดับของเส้นจะมี 5-ระดับด้วยกัน เพื่อระบุการแสดงออกของยีนได้ถูกต้องและชัดเจนมากขึ้น

#### 2.2.5.2 การแสดงผลในรูปของกราฟ

การแสดงผลโดยกราฟนั้นจะนำข้อมูลของความเข้มข้นของยีนมาไว้ในรูปของเส้นและลักษณ์ในแต่ละยีนในแต่ละการทดลองมาเพื่อท่องเที่ยว โดยการแสดงผลในรูปกราฟนั้นทำให้ผู้ใช้งานสามารถดูระดับของการเปลี่ยนแปลงความเข้มข้นของยีนมาเพื่อคำนวณวิเคราะห์ผลได้ละเอียด และแม่นยำยิ่งขึ้น

### 3. ผลการทดลอง

จากการกลุ่มจัดยีน โดยใช้การแสดงออกของยีนเป็นเกณฑ์ในการจัดกลุ่มเพียงอย่างเดียว ได้ผลการทดลองดังนี้ กลุ่ม 0 = 382 ยีน, กลุ่ม 1 = 150 ยีน, กลุ่ม 2 = 142 ยีน, กลุ่ม 3 = 20 ยีน, กลุ่ม 4 = 18 ยีน, กลุ่ม 5 = 10 ยีน และ กลุ่ม 6 = 9 ยีน ส่วนการจัดกลุ่มยีนโดยใช้ส่วนหน้าของยีนเป็นเกณฑ์เพียงอย่างเดียว ได้ผลการทดลองดังนี้ กลุ่ม 0 = 636 ยีน และ

กลุ่ม 1 = 45 ยีน สังเกตได้ว่าผลรวมของจำนวนยีนจะไม่เท่ากันในทั้งสองกลุ่มนี้เนื่องจากยีนบางตัวซึ่งไม่มีข้อมูลส่วนหน้าของยีน ดังนั้นจำนวนยีนที่ใช้ในการจัดกลุ่มโดยใช้ส่วนหน้าของยีนจึงมีจำนวนน้อยกว่า ผลลัพธ์ของการจัดกลุ่มยีนที่ใช้ข้อมูลการแสดงออกของยีน และข้อมูลส่วนหน้าของยีนจะถูกนำมาหาเย็นร่วมโดยในที่นี้จะกล่าวในรายละเอียดเฉพาะกลุ่มยีนร่วม ที่เกิดมาจากการจัดกลุ่มของยีนใดๆ ที่ใช้การแสดงออกของยีนเป็นเกณฑ์ กับกลุ่มที่พบในที่พึงที่เราสนใจบันทึกว่า นั้นคือ กลุ่ม 0-1, กลุ่ม 1-1, กลุ่ม 2-1, กลุ่ม 3-1 และ กลุ่ม 6-1 ซึ่งกลุ่มของยีนร่วมที่ได้ออกมาเน้นจะถูกนำมาหาหน้าที่ของยีนเพื่อให้ทราบว่ายีนใดบ้างเป็นยีนที่เกี่ยวข้องกับวัฏจักรเซลล์ เป็นการทดสอบประสิทธิภาพของเครื่องมือที่เราทำการพัฒนาขึ้น เว็บไซต์ที่เราใช้ในการตรวจสอบหน้าที่ของยีนคือ [www.yeastgenome.com](http://www.yeastgenome.com) หลังจากนั้นเราก็จะนำกลุ่มยีนร่วมที่ได้มาเทียบกับสารต่างๆ ที่ได้มีรายงานถึงยีนที่ทำหน้าที่เกี่ยวข้องกับวัฏจักรเซลล์ โดยสารสารหลักที่เราใช้เป็นสารอ้างอิงคือ Comprehensive Identification of Cell Cycle-regulated Genes of the Yeast *Saccharomyces cerevisiae* by Microarray Hybridization [13] วารสารฉบับนี้แสดงถึงกลุ่มยีนที่

ทำงานเกี่ยวข้องกับวัฏจักรเซลล์ รายละเอียดของยีนในกลุ่มต่างๆ นี้ ดังนี้ กลุ่ม 0-1 ประกอบด้วยยีนทั้งหมด 16 ยีน โดย 12 ยีนได้ถูกกำหนดหน้าที่ของยีนไว้แล้ว แต่อีก 4 ยีนยังไม่ได้ถูกกำหนดหน้าที่ของยีน (YOR131C, YGL050W, YCL005W และ YGL242C) โดยมี 6 ยีน มีหน้าที่เกี่ยวข้องกับวัฏจักรเซลล์ คือ DOT1, SMC2, BIM1, TOP2, SPC110 และ APC4 กลุ่ม 1-1 ประกอบด้วยยีนทั้งหมด 9 ยีน โดยมี 6 ยีน มีหน้าที่เกี่ยวข้องกับวัฏจักรเซลล์ คือ RPS4A, FKS1, PXR1, IPL1, HYS2 และ PRO2 กลุ่ม 2-1 ประกอบด้วยยีนทั้งหมด 11 ยีน โดยมี 8 ยีน มีหน้าที่เกี่ยวข้องกับวัฏจักรเซลล์ คือ SWI4, TUB4, SMC1, SMC3, PRE10, JEM1, RFA1 และ RHO1 กลุ่ม 3-1 ประกอบด้วยยีนทั้งหมด 6 ยีน โดย 2 ยีนยังไม่ถูกกำหนดหน้าที่ของยีน คือ YLR049C และ YDL156W และ มี 4 ยีน มีหน้าที่เกี่ยวข้องกับวัฏจักรเซลล์ คือ PRI2, RNR1, CRH1 และ POL2 กลุ่ม 6-1 ประกอบด้วยยีนทั้งหมด 3 ยีน โดย ยีนทั้งหมดในกลุ่มนี้เป็นยีนที่มีหน้าที่เกี่ยวข้องกับวัฏจักรเซลล์ คือ SPT21, KCC4 และ HTA2 ดังแสดงในตารางที่ 1

ตารางที่ 1 แสดงผลลัพธ์ของการจัดกลุ่มยีนร่วม

กลุ่มยีน	ยีนทั้งหมด	ยีนที่เกี่ยวข้องกับวัฏจักรเซลล์	C/N
0-1	SPA2, SEC31, DOT1, YOR131C, YGL050W, SMC2, MRPS35, BIM1, YCL005W, SAR1, TOP2, SMT3, SPC110, YGL242C, GID8 และ APC4	DOT1, SMC2, BIM1, TOP2, SPC110 และ APC4	6/16
1-1	RPS4A, FKS1, PXR1, IPL1, HYS2, RFC4 NAM2, PRO2 และ MNL1	RPS4A, FKS1, PXR1, IPL1, HYS2 และ PRO2	6/9
2-1	SWI4, TUB4, UNG1, SMC1, SMC3, PRE10, APJ1, JEM1, RFA1, EUG1 และ RHO1	SWI4, TUB4, SMC1, SMC3, PRE10, JEM1, RFA1 และ RHO1	8/11
3-1	YLR049C, PRI2, RNR1, CRH1, POL2 และ YDL156W	PRI2, RNR1, CRH1 และ POL2	4/6
6-1	SPT21, KCC4 และ HTA2	SPT21, KCC4 และ HTA2	3/3

C/N = สัดส่วนจำนวนยีนที่เกี่ยวข้องกับการทำงานของวัฏจักรเซลล์กับจำนวนยีนทั้งหมดในแต่ละกลุ่มยีน

#### 4. บทสรุป

การจัดกลุ่มยีนโดยการใช้ข้อมูลของการแสดงออกของยีนร่วมกับข้อมูลส่วนหน้าของยีนสามารถที่จะเพิ่มประสิทธิภาพของการจัดกลุ่มยีนให้มีความละเอียด และมีความถูกต้องมากยิ่งขึ้น โดยเราจะให้ความสำคัญแก่กลุ่มที่ทำให้ยีนร่วมระหว่างกลุ่มยีนที่พบในพืช กับกลุ่มยีนใดๆ ของการแสดงออกของยีน ก่อตัวคือ เราจะให้สนใจเฉพาะกลุ่ม 0-1, กลุ่ม 1-1, กลุ่ม 2-1, กลุ่ม 3-1 และ กลุ่ม 6-1 ยีนจากกลุ่มเหล่านี้รวมกันทั้งหมดเท่ากับ 45 ยีน ซึ่งจากผลการทดลองพบว่า 60% ของยีนทั้งหมดเกี่ยวข้องกับการควบคุมยีนในวัฏจักรเซลล์ ได้แก่ SMS2, BIM1, SPC110, TOP2, APC4, FKS1, PRO2, IPL1, RPS44, SWI, SMC1, SMC2, TUB4, JEM1, RFA1, POL2, PRI2, RNRI, CRH1, HTA2, KCC4, SPT2, DOT1, PXR1, HYS2, PRE2 และ RHO1 และประมาณ 27% เป็นยีนที่ไม่เกี่ยวข้องกับการควบคุมการทำงานของวัฏจักรเซลล์ ได้แก่ SPA2, SEC31, MRPS35, SAR1, SMT3, GID8, RFC4, NAM2, MNL1, UNG1, APJ1 และ EUG1 อีกประมาณ 13% เป็นยีนที่ซึ้งไม่ถูกกำหนดหน้าที่ ได้แก่ YOR131C, YGL050W, YCL005W, YGL242C, YLR049C และ YDL156W จากผลการทดลองพบว่า เราได้ก่อ群ยีนที่เกี่ยวข้องกับการทำงานในวัฏจักรเซลล์ อายุ 45 ยีน จากทั้งหมด 800 ยีน [13] ซึ่งจำนวนยีนที่ได้ออกมาหนึ่งไม่น่าพอใจทั้งนี้อาจเกิดจากการเลือกชนิดของโมทิฟที่ซึ้งไม่มีจำนวนและความจำเพาะมากพอในการที่จะดึงเอาข้อมูลในส่วนที่เราต้องการออกมานำไปใช้ นอกจากนี้ในขั้นการกรองข้อมูลการแสดงออกของยีน กลุ่มยีนที่เราสนใจอาจถูกกรองออกไป เนื่องจากยีนเหล่านั้นเกิด missing data หรือยีนเหล่านั้นไม่มีนัยสำคัญมากพอที่จะผ่านกระบวนการกรองข้อมูลก็เป็นได้ แต่ทั้งนี้ทั้งนั้น ยีนที่ได้มาทั้ง 45 ยีน เป็นยีนที่เกี่ยวข้องกับโมทิฟที่เราสนใจมากกว่าครึ่งหนึ่ง ซึ่งนับเป็นที่น่าพอใจ เมื่อเทียบกับการใช้ข้อมูลการแสดงออกของยีนเพียงข้อมูลเดียว และพบว่าซึ้งนี้ก่อกลุ่มยีนเหล่านี้อาจเป็นกลุ่มยีนที่เกี่ยวข้องกับกระบวนการควบคุมการทำงานของวัฏจักรเซลล์ ก็เป็นไปได้ ดังนั้นจึงต้องมีการทำการทำการทำทดลองเพื่อหาหน้าที่ของยีนในกลุ่มนี้ต่อไป ในงานวิจัยนี้เราได้เลือกส่วนหน้าของยีนที่มีความยาว 800 เบส เนื่องจากเป็นความยาวที่เหมาะสมสำหรับบีทีดี [14] แต่หากเราทำการเปลี่ยนชนิดของลิงเมธิวที่จะนำมาทำการทดลอง เราอาจจะคำนึงถึงความยาวของส่วนหน้าของยีนของสิ่งมีชีวิตนั้นด้วย เช่น หากเราสนใจทำการศึกษาการจัดกลุ่มของยีนในพืช เราควรจะเพิ่มขนาดของส่วนหน้าของยีน เป็น 1,000 – 1,500 เบส [15] เนื่องจากตำแหน่งของการควบคุมการทำงานของยีนในพืชนั้น อยู่ไกลจากตำแหน่ง +1

มาก เพราะฉะนั้นเราต้องทำการเลือกส่วนหน้าของยีนให้ครอบคลุมกับตำแหน่งของการควบคุมการทำงานของยีน อีกทั้งความยาวของโมทิฟก็เป็นส่วนสำคัญในการจัดกลุ่มยีนใหม่ เนื่องจากหากความยาวของโมทิฟมีขนาดที่ยาวจนเกินไป อาจส่งผลให้การค้นหาไม่ทิฟบนส่วนหน้าของยีน ไม่พบรูปแบบของโมทิฟนั้นๆ อยู่เลย ในทางตรงกันข้ามหากเราเลือกชนิดของโมทิฟที่มีขนาดสั้นจนเกินไป จะทำให้พบรูปแบบของโมทิฟบนส่วนหน้าของยีนมากกว่าความเป็นจริง ดังนั้นในงานวิจัยนี้เราได้ทำการเลือกชุดของโมทิฟที่มีความยาวประมาณ 6 – 10 เบส ซึ่งเป็นความยาวที่เหมาะสม [15] ก่อตัวโดยสรุป การพัฒนาเครื่องมือการจัดกลุ่มยีนโดยการใช้ข้อมูลการแสดงออกของยีน และข้อมูลส่วนหน้าของยีน สามารถช่วยเพิ่มประสิทธิภาพของการจัดกลุ่มยีนให้มีความละเอียด และมีความถูกต้องมากขึ้น

#### เอกสารอ้างอิง

- [1] Eisen MB, Spellman PT, Brown PO and Botstein D. (1998). Cluster Analysis and Display of Genome-Wide Expression Patterns. *Proc Natl Acad Sci U S A* 95, pp. 14863-8.
- [2] <http://www-stat.stanford.edu/~tibs/SAM/index.html>
- [3] Reich M, Ohm K, Angelo M, Tamayo P and Mesirov JP. "GeneCluster 2.0: an advanced toolset for bioarray analysis." *Bioinformatics*. 2004 Jul 22; 20(11) pp.1797-8
- [4] [http://www.molmine.com/frameset/frm\\_jexpress2.asp](http://www.molmine.com/frameset/frm_jexpress2.asp)
- [5] E. Segal , H. Wang and D. Koller "Discovering molecular pathways from protein interaction and gene expression data" *Bioinformatics* Vol. 19 Suppl. 1 2003 pp. i264-i272
- [6] Peter Cheeseman and John Stutz "Bayesian Classification (AutoClass) Theory and Results" *Advances in knowledge discovery and data mining* 1996 pp.153 - 180
- [7] Zhu G, Spellman PT, Volpe T, Brown PO, Botstein D, Davis TN and Futcher B. "Two yeast forkhead genes regulate the cell cycle and pseudohyphal growth." *Nature*. 2000 Jul 6;406(6791) pp.90-4.
- [8] <http://www.mathworks.com/products/bioinfo/>
- [9] <http://rsat.ulb.ac.be/rsat/>

- [10] <http://cgsigma.cshl.org/jian/>
- [11] <http://www.gene-regulation.com/pub/databases.html#transfac>
- [12] E. J. Moler , D. C. Radisky and I. S. Mian “Integrating naive Bayes models and external knowledge to examine copper and iron homeostasis in *S. cerevisiae” Physiol. Genomics* 4: 2000, pp.127-135
- [13] Paul T. Spellman, Gavin Sherlock, Michael Q. Zhang, Vishwanath R. Iyer, Kirk Anders, Michael B. Eisen, Patrick O. Brown, David Botstein, and Bruce Futcher, “Comprehensive Identification of Cell Cycle-regulated Genes of the Yeast *Saccharomyces cerevisiae* by Microarray Hybridization” *Mol Biol Cell.* 1998 Dec;9(12) pp. 3273-97.
- [14] Van Helden J ,“Metrics for comparing regulatory sequences on the basis of pattern counts.”*Bioinformatics.* 2004 Feb 12;20(3):399-406. Epub 2004 Feb 5.
- [15] Chintalapati Janaki and Rajendra R. Joshi, “ Motif detection in *Arabidopsis*: Correlation with gene expression data”, *In Silico Biology* 4, 0014 (2004);

วัฒน์วิญญา แพร่งมงคล จบการศึกษาระดับปริญญาตรี ในสาขาวิชา จุลชีววิทยา และกำลังศึกษาระดับปริญญาโท ในสาขาวิชาสารสนเทศ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี งานวิจัยที่สนใจคือ การวิเคราะห์ข้อมูลการแสดงออกของยีนที่จากไมโครอาร์เจียโนเมต์ และการพัฒนาซอฟต์แวร์ที่เกี่ยวข้องกับการวิเคราะห์ข้อมูลทางชีววิทยาไม่เล็กระดับโมโนิก

**Anan Tongta** M.S., Ph.D. (Chemical Engineering), University of Missouri-Rolla, Rolla, Missouri, USA. B.S. (Chemical Engineering), Chulalongkorn University, Bangkok, Thailand. Research Interests: Modeling of Biological Processes, Adsorption of Biological Molecules

ดวงดาว วิชาดาฤทธิ์ จบการศึกษาปริญญาโทและเอกทางวิทยาศาสตร์คอมพิวเตอร์ จากมหาวิทยาลัยแห่งรัฐออลิมินอยส์ ความรู้และประสบการณ์ที่ผ่านมาก็เกี่ยวข้องกับการวิจัยและพัฒนาซอฟต์แวร์ระบบมิคิดิล แวร์และเมตตาดา๊เพื่อสนับสนุนการพัฒนา โปรแกรมเชิงประยุกต์ ในระบบเครือข่ายแบบกระจาย ที่ต้องการการประกันคุณภาพ (Quality of Service) เช่นประสิทธิภาพ ความเสถีร์ และความปลอดภัย ความสนใจปัจจุบันเกี่ยวข้องกับการวิจัยและพัฒนาทาง ชีวสารสนเทศโดยเฉพาะในสาขาที่เกี่ยวข้องกับการศึกษาการทำงานของกลุ่มยีนเครือข่าย ควบคุมการทำงานของกลุ่มยีนในระดับจีโนม ความสัมพันธ์ของ เครือข่ายควบคุมการทำงานของกลุ่มยีนระหว่างจีโนม เครือข่าย ควบคุมการทำงานของกลุ่มโปรตีน รวมทั้งการประสานการทำงาน ของระบบในระดับยีนโปรตีน และเมตตาโนโลยีชีว