

บทที่ 4

การอนุมานแบบจำลองการควบคุมกันระหว่างยีนด้วยเครือข่ายเบย์เซียน โดยอาศัยวิธีการมาร์คอฟเชนมอนติคาร์โล

ยีนของเซลล์สิ่งมีชีวิตจะมีหน้าที่ที่เฉพาะเจาะจงของมันภายในกระบวนการทำงานของเซลล์ การแสดงออกของยีนจะถูกควบคุมจากปัจจัยต่างๆ เพื่อทำการสำเนารหัสพันธุกรรม (Transcribe) เป็นอาร์เอ็นเอ (RNA) จากนั้นจึงเข้าสู่กระบวนการแปลรหัสพันธุกรรม (Translate) เป็นโปรตีนที่ทำหน้าที่ต่าง ๆ โดยเฉพาะ (Alberts, 2002) ระดับการแสดงออกของยีนสามารถวัดออกมาได้ด้วยเทคโนโลยีดีเอ็นเอไมโครอาร์เรย์ ที่เป็นตัวบ่งบอกว่ายีนมีการตอบสนองต่อสิ่งแวดล้อมมากน้อยเพียงใด โดยการแสดงออกของยีนนี้จะถูกวัดออกมาเพื่อการศึกษาภายใต้สถานะหนึ่ง ๆ ซึ่งในการแสดงออกของยีนนี้จะต้องมีกลุ่มของโปรตีนเข้ามาเกี่ยวข้องด้วยในลักษณะของการควบคุมกันระหว่างยีนในระหว่างกระบวนการแสดงออกของยีน ได้แก่ ทรานสคริปต์ชัน-นอลแฟกเตอร์ แอกทิเวเตอร์ (Activators) และโคแอกทิเวเตอร์ (Co-Activators) เป็นต้น ในทางชีวภาพกลไกการควบคุมกันระหว่างยีนนั้นมีความสำคัญ และเป็นวิธีการศึกษาพื้นฐานในการที่จะนำไปสู่การเข้าใจพฤติกรรมของยีนที่มีความซับซ้อน

การศึกษาโดยทั่วไปที่ไม่ได้อาศัยความรู้ทางด้านชีววิทยาเข้ามาเกี่ยวข้อง เช่น การวิเคราะห์ข้อมูลดีเอ็นเอไมโครอาร์เรย์ด้วยเทคนิควิธีการแบ่งกลุ่มข้อมูล (Cluster analysis) ตามลักษณะการแสดงออกของยีนมักจะถูกนำมาใช้ในการอนุมานหากกลุ่มยีนที่ถูกควบคุมด้วยปัจจัยต่างๆ ร่วมกัน (Dirisi *et al.*, 1997) แต่อย่างไรก็ตามเป็นการยากที่จะทำการพิสูจน์ความถูกต้องของผลลัพธ์ที่ได้จากการแบ่งกลุ่มข้อมูลนี้ ดังนั้นวิธีการอนุมานทางสถิติหลายๆ วิธีการจึงถูกนำเสนอขึ้นมาเพื่อทำการอนุมานเครือข่ายการควบคุมกันระหว่างยีน ได้แก่ โมเดลเกาส์เซียนเชิงกราฟ (Graphical Gaussian Model) (Wu and Subramanian, 2003) เครือข่ายความน่าจะเป็นแบบบูลีน (Probabilistic Boolean Networks) (Shmulevith *et al.*, 2002) และเครือข่ายเบย์เซียน (Bayesian Networks) (Hartemink, 2001 and Husmeier, 2003) ซึ่งด้วยวิธีการเหล่านี้อาจไม่สามารถทำการพิสูจน์ได้ว่าผลลัพธ์ที่ได้มีความถูกต้องหรือสมบูรณ์ครบถ้วนในทางชีววิทยา

ในการอนุมานเครือข่ายการควบคุมกันระหว่างยีนด้วยเครือข่ายเบย์เซียน ซึ่งอาจต้องมีการสร้างเครือข่ายที่ต้องการเปรียบเทียบขึ้นเอง หรือทำการหาเครือข่ายที่เป็นไปได้ทั้งหมดไว้ก่อนแล้ว จึงทำการพิจารณาเครือข่ายที่ดีที่สุดโดยใช้วิธีการคิดคะแนนให้กับแต่ละเครือข่าย (Hartemink *et al.*, 2001) แต่ในทางปฏิบัติข้อมูลไมโครอาร์เรย์สามารถถูกสร้างออกมาได้เป็นจำนวนน้อยเมื่อ

เทียบกับจำนวนยีนที่กำลังศึกษา ซึ่งการวิเคราะห์ด้วยข้อมูลการแสดงออกของยีนที่มีอยู่เป็นจำนวนน้อยนี้อาจทำให้ได้ผลการวิเคราะห์ที่มีความน่าเชื่อถือต่ำ (Husmeier, 2003)

ดังนั้นในงานวิจัยนี้จึงได้นำวิธีการหนึ่งของมาร์คอฟเชนมอนติคาร์โล (Markov Chain Monte Carlo: MCMC) นั่นก็คือ อัลกอริทึมเมโทรโพลิส – แฮสติงส์ (Metropolis – Hastings algorithm) มาทำงานร่วมกับเครือข่ายเบย์เซียนในการสร้างแบบจำลองที่เป็นไปได้ของเครือข่ายการควบคุมกันระหว่างยีน โดยเครือข่ายการควบคุมระหว่างยีนที่มีการรายงานไว้แล้วในทางชีววิทยาจะถูกกำหนดเป็นโมเดลเริ่มต้นให้กับเครือข่ายเบย์เซียน จากนั้นความสัมพันธ์ระหว่างสองยีนในเครือข่ายใหม่จะถูกสร้างขึ้นแบบสุ่มด้วยการแจกแจงทวินาม (Binomial distribution) โดยที่ค่าความน่าจะเป็นของความสัมพันธ์ระหว่างยีนแต่ละคู่จะสร้างมาจากการแจกแจง Dirichlet (Dirichlet distribution) อีกทีหนึ่ง โดยพารามิเตอร์ของการแจกแจง Dirichlet นี้จะเป็นจำนวนความถี่ของความสัมพันธ์ที่เกิดขึ้นในเครือข่ายทั้งหมดที่ยอมรับไว้ก่อนหน้า จากนั้นจึงทำการคำนวณความน่าจะเป็นที่ยอมรับได้ด้วยอัลกอริทึมเมโทรโพลิส – แฮสติงส์ สำหรับใช้ในการพิจารณายอมรับเครือข่ายใหม่ที่ถูกสร้างขึ้นมา ความน่าจะเป็นที่ยอมรับได้นี้ประกอบด้วยเทอมการแจกแจงที่น่าเสนอ และการแจกแจงที่คงที่ที่อยู่ในรูปแบบของการแจกแจงโพสทีเรีย (Posterior distribution) ของเครือข่ายก่อนหน้าและเครือข่ายที่ถูกสร้างขึ้นมาใหม่ โดยการแจกแจงที่น่าเสนอที่ใช้ในงานวิจัยนี้จะเหมือนกับที่ Husmeier (2003) ได้เสนอไว้ ส่วนการแจกแจงโพสทีเรียจะคำนวณมาจากค่าความน่าจะเป็นที่มีเงื่อนไข (Conditional distribution) ของข้อมูลการแสดงออกของยีนที่ถูกแปลงเป็นข้อมูลชนิดไม่ต่อเนื่องแล้ว และงานวิจัยนี้ได้ใช้ชุดข้อมูลตัวอย่างในการทดลอง เป็นการแสดงออกของยีน CYC1 ที่ถูกควบคุมร่วมด้วย HAP2 HAP3 HAP4 ซึ่งเป็นข้อมูลยีนของยีสต์แซคคาโรไมซีส เซรีวิซิเย

4.1 ชุดข้อมูลการทดลอง

การแสดงออกของยีน CYC1 (Cytochrome c, isoform 1) ซึ่งถูกควบคุมร่วมด้วยโคแอกทิเวเตอร์ HAP2 HAP3 HAP4 จะถูกนำมาศึกษาในงานวิจัยนี้ ยีน CYC1 จะทำหน้าที่เป็นตัวนำอิเล็กตรอน (Electron carrier) ในผนังเซลล์ชั้นในของไมโทคอนเดรีย (Mitochondrial intermembrane space) ที่ส่งอิเล็กตรอนจาก ubiquinone-cytochrome c oxidoreductase ไปยัง cytochrome c oxidase ในระหว่างกระบวนการหายใจของเซลล์ของยีสต์แซคคาโรไมซีส เซรีวิซิเย (Hortner *et al.*, 1982) ซึ่งได้มีรายงานไว้แล้วในงานวิจัยว่ายีนทั้งสี่ตัวนี้มีความเกี่ยวข้องกัน โดยกลุ่มโปรตีน HAP2/3/4 ต่างไปร่วมกันควบคุมการแสดงออกของยีน CYC1 โดยที่ HAP2

และ HAP3 เป็นโปรตีนควบคุมที่เข้าไปจับกับส่วน โพร โมเตอร์ที่เฉพาะเจาะจงของยีน CYC1 และ โปรตีน HAP4 จะเป็นตัวกระตุ้นเพื่อให้ยีน CYC1 เริ่มทำงานได้ (Olesen and Guarente, 1990)

ข้อมูลการแสดงผลออกของยีนในทั้งสี่นี้เป็นข้อมูลชนิดต่อเนื่องแสดงดังตาราง 4.1 ซึ่งในการศึกษาครั้งนี้ข้อมูลการแสดงผลออกยีนชนิดต่อเนื่องนี้จะถูกแปลงเป็นข้อมูลชนิดไม่ต่อเนื่องก่อนที่จะนำไปทำการทดลองดังตาราง 4.2 สำหรับเงื่อนไขที่ใช้ในการพิจารณาแปลงข้อมูลการแสดงผลออกของยีนจากข้อมูลชนิดต่อเนื่องให้เป็นข้อมูลชนิดไม่ต่อเนื่องจะพิจารณาจากการแสดงผลออกที่เพิ่มขึ้น ลดลง หรือคงที่ เมื่อทำการเปรียบเทียบกับค่าคงที่ที่กำหนดไว้ ดังนี้

เมื่อกำหนดให้ x คือข้อมูล เรากำหนดเงื่อนไขดังต่อไปนี้ คือ

- ถ้า $x > 0.2$ หมายถึง ยีนมีการแสดงผลออกเพิ่มขึ้น แทนด้วยเครื่องหมาย \uparrow
- ถ้า $-0.2 \leq x \leq 0.2$ หมายถึง ยีนมีการแสดงผลออกคงที่ แทนด้วยเครื่องหมาย $-$ และ
- ถ้า $x < -0.2$ หมายถึง ยีนมีการแสดงผลออกลดลง แทนด้วยเครื่องหมาย \downarrow

ในการศึกษาครั้งนี้ได้เลือกใช้ค่า 0.2 และ -0.2 เป็นขอบเขตของข้อมูลที่ใช้ในการแปลงข้อมูลการแสดงผลออกของยีนจากข้อมูลชนิดต่อเนื่องให้เป็นข้อมูลชนิดไม่ต่อเนื่อง ซึ่งเป็นผลจากการสังเกตชุดข้อมูลการแสดงผลออกของทั้งสี่นี้ แล้วพบว่าค่าที่เลือกใช้นี้สามารถแบ่งลักษณะการแสดงผลออกที่แตกต่างกันออกเป็นการแสดงผลออกที่เพิ่มขึ้น ลดลง และคงที่ได้

ตาราง 4.1 ข้อมูลการแสดงผลออกของยีน CYC1, HAP2, HAP3 และ HAP4

CYC1	HAP2	HAP3	HAP4
-0.14	-0.15	-0.29	0.24
-0.22	0.03	0.24	0.58
-0.01	-0.12	0.12	1.04
-0.09	-0.32	-0.14	0.66
0.31	-0.23	-0.36	0.62
1.18	-0.04	-0.15	2.54
1.75	0.51	-0.09	3.13

ตาราง 4.2 ระดับการแสดงผลออกของยีน CYC1, HAP2, HAP3 และ HAP4

ที่ผ่านการแปลงให้เป็นข้อมูลชนิดไม่ต่อเนื่องแล้ว

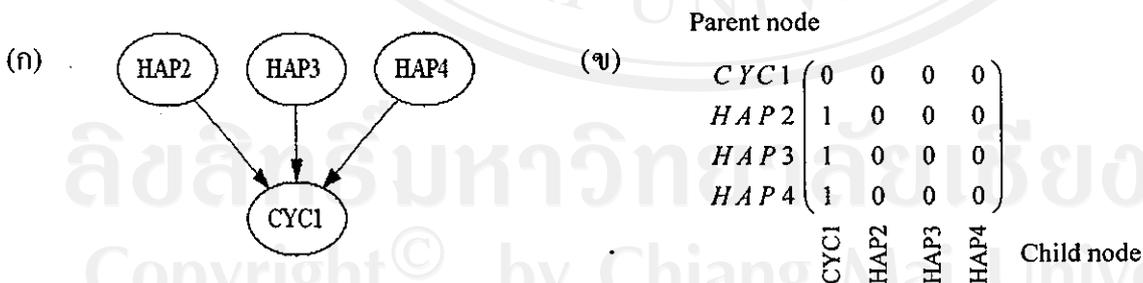
CYC1	HAP2	HAP3	HAP4
-	-	\downarrow	\uparrow
\downarrow	-	\uparrow	\uparrow
-	-	-	\uparrow
-	\downarrow	-	\uparrow
\uparrow	\downarrow	\downarrow	\uparrow
\uparrow	-	-	\uparrow
\uparrow	\uparrow	-	\uparrow

ยกตัวอย่างเช่นข้อมูลในคอลัมน์ที่ 1 แถวที่ 1 ของตาราง 4.1 จะได้ว่า $x = -0.14$ ตรงตามเงื่อนไขที่สองคือ $-0.2 \leq x \leq 0.2$ จึงได้ว่า x มีการแสดงออกคงที่ (-) เป็นต้น

4.2 วิธีการและการทดลอง

ในการศึกษาครั้งนี้ได้นำวิธีการของอัลกอริทึมเมโทรโพลิส – แฮสติงส์ ซึ่งเป็นวิธีการหนึ่งของวิธีการมาร์คอฟเชนมอนติคาร์โล มาผนวกกับเครือข่ายเบย์เซียน เพื่อทำการสร้างเครือข่ายการควบคุมกันระหว่างยีนของกลุ่มยีนตัวอย่าง ตามหลักการของเครือข่ายเบย์เซียน โครงสร้างของเครือข่าย (Network structure) จะเป็นแบบจำลองเชิงกราฟที่มีความสัมพันธ์ระหว่างโหนด (node) แบบระบุทิศทางและไม่มีลักษณะเป็นวงจร (Directed Acyclic Graph) หรือที่เรียกว่า DAG โดยที่แต่ละโหนดของเครือข่ายจะเป็นตัวแทนของแต่ละยีนในเครือข่าย และเส้นเชื่อม (edge) แทนความสัมพันธ์ที่บ่งบอกถึงการควบคุมกันระหว่างยีน ในงานวิจัยนี้ได้ใช้เมทริกซ์เครือข่าย (Network matrix) ขนาด $n \times n$ (n = จำนวนยีนในเครือข่าย) เป็นตัวแทนแสดงความสัมพันธ์ของการควบคุมกันระหว่างยีนต่าง ๆ ในเครือข่าย โดยกำหนดค่าความสัมพันธ์ระหว่างยีนในเครือข่ายดังต่อไปนี้

$$M[i,j] = \begin{cases} 0 & \text{หมายความว่า ไม่มีเส้นเชื่อม หรือไม่มีความสัมพันธ์ระหว่างยีนแม่ตัวที่ } i \text{ และ} \\ & \text{ยีนลูกตัวที่ } j \\ 1 & \text{หมายความว่า มีเส้นเชื่อม หรือมีความสัมพันธ์ระหว่างยีนแม่ตัวที่ } i \text{ และยีนลูก} \\ & \text{ตัวที่ } j \end{cases}$$



รูป 4.1 เครือข่ายเบย์เซียนแสดงการควบคุมกันระหว่างยีน CYC1 HAP2 HAP3 และ HAP4 โดย (ก) แบบจำลองเชิงกราฟ และ (ข) เมทริกซ์เครือข่ายของแบบจำลอง

สามารถแสดงตัวอย่างของเครือข่ายการควบคุมกันที่มีการรายงานเอาไว้แล้วของกลุ่มยีนตัวอย่าง CYC1 HAP2 HAP3 และ HAP4 ที่นำมาศึกษาในครั้งนี้ได้ดังรูป 4.1(ก) และใช้เมทริกซ์เครือข่ายเป็นตัวแทนแบบจำลองเชิงกราฟแสดงการควบคุมกันระหว่างยีนได้ดังรูป 4.1(ข)

โดยยีนในแนวแถวของเมทริกซ์เครือข่ายจะแทนยีนที่เป็นโหนดพ่อแม่ (parent nodes) หรือตัวควบคุม (Regulators) และยีนในแนวคอลัมน์จะแทนยีนที่เป็นโหนดลูก (child node) หรือยีนที่ถูกควบคุม (Regulated genes)

4.2.1 อัลกอริทึมเมโทรโพลิต – แฮสติงส์

งานวิจัยนี้จะอาศัยหลักการของอัลกอริทึมเมโทรโพลิต – แฮสติงส์ (Gilks, 1996) ในการเรียนรู้เครือข่ายการควบคุมกันระหว่างยีนที่ถูกสร้างขึ้นแบบสุ่มเพื่อทำการสร้างเครือข่ายการควบคุมกันระหว่างกลุ่มยีนที่เราสนใจ โดยในตอนเริ่มต้นของการทดลองจะทำการกำหนดเครือข่ายความสัมพันธ์ระหว่างยีนเริ่มต้น M_{old} ด้วยเครือข่ายจริงทางชีววิทยาของยีนทั้งสี่ดังรูป 4.1 หลังจากนั้นอัลกอริทึมเมโทรโพลิต – แฮสติงส์จะทำการคำนวณแบบวนซ้ำเพื่อสร้างเครือข่ายการควบคุมกันระหว่างยีนแบบสุ่มขึ้นมาเป็นเครือข่ายใหม่ M_{new}

ค่าความสัมพันธ์ของเส้นเชื่อมที่แต่ละตำแหน่งของเมทริกซ์เครือข่ายใหม่จะถูกสร้างขึ้นแบบสุ่มด้วยการแจกแจงทวินาม (Binomial distribution) (Milton and Tsokos, 1983) แสดงดังสมการที่ (17)

$$M_{new}[i, j] \sim \text{binomial}(\text{edge_prob}[i, j]) \quad (17)$$

โดย $M_{new}[i, j]$ คือค่าความสัมพันธ์ระหว่างตัวควบคุมตัวที่ i และยีนที่ถูกควบคุมตัวที่ j ในเมทริกซ์เครือข่ายใหม่ โดยค่าที่ได้จากสุ่มจะเป็น 0 หรือ 1 เพียงค่าเดียวเท่านั้น พารามิเตอร์ $\text{edge_prob}[i, j]$ ในสมการที่ (17) คือค่าความน่าจะเป็นของการสุ่ม (Binomial success probability) สำหรับสร้างเส้นเชื่อมที่ตำแหน่ง (i, j) ในเมทริกซ์เครือข่ายใหม่ M_{new}

สำหรับค่าของพารามิเตอร์ edge_prob นี้จะถูกสุ่มมาจากการแจกแจง Dirichlet (Regazzini, 2002) อีกทีหนึ่ง แสดงการแจกแจง Dirichlet ได้ดังสมการที่ (18)

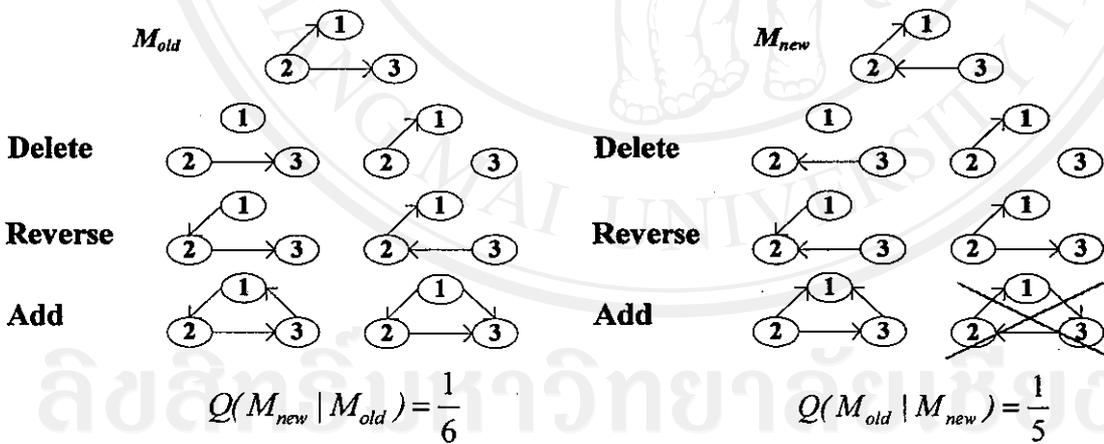
$$\text{edge_prob}[i, j] \sim \text{dirichlet}(a) \quad (18)$$

ซึ่ง a แทนพารามิเตอร์รูปร่าง (Shape parameters) ของการแจกแจง Dirichlet ที่ประกอบด้วย ซุปเปอร์-พารามิเตอร์ (Super-parameters) อีกสองตัว คือ $\{\alpha_1, \alpha_2\}$ ที่ได้มาจากความถี่ในการเกิดเส้นเชื่อมในแต่ละตำแหน่งของเมทริกซ์เครือข่ายทั้งหมดที่ถูกยอมรับไว้ก่อนหน้า โดยที่ α_1 จะเป็นพารามิเตอร์สำหรับการสุ่มกรณีมีเส้นเชื่อม (ค่าความสัมพันธ์เป็น 1) และ α_2 สำหรับการสุ่มกรณีไม่มีเส้นเชื่อม (ค่าความสัมพันธ์เป็น 0)

หลังจากทำการสุ่มเครือข่ายใหม่ M_{new} เรียบร้อยแล้ว จึงเข้าสู่กระบวนการพิจารณาว่าจะยอมรับเครือข่ายใหม่นี้หรือไม่ โดยพิจารณาจากความน่าจะเป็นที่ยอมรับได้ของอัลกอริทึมเมโทรโพลิส – แฮสติงส์ แสดงดังสมการที่ (19)

$$\alpha(M_{old}, M_{new}) = \min \left\{ 1, \frac{P(M_{new} | D) * Q(M_{old} | M_{new})}{P(M_{old} | D) * Q(M_{new} | M_{old})} \right\} \quad (19)$$

โดย D คือข้อมูลการแสดงของกลุ่มยีนในเครือข่ายที่เราสนใจที่ถูกแปลงเป็นข้อมูลชนิดไม่ต่อเนื่อง เรียบร้อยแล้ว ในส่วนของการแจกแจงที่คงที่ $P(. | D)$ จะถูกคำนวณโดยอาศัยหลักการของเบย์เซียน ซึ่งจะกล่าวถึงต่อไปในหัวข้อที่ 4.2.2 และในส่วนของการแจกแจงที่นำเสนอ $Q(. | .)$ จะคำนวณมาจากการหาเครือข่ายเนจเบอร์ (neighbor network) ของ M_{old} และ M_{new} ในแต่ละรอบของการทดลอง ซึ่งเหมือนกับวิธีการที่ได้เสนอไว้โดย Husmeier (2003) โดยเครือข่ายเนจเบอร์นี้ต้องเป็นกราฟชนิด DAG ที่เกิดมาจากการปรับปรุงเครือข่าย (update network) M_{old} และ M_{new} ด้วยวิธีการลบ (deletion) การกลับทิศทาง (reversion) และการเพิ่ม (addition) เส้นเชื่อมของเครือข่าย M_{old} และ M_{new} ที่ละหนึ่งเส้นเชื่อม สามารถแสดงตัวอย่างการหาเครือข่ายเนจเบอร์ได้ดังรูป 4.2



$$\frac{Q(M_{old} | M_{new})}{Q(M_{new} | M_{old})} = \frac{1/5}{1/6} = \frac{6}{5} = \frac{N(M_{old})}{N(M_{new})}$$

รูป 4.2 ตัวอย่างการหาเครือข่ายเนจเบอร์ของ M_{old} และ M_{new} ที่ได้มาจากการลบ การกลับทิศทาง และการเพิ่มเส้นเชื่อมทีละหนึ่งเส้นเชื่อม ซึ่งเครือข่ายเนจเบอร์จะต้องเป็นกราฟชนิด DAG ดังนั้นเครือข่ายเนจเบอร์สุดท้ายของ M_{new} จึงถูกตัดออก ทำให้เครือข่าย M_{old} มีเครือข่ายเนจเบอร์ทั้งหมด 6 เครือข่าย และเครือข่าย M_{new} มีเครือข่ายเนจเบอร์ทั้งหมด 5 เครือข่าย

จากตัวอย่างการหาเครือข่ายเน้จเบอร์ในรูปแบบ 4.2 เมื่อทำการคำนวณหาค่าความน่าจะเป็นของการแจกแจงที่นำเสนอ $Q(\cdot)$ โดยพิจารณาจากเครือข่ายเน้จเบอร์ของ M_{old} และ M_{new} พบว่า ค่าความน่าจะเป็นของการแจกแจงที่นำเสนอของ M_{old} เมื่อทราบค่าของ M_{new} แทนด้วย $Q(M_{old} | M_{new})$ มีค่าเท่ากับ $1/5$ และค่าความน่าจะเป็นของการแจกแจงที่นำเสนอของ M_{new} เมื่อทราบค่าของ M_{old} แทนด้วย $Q(M_{new} | M_{old})$ มีค่าเท่ากับ $1/6$ เมื่อพิจารณาค่าของเทอมการแจกแจงที่นำเสนอนี้จะมีค่าเท่ากับอัตราส่วนของจำนวนเครือข่ายเน้จเบอร์ของ M_{old} และ M_{new} ซึ่งจะถูกเรียกว่าอัตราส่วนแฮสติงส์ (Hastings ratio) ของ M_{old} และ M_{new} คั้งนั้นการแจกแจงที่นำเสนอ $Q(\cdot)$ ในสมการที่ (19) จะถูกคำนวณด้วยอัตราส่วนในสมการที่ (20) โดย N แทนจำนวนเครือข่ายเน้จเบอร์ของ M_{old} และ M_{new}

$$\frac{Q(M_{old} | M_{new})}{Q(M_{new} | M_{old})} = \frac{N(M_{old})}{N(M_{new})} \quad (20)$$

สุดท้ายจึงทำการพิจารณาว่าจะยอมรับเครือข่าย M_{new} ที่ถูกสร้างขึ้นมานี้หรือไม่ โดยการเปรียบเทียบค่าความน่าจะเป็นที่ยอมรับได้ซึ่งคำนวณได้จากสมการที่ (19) กับค่าความน่าจะเป็นที่สุ่มมาได้จากการแจกแจงเอกรูป (Uniform distribution) เมื่อกำหนดค่าพารามิเตอร์ของการแจกแจงนี้คือ พารามิเตอร์ค่าน้อยที่สุด (min) เท่ากับ 0 และพารามิเตอร์ค่ามากที่สุด (max) เท่ากับ 1 สามารถแสดงดังอัลกอริทึมของการพิจารณายอมรับเครือข่าย M_{new} ได้ดังต่อไปนี้

$U \sim \text{uniform}(0, 1)$

If ($U \leq \alpha(M_{old}, M_{new})$)

$M_{old}[t+1] = M_{new}[t]$

Network $[t] = M_{new}[t]$

$t = t + 1$

4.2.2 เครือข่ายเบย์เซียน

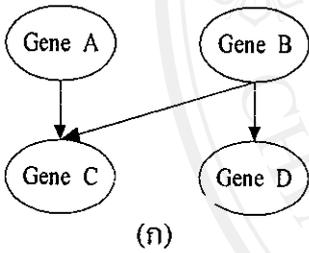
จากที่กล่าวไว้ในหัวข้อ 4.2.1 ว่าหลักการของเบย์เซียนจะถูกนำมาใช้ในส่วนของการแจกแจงที่คงที่ของอัลกอริทึมเมโทรโพลิส – แฮสติงส์ โดยการคำนวณจะอาศัยหลักการทฤษฎีของเบย์ (Baye's theorem) และเครือข่ายความเชื่อของเบย์เซียน (Bayesian belief network) คั้งนี้

จากทฤษฎีของเบย์ (Gamerman, 1997) พบว่าเทอมการแจกแจงที่คงที่ $P(\cdot|D)$ ในสมการที่ (17) ก็คือการแจกแจงโพลที่เรียของเครือข่ายที่เราสนใจที่มีเงื่อนไขภายใต้ข้อมูลการแสดงผลออกของอินในเครือข่าย D คั้งนั้นจากทฤษฎีของเบย์จึงทำให้ได้ว่า

$$\frac{P(M_{new} | D)}{P(M_{old} | D)} = \frac{P(D | M_{new})P(M_{new})}{P(D | M_{old})P(M_{old})} \quad (21)$$

โดยที่ $P(.)$ คือการแจกแจงไพโรเออร์ของเมทริกซ์เครือข่าย M และ $P(D|M)$ คือค่าโลคัลลิสต์ที่คำนวณมาจากตารางความน่าจะเป็นอย่างมีเงื่อนไขสำหรับแต่ละยีนในเครือข่าย ด้วยวิธีการของเครือข่ายความเชื่อของเบย์เซียน (Han and Kamber, 2001)

เครือข่ายความเชื่อของเบย์เซียนเป็นวิธีที่คำนึงถึงข้อมูลที่เป็นจริงว่า ในแต่ละแถวข้อมูลหรือการทดลองในแต่ละครั้งอาจมีคุณลักษณะบางประการของข้อมูลที่มีความสัมพันธ์ต่อกัน ในเครือข่ายความเชื่อของเบย์เซียนจึงได้จัดให้มีแบบจำลองเชิงกราฟของความเชื่อของความสัมพันธ์ที่เรียกว่าเครือข่ายความเชื่อ (Belief network) ซึ่งประกอบด้วย 2 ส่วน ส่วนแรกคือกราฟของเครือข่ายความสัมพันธ์ชนิด DAG จากรูป 4.3(ก) เป็นตัวอย่างกราฟ DAG จะเห็นได้ว่า GeneC จะทำงานได้ก็ต่อเมื่อถูกควบคุมโดย GeneA และ GeneB แต่ไม่ขึ้นกับ GeneD ส่วนที่สองคือตารางความน่าจะเป็นอย่างมีเงื่อนไข หรือเรียกง่าย ๆ ว่าตารางซีพีที (CPT) สำหรับแต่ละตัวแปร โดยที่ตารางซีพีทีของตัวแปร Z จะเจาะจงการกระจายของเงื่อนไข $P(Z|Parents(Z))$



	A↑,B↑	A↑,B↓	A↓,B↑	A↓,B↓	A-,B-	A-,B↓	A↓,B↑	A↓,B-	A↓,B↓
C↑	0.9	0.2	0.5	0.2	0.15	0.8	0.3	0.25	0.7
C↓	0.05	0.7	0.1	0.4	0.35	0.1	0.6	0.45	0.2
C↓	0.05	0.1	0.4	0.4	0.5	0.1	0.1	0.3	0.1

(ข)

รูป 4.3 ส่วนประกอบของเครือข่ายความเชื่อของเบย์เซียน (ก) กราฟของเครือข่ายความสัมพันธ์ชนิด DAG และ (ข) ตารางซีพีที สำหรับ GeneC

จากรูป 4.3 (ข) ซึ่งแสดงตารางซีพีที สำหรับ GeneC ค่าความน่าจะเป็นที่ GeneC จะทำงาน แต่ละค่าที่ให้มาเป็นการรวมกันของค่าความเป็นไปได้ของค่า ของโหนดพ่อแม่ของ GeneC เช่นจากตารางซีพีที ช่องด้านบนซ้ายสุดและด้านล่างขวาสุด เราจะเห็นได้ว่า

$$P(\text{GeneC} = \text{“↑”} | \text{GeneA} = \text{“↑”}, \text{GeneB} = \text{“↑”}) = 0.9$$

$$P(\text{GeneC} = \text{“↓”} | \text{GeneA} = \text{“↓”}, \text{GeneB} = \text{“↓”}) = 0.1$$

ความน่าจะเป็นร่วมกันของแถวใดๆ (z_1, z_2, \dots, z_n) ที่สอดคล้องกับตัวแปรหรือแอททริบิวต์ Z_1, \dots, Z_n คำนวณได้จากสมการที่ (22)

$$P(z_1, \dots, z_n) = \prod_{i=1}^n P(z_i | Parents(Z_i)) \tag{22}$$

โดยที่ค่าสำหรับ $P(z_i | Parents(Z_i))$ สอดคล้องกับค่าในตารางซีพีทีสำหรับ Z_i

เราได้ทำการคำนวณค่าในตารางซีพีที ซึ่งก็คือค่าความน่าจะเป็นอย่างมีเงื่อนไขของตัวแปรที่เราสนใจโดยอ้างอิงตามสมการที่ (1) และเรากำหนดตัวแปรดังต่อไปนี้ นั่นคือ ให้ S เป็นเซตของตัวอย่างข้อมูลที่นำมาศึกษา (Training sample) จำนวน s ตัวคือ X_1, X_2, \dots, X_s และให้ w_{ijk} เป็นค่าในตารางซีพีทีสำหรับตัวแปร $Y_i = y_{ij}$ โดยมีกลุ่มของตัวแปรพ่อแม่ $U_i = u_{ik}$ โดยที่ i คือตัวแปร, j คือค่าที่เป็นไปได้ของตัวแปร i และ k คือค่าที่เป็นไปได้ของพ่อแม่ของ i ยกตัวอย่างเช่น ถ้า w_{ijk} เป็นค่าในตารางซีพีทีที่อยู่ด้านบนซ้ายสุดของรูป 4.3(ข) ซึ่งมีค่าความน่าจะเป็นเท่ากับ 0.9 จะได้ว่า Y_i เป็น GeneC ที่มีค่าเป็น $y_{ij} = \text{“}\uparrow\text{”}$ และ U_i เป็นรายการของโหนดพ่อแม่ของ Y_i คือ {GeneA, GeneB} ที่มี u_{ik} แสดงรายการค่าของโหนดพ่อแม่ดังนี้ {“ \uparrow ”, “ \uparrow ”} เราสามารถมองว่า w_{ijk} เป็นน้ำหนัก (Weight) ของข้อมูล โดยที่ในแต่ละรอบของการทำซ้ำ เราจะปรับค่าน้ำหนักจนกระทั่งเมื่อค่าของน้ำหนักไม่เปลี่ยนแปลง วิธีนี้จะค้นหาค่า w_{ijk} ที่สามารถแสดงข้อมูลได้ดีที่สุด มีเป้าหมายคือต้องการหาค่าที่มากที่สุดของความน่าจะเป็นของกลุ่มตัวอย่างข้อมูลที่นำมาศึกษา ถ้าให้โครงสร้างเครือข่ายการทำงานก็จะเกิดขึ้นดังต่อไปนี้

- (1) คำนวณค่าความน่าจะเป็น $P(Y_i = y_{ij} | U_i = u_{ik})$ สำหรับทุกค่า i, j, k ที่เป็นไปได้ จะได้ว่า w_{ijk} ที่เป็นสมาชิกในตารางซีพีทีสำหรับตัวแปร Y
- (2) คำนวณค่าความน่าจะเป็นสำหรับแต่ละ i, j, k โดยพิจารณาในแต่ละกรณีของข้อมูลดังนี้

$$\frac{\partial \ln P_w(S)}{\partial w_{ijk}} = \sum_{d=1}^s \frac{P(Y_i = y_{ij}, U_i = u_{ik} | X_d)}{w_{ijk}} \quad (23)$$

เมื่อ $P_w(S) = \prod_{d=1}^s P_w(X_d)$ และความน่าจะเป็นในด้านขวามือของสมการที่ (23) จะถูกคำนวณสำหรับแต่ละตัวอย่างข้อมูลที่นำมาศึกษา X_d ใน S

- (3) ทำการปรับค่าน้ำหนักโดย

$$w_{ijk} \leftarrow w_{ijk} + (l) \frac{\partial \ln P_w(S)}{\partial w_{ijk}} \quad (24)$$

โดยที่ l เป็นอัตราการเรียนรู้ (Learning rate) แทนขนาดของก้าว (Step) ของการเรียนรู้จะถูกกำหนดให้เป็นค่าคงที่ค่าหนึ่งที่มีค่าน้อยมาก และ $\frac{\partial \ln P_w(S)}{\partial w_{ijk}}$ คือค่าที่

คำนวณได้จากสมการที่ (23)

- (4) ทำการรีนอร์มอลไลซ์น้ำหนัก เนื่องจากน้ำหนัก w_{ijk} เป็นค่าความน่าจะเป็นจึงมีค่าตั้งแต่ศูนย์ถึงหนึ่ง และ $\sum_j w_{ijk}$ จะต้องเท่ากับหนึ่งสำหรับทุกๆ i, k โดยการทำรีนอร์มอลไลซ์ค่าน้ำหนัก หลังจากถูกปรับค่าโดยสมการที่ (24) แล้ว ดังสมการต่อไปนี้

$$w_{ijk} \leftarrow \frac{w_{ijk}}{\sum_j w_{ijk}} \quad (25)$$

และเราจะหยุดการเรียนรู้ค่าในตารางซีพีที เมื่อค่า w_{ijk} ไม่เปลี่ยนแปลง หรือเปลี่ยนแปลงน้อยมากจนเรียกได้ว่าคงที่ และจะได้ตารางซีพีทีที่เป็นตัวแทนของแต่ละตัวแปร บอกค่าความน่าจะเป็นอย่างมีเงื่อนไข (Conditional probability)

(ออมฟิโล มโนรัตน์, 2548)

4.2.3 อัลกอริทึมของการทดลอง

จากวิธีการและการทดลองที่ได้กล่าวมาแล้วข้างต้น สามารถสรุปเป็นอัลกอริทึมของการทดลองในครั้งนี้ได้ดังต่อไปนี้

Algorithm MH-based Bayesian Regulatory Network

Input: *ExpData*: Gene expression data

HypoNet: Hypothetical regulatory network

Output: *Network*: A set of all accepted networks by Metropolis – Hastings

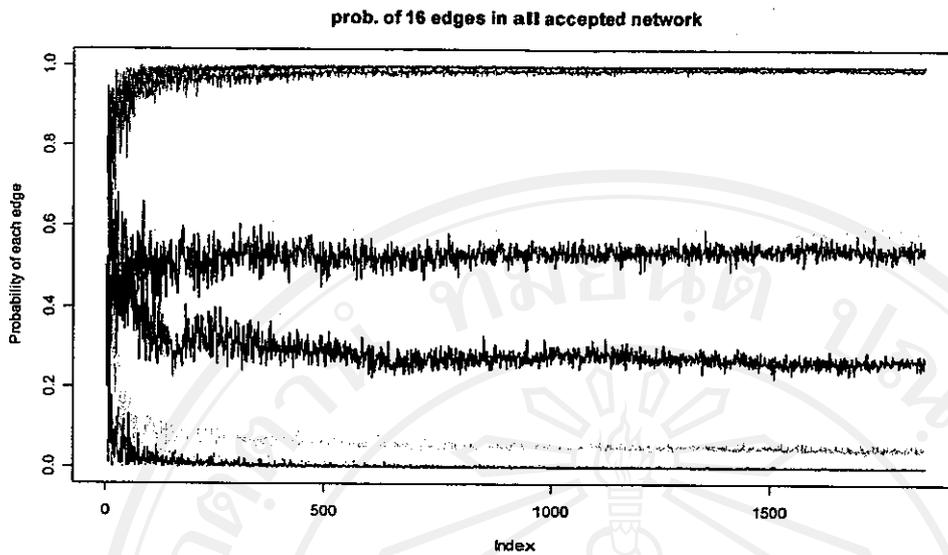
1. Transform *ExpData* to discrete dataset
2. Initialize M_{old} with the hypothetical regulatory network *HypoNet*
3. Repeat step 4 to step 9 for long enough time
4. Sampling a new acyclic network M_{new} by
 - If (it is the first sampling) Then
 - $M_{new}[i, j] \sim \text{binomial}(0.5)$, for each pair of genes (i, j)
 - Else
 - $\text{edge_prob}[i, j] \sim \text{dirichlet}(a)$
 - $M_{new}[i, j] \sim \text{binomial}(\text{edge_prob}[i, j])$, for each pair of genes (i, j)
5. Find $N(M_{old})$ the number of acyclic neighbor networks of M_{old}
6. Find $N(M_{new})$ the number of acyclic neighbor networks of M_{new}
7. Compute acceptance probability: $\alpha(M_{old}, M_{new})$
 - where $\alpha(M_{old}, M_{new}) = \min \left\{ 1, \frac{P(M_{old}|D) * N(M_{old})}{P(M_{new}|D) * N(M_{new})} \right\}$
8. Random a number U from uniform(0,1)
9. If($U \leq \alpha(M_{old}, M_{new})$) Then
 - Accept M_{new} and keep it into *Network* set
 - Set M_{new} to be M_{old} for the next sampling
 - Update Dirichlet parameter $a = \{\alpha_1, \alpha_2\}$:
 - $\alpha_1[i, j] = \alpha_1[i, j] + 2$ If $M_{new}[i, j] = 1$
 - $\alpha_2[i, j] = \alpha_2[i, j] + 2$ If $M_{new}[i, j] = 0$

4.3 ผลการทดลอง

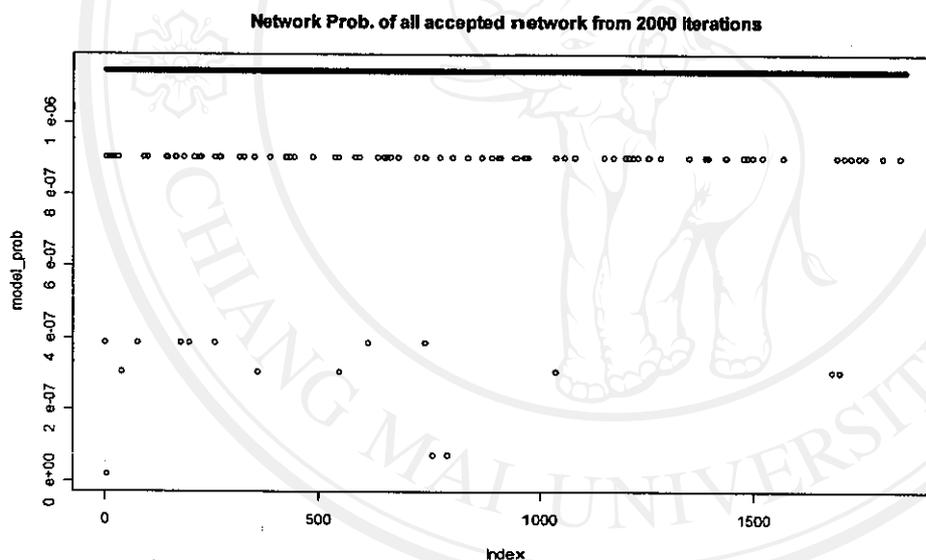
จากการรันโปรแกรมตามอัลกอริทึมในหัวข้อ 4.2.3 แบบทำซ้ำด้วยเครือข่ายที่มีการรายงานไว้แล้วและข้อมูลระดับการแสดงผลออกของยีน HAP2 HAP3 HAP4 และ CYC1 ทั้งหมด 2,000 รอบ เพื่อทำการสร้าง (reconstructing) เครือข่ายการควบคุมกันระหว่างยีนที่เป็นไปได้พบว่าด้วยวิธีการของเมโทรโพลิส – แอสติงส์ จะยอมรับเครือข่ายที่ถูกสร้างขึ้นมาจำนวน 1,853 เครือข่าย โดยค่าของ *edge_prob* ซึ่งเป็นความน่าจะเป็นของเส้นเชื่อมในแต่ละตำแหน่งทั้งหมด 16 เส้นเชื่อมที่เป็นผลจากการแจกแจง Dirichlet ที่นำไปใช้สร้างเครือข่ายที่ยอมรับทั้งหมดนี้จะค่อย ๆ ลู่เข้าจนมีค่าคงที่แสดงดังรูป 4.4 โดยในตอนเริ่มต้นของการทดลอง ค่าความน่าจะเป็นของเส้นเชื่อมทุกตำแหน่งจะถูกกำหนดด้วยค่า 0.5 หลังจากนั้นค่าความน่าจะเป็นที่ได้จากการแจกแจง Dirichlet ของแต่ละเส้นก็จะมีค่ามากขึ้นหรือลดลงจนลู่เข้าสู่ค่าใดค่าหนึ่ง (local optimum)

เมื่อพิจารณาเฉพาะเครือข่ายที่ยอมรับทั้ง 1,853 เครือข่าย พบว่าเครือข่ายที่ได้นั้นมีลักษณะใกล้เคียงกับเครือข่ายจริงของการควบคุมกันระหว่างกลุ่มยีน HAP2 HAP3 HAP4 และ CYC1 นั่นคือในทุกเครือข่ายที่ยอมรับนั้นจะมีความสัมพันธ์ของทั้งสี่ยีนนี้เกิดขึ้นอย่างน้อยหนึ่งความสัมพันธ์ ซึ่งสามารถแสดงค่าความน่าจะเป็นโพสทีเรียของทุกเครือข่ายที่ยอมรับได้ดังรูป 4.5 พบว่าค่าความน่าจะเป็นของเครือข่ายที่ยอมรับส่วนใหญ่จะมีค่าเท่ากับ $1.143835e-06$ ซึ่งเป็นค่าความน่าจะเป็นโพสทีเรียของเครือข่ายที่สูงที่สุด ซึ่งตรงกับแนวคิดที่ว่าเครือข่ายที่ดีที่สุดควรมีค่าความน่าจะเป็นของเครือข่ายมากที่สุด ถึงแม้ว่ายังมีบางเครือข่ายที่ยอมรับที่มีค่าความน่าจะเป็นต่ำ แต่พบว่าปริมาณของเครือข่ายเหล่านั้นจะมีจำนวนลดลงเมื่อเข้าสู่การทดลองซ้ำในรอบที่มากขึ้น ดังนั้นถ้าทำการเรียนรู้ต่อไปด้วยจำนวนการทดลองที่เพิ่มมากขึ้นอาจจะทำให้ได้เฉพาะผลการทดลองที่เป็นเครือข่ายที่ยอมรับที่มีค่าความน่าจะเป็นของเครือข่ายสูงที่สุดเท่านั้น

จากผลลัพธ์ของการสร้างและพิจารณายอมรับเครือข่ายความสัมพันธ์ของกลุ่มยีนจากการทดลองนี้จึงได้เครือข่ายที่ยอมรับทั้งหมดออกมา จากนั้นจึงทำการพิจารณาเลือกเครือข่ายที่ยอมรับทั้งหมด 100 เครือข่ายสุดท้ายออกมา ซึ่งเครือข่ายเหล่านี้ถูกสร้างมาจากความน่าจะเป็นของเส้นเชื่อมที่อยู่ในช่วงที่คงที่แล้ว โดยเครือข่ายที่ยอมรับในช่วงแรกจะเป็นเครือข่ายที่อยู่ในช่วงที่ยังไม่คงที่ (burn - in) ซึ่งจะไม่ถูกนำมาพิจารณา โดยพบว่า เครือข่ายทั้ง 100 เครือข่ายที่ถูกเลือกมานั้นเป็นเครือข่ายที่มีลักษณะความสัมพันธ์คล้ายคลึงกัน โดยมีรูปแบบความสัมพันธ์ที่พบทั้งหมด 10 รูปแบบ แสดงดังรูป 4.6 ซึ่งแต่ละรูปแบบจะประกอบด้วยลักษณะรูปแบบความสัมพันธ์ของเครือข่ายการควบคุมกันระหว่างยีน ค่าความถี่ของการเกิดเครือข่ายที่ยอมรับนั้น (freq.) ค่าความน่าจะเป็นโพสทีเรียของเครือข่าย (prob.) และค่าความน่าจะเป็นของการเกิดขึ้นของเส้นเชื่อมในแต่ละตำแหน่ง (ตัวเลขบนเส้นเชื่อม)

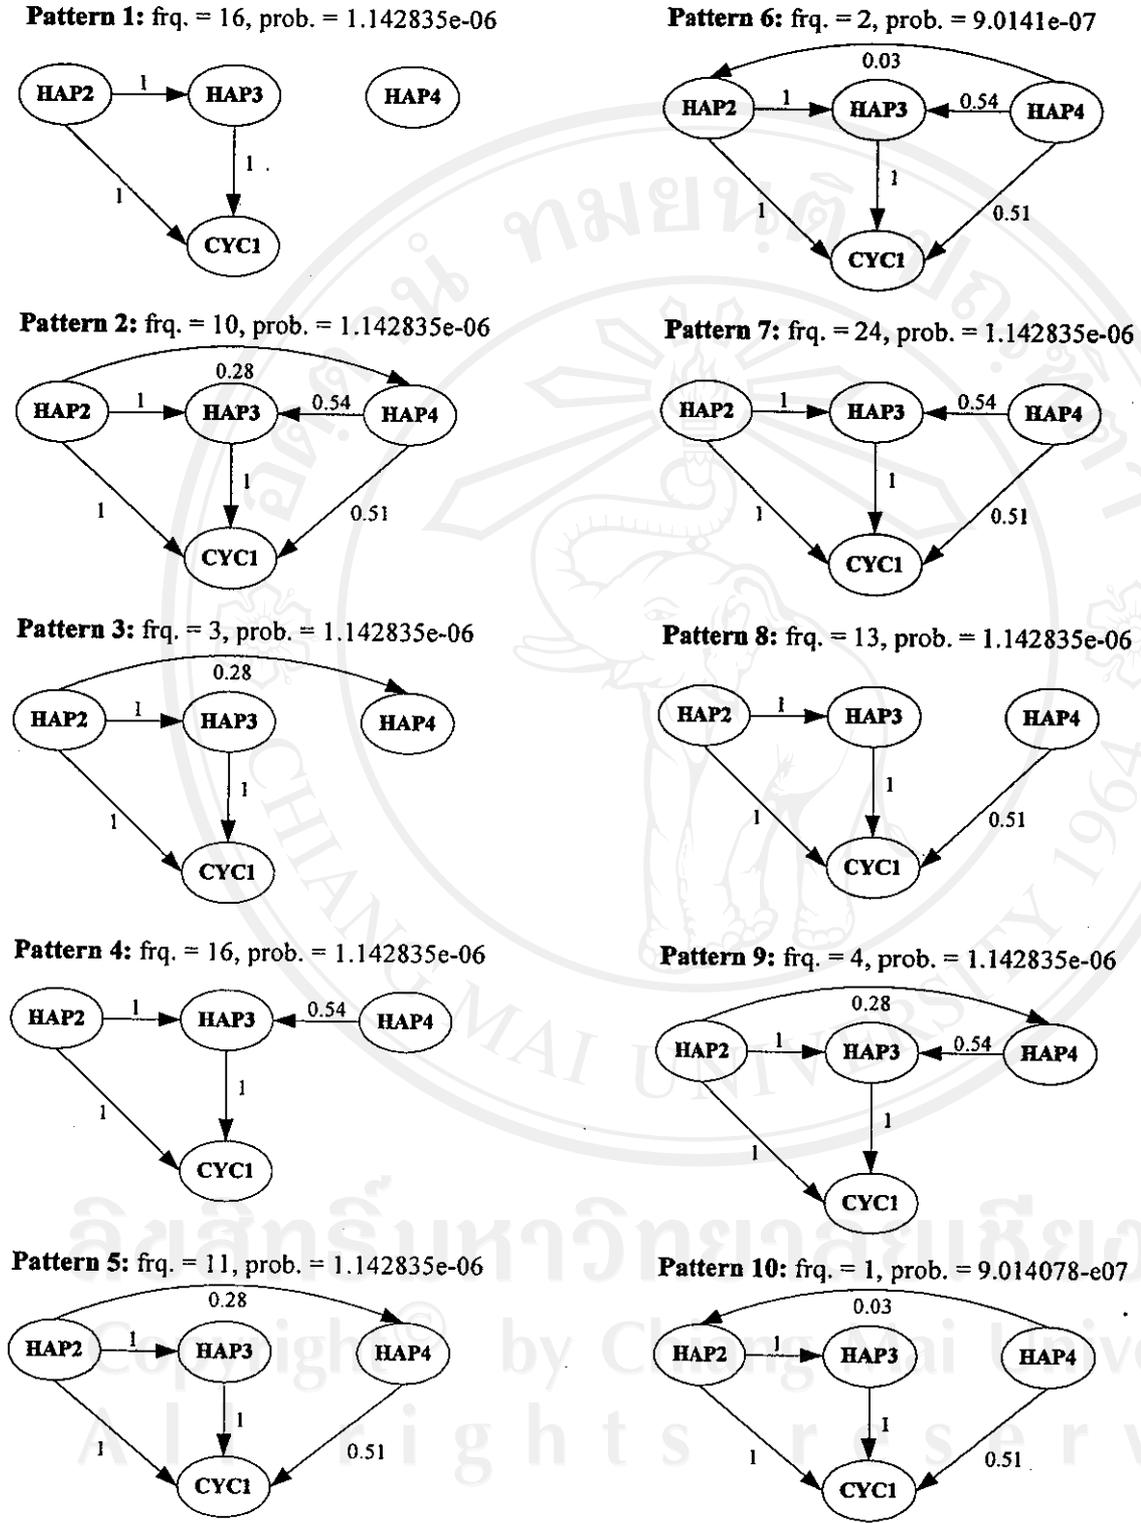


รูป 4.4 การลู่เข้าของค่าความน่าจะเป็นของ *edge_prob* สำหรับทุกเส้นเชื่อม



รูป 4.5 ค่าความน่าจะเป็นของเครือข่ายที่ยอมรับทั้ง 1,853 เครือข่าย

ในรูป 4.6 พบว่าเครือข่ายทั้งสิบรูปแบบนี้มีความสัมพันธ์ของยีน HAP2 และ HAP3 ไปยังยีน CYC1 ปรากฏอยู่ทุกเครือข่าย ซึ่งตรงกับเครือข่ายจริงที่ได้มีการรายงานไว้ว่าทั้งสองยีนนี้ต่างร่วมกันไปควบคุมส่วนโปรโมเตอร์ของยีน CYC1 และเครือข่ายที่ยอมรับในรูปแบบที่ 2, 5, 6, 7, 8 และ 10 นั้นพบว่ามีความสัมพันธ์ระหว่างยีนทั้งสี่นี้เกิดขึ้นตามเครือข่ายจริงทุกความสัมพันธ์ แต่อย่างไรก็ตามยังคงมีบางความสัมพันธ์ที่ไม่ตรงตามเครือข่ายจริงปรากฏอยู่ ซึ่งต้องมีการศึกษาเพิ่มเติมต่อไปทั้งในด้านการคำนวณและด้านชีววิทยาเพื่อเป็นคั่นกว่าความสัมพันธ์ระหว่างยีนอื่นๆ ที่พบในการทดลองครั้งนี้มีความเป็นไปได้มากน้อยเพียงใด



รูป 4.6 รูปแบบความสัมพันธ์ที่พบทั้งหมด 10 รูปแบบ จากเครือข่ายที่ยอมรับ 100 เครือข่ายที่ถูกเลือก

สุดท้ายเมื่อทำการพิจารณาความน่าจะเป็นของเครือข่ายที่ยอมรับที่เลือกมาทั้ง 100 เครือข่ายนี้ พบว่าเครือข่ายส่วนใหญ่ (97 เครือข่าย) มีค่าความน่าจะเป็นของเครือข่ายเท่ากับค่าความน่าจะเป็นสูงสุดซึ่งเท่ากับ $1.143835e-06$ และในทั้ง 97 เครือข่ายนี้ พบว่าเครือข่ายที่มีความถี่ในการยอมรับมากที่สุดเท่ากับ 24 % คือ เครือข่ายรูปแบบที่ 7 ซึ่งมีลักษณะของเครือข่ายจริงปรากฏอยู่ด้วย ส่วนเครือข่ายที่มีค่าความน่าจะเป็นต่ำที่สุดเท่ากับ $9.014078e-07$ ทั้งหมด 3 เครือข่าย และเป็นเครือข่ายที่มีความถี่ในการยอมรับน้อยที่สุดเท่ากับ 1 % และ 2 % คือ เครือข่ายในรูปแบบที่ 10 และรูปแบบที่ 6 ตามลำดับ และเมื่อพิจารณาค่าความน่าจะเป็นของการเกิดขึ้นของเส้นเชื่อมในแต่ละตำแหน่งของเครือข่ายที่ถูกเลือกมาทั้ง 100 เครือข่ายนี้พบว่าค่าความน่าจะเป็นนี้มีค่าใกล้เคียงกับค่าความน่าจะเป็นของการสร้างเส้นเชื่อม (*edge prob*) ดังรูป 4.4 โดยความสัมพันธ์ระหว่างยีนที่เกิดขึ้นเสมอในเครือข่ายทั้งสิบรูปแบบซึ่งมีค่าความน่าจะเป็นของการเกิดของเส้นเชื่อมเป็น 1 คือ ความสัมพันธ์ที่ยีน HAP2 ไปควบคุมการแสดงออกของยีน HAP3 และ CYC1 และความสัมพันธ์ที่ยีน HAP3 ไปควบคุมยีน CYC1 และสำหรับความสัมพันธ์ที่ยีน HAP4 ไปควบคุมการแสดงออกของยีน CYC1 มีค่าความน่าจะเป็นของการเกิดของเส้นเชื่อมเป็น 0.54

4.4 บทสรุป

จากงานวิจัยนี้ได้เสนอวิธีการของมาร์คอฟเชนมอนติคาร์โลเพื่อทำการสร้างเครือข่ายเบย์เซียนจากเครือข่ายการควบคุมกันระหว่างยีนที่ได้มีการรายงานไว้แล้วและข้อมูลการแสดงออกของยีนเหล่านั้นในเครือข่าย ซึ่งจากการทดลองในครั้งนี้ก็แสดงให้เห็นว่ากระบวนการควบคุมกันระหว่างยีนสามารถตรวจสอบได้ด้วยเครือข่ายเบย์เซียนร่วมด้วยวิธีการมาร์คอฟเชนมอนติคาร์โลได้อย่างถูกต้องและมีความน่าเชื่อถือในระดับหนึ่ง โดยในงานวิจัยนี้จะใช้ทั้งสองวิธีการข้างต้นร่วมกันในการสร้างและพิจารณาเครือข่ายการควบคุมกันระหว่างยีน ซึ่งพบว่าผลลัพธ์ที่ได้จากการทดลองในครั้งนี้มีความใกล้เคียงกับเครือข่ายจริงที่ได้มีการรายงานไว้แล้ว แต่ยังมีบางความสัมพันธ์ระหว่างยีนที่ไม่เป็นไปตามเครือข่ายจริง

นอกจากนี้ผลลัพธ์ที่ได้ก็เป็นผลจากการทดลองกับข้อมูลเพียงชุดเดียว ดังนั้นเพื่อเป็นการยืนยันความถูกต้องของวิธีการตามอัลกอริทึมข้างต้นมากยิ่งขึ้น เราควรทำการทดลองกับข้อมูลชุดอื่นๆ ด้วย และควรทำการพัฒนาโปรแกรมนี้ให้สามารถวิเคราะห์ข้อมูลชนิดต่อเนื่องได้ ซึ่งจะถือได้ว่าเป็นการทำการวิเคราะห์จากข้อมูลการแสดงออกของยีนโดยตรง

แต่อย่างไรก็ดีในการที่จะนำวิธีการนี้ไปใช้เพื่อทำการสร้างหรือทำนายเครือข่ายการควบคุมกันระหว่างยีนที่ยังไม่มีการรายงานไว้ ควรมีการศึกษาเพิ่มเติม หรือ เพิ่มวิธีการบางอย่างเข้าไป

เพื่อให้ได้ผลการทดลองที่มีความถูกต้องและน่าเชื่อถือมากยิ่งขึ้น ซึ่งจะเป็นงานที่จะดำเนินต่อไปในอนาคต



ลิขสิทธิ์มหาวิทยาลัยเชียงใหม่
Copyright© by Chiang Mai University
All rights reserved