

บทที่ 4 การเรียนรู้ของระบบชาญฉลาด (The learning of intelligent systems)

นำเสนอโดย

ผู้ช่วยศาสตราจารย์จุฑาทูตจิ จันทรมาลี

หลักสูตรวิทยาการคอมพิวเตอร์

มหาวิทยาลัยสวนดุสิต

การเรียนรู้ของเครื่อง

บทนี้กล่าวถึงการเรียนรู้ของเครื่อง (*machine learning*) ซึ่งเทคนิคการเรียนรู้ส่วนมากเป็นการเรียนรู้เชิงอุปนัย (*inductive learning*) และมีบางเทคนิคเป็นการเรียนรู้เชิงวิเคราะห์ (*analytical learning*) การเรียนรู้เชิงอุปนัยคือการเรียนรู้ที่หากฎเกณฑ์หรือความรู้ที่แฝงอยู่ในชุดตัวอย่างสอน (*training example set*) เพื่อเรียนรู้ให้ได้ความรู้ใหม่ที่สอดคล้องกับชุดตัวอย่างสอน ส่วนการเรียนรู้เชิงวิเคราะห์เป็นการจัดรูปแบบของความรู้ใหม่เพื่อให้ใช้งานได้อย่างมีประสิทธิภาพมากขึ้น ทำงานได้เร็วขึ้น

6.1 ขั้นตอนวิธีเชิงพันธุกรรม

ขั้นตอนวิธีเชิงพันธุกรรม – จีเอ (Genetic Algorithm – GA) [Goldberg, 1989; Mitchell, 1996] เป็นการเรียนรู้ที่จำลองการวิวัฒนาการ เราอาจมองได้ว่าจีเอเป็นกระบวนการค้นหาประเภทหนึ่งหรืออาจมองว่าจีเอเป็นการเรียนรู้ของเครื่องประเภทหนึ่งก็ได้ จีเอได้ถูกขยายขึ้นเป็นการโปรแกรมเชิงพันธุกรรม – จีพี (Genetic Programming – GP) [Koza, 1992] ข้อแตกต่างที่สำคัญอย่างหนึ่งระหว่างจีเอกับจีพีก็คือในจีเอสิ่งที่เรียนรู้ได้เป็นสายอักขระความยาวคงที่ (fixed-length string) ส่วนในจีพีจะได้สายอักขระความยาวแปรได้ (variable length string) ซึ่งมักแสดงในรูปของโปรแกรมภาษา LISP แนวคิดของจีเอมาจากทฤษฎีวิวัฒนาการของสิ่งมีชีวิต เช่นการไขว้เปลี่ยนของโครโมโซม (chromosome crossover) การกลายพันธุ์ของยีน (gene mutation) การวิวัฒนาการของสิ่งมีชีวิต เป็นต้น จีเอสามารถจัดการกับปัญหาค่าที่ดีที่สุดเฉพาะที่ (local optimum) ในการค้นหาได้ การค้นหาทั่วไปจะมองว่าจุดที่ดีที่สุดเฉพาะที่เป็นกับดัก และจะหลีกเลี่ยงกับดักโดยใช้วิธีต่างๆ เช่น การย้อนรอย (backtracking) หรือการค้นหาแบบขนาน (parallel search) โดยใช้สถานะเริ่มต้นที่ต่างๆ กัน เป็นต้น แต่เทคนิคการค้นหาด้วยจีเอจะใช้วิธีการที่แตกต่างไปดังจะกล่าวต่อไป

6.1 ขั้นตอนวิธีเชิงพันธุกรรม

โครโมโซมกำหนดลักษณะพิเศษที่สืบทอดได้

เซลล์แต่ละเซลล์ในพืชชั้นสูงและสัตว์ประกอบด้วยนิวเคลียส 1 นิวเคลียส และนิวเคลียสหนึ่งๆ ประกอบด้วยโครโมโซมจำนวนมาก โครโมโซมจะอยู่กันเป็นคู่โดยได้รับมาจากพ่อและแม่อย่างละ 1 เส้น โครโมโซมแต่ละเส้นจะมียีนเป็นตัวกำหนดลักษณะพิเศษของสิ่งมีชีวิต ในขณะที่มีการจับคู่กันของโครโมโซมอาจเกิด *การไขว้เปลี่ยน (crossover)* ซึ่งเป็นการที่ยีนจากโครโมโซมพ่อแม่สลับเปลี่ยนกันทำให้เกิดโครโมโซมใหม่ขึ้น 2 คู่ และในขณะที่เซลล์แบ่งตัวจะเกิดกระบวนการ *คัดลอกโครโมโซม (chromosome copying)* ซึ่งบางครั้งจะมีการเปลี่ยนแปลงของยีนที่มาจากยีนพ่อแม่เกิดเป็นยีนที่ไม่เคยมีมาก่อน เราเรียกการเกิดยีนลักษณะนี้ว่า *การกลายพันธุ์ (mutation)*

6.1.1 การออกแบบขั้นตอนวิธีเชิงพันธุกรรม


จะยกตัวอย่างปัญหาการทำคุกกี้เพื่ออธิบายการออกแบบจีเอ [Winston, 1992] สมมติว่าเราต้องการหาส่วนผสมที่ดีที่สุดเพื่อทำคุกกี้โดยที่คุกกี้มีส่วนผสมสองอย่างคือแป้งและน้ำตาลและสมมติว่าคุณภาพของคุกกี้เป็นฟังก์ชันแสดงในรูปที่ 2-8 ด้านล่างนี้

9	1	2	3	4	5	4	3	2	1
8	2	3	4	5	6	5	4	3	2
7	3	4	5	6	7	6	5	4	3
6	4	5	6	7	8	7	6	5	4
น้ำตาล 5	5	6	7	8	9	8	7	6	5
4	4	5	6	7	8	7	6	5	4
3	3	4	5	6	7	6	5	4	3
2	2	3	4	5	6	5	4	3	2
1	1	2	3	4	5	4	3	2	1
	1	2	3	4	5	6	7	8	9
				แป้ง					

รูปที่ 6-1 ฟังก์ชันภูเขาเรียบของคุณภาพคุกกี้การไขว้เปลี่ยนการกลายพันธุ์

6.1.1 การออกแบบขั้นตอนวิธีเชิงพันธุกรรม


น้ำตาล 1 กก. กับแป้ง 1 กก. ผลิตได้คุกกี้มีคุณภาพ 1 หน่วย ฟังก์ชันนี้จะมีค่าสูงสุดอยู่ที่ 5-5 (น้ำตาล 5 กก. กับแป้ง 5 กก. ผลิตได้คุกกี้คุณภาพ 9 หน่วย) เราออกแบบให้แต่ละภาคของคุกกี้ถูกแทนด้วยโครโมโซมเส้นหนึ่งดังแสดงในรูปที่ 1-1



ในการออกแบบครั้งนี้กำหนดให้โครโมโซมมียีน 2 ตัว ยีนด้านซ้ายแทนจำนวนกิโลกรัมของน้ำตาลและยีนด้านขวาแทนจำนวนกิโลกรัมของแป้ง กำหนดให้ตัวเลขแสดงจำนวนกิโลกรัมของทั้งน้ำตาลและแป้งมีค่าตั้งแต่ 1 ถึง 9 โครโมโซมแทนภาคของคุกกี้กำหนดความเหมาะสม (fitness) กับธรรมชาติของคุกกี้ โครโมโซมสามารถสร้างขึ้นจากยีนน้ำตาลและแป้ง สร้างขึ้นจากการไขว่เปลี่ยนของโครโมโซมพ่อแม่คู่หนึ่ง หรือสร้างได้จากการกลายพันธุ์ของยีนในโครโมโซมตัวหนึ่งที่มีอยู่ และถ้าหากเรามีโครโมโซม 1 เส้น เราสามารถตัดแบ่งเอายีนของน้ำตาลหรือยีนของแป้งได้

6.1.1 การออกแบบขั้นตอนวิธีเชิงพันธุกรรม


ในการทำจีเอครั้งนี้ กำหนดให้ประชากรรุ่นหนึ่งๆ มีโครโมโซมที่เหมือนกันเพียงเส้นเดียว เราจำลองการเกิดการกลายพันธุ์ของโครโมโซมโดยการเลือกยีนตัวหนึ่งแบบสุ่มแล้วเปลี่ยนค่าของยีนโดยบวกหนึ่งหรือลบหนึ่งแบบสุ่มและยอมรับค่าที่ได้ถ้าค่านั้นอยู่ระหว่าง 1 ถึง 9 รูปที่ 6-3 แสดงวิวัฒนาการของโครโมโซมโดยการกลายพันธุ์ ในรูปแสดงการกลายพันธุ์สองรูปแบบซึ่งในแต่ละแบบแสดงการกลายพันธุ์เมื่อผ่านไป 4 ครั้ง ในแต่ละครั้งยีนที่เลือกและค่าที่เปลี่ยนไปเกิดจากการสุ่มในครั้งนั้นๆ เราเห็นได้ว่าเมื่อผ่านการกลายพันธุ์ไป 4 ครั้งโครโมโซมที่ได้มีความต่างกันค่อนข้างมาก โครโมโซมเส้นที่ดีเหมาะสมกับธรรมชาติก็就会被คัดเลือกซึ่งจะกล่าวต่อไป



รูปที่ 6-3 การจำลองการกลายพันธุ์ของโครโมโซมสุ่ม

6.1.1 การออกแบบขั้นตอนวิธีเชิงพันธุกรรม

เราจำลองการไขว้เปลี่ยนของโครโมโซมโดยตัดที่กึ่งกลางของโครโมโซมพ่อแม่ 2 เส้นแล้วนำแต่ละส่วนมาต่อกัน ดังรูปที่ 4-1



รูปที่ 6-4 การจำลองการไขว้เปลี่ยนของโครโมโซมคู่ก็

จากรูปเราจะเห็นได้ว่าโครโมโซมพ่อแม่ 5-1 และ 2-4 ผลิตได้โครโมโซมลูกสองเส้นคือ 5-4 กับ 2-1 ในกรณีทั่วไปที่โครโมโซมประกอบด้วยยีนมากกว่า 2 ตัว การตัดและการต่อจะซับซ้อนยิ่งขึ้น

6.1.2 ค่าความเหมาะสมมาตรฐาน

ค่าความเหมาะสม (*fitness*) ของโครโมโซมคือความน่าจะเป็นที่โครโมโซมจะอยู่รอดในรุ่น (generation) ถัดไป ค่าความเหมาะสมมาตรฐานสามารถนิยามได้ดังนี้

$$f_i = \frac{q_i}{\sum_j q_j}$$

โดยที่ f_i คือค่าความเหมาะสมของโครโมโซมเส้นที่ i ซึ่งมีค่าระหว่าง 0 ถึง 1 และ q_i คือคุณภาพของคู่ก๊อที่ถูกลำหนดโดยโครโมโซมเส้นที่ i

6.1.2 ค่าความเหมาะสมมาตรฐาน

ตารางที่ 6-1 ตัวอย่างค่าความเหมาะสมมาตรฐานของโครโมโซมคู่ก่

โครโมโซม	คุณภาพ	ค่าความเหมาะสมมาตรฐาน
1-4	4	0.40
3-1	3	0.30
1-2	2	0.20
1-1	1	0.10

ค่าความเหมาะสมมาตรฐานที่คำนวณได้ในตารางนี้ (เช่นค่าความเหมาะสมของโครโมโซม 1-4จะเท่ากับ $4/(4+3+2+1)=0.40$) เป็นความน่าจะเป็นที่โครโมโซมจะอยู่รอด (ถูกเลือก) ในรุ่นถัดไป ดังนั้นโครโมโซม 1-4 จะมีโอกาสอยู่รอดมากกว่าโครโมโซมเส้นอื่นๆ และมีโอกาสอยู่รอดมากกว่าโครโมโซม 1-1 ถึง 4 เท่า แต่ก็ไม่ได้หมายความว่าถ้าให้เลือกโครโมโซมได้แค่เส้นเดียวแล้วโครโมโซม 1-4 ที่มีค่าความเหมาะสมสูงสุดจะถูกเลือกทุกครั้งไป แต่จะขึ้นอยู่กับการสุ่มค่าแน่นอนว่า 1-4 มีโอกาสมากที่สุด และถ้าการสุ่มทำได้โดยไม่โน้มเอียงในการสุ่ม 100 ครั้ง 1-4 น่าจะมีโอกาสถูกเลือกสัก 40 ครั้ง

6.1.3 การจำลองการคัดเลือกโดยธรรมชาติ

เราได้ออกแบบโครโมโซมสำหรับปัญหาที่เราสนใจ การกลายพันธุ์ การไขว้เปลี่ยน ค่าความเหมาะสมแล้ว หัวข้อนี้จะกล่าวถึงการจำลองการคัดเลือกโดยธรรมชาติซึ่งสามารถทำได้โดยใช้ขั้นตอนทั่วไปดังต่อไปนี้

- กำหนดประชากรเริ่มต้น อาจมีโครโมโซม 1 เส้นหรือหลายเส้นก็ได้ เราอาจสุ่มโครโมโซมเหล่านี้หรือกำหนดขึ้นเองก็ได้
- ทำการกลายพันธุ์ยีนในโครโมโซมในรุ่นปัจจุบันและผลิตลูก
- ทำการไขว้เปลี่ยนโครโมโซม (พ่อแม่) ในรุ่นปัจจุบันและผลิตลูก
- เพิ่มลูกที่เกิดใหม่ในประชากร
- สร้างประชากรรุ่นใหม่โดยเลือกโครโมโซมตามค่าความเหมาะสมอย่างสุ่ม

6.1.3 การจำลองการคัดเลือกโดยธรรมชาติ

ในปัญหาการหาส่วนผสมที่ดีที่สุดของคูกี้กึ่งนี้ เราจะจำลองการคัดเลือกโดยธรรมชาติดังนี้

- เริ่มจากโครโมโซม 1-1 เพียงเส้นเดียว
- โครโมโซมที่เหมือนกันจะมีแค่เส้นเดียวในประชากรรุ่นหนึ่งๆ
- โครโมโซม 4 เส้นหรือน้อยกว่าจะอยู่รอดไปถึงรุ่นใหม่
- สำหรับโครโมโซมแต่ละเส้นที่อยู่รอด เลือกยีนตัวหนึ่งแบบสุ่มเพื่อทำการกลายพันธุ์ ถ้าโครโมโซมที่ได้จากการกลายพันธุ์ยังไม่เคยมีมาเลยให้เพิ่มเข้าไปในประชากร
- ไม่ทำการไขว้เปลี่ยน
- โครโมโซมที่อยู่รอดจะแข่งขันกับโครโมโซมใหม่เพื่อกำหนดโครโมโซมที่จะอยู่ในรุ่นถัดไป โครโมโซมที่มีค่าความเหมาะสมสูงสุดจะถูกเลือกเสมอให้อยู่รอดไปถึงรุ่นถัดไป ส่วนเส้นที่อยู่รอดที่เหลือจะถูกเลือกจากโครโมโซมที่เหลือแบบสุ่มตามค่าความเหมาะสม

6.1.4 การไขว้เปลี่ยนเพื่อเอาชนะจุดดีที่สุดเฉพาะที่

หัวข้อนี้เราจะดูผลของการไขว้เปลี่ยนที่มีต่อจีเอ โดยทำการทดลองเหมือนการทดลองที่แล้วแต่เพิ่มการไขว้เปลี่ยนเพื่อสร้างโครโมโซมใหม่ด้วย การไขว้เปลี่ยนทำดังต่อไปนี้

- ทำการไขว้เปลี่ยนโดยใช้โครโมโซมที่อยู่รอดจากรุ่นที่แล้ว (อย่างมากสุด 4 เส้น)
- สำหรับโครโมโซมที่จะทำการไขว้เปลี่ยนเส้นหนึ่งๆ ให้เลือกคู่ทำการไขว้เปลี่ยนแบบสุ่ม
- สลับยีนของโครโมโซมพ่อแม่และผลิตโครโมโซมลูก 2 เส้น ถ้าโครโมโซมลูกยังไม่เคยมีมาเลยให้เพิ่มเข้าไปในประชากรเพื่อแข่งขันที่จะอยู่รอดในรุ่นถัดไป

6.1.4 การไขว้เปลี่ยนเพื่อเอาชนะจุดดีที่สุดเฉพาะที่

ผลจากการทดลอง 1,000 ครั้ง ส่วนผสมที่ดีที่สุดถูกผลิตในรุ่นที่ 14 โดยเฉลี่ย ใช้จำนวนรุ่นน้อยกว่ากรณีไม่ใช้การไขว้เปลี่ยน 2 รุ่น แม้ว่าการไขว้เปลี่ยนจะช่วยให้เราพบส่วนผสมที่ดีที่สุดโดยใช้จำนวนรุ่นน้อยกว่าเดิม แต่เราต้องใช้เวลาคำนวณในแต่ละรุ่นมากขึ้นกว่าเดิมเนื่องจากจำนวนโครโมโซมที่มากขึ้นและการคำนวณค่าความเหมาะสมที่เพิ่มขึ้นดังนั้นเวลาโดยรวมจะเพิ่มขึ้นกว่าเดิม สำหรับปัญหานี้เป็นปัญหาที่ไม่มีจุดดีที่สุดเฉพาะที่มีแค่จุดดีสุดวงกว้างจุดเดียว ประสิทธิภาพของการไขว้เปลี่ยนจึงไม่เห็นอย่างชัดเจนปัญหาที่เราจะพิจารณาต่อไปเป็นปัญหาที่มีจุดดีที่สุดเฉพาะที่ซึ่งจะสร้างความยากลำบากสำหรับวิธีการค้นหาทั่วไป แต่จีเอสามารถจัดการกับปัญหาลักษณะนี้ได้ ปัญหานี้เป็นการหาส่วนผสมที่ดีที่สุดของคูกี้ก็เหมือนเดิมแต่ใช้ฟังก์ชันใหม่ดังรูปที่ 6-5 ต่อไปนี้

9	1	2	3	4	5	4	3	2	1
8	2	0	0	0	0	0	0	0	2
7	3	0	0	0	0	0	0	0	3
6	4	0	0	7	8	7	0	0	4
5	5	0	0	8	9	8	0	0	5
4	4	0	0	7	8	7	0	0	4
3	3	0	0	0	0	0	0	0	3
2	2	0	0	0	0	0	0	0	2
1	1	2	3	4	5	4	3	2	1
	1	2	3	4	5	6	7	8	9

น้ำตาล

แป้ง

รูปที่ 6-5 ฟังก์ชันภูมิเขามีสองน้ำส้มของคุณภาพคูกี้

6.1.4 การไขว้เปลี่ยนเพื่อเอาชนะจุดดีที่สุดเฉพาะที่

เริ่มต้นจากโครโมโซม 1-1 เช่นเดิม เราพบว่าในกรณีนี้การกลายพันธุ์เพียงอย่างเดียวไม่สามารถทำให้โครโมโซมในรุ่นที่อยู่ภายนอกคูกน้ำ (บริเวณที่มีค่าเป็น 0) ผลิตโครโมโซมทะลุเข้าไปอยู่พื้นที่ภายในคูกน้ำได้ เนื่องจากโครโมโซมตรงกลางมีค่าความเหมาะสมเป็น 0 ซึ่งไม่สามารถอยู่รอดในรุ่นถัดไปได้ (ค่าความเหมาะสมของโครโมโซมเป็น 0 ทำให้ความน่าจะเป็นที่จะอยู่รอดไม่มีเลย) อย่างไรก็ตามการไขว้เปลี่ยนที่จับคู่โครโมโซมพ่อแม่ที่เหมาะสมเช่น 1-5 และ 5-1 จะสามารถผลิตลูกที่ข้ามคูกน้ำไปได้ จากการทดลอง 1,000 ครั้งพบว่าส่วนผสมที่ดีที่สุดถูกผลิตในรุ่นที่ 155 โดยเฉลี่ย!! เป็นผลที่ไม่ดี ถ้าเราคำนวณดูก็จะทราบทันทีว่าโครโมโซมที่แตกต่างกันที่เป็นไปได้ทั้งหมดมีแค่ $9 \times 9 = 81$ เส้นเท่านั้น ผลที่ได้คือรุ่นที่ 155 และแต่ละรุ่นมีโครโมโซมที่เราทดสอบมากกว่าหนึ่งเส้น (แม้ว่าจะมีโครโมโซมมากมายที่ซ้ำกันในรุ่นต่างๆ)

6.1.4 การไขว้เปลี่ยนเพื่อเอาชนะจุดดีที่สุดเฉพาะที่

สาเหตุหนึ่งที่ไม่ดีก็เพราะว่าก่อนที่โครโมโซมจะกลายเป็นโครโมโซมที่อยู่บริเวณ 1-5 หรือ 5-1 นั้น โดยมากตายไปก่อนที่จะไปสู่บริเวณนั้นสำเร็จ และโอกาสที่คู่ที่เหมาะสมของโครโมโซมจะเกิดการไขว้เปลี่ยนก็มีโอกาสน้อยมาก ซึ่งที่จริงแล้วคู่ที่เหมาะสมของการไขว้เปลี่ยนมีจำนวนมากอย่างเช่น 2-6 กับ 4-2, 4-8 กับ 2-5, 6-8 กับ 2-4 เป็นต้น และโครโมโซมในคู่ทั้งหมดนี้ล้วนมีความน่าจะเป็นที่จะอยู่รอดเป็น 0 ทั้งสิ้น ที่เป็นเช่นนี้เกิดขึ้นจากฟังก์ชันความเหมาะสมมาตรฐานที่จะกำหนดให้โครโมโซมเหล่านี้มีความน่าจะเป็นที่จะอยู่รอดเป็น 0 หากเราปรับแก้ฟังก์ชันความเหมาะสมให้โครโมโซมเหล่านี้มีโอกาสอยู่รอดบ้างแม้จะน้อย ก็น่าจะช่วยให้การค้นหาส่วนผสมที่ดีที่สุดทำได้ดีขึ้น ดังจะกล่าวในหัวข้อต่อไป

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับ

ฟังก์ชันความเหมาะสมใหม่ที่เราจะพิจารณากันนี้เรียกว่า *ค่าความเหมาะสมแบบลำดับ (rank fitness)* เป็นวิธีที่ใช้ควบคุมการเลือกโครโมโซมโดยไม่สนใจคุณภาพของโครโมโซมว่ามีค่าเท่าไร จะเพียงแค่จัดลำดับเรียงโครโมโซมตามคุณภาพที่มีค่าสูงสุดจนถึงต่ำสุด จากนั้นกำหนดให้ p ค่าคงที่ค่าหนึ่งเป็นความน่าจะเป็นที่โครโมโซมลำดับที่ 1 จะถูกเลือก และเป็นความน่าจะเป็นที่โครโมโซมลำดับที่ 2 จะถูกเลือกเมื่อลำดับที่ 1 ไม่ถูกเลือก และเป็นความน่าจะเป็นที่ลำดับที่ 3 จะถูกเลือกเมื่อลำดับที่ 1 และ 2 ไม่ถูกเลือก เป็นเช่นนี้ไปจนกระทั่งถึงลำดับสุดท้ายซึ่งจะถูกเลือกเมื่อลำดับก่อนหน้านั้นไม่ถูกเลือกเลย

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ตัวอย่างเช่นสมมติว่า $p=2/3$ และโครโมโซมที่เราสนใจอยู่คือ 1-4, 3-1, 1-2, 1-1 และ 7-5 (ในกรณีของภูเขามีสุนัขน้ำล่อม) จะได้ค่าความเหมาะสมของโครโมโซมดังตารางที่ 6-3 ซึ่งเปรียบเทียบค่าความเหมาะสมแบบลำดับกับค่าความเหมาะสมมาตรฐาน

ตารางที่ 6-3 เปรียบเทียบค่าความเหมาะสมแบบลำดับกับค่าความเหมาะสมมาตรฐาน

โครโมโซม	คุณภาพ	ลำดับ	ค่าความเหมาะสมมาตรฐาน	ค่าความเหมาะสมแบบลำดับ
1-4	4	1	0.40	0.667
1-3	3	2	0.30	0.222
1-2	2	3	0.20	0.074
1-1	1	4	0.10	0.025
7-5	0	5	0.00	0.012

ดังแสดงในตารางที่ 6-3 ค่าความเหมาะสมแบบลำดับของโครโมโซม 1-4 เท่ากับ $p = 2/3$ (ประมาณ 0.667) ส่วนโครโมโซม 1-3 มีความน่าจะเป็นเท่ากับ $p(1-p)$ (ความน่าจะเป็นที่ตัวเองจะถูกเลือกเมื่อโครโมโซมลำดับที่ 1 ไม่ถูกเลือก) ซึ่งมีค่าประมาณ 0.222 ส่วนลำดับที่ 3 จะถูกเลือกเมื่อเส้นที่ 1 และ 2 ไม่ถูกเลือกด้วยความน่าจะเป็นเท่ากับ $p(1-p)(1-p) \approx 0.074$ ส่วนเส้นที่ 4 ก็เท่ากับ $p(1-p)(1-p)(1-p) \approx 0.025$ และเส้นสุดท้ายมีความน่าจะเป็นเท่ากับ $1 - (0.667+0.222+0.074+0.025+0.012) = 0.012$

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

จากผลการทดลอง 1,000 ครั้งโดยใช้ค่าความเหมาะสมแบบลำดับและจำลองการคัดเลือกโดยธรรมชาติเหมือนเดิมทุกประการ พบว่าส่วนผสมที่ดีที่สุดถูกผลิตในรุ่นที่ 75 โดยเฉลี่ยเร็วขึ้นกว่าเดิม (ส่วนผสมดีที่สุดถูกผลิตในรุ่นที่ 155) ประมาณ 2 เท่า ซึ่งแสดงให้เห็นว่าค่าความเหมาะสมแบบลำดับดีกว่าค่าความเหมาะสมมาตรฐาน และจากการใช้ค่าความเหมาะสมแบบลำดับนี้ทำให้โครโมโซมที่อยู่ตรงกลางในคู่สามารถอยู่รอดถึงรุ่นถัดไปและวิวัฒนาการเป็นโครโมโซมที่อยู่ภายในซึ่งมีคุณภาพสูงต่อไปได้ อย่างไรก็ตามแม้ว่าค่าความเหมาะสมแบบลำดับจะทำให้เร็วขึ้นกว่าเดิมประมาณ 2 เท่า แต่ยังคงเป็นผลที่ไม่ดีนักดังเช่นที่ได้กล่าวแล้วว่า 75 รุ่นแต่ละรุ่นเราตรวจสอบโครโมโซมมากกว่า 1 เส้น

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

เพิ่มประสิทธิภาพจีเอให้สูงขึ้นโดยความหลากหลาย

หัวข้อนี้แสดงการใช้ความหลากหลาย (diversity) เพื่อเพิ่มประสิทธิภาพของจีเอให้สูงขึ้นอีกซึ่งได้แนวคิดจากการวิวัฒนาการของสิ่งมีชีวิต ที่เรามักพบว่าบ่อยครั้งในธรรมชาติที่สปีชีส์ซึ่งลักษณะแตกต่างไปจากสปีชีส์ที่เหมาะสมกับธรรมชาติสามารถอยู่รอดได้ดี ซึ่งความหลากหลายนี้จะช่วยให้โครโมโซมที่มียีนต่างจากพวกพ้องถูกคัดเลือกได้ง่ายขึ้นการจะนำความต่างเข้าไปช่วยเลือกโครโมโซมนั้น อย่างแรกที่ต้องทำก็คือนิยามความต่างในรูปที่วัดได้ ในที่นี้เราจะวัดความต่างของโครโมโซมเส้นหนึ่งๆ โดยคำนวณค่าของ “ผลรวมของ 1/ระยะห่างกำลังสองระหว่างโครโมโซมนั้นกับโครโมโซมอื่นที่ถูกเลือกแล้วว่าให้อยู่รอดในรุ่นถัดไป” เนื่องจากเราต้องการโครโมโซมเส้นที่ต่างจากโครโมโซมที่เหมาะสมกับธรรมชาติ ดังนั้นการวัดความต่างหรือความหลากหลายจึงเทียบกับโครโมโซมเส้นที่เหมาะสมกับธรรมชาติ ส่วนระยะห่างหมายถึงระยะห่างตามระยะยุคลิด (Euclidian distance) เช่น 5-2 กับ 1-4 มีระยะห่างกำลังสองเท่ากับ $(5-1)^2 + (2-4)^2 = 20$ เป็นต้น

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

พิจารณาโครโมโซม 5-1, 1-4, 3-1, 1-2, 1-1 และ 7-5 โครโมโซมที่มีคุณภาพสูงสุดคือ 5-1 (ซึ่งเราจะเลือกเลยให้อยู่ในรุ่นถัดไปเป็นเส้นแรก) ตารางที่ 6-4 ด้านล่างแสดงลำดับของ 5 เส้นที่เหลือโดยเรียงตามคุณภาพและผลรวม $1/\text{ระยะห่างกำลังสอง}$ จาก 5-1

ตารางที่ 6-4 ลำดับของโครโมโซมเรียงตามลำดับความหลากหลายและลำดับคุณภาพ

โครโมโซม	คุณภาพ	$1/d^2$	ลำดับความ หลากหลาย	ลำดับคุณภาพ
1-4	4	0.040	1	1
3-1	3	0.250	5	2
1-2	2	0.059	3	3
1-1	1	0.062	4	4
7-5	0	0.050	2	5

5-1 มีค่าเท่ากับ $1/((5-1)^2+(1-4)^2) = 0.040$ เป็นต้น จากตารางจะพบว่าโครโมโซม 7-5 ซึ่งมีคุณภาพเป็น 0 และจะไม่เคยถูกเลือกเลยโดยค่าความเหมาะสมมาตรฐาน แต่เมื่อคำนวณค่าความเหมาะสมแบบลำดับความหลากหลายจะอยู่ในลำดับที่ 2 ซึ่งในกรณีนี้เมื่อดูจากรูปที่ 6-5 จะเห็นว่า 7-5 เป็นโครโมโซมที่ดีเส้นหนึ่งและมีโอกาสกลายพันธุ์เข้าสู่บริเวณด้านในของคูน้าเพื่อเป็นคำตอบต่อไป

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

เมื่อเราได้ลำดับความหลากหลายแล้ว เราจำเป็นต้องนำลำดับนี้
ผนวกเข้าไปใช้ร่วมกับค่าความเหมาะสมเดิม เราไม่อาจใช้ลำดับความหลากหลาย
อย่างเดียวได้เพราะเป็นแค่ปัจจัยหนึ่งในการเลือกโครโมโซม ลำดับคุณภาพเดิม
ซึ่งค่อนข้างดีอยู่แล้วก็ไม่อาจตัดทิ้งได้ ดังนั้นวิธีผนวกลำดับความหลากหลายเข้า
ใช้ร่วมกับลำดับคุณภาพสามารถทำได้โดยนำลำดับทั้งสองบวกกันแล้วจัด
เรียงลำดับใหม่อีกครั้ง เราเรียกลำดับที่ได้ใหม่นี้ว่าลำดับรวม (*combined rank*)
เมื่อได้ลำดับรวมซึ่งคิดทั้งคุณภาพและความหลากหลายแล้ว การเลือกกระทำ
ได้เหมือนเดิมโดยกำหนดความน่าจะเป็นของลำดับแรกเป็น $p = 2/3$ (ดูตาราง
ที่ 6-5)

ตารางที่ 6-5 ลำดับรวมที่พิจารณาทั้งคุณภาพและความหลากหลาย

โครโมโซม	ผลรวมของลำดับ คุณภาพและลำดับ ความหลากหลาย	ลำดับผลรวม	ค่าความเหมาะสม
1-4	2	1	0.667
3-1	7	4	0.025
1-2	6	2	0.222
1-1	8	5	0.012
7-5	7	3	0.074

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ลำดับผลรวมในตารางได้จากการเรียงลำดับผลในสดมภ์ที่สองใหม่ ในกรณีที่มีค่าเท่ากันอย่างเช่น 3-1 กับ 7-5 มีค่าเท่ากันเท่ากับ 7 ก็ใช้การสุ่มเลือก ในที่นี้ 7-5 ถูกสุ่มให้มีลำดับผลรวมเป็นลำดับสาม จากตารางสมมติว่าเราเลือกโครโมโซมตามค่าความเหมาะสมได้เป็น 1-4 และเป็นเส้นที่สองต่อจาก 5-1 หลังจากนั้นเราจะเลือกเส้นที่ 3 ในครั้งนี้เราต้องคำนวณหา $1/\text{ระยะห่างกำลังสอง}$ โดยคิดทั้ง 5-1 และ 1-4 (ดูตารางถัดไป)

ตารางที่ 6-6 การเลือกโครโมโซมเส้นที่ 3 ต่อจาก 5-1 และ 1-4

โครโมโซม	$\sum \frac{1}{d_i^2}$	ลำดับความ หลากหลาย	ลำดับ คุณภาพ	ลำดับรวม	ค่า ความเหมาะสม
3-1	0.327	4	1	4	0.037
1-2	0.309	3	2	3	0.074
1-1	0.173	2	3	2	0.222
7-5	0.077	1	4	1	0.667

ตัวอย่างการคำนวณค่าของ $\sum \frac{1}{d_i^2}$ อย่างเช่นในกรณีของโครโมโซม 3-1 จะได้ค่าเป็น

$$\frac{1}{(5-3)^2 + (1-1)^2} + \frac{1}{(1-3)^2 + (4-1)^2} = 0.327$$

เป็นต้น สมมติว่าโครโมโซมที่ถูกเลือกตามค่าความ

เหมาะสมเส้นต่อไปคือ 7-5 และโครโมโซมเส้นสุดท้ายเราก็สามารถทำได้ในลักษณะเดียวกัน และเลือกได้เป็น 1-1 ดังแสดงตารางที่ 6-7 ต่อไปนี้

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ตารางที่ 6-7 การเลือกโครโมโซมเส้นที่ 3 ต่อจาก 5-1, 1-4 และ 7-5

โครโมโซม	$\sum \frac{1}{d_i^2}$	ลำดับความ หลากหลาย	ลำดับ คุณภาพ	ลำดับรวม	ค่า ความเหมาะสม
3-1	0.358	3	1	3	0.111
1-2	0.331	2	2	2	0.222
1-1	0.190	1	3	1	0.667

ค่าความเหมาะสมที่คำนวณตามลำดับรวมมีความแตกต่างจากค่าความเหมาะสมมาตรฐานที่โครโมโซม 7-5 ซึ่งเป็นโครโมโซมที่ดีเส้นหนึ่ง และไม่เคยถูกเลือกเลยด้วยค่าความเหมาะสมมาตรฐาน แต่สามารถจะถูกเลือกได้ด้วยค่าความเหมาะสมตัวใหม่นี้จากการทดลอง 1,000 ครั้งโดยใช้ลำดับรวมด้วยค่า $p = 2/3$ เริ่มจากโครโมโซม 1-1คำตอบที่ดีที่สุดถูกผลิตได้ในรุ่นที่ 15 โดยเฉลี่ย!!! เร็วกว่าลำดับคุณภาพถึง 5 เท่านอกจากนั้นค่าความเหมาะสมแบบลำดับรวมนี้ไม่ได้ถูกพัฒนาขึ้นโดยเฉพาะสำหรับแก้ปัญหาภูเขาหิมะมีคูน้ำล้อมอย่างเดียวนั้นยังสามารถทำงานได้ดีสำหรับปัญหาภูเขาเรียบด้วย ซึ่งดูสรุปการเปรียบเทียบค่าความเหมาะสมได้ในตารางที่ 6-8 ด้านล่างนี้ (ค่าในตารางได้จากการใช้การกลายพันธุ์และการไขว้เปลี่ยนเหมือนกันหมด)

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ตารางที่ 6–8 เปรียบเทียบค่าความเหมาะสม 3 วิธี: มาตรฐาน ลำดับคุณภาพ และลำดับรวม

ฟังก์ชัน	ค่าความเหมาะสม	ค่าความเหมาะสมแบบ	ค่าความเหมาะสมแบบ
	มาตรฐาน	ลำดับคุณภาพ	ลำดับรวม
ภูเขาเรียบ	14	12	12
ภูเขามีสุน้ำล้อม	155	75	15

ในจำนวนการทดลอง 1,000 ครั้งโดยใช้ลำดับรวมนั้น ครั้งที่ดีที่สุดโครโมโซม 5-5 ถูกผลิตในรุ่นที่ 7 ดังแสดงในตารางที่ 6–9 ต่อไปนี้

6.1.5 ปรับปรุงจีเอดด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ตารางที่ 6-9 ผลการทดลองที่ดีที่สุดที่ผลิตโครโมโซมดีที่สุดได้ในรุ่นที่ 7 โดยลำดับรวม

รุ่นที่ 0:		• 1-1 กลายพันธุ์เป็น 2-1		
โครโมโซม	คุณภาพ			
1-1	1			
รุ่นที่ 1:		• การกลายพันธุ์ผลิตได้ 3-1 ส่วนการไขว้เปลี่ยนไม่ได้ลูกตัวใหม่เพราะยีนตัวที่สองเหมือนกัน		
โครโมโซม	คุณภาพ			
2-1	2			
1-1	1			
รุ่นที่ 2:		• การกลายพันธุ์ผลิตได้ 4-1 และ 2-2 ส่วนการไขว้เปลี่ยนยังคงไม่เกิดผล		
โครโมโซม	คุณภาพ			
3-1	3			
2-1	2			
1-1	1			
รุ่นที่ 3:		• การกลายพันธุ์ผลิตได้โครโมโซมใหม่ 3 เส้นคือ 5-1, 1-2, 2-3 ส่วนการไขว้เปลี่ยนของ 2-2 กับ 4-1 ผลิตได้ 2-1 กับ 4-2 การไขว้เปลี่ยนของคู่อื่นซ้ำกับโครโมโซมที่ผลิตได้ก่อนมัน		
โครโมโซม	คุณภาพ			
4-1	4			
3-1	3			
1-1	1			
2-2	0			
			โครโมโซม	คุณภาพ
			5-1	5
			1-2	2
			2-3	0
		2-1	2	
		4-2	0	

รุ่นที่ 4:	
โครโมโซม	คุณภาพ
5-1	5
3-1	4
1-2	2
2-3	0

• การกลายพันธุ์ผลิตได้ 6-1, 3-2, 2-2, 2-4 ส่วนการไขว้เปลี่ยนผลิต 2-1, 1-1, 5-2, 3-2, 5-3

โครโมโซม	คุณภาพ
6-1	4
3-2	0
2-2	0
2-4	0
2-1	2
1-1	1
5-2	0
3-2	0
5-3	0

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

<p>รุ่นที่ 5:</p> <p>โครโมโซม</p>		<p>• ที่จุดนี้เกิดการไขว่เปลี่ยนของ 5-1 กับ 2-4 ได้ 5-4 ซึ่งเป็นโครโมโซมที่ดีในรุ่นหน้า</p>
5-1	5	
3-1	3	
1-2	2	
2-4	0	
<p>รุ่นที่ 6:</p> <p>โครโมโซม</p>		<p>• และในท้ายที่สุด 5-4 กลายพันธุ์เป็น 5-5</p>
5-4	8	
1-4	4	
3-1	3	
1-2	2	
<p>รุ่นที่ 7:</p> <p>โครโมโซม</p>		
5-5	9	
1-4	4	
1-2	2	
5-2	0	

6.1.5 ปรับปรุงจีเอดด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

ด้านล่างนี้แสดงการค้นหาคำตอบโดยจีเอ โดยแสดงเฉพาะโครโมโซมที่ถูกเลือกในแต่ละรุ่น

(0)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(1)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(4)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(5)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(2)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(3)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(6)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

(7)

1	2	3	4	5	4	3	2	1
2	0	0	0	0	0	0	0	2
3	0	0	0	0	0	0	0	3
4	0	0	7	8	7	0	0	4
5	0	0	8	9	8	0	0	5
4	0	0	7	8	7	0	0	4
3	0	0	0	0	0	0	0	3
2	0	0	0	0	0	0	0	2
1	2	3	4	5	4	3	2	1

6.1.5 ปรับปรุงจีเอด้วยฟังก์ชันความเหมาะสมแบบลำดับและการใช้ความหลากหลาย

จากรูปจะเห็นได้ว่าในรุ่นที่ 3 โครโมโซมที่คุณภาพเป็น 0 สามารถถูกเลือกได้โดยค่าความเหมาะสมแบบลำดับรวมและจะเห็นการเคลื่อนที่ของโครโมโซมจากรุ่นที่ 1 ถึง 4 ว่าโครโมโซมค่อยๆ ขยับตัวไปยังจุดสูงสุดเฉพาะที่ซึ่งมีคุณภาพเท่ากับ 5 และจะเห็นการเคลื่อนที่ของโครโมโซมที่มีคุณภาพเท่ากับ 0 ที่ค่อยๆ ขยับออกจากจุดสูงสุดเฉพาะที่ทีละน้อย จนกระทั่งในรุ่นที่ 5 เมื่ออยู่ในตำแหน่งที่เหมาะสมและเกิดการไขว้เปลี่ยนกับจุดสูงสุดเฉพาะที่แล้วสามารถทะลุผ่านค้ำน้ำเข้าไปยังภายในค้ำได้ แล้วเปลี่ยนเป็นจุดสูงสุดในที่สุด จากรูปแสดงการทำงานของจีเอ เราสามารถเห็นได้ว่าการค้นหาโดยทั่วไปมักจะพยายามหลีกเลี่ยงจุดดีสุดเฉพาะที่ แต่การทำงานของจีเอใช้วิธีการที่ต่างไป โดยการผลิตโครโมโซมที่เป็นค่าดีสุดเฉพาะที่จากนั้นจึงใช้ความหลากหลายเพื่อเป็นส่วนประกอบของค่าความเหมาะสมแล้วผลิตโครโมโซมที่อยู่ห่างออกจากค่าดีสุดเฉพาะที่ หากมีโครโมโซมอยู่ในจุดดีสุดเฉพาะที่ทุกจุดแล้ว ก็มีโอกาที่โครโมโซมเหล่านี้จะหาทางไปยังจุดดีสุดวงกว้าง (global optimum) ได้ในที่สุด

6.2 การเรียนรู้โดยการจำ


การเรียนรู้โดยการจำ (rote learning) เป็นการเรียนรู้แบบที่ง่ายที่สุดของกระบวนการเรียนรู้ทั้งหลาย โดยเมื่อพบความรู้หรือข้อเท็จจริงใหม่ๆ ก็เก็บไว้ในหน่วยความจำ เวลาที่ต้องการใช้ก็เพียงแค่อ้างความรู้นี้มาใช้ ถ้าเรามองว่าระบบปัญญาประดิษฐ์มีหน้าที่รับอินพุต (X_1, \dots, X_n) แล้วทำการหาเอาต์พุต $(Y_1, \dots, Y_n) = f(X_1, \dots, X_n)$ โดยที่ f เป็นฟังก์ชันใดๆ ในการคำนวณเอาต์พุตหรืออาจเป็นการอนุมานหาค่าเอาต์พุตจากอินพุตก็ได้ ดังนั้นการเรียนรู้โดยการจำก็คือการเก็บคู่ลำดับ $[(X_1, \dots, X_n), (Y_1, \dots, Y_n)]$ ไว้ในหน่วยความจำ หลังจากนั้นเมื่อเราต้องการหา $f(X_1, \dots, X_n)$ ใหม่ก็ทำโดยการดึง (Y_1, \dots, Y_m) จากคู่ลำดับนี้เท่านั้นโดยไม่ต้องคำนวณหรืออนุมานซ้ำอีกครั้งซึ่งโดยมากจะเสียต้นทุนและเวลาสูง จะเห็นได้ว่าแนวคิดนี้ง่ายแต่ไม่ได้หมายความว่า การเรียนรู้จะไม่มีประสิทธิภาพ มนุษย์เราก็เรียนรู้โดยการจำด้วยเช่นกันหรือซอฟต์แวร์ในปัจจุบันหลายตัวก็สามารถจำชื่อไฟล์ที่ผู้ใช้ใช้งานครั้งล่าสุดได้และช่วยให้การเปิดไฟล์ทำได้ง่ายขึ้นมีประโยชน์ในการใช้งานจริงในการเรียนรู้โดยการจำนี้ สิ่งที่เราต้องพิจารณาเพิ่มเติมได้แก่ (1) การจัดการหน่วยความจำ (memory organization) ที่ต้องมีประสิทธิภาพสามารถดึงความรู้ที่เก็บไว้ได้อย่างรวดเร็ว (2) ความเสถียรภาพของสภาพแวดล้อมต้องไม่เปลี่ยนแปลงอย่างรวดเร็วจนส่งผลให้ความรู้ที่เก็บไว้ไม่ถูกต้องเมื่อเวลาเปลี่ยนไป (3) ความสมดุลระหว่างการคำนวณใหม่กับการจัดเก็บ ต้องมีสมดุลที่ดีไม่จัดเก็บมากเกินไปจนทำให้การค้นคืนคู่ลำดับที่จัดเก็บมีประสิทธิภาพต่ำ ส่งผลให้ประสิทธิภาพโดยรวมลดลงเพราะเสียเวลามากไปเพื่อตรวจสอบว่าเป็นความรู้ที่อยู่ในหน่วยความจำหรือไม่ ดังนั้นควรเลือกจำเฉพาะความรู้ที่ใช้บ่อย

6.2 การเรียนรู้โดยการจำ

การเรียนรู้โดยการจำ (*rote learning*) เป็นการเรียนรู้แบบที่ง่ายที่สุดของกระบวนการเรียนรู้ทั้งหลาย โดยเมื่อพบความรู้หรือข้อเท็จจริงใหม่ๆ ก็เก็บไว้ในหน่วยความจำ เวลาที่ต้องการใช้ก็เพียงแค่อ้างความรู้ขึ้นมาใช้ ถ้าเรามองว่าระบบปัญญาประดิษฐ์มีหน้าที่รับอินพุต (X_1, \dots, X_n) แล้วทำการหาเอาต์พุต $(Y_1, \dots, Y_n) = f(X_1, \dots, X_n)$ โดยที่ f เป็นฟังก์ชันใดๆ ในการคำนวณเอาต์พุตหรืออาจเป็นการอนุมานหาค่าเอาต์พุตจากอินพุตก็ได้ ดังนั้นการเรียนรู้โดยการจำก็คือการเก็บคู่ลำดับ $[(X_1, \dots, X_n), (Y_1, \dots, Y_n)]$ ไว้ในหน่วยความจำ หลังจากนั้นเมื่อเราต้องการหา $f(X_1, \dots, X_n)$ ใหม่ก็ทำโดยการดึง (Y_1, \dots, Y_n) จากคู่ลำดับนี้เท่านั้นโดยไม่ต้องคำนวณหรืออนุมานซ้ำอีกครั้งซึ่งโดยมากจะเสียต้นทุนและเวลาสูงจะเห็นได้ว่าแนวคิดนี้ง่ายแต่ไม่ได้หมายความว่า การเรียนรู้จะไม่มีประสิทธิภาพ มนุษย์เราก็เรียนรู้โดยการจำด้วยเช่นกันหรือซอฟต์แวร์ในปัจจุบันหลายตัวก็สามารถจำชื่อไฟล์ที่ผู้ใช้ใช้งานครั้งล่าสุดได้และช่วยให้การเปิดไฟล์ทำได้ง่ายขึ้นมีประโยชน์ในการใช้งานจริงในการเรียนรู้โดยการจำนี้ สิ่งที่เราต้องพิจารณาเพิ่มเติมได้แก่ (1) การจัดการหน่วยความจำ (*memory organization*) ที่ต้องมีประสิทธิภาพสามารถดึงความรู้ที่เก็บไว้ได้อย่างรวดเร็ว (2) ความเสถียรภาพของสภาพแวดล้อมต้องไม่เปลี่ยนแปลงอย่างรวดเร็วจนส่งผลให้ความรู้ที่เก็บไว้ไม่ถูกต้องเมื่อเวลาเปลี่ยนไป (3) ความสมดุลระหว่างการคำนวณใหม่กับการจัดเก็บ ต้องมีสมดุลที่ดีไม่จัดเก็บมากเกินไปจนทำให้การค้นคืนคู่ลำดับที่จัดเก็บมีประสิทธิภาพต่ำ ส่งผลให้ประสิทธิภาพโดยรวมลดลงเพราะเสียเวลามากไปเพื่อตรวจสอบว่าเป็นความรู้ที่อยู่ในหน่วยความจำหรือไม่ ดังนั้นควรเลือกจำเฉพาะความรู้ที่ใช้บ่อย

6.2 การเรียนรู้ โดยการจำ

เป็นเกมคล้ายกับหมากฮอสไทย แต่มีจำนวนเบี้ยแต่ละฝ่าย 12 ตัวที่สร้างได้ ลักษณะของอัลกอริทึมประเภทนี้เป็นการค้นหาแบบหนึ่งซึ่งมีผู้เล่นสองฝ่ายคือโปรแกรมกับฝ่ายตรงข้าม อัลกอริทึมที่นิยมใช้ในเกมนี้อีกคือ การค้นหาต้นไม้เกมน้อยสุดมากที่สุด (*minimax game-tree search*) ดังแสดงในรูปที่ 6-7



รูปที่ 6-7 ต้นไม้เกมน้อยสุดมากที่สุด

6.2 การเรียนรู้โดยการจำ

การค้นหาค่าต้นไม้เกมน้อยสุดมากที่สุดแตกต่างจากการค้นหาในปริภูมิสถานะทั่วไป ที่ต้นไม้เกมมีผู้สร้างสถานะในต้นไม้ 2 คนคือ *ผู้เล่นฝ่ายทำมากที่สุด (maximizing player)* โดยทั่วไปคือโปรแกรมและผู้เล่นฝ่ายทำน้อยสุด (*minimizing player*) หรือฝ่ายตรงข้าม ในรูปสถานะ A เป็นสถานะเริ่มต้น (แทนการจัดเรียงตัวหมากบนกระดานหนึ่งๆ) สมมติว่า A มีสถานะลูกคือ B, C และ D การสร้างสถานะลูกทำโดยการเดินหมากทุกรูปแบบที่เป็นไปได้ และผู้เล่นที่ทำหน้าที่สร้างสถานะลูกคือผู้เล่นฝ่ายทำมากที่สุด จากสถานะ B, C และ D ผู้เล่นฝ่ายตรงข้ามหรือผู้เล่นฝ่ายทำน้อยสุดจะสร้างสถานะลูกทั้งหมดของ B, C และ D ได้เป็น E, F,..., K ในทางปฏิบัติโปรแกรมจะทำหน้าที่คำนวณสถานะทั้งหมดด้วยตัวเอง

6.2 การเรียนรู้โดยการจำ

ตัวเลขที่สถานะแต่ละตัวแสดงค่าความดีของสถานะนั้นๆ ค่าเหล่านี้เป็นค่าของผู้เล่นฝ่ายทำมากที่สุด ถ้าค่ามากแสดงว่าโอกาสชนะของผู้เล่นฝ่ายทำมากที่สุดมีมาก แต่ถ้าน้อยแสดงว่าผู้เล่นฝ่ายทำมากที่สุดมีโอกาสชนะน้อย ดังนั้นหน้าที่ของผู้เล่นฝ่ายทำมากที่สุดคือพยายามทำให้ตัวเลขเหล่านี้มีค่ามากโดยเลือกเส้นทางที่จะทำให้ค่าสูงสุด ตัวเลขเหล่านี้แบ่งเป็น 2 จำพวกคือ (1) ตัวเลขที่สถานะปลายต้นไม้ (ใบ) (9, -6, 0, ..., -3) และ (2) ตัวเลขที่สถานะเริ่มต้นและสถานะภายในต้นไม้ เราเรียกว่าตัวเลขที่ปลายต้นไม้ว่า *ค่าประเมินสถิต (static evaluation value)* ค่าเหล่านี้เป็นค่าฮิวริสติกที่วัดค่าความดีของการจัดเรียงตัวหมากบนกระดานว่าโอกาสชนะของผู้เล่นฝ่ายทำมากที่สุดมีมากแค่ไหน ค่าประเมินสถิตนี้วัดจากจำนวนเบี้ยของเราว่ามากกว่าของฝ่ายตรงข้ามมากน้อยแค่ไหน จำนวนขุน (king) ของเรามีมากกว่าฝ่ายตรงข้ามแค่ไหน ตำแหน่งของตัวหมากของเราอยู่ในตำแหน่งที่ได้เปรียบฝ่ายตรงข้ามมากน้อยแค่ไหน เป็นต้น

6.2 การเรียนรู้โดยการจำ


ตัวเลขที่สถานะเริ่มต้นและสถานะภายในต้นไม้เรียกว่า *ค่าแบ็คอัป (backup value)* เป็นค่าที่ได้จากการส่งค่าประเมินสถิติจากด้านล่างย้อนกลับขึ้นไปทางด้านบนที่ระดับ ในการคำนวณค่าแบ็คอัปนั้นจะพิจารณาเป็น 2 กรณีคือ (1) กรณีที่ผู้เล่นฝ่ายทำน้อยสุดเป็นผู้สร้างสถานะลูก ค่าแบ็คอัปของสถานะพ่อแม่จะเป็นค่าต่ำสุดในจำนวนค่าทั้งหมดของสถานะลูก (2) กรณีที่ผู้เล่นฝ่ายทำมากที่สุดเป็นผู้สร้างสถานะลูก ค่าแบ็คอัปของสถานะพ่อแม่จะเป็นค่าสูงสุดในจำนวนค่าทั้งหมดของลูก เช่นกรณีการคำนวณค่าแบ็คอัปของสถานะ B ซึ่งเป็นกรณีที่ (1) นั้น ค่าของ B จะเท่ากับ $\min\{9, -6, 0\} = -6$ กรณีการคำนวณค่าแบ็คอัปของสถานะ A ซึ่งเป็นกรณีที่ (2) นั้น ค่าของ A จะเท่ากับ $\max\{-6, -2, -4\} = -2$ เนื่องจากค่าในต้นไม้เป็นค่าที่แสดงโอกาสที่ผู้เล่นฝ่ายทำมากที่สุดมีโอกาสชนะ ดังนั้นผู้เล่นฝ่ายทำมากที่สุดจึงต้องพยายามทำให้ค่าที่ได้มีค่ามากที่สุด ส่วนผู้เล่นฝ่ายทำน้อยสุดมีหน้าที่สกัดกั้นไม่ให้ผู้เล่นฝ่ายทำมากที่สุดมีโอกาสชนะ ดังนั้นจึงต้องพยายามทำให้ค่าที่ได้มีค่าน้อยสุด และเป็นที่มาของชื่ออัลกอริทึมนี้

6.2 การเรียนรู้โดยการจำ

จากตัวอย่างในรูปแบบด้านบน เมื่อผู้เล่นฝ่ายทำมากที่สุดจะเลือกตาเดินก็ควรเลือกเส้นทางตามค่าแบ็คอัฟ กล่าวคือเมื่ออยู่ที่สถานะ A ควรเลือกตาเดินไปยังสถานะ C ซึ่งคาดว่าหลังจากนั้นฝ่ายผู้เล่นทำน้อยสุดน่าจะเดินไปยัง I สังเกตว่าในจำนวนสถานะทั้งหมดค่าที่มากที่สุดคือ 9 ของสถานะ E แต่อย่างไรก็ดีผู้เล่นฝ่ายทำมากที่สุดไม่มีโอกาสที่จะได้ค่าแบ็คอัฟเป็น 9 ได้ แม้ว่าตนเองจะเดินจากสถานะ A ไปยัง B เพราะว่ามีผู้เล่นฝ่ายทำน้อยสุดพยายามขัดขวางให้ค่าที่ได้มีค่าน้อยสุด ถ้าผู้เล่นฝ่ายทำมากที่สุดเดินมายังสถานะ B ผู้เล่นฝ่ายทำน้อยสุดก็จะเดินไปยัง F ทำให้โอกาสชนะของผู้เล่นฝ่ายทำมากที่สุดเหลือ -6 (อย่าลืมว่าตัวเลขในต้นไม้เป็นค่าที่แสดงโอกาสชนะของผู้เล่นฝ่ายทำมากที่สุดเท่านั้น) ในรูปที่ 6-7 นั้นแสดงการค้นหาที่มองล่วงหน้า 2 ก้าวเดิน (2 moves look-ahead) ค่าแบ็คอัฟที่คำนวณได้ของสถานะ A นี้จะไม่เท่ากับค่าประเมินสถิติของ A เนื่องจากว่าถ้าเราวัดค่าประเมินสถิติก็คือการคำนวณค่าฮิวริสติกของ A โดยตรงโดยดูที่ตัวหมาก ณ สถานะ A แต่ค่าแบ็คอัฟของ A คือการมองล่วงหน้าต่อจากนี้อีก 2 ก้าวเดินในทุกเส้นทางแล้วคำนวณเส้นทางที่น่าจะเป็นที่สุด (เส้นทางที่ผู้เล่นทั้งสองเลือกตาเดินได้ดีที่สุด) แล้วส่งค่าประเมินสถิติที่ปลายต้นไม้ย้อนกลับมาที่สถานะ A ดังนั้นค่าแบ็คอัฟจะมีความถูกต้องแม่นยำมากกว่าค่าประเมินสถิติโดยตรงของ A

6.2 การเรียนรู้โดยการจำ


ค่าเบ็คอัพที่ได้จากการมองล่วงหน้า 2 ก้าวเดินมีความแม่นยำมากกว่าค่าประเมินสถิติในทำนองเดียวกันค่าเบ็คอัพที่ได้จากการมองล่วงหน้า 3 ก้าวเดินก็ย่อมมีความแม่นยำมากกว่ามองล่วงหน้า 2 ก้าวเดิน ยิ่งเราเพิ่มการมองล่วงหน้าได้ลึกเท่าไร ความแม่นยำของค่าเบ็คอัพที่คำนวณได้ก็ยิ่งสูงขึ้นเท่านั้น และถ้าเราสามารถมองล่วงหน้าจนถึงสถานะที่จบเกม ค่าที่ได้ก็จะถูกต้องสมบูรณ์ อย่างไรก็ตามในทางปฏิบัติเราไม่สามารถมองล่วงหน้าจนจบเกมได้เนื่องจากข้อจำกัดด้านเวลา โปรแกรมจะเดินตัวหมากรุกได้เก่งถ้าสามารถมองล่วงหน้าได้ลึกมากๆ



รูปที่ 6-8 ตัวอย่างต้นไม้เกมในกรณีมองล่วงหน้า 3 ก้าวเดิน

6.2 การเรียนรู้โดยการจำ

วงหน้า เพราะยิ่งมองลวงหน้าได้ลึกลงค่าแบ็กอัปก็จะต้องมากขึ้น และดังเช่นที่กล่าวแล้วว่าจากข้อจำกัดเรื่องเวลาที่โปรแกรมสามารถใช้ได้ การกระจายสถานะเพิ่มขึ้นจึงไม่สามารถทำได้ แต่อย่างไรก็ดีโดยการใช้การเรียนรู้โดยการจำจะสามารถเพิ่มความสามารถของโปรแกรมให้เสมือนกับว่าโปรแกรมมองลวงหน้าได้มากขึ้น เราใช้การเรียนรู้โดยการจำเพื่อที่จะเก็บคู่ลำดับค่าแบ็กอัปของสถานะเริ่มต้น เช่นในรูปที่ 6-8 หลังจากที่เราได้ค้นหาลวงหน้า 3 ก้าวเดินและพบว่าค่าแบ็กอัปของ A เท่ากับ 8 แล้ว เราจะจำคู่ลำดับ $[A, 8]$ ไว้ในหน่วยความจำ เมื่อ A ถูกพบอีกครั้งที่ปลายของต้นไม้เกมต้นอื่นในการเล่นครั้งใหม่ เราจะไม่ต้องการหาค่าประเมินสถิติของ A แต่จะนำค่าแบ็กอัปของ A มาใช้แทน การนำเอาค่าแบ็กอัปมาใช้แทนที่จะคำนวณค่าประเมินสถิตินั้น นอกจากจะมีข้อดีที่รวดเร็วยิ่งขึ้นเนื่องจากการคำนวณค่าประเมินสถิติจะใช้เวลานานกว่าแล้ว ยังส่งผลดีอีกประการที่สำคัญดังแสดงรูปที่ 6-9 ซึ่งแสดงต้นไม้เกมต้นหนึ่งที่มี E เป็นสถานะแรกและมีสถานะที่ปลายต้นไม้สถานะหนึ่งคือ A



รูปที่ 6-9 การเรียนรู้โดยการจำเพิ่มประสิทธิภาพของการค้นหา

6.2 การเรียนรู้โดยการจำ

ด้วยการใช้ค่าเบ็คอัฟของ A แทนที่จะใช้ค่าประเมินสถิติก็เสมือนกับว่าที่จุด A นี้ได้รวมการค้นหาอีก 3 ก้าวเดินล่วงหน้าเอาไว้ด้วย ดังนั้นที่ E แม้ว่าด้วยข้อจำกัดทางเวลาทำให้เราค้นหาได้เพียง 3 ก้าวเดินล่วงหน้า แต่ก็เสมือนกับว่าในเส้นทางที่รวม A จะเป็นการค้นหาล่วงหน้าถึง 6 ก้าวเดินล่วงหน้า และด้วยการจำคู่ลำดับระหว่างสถานะกับค่าเบ็คอัฟไว้จำนวนมากก็จะทำให้การค้นหาเพิ่มจำนวนก้าวเดินล่วงหน้าเป็น 3, 6, 9, ... ตามลำดับ ซึ่งส่งผลให้ประสิทธิภาพของโปรแกรมเพิ่มขึ้น

6.2 การเรียนรู้โดยการจำ

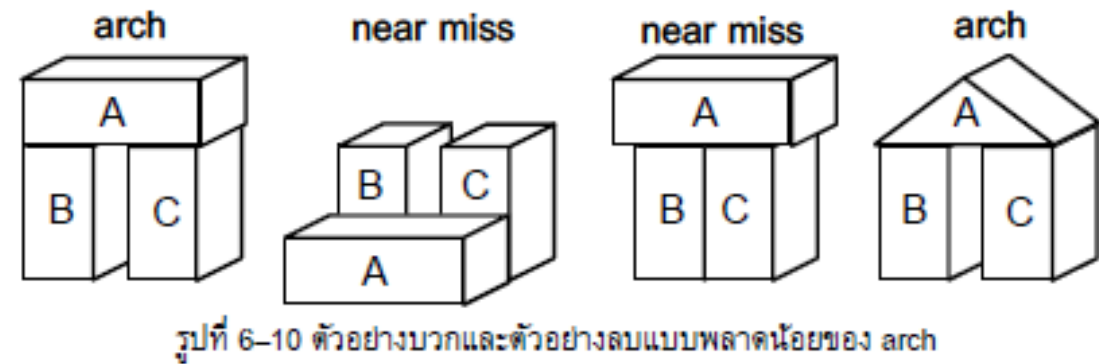
ตัวอย่างนี้แสดงให้เห็นการประยุกต์ใช้การเรียนรู้โดยการจำที่ส่งผลให้ประสิทธิภาพของงานที่กระทำดีขึ้นอย่างชัดเจน และโปรแกรมเรียนรู้การเล่นเกมเชกเกอร์ส์นี้ยังมีการจัดการหน่วยความจำอย่างประหยัดโดยจัดเก็บเฉพาะตำแหน่งตัวหมากบนกระดานของผู้เล่นฝ่ายทำมากที่สุดฝ่ายเดียว และเมื่อจะใช้กับผู้เล่นฝ่ายทำน้อยสุดก็สลับตำแหน่งของตัวหมากกลับด้านกันเท่านั้น นอกจากนี้ยังมีการทำดัชนีเพื่อตั้งตำแหน่งตัวหมากบนกระดานให้ได้อย่างรวดเร็วโดยใช้คุณสมบัติของกระดาน เช่นจำนวนตัวหมาก การมีหรือไม่มีขุน เพื่อใช้เป็นดัชนี และยังสามารถจัดการปัญหาความสมดุลง่ายระหว่างการจัดเก็บกับการคำนวณใหม่โดยใช้วิธีที่เรียกว่าการแทนที่ตัวที่ถูกใช้น้อยสุด (least recently used replacement) วิธีนี้พยายามจะไม่จัดเก็บคู่ลำดับให้มากมายเกินไปเพราะจะทำให้การค้นคืนคู่ลำดับใช้เวลาามาก โดยกำหนดจำนวนคู่ลำดับที่จะจำเป็นค่าคงที่ค่าหนึ่ง เช่น 100,000 คู่ลำดับ จากนั้นคู่ลำดับใดที่ถูกใช้น้อยสุด (เมื่อจำไว้แล้วถูกพบในต้นไม้เกมอื่นน้อยสุด) จะถูกลบออกจากหน่วยความจำแล้วแทนที่ด้วยคู่ลำดับใหม่ตัวอื่น วิธีนี้ทำโดยกำหนดอายุให้กับคู่ลำดับแต่ละคู่และทุกครั้ง que คู่ลำดับถูกเรียกมาใช้อายุของมันจะลดลงครึ่งหนึ่ง และทุกครั้งที่มีการจำคู่ลำดับใหม่ อายุของคู่ลำดับอื่นทุกตัวในหน่วยความจำจะถูกบวกเพิ่ม 1 หน่วย จากนั้นตัวที่มีอายุมากที่สุดจะถูกลบออกจากหน่วยความจำ

6.3 การเรียนรู้ โดยการวิเคราะห์ความแตกต่าง

การเรียนรู้โดยการวิเคราะห์ความแตกต่าง (*learning by analyzing differences*) ถูกพัฒนาโดย Winston ในปีค.ศ. 1975 [Winston, 1992] แม้ว่าจะเป็นวิธีการเรียนรู้ที่ค่อนข้างเก่ามาแล้วก็ตาม แต่ว่าแนวคิดต่างๆ สามารถนำไปใช้ในการเรียนรู้แบบใหม่ๆ ได้อย่างดี ในที่นี้จึงยกวิธีการเรียนรู้แบบนี้มาเพื่อศึกษาแนวคิดของการเรียนรู้เชิงอุปนัย การเรียนรู้โดยการวิเคราะห์ความแตกต่างนี้ใช้เรียนรู้มโนทัศน์ทางโครงสร้าง (structural concept) ในโดเมนปัญหาโลกของบล็อก เช่น arch, tent หรือ house เป็นต้น วิธีการเรียนรู้นี้จะวิเคราะห์ความแตกต่างที่ปรากฏในลำดับของตัวอย่างที่ผู้สอนป้อนให้ โดยตัวอย่างสอน (training example) มี 2 ประเภทคือ ตัวอย่างบวก (*positive example*) และตัวอย่างลบ (*negative example*) ตัวอย่างบวกคือตัวอย่างที่ถูกต้องของมโนทัศน์ (concept) ที่สอน เช่นจะสอน house ตัวอย่างบวกก็จะเป็นบ้านหลังที่หนึ่ง บ้านหลังที่สอง เป็นต้น ตัวอย่างลบคือตัวอย่างที่ไม่ถูกต้อง เช่นจะสอน house ตัวอย่างลบก็จะเป็นเต็นท์หลังที่หนึ่ง โรงเรียนหลังที่หนึ่งเหล่านี้เป็นต้น

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง

สำหรับการเรียนรู้โดยการวิเคราะห์ความแตกต่างนี้ ตัวอย่างลบที่ผู้สอนให้จะต้องเป็นตัวอย่างลบแบบที่เรียกว่า *พลาดน้อย (near miss)* กล่าวคือตัวอย่างลบแบบพลาดน้อยนี้จะต่างจากตัวอย่างบวกเพียงเล็กน้อย เช่นจะสอน house ตัวอย่างลบแบบพลาดน้อยก็จะเป็นบ้านที่ขาดประตู หรือบ้านที่ไม่มีหลังคา เป็นต้น การเรียนรู้แบบนี้ผู้สอนจะจัดเตรียมลำดับของตัวอย่างไว้ค่อนข้างดีเพื่อให้โปรแกรมเรียนรู้สามารถวิเคราะห์ความต่างของตัวอย่างบวกกับตัวอย่างลบแบบพลาดน้อย ด้านล่างนี้ยกตัวอย่างการเรียนรู้มอนัทช์ arch ซึ่งมีลำดับของตัวอย่างที่จะสอนดังแสดงในรูปที่ 6-10




รูปที่ 6-10 ตัวอย่างบวกและตัวอย่างลบแบบพลาดน้อยของ arch

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง

ในรูป ‘arch’ และ ‘near miss’ หมายถึงตัวอย่างบวกและตัวอย่างลบแบบพลาตน้อยตามลำดับ จากตัวอย่างที่ให้ทั้งสี่ตัวนี้ โปรแกรมจะเรียนรู้ว่าอะไรคือ arch เมื่อเราดูตัวอย่างข้างต้น เราจะพอเข้าใจได้ว่าตัวอย่างบวกตัวแรกบอกว่า arch คือสิ่งที่ประกอบด้วยอิฐ (brick) แนวตั้ง 2 ก้อนและอิฐแนวนอน 1 ก้อนที่ถูกรองรับด้วยอิฐแนวตั้ง ตัวอย่างที่สองอธิบายสิ่งที่ไม่ใช่ arch ว่าคือสิ่งที่ประกอบด้วยอิฐแนวตั้ง 2 ก้อนและอิฐแนวนอนซึ่งไม่ถูกรองรับด้วยอิฐแนวตั้ง ตัวอย่างที่ 3 และ 4 แสดงตัวอย่างของ arch และสิ่งที่ไม่ใช่ตามลำดับโปรแกรมเรียนรู้นี้ใช้การแทนความรู้เพื่อแสดงมโนทัศน์ในรูปของ *ข่ายงานความหมาย (semantic network)* การแทนความรู้แบบนี้จะประกอบด้วยบัพ (node) และเส้นเชื่อม (link) บัพแสดงวัตถุและเส้นเชื่อมแทนความสัมพันธ์ระหว่างวัตถุในโดเมนนั้น

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง

จากตัวอย่างบวกตัวที่หนึ่ง โปรแกรมจะสร้างคำอธิบายเริ่มต้น (initial description) ของมโนทัศน์ดังรูปที่ 6-11

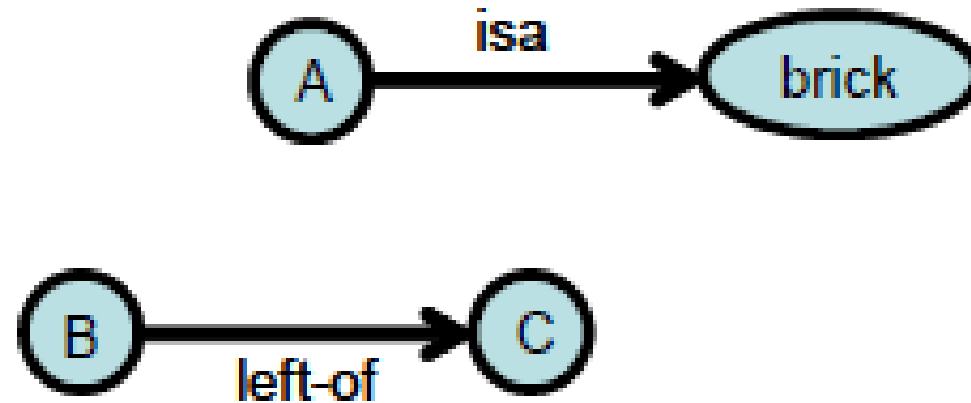


รูปที่ 6-11 คำอธิบายเริ่มต้น

บัพ A มีเส้นเชื่อม isa แสดงความสัมพันธ์ว่า A เป็น brick และเส้นเชื่อมจาก B และ C ไป A คือ support แสดงความสัมพันธ์ว่า B และ C รองรับ A และมีเส้นเชื่อม left-of แสดงว่า B อยู่ด้านซ้ายของ C ส่วนเส้นเชื่อมอื่นๆ ที่ไม่เกี่ยวข้องโดยตรงกับ concept ขอละไว้ในที่นี้ เช่นเส้นเชื่อม isa จาก B ไปยังบัพ brick เป็นต้น

6.3 การเรียนรู้ โดยการใช้การวิเคราะห์ความแตกต่าง

จากตัวอย่างแบบพลาตน้อยตัวที่สอง โปรแกรมสร้างคำอธิบายของตัวอย่างลบได้ดังรูปที่ 6-12




รูปที่ 6-12 คำอธิบายของตัวอย่างตัวที่สอง

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง

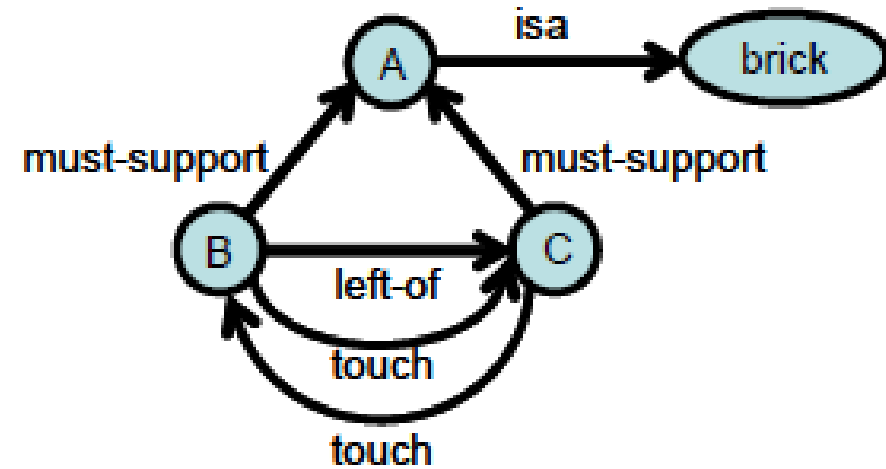
ที่จุดนี้โปรแกรมจะวิเคราะห์หาความแตกต่างของตัวอย่างที่ถูกกับที่ผิดโดยการจับคู่บัพและเส้นเชื่อม และพบว่าเส้นเชื่อม support ซึ่งต่างกันในตัวอย่างทั้งสองจำเป็นสำหรับมโนทัศน์ arch โปรแกรมจึงใส่เงื่อนไขเพิ่มเข้าไปในคำอธิบายในรูปที่ 6-11 โดยใช้เส้นเชื่อมใหม่ชื่อ must-support แทนที่เส้นเชื่อมเดิมดังแสดงในรูปที่ 6-13 เราเรียกคำอธิบายใหม่ที่ได้นี้ว่า โมเดลระหว่างวิวัฒนาการ (*evolving model*) ในกรณีนี้ตัวอย่างลบให้ข้อมูลสำหรับการใช้ฮิวริสติกเส้นเชื่อมจำเป็น (*require-link heuristic*) ที่ใส่เงื่อนไขที่มากขึ้นในเส้นเชื่อมเดิม เราเรียกการทำเช่นนี้ว่าเป็นฮิวริสติกแบบหนึ่งเนื่องจากการคาดคะเนจากเหตุผลของความแตกต่างระหว่างตัวอย่างที่น่าจะเป็น แต่ก็อาจไม่ถูกต้องเสมอไปก็ได้ ในกรณีนี้ตัวอย่างลบแบบพลาตน้อยเป็นตัวอย่างที่ให้ข้อมูลสำหรับ *การแจงจำเพาะของมโนทัศน์* (*specialization of concept*) ซึ่งหมายถึงว่าคำอธิบายของมโนทัศน์จะถูกทำให้แคบลง มีเงื่อนไขมากขึ้น ตรงกับตัวอย่างจำนวนน้อยลง

6.3 การเรียนรู้โดยการใช้ความแตกต่าง



รูปที่ 6-13 โมเดลระหว่างวิวัฒนาการ

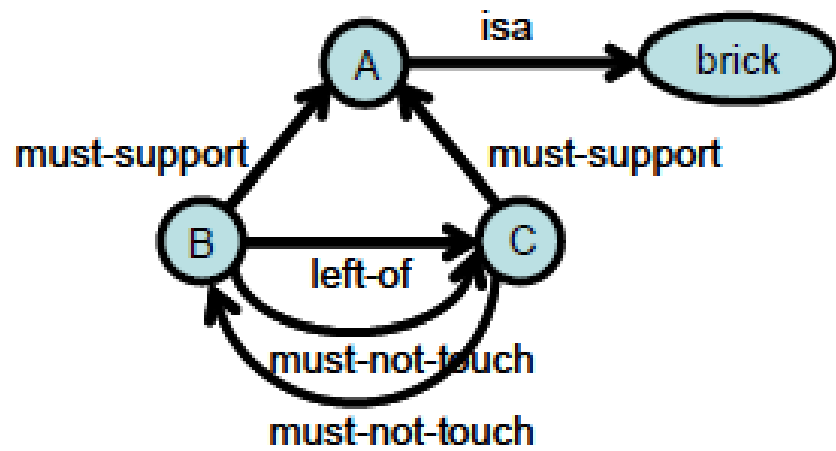
จากตัวอย่างลบตัวที่สาม โปรแกรมสร้างคำอธิบายของตัวอย่างลบได้ดังรูปที่ 6-14



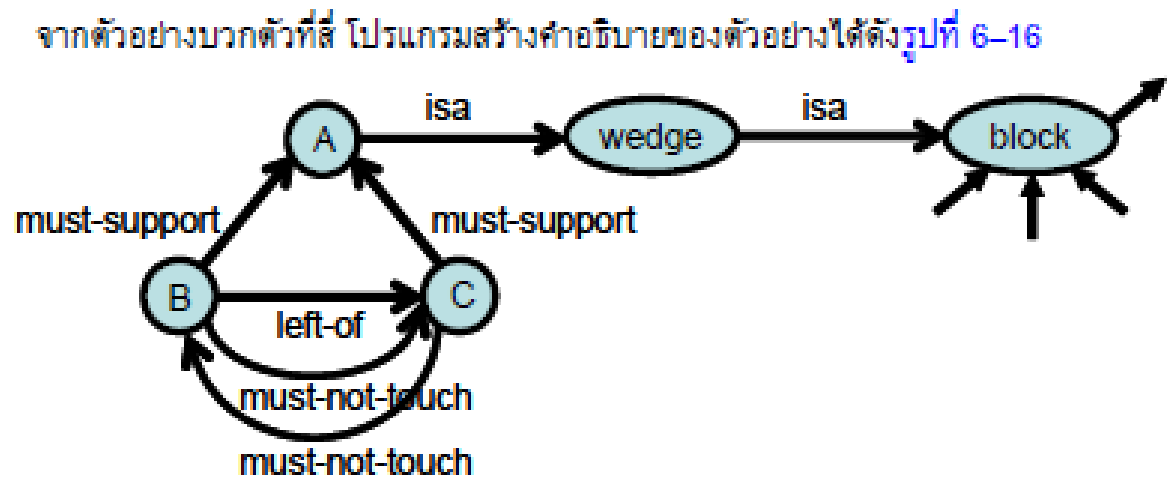
รูปที่ 6-14 คำอธิบายของตัวอย่างลบตัวที่สาม

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง

โปรแกรมหาความแตกต่างระหว่างคำอธิบายของตัวอย่างที่สามกับโมเดล พบว่ามีเส้นเชื่อม touch อยู่ในตัวอย่างลบซึ่งไม่มีในโมเดล ดังนั้นโปรแกรมจึงเพิ่มเส้นเชื่อมเข้าไปในโมเดลและปรับโมเดลใหม่ได้ดังรูปที่ 6-15 ในกรณีนี้ตัวอย่างลบให้ข้อมูลสำหรับฮิวริสติกเส้นเชื่อมห้าม (*forbid-link heuristic*)




รูปที่ 6-15 โมเดลหลังรับตัวอย่างตัวที่สาม



รูปที่ 6-16 คำอธิบายของตัวอย่างบวกตัวที่สี่

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง

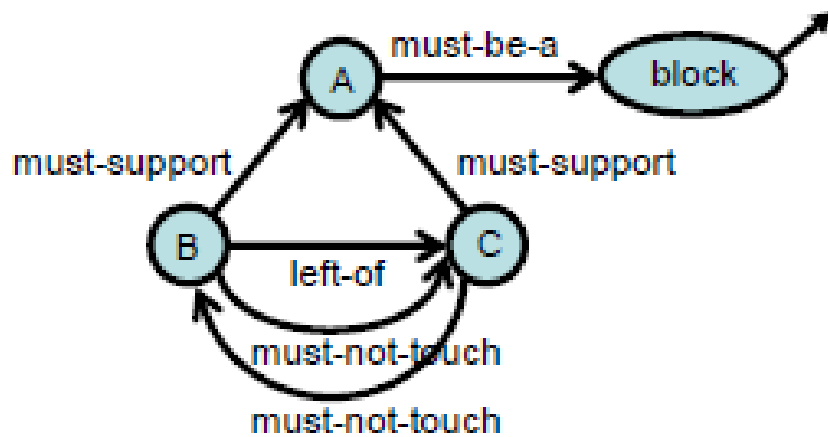
สมมติว่าเรามีความสัมพันธ์ของต้นไม้จำแนกประเภท (classification tree) ว่าวัตถุหนึ่งๆ จัดอยู่ในประเภทอะไรในฐานความรู้ของเราด้วย เช่นในที่นี้ wedge จัดเป็นวัตถุหนึ่งในประเภทของ block ในทำนองเดียวกัน brick ก็จัดเป็นวัตถุหนึ่งในประเภทของ block ด้วย โมเดลของเราในรูปที่ 6-15 เมื่อนำมาเขียนใหม่ให้รวมความสัมพันธ์ของต้นไม้จำแนกประเภทเข้าไปด้วยก็จะได้ดังรูปที่ 6-17



รูปที่ 6-17 โมเดลหลังรับตัวอย่างตัวที่สามที่รวมต้นไม้จำแนกประเภทด้วย

เมื่อนำโมเดลเปรียบเทียบกับคำอธิบายตัวอย่างที่สี่ข้างต้นจะพบว่ามีความแตกต่างกันที่ brick กับ wedge และทั้งคู่ต่างก็เป็นวัตถุในประเภทของ block ดังนั้นเราจึงแทนที่ brick ด้วยประเภทที่สูง (กว้าง) กว่าคือ block ได้เป็นโมเดลในรูปที่ 6-18 เราเรียกฮิวริสติกแบบนี้ว่าฮิวริสติกปีนต้นไม้ (climb-tree heuristic)

6.3 การเรียนรู้โดยการวิเคราะห์ความแตกต่าง



รูปที่ 6-18 โมเดลเมื่อรับตัวอย่างครบทุกตัว

ในกรณีที่เราไม่มีต้นไม้จำแนกประเภท โปรแกรมจะสร้างประเภทใหม่คือ “brick-orwedge” ขึ้นมาเพื่อใช้แทนบัพ block ในรูปที่ 6-18 เราเรียกฮิวริสติกแบบนี้ว่าฮิวริสติกขยายเซต (*enlarge-set heuristic*) และถ้าหากว่าในกรณีที่เราไม่มีวัตถุอื่นอยู่ในโดเมนนี้อีกเลยที่นอกเหนือจาก brick และ wedge เราก็สามารถตัดเส้นเชื่อม isa ออกได้เลยเพื่อเป็นการลดเงื่อนไข และในกรณีนี้เราเรียกฮิวริสติกนี้ว่า ฮิวริสติกตัดเส้นเชื่อม (*drop-linkheuristic*) ในกรณีเหล่านี้ตัวอย่างบวกทำหน้าที่สำหรับการวางนัยทั่วไปของมโนทัศน์ (*generalization of concept*) ซึ่งหมายถึงว่าคำอธิบายของมโนทัศน์จะถูกทำให้กว้างขึ้น มีเงื่อนไขน้อยลง ตรงกับตัวอย่างจำนวนมากขึ้น อัลกอริทึมของโปรแกรมเรียนรู้โดยวิเคราะห์ความแตกต่างแสดงในตารางที่ 6-10

ตารางที่ 6-10 อัลกอริทึมการเรียนรู้โดยวิเคราะห์ความแตกต่าง

Algorithm: Learning by Analyzing Differences

- Near-miss is for specialize model by using
 - require-link heuristic
 - forbid-link heuristic
- Positive example is for generalize mode by using
 - climb-tree heuristic
 - enlarge-set heuristic
 - drop-link heuristic

Speicalization algorithm

Specialization to make a model more restrictive by:

- (1) Match the evolving model to the example to establish correspondences among parts.
- (2) Determine whether there is a single, most important difference between the evolving model and the near miss.
 - If there is a single, most important difference,
 - (a) If the evolving model has a link that is not in the near miss, use the require-link heuristic
 - (b) If the near miss has a link that is not in the model, use the forbid-link heuristic
 - Otherwise, ignore the example.

Generalization algorithm

Generalization to make a model more permissive by:

- (1) Match the evolving model to the example to establish correspondences among parts.
- (2) For each difference, determine the difference type:
 - If a link points to a class in the evolving model different from the class to which the link points in the example,
 - (a) If the classes are part of a classification tree, use the climb-tree heuristic
 - (b) If the classes form an exhaustive set, use the drop-link heuristic
 - (c) Otherwise, use the enlarge-set heuristic
- (3) If a link is missing in the example, use the drop-link heuristic
- (4) Otherwise, ignore the difference.

6.4 เวอร์ชันสเปซ

เวอร์ชันสเปซ (version space) [Mitchell, 1977] เรียนรู้คำอธิบายที่อธิบายตัวอย่างบวกและไม่อธิบายตัวอย่างลบ รูปที่ 6-19 ด้านล่างแสดงตัวอย่างของการเรียนมโนทัศน์ car ซึ่งใช้การแทนความรู้แบบกรอบ (frame)

Car023	
origin:	Japan
manufacturer:	Honda
color:	Blue
decade:	1970
type:	Economy

รูปที่ 6-19 ตัวอย่างบวกของมโนทัศน์ car

กรอบประกอบด้วยชื่อกรอบ ในที่นี้คือ Car023 และสล็อต (slot) ในที่นี้สล็อตมี 5 ตัวคือ origin, manufacture, color, decade และ type ซึ่งแสดงคุณสมบัติทั้งห้าอย่างของรถยนต์สมมติว่าสล็อตแต่ละตัวมีค่าที่เป็นไปได้ตามตารางที่ 6-11 ด้านล่างนี้

6.4 เวอร์ชันสเปซ

ตารางที่ 6-11 ค่าที่เป็นไปได้ของสล็อตแต่ละตัว

origin	∈	{Japan, USA, Britain, Germany, Italy}
manufacturer	∈	{Honda, Toyota, Ford, Chrysler, Jaguar, BMW, Fiat}
color	∈	{Blue, Green, Red, White}
decade	∈	{1950, 1960, 1970, 1980, 1990, 2000}
type	∈	{Economy, Luxury, Sports}

การเรียนรู้โดยเวอร์ชันสเปซจะแสดงคำอธิบายมโนทัศน์ในรูปแบบของสล็อตและค่าของสล็อตเช่นถ้าเป็นมโนทัศน์ “Japanese economy car” จะแสดงได้ดังรูปที่ 6-20 โดยที่ x1, x2 และ x3 เป็นตัวแปรสามารถถูกแทนด้วยค่าคงที่ใดๆ

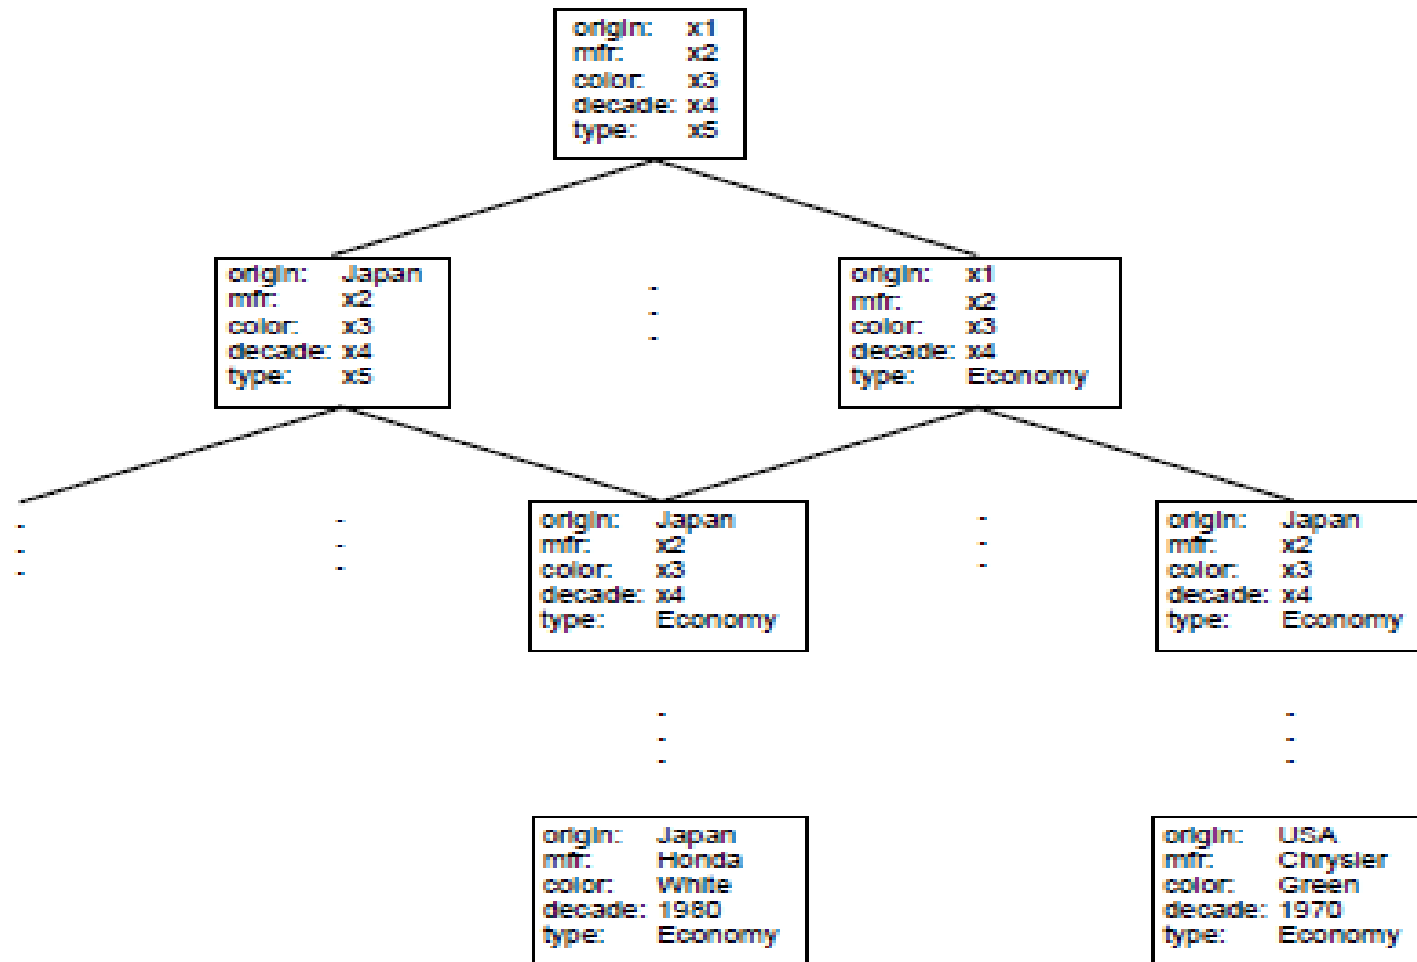
origin:	Japan
manufacturer:	x1
color:	x2
decade:	x3
type:	Economy

รูปที่ 6-20 มโนทัศน์ “Japanese economy car”

6.4 เวอร์ชันสเปซ

ปัญหาการเรียนรู้ที่เราสนใจคือ กำหนดค่าที่เป็นไปได้ของสล็อต ตัวอย่างบวกและตัวอย่างลบให้ จงหาคำอธิบายมโนทัศน์ที่สอดคล้องกับ (*consistent with*) ตัวอย่าง (อธิบายตัวอย่างบวกและไม่อธิบายตัวอย่างลบ)วิธีการเรียนรู้เวอร์ชันสเปซนี้มองว่าการเรียนรู้คือการค้นหาในปริภูมิค้นหาที่เรียกว่า *ปริภูมิมโนทัศน์ (concept space)* ซึ่งเป็นปริภูมิที่มีสมาชิกแต่ละตัวเป็นคำอธิบายในรูปของกรอบโดยที่สมาชิกเหล่านี้มีลำดับบางส่วน (*partial ordering*) ในลำดับนี้สมาชิกตัวที่มีนัยทั่วไปกว่า (*more general*) จะอยู่ด้านบนของสมาชิกตัวที่จำเพาะกว่า (*more specific*) ดังแสดงในรูปที่ 6-21 โดยที่ตัวอักษรเล็ก (x_1, x_2, x_3, x_4 และ x_5) แสดงตัวแปรซึ่งสามารถแทนที่ด้วยค่าคงที่ได้ ส่วนตัวอักษรใหญ่และตัวเลข (เช่น Japan, Economy, 1980) แสดงค่าคงที่

6.4 เวอร์ชันสเปซ



รูปที่ 6-21 ปริภูมิในทศน์


6.4 เวอร์ชันสเปซ

ตัวที่อยู่บนสุดในรูปแสดงมโนทัศน์มีนัยทั่วไปสุด (*most general concept*) ส่วนตัวที่อยู่ล่างสุดแสดงมโนทัศน์จำเพาะสุด (*most specific concept*) ซึ่งเป็นตัวอย่างหนึ่งๆ และตัวที่เป็นคำอธิบายมโนทัศน์เป้าหมาย (*target concept description*) จะอยู่ระหว่างบนสุดกับล่างสุด วิธีการเรียนรู้เวอร์ชันสเปซคือการสร้างเซตย่อยประกอบด้วยสมมติฐาน (*hypothesis*) ที่อยู่ในปริภูมิมโนทัศน์ที่สอดคล้องกับตัวอย่างสอน และเรียกเซตย่อยนี้ว่าเวอร์ชันสเปซ (*version space*) เวอร์ชันสเปซที่สร้างขึ้นนี้จะต้องประกอบด้วยสมมติฐาน (คำอธิบาย) ที่สอดคล้องกับตัวอย่างที่เคยพบมาทั้งหมด วิธีการสร้างเวอร์ชันสเปซที่ทำได้วิธีหนึ่งคือการแจงสมาชิกทุกตัวในปริภูมิมโนทัศน์ แล้วตรวจสอบกับตัวอย่างสอนทุกตัวที่รับเข้ามา หากสมาชิกตัวใดไม่สอดคล้องกับตัวอย่างก็ตัดทิ้งไป คงไว้เฉพาะตัวที่สอดคล้องเท่านั้น อย่างไรก็ตาม ปริภูมิ-มโนทัศน์มีขนาดใหญ่มาก วิธีการนี้จึงไม่มีประสิทธิภาพ ตัวอย่างเช่นในกรณีของปัญหาในรูปที่ 6-21 เมื่อพิจารณาค่าที่เป็นไปได้ในสล็อตแต่ละตัวตามตารางที่ 6-11 จะเห็นว่าปริภูมิมโนทัศน์มีขนาดเท่ากับ $((5+1)(7+1)(4+1)(6+1)(3+1)) = 6,720$ และในกรณีที่จำนวนสล็อตมีมากขึ้นเช่น 10 ตัว และสล็อตแต่ละตัวมีค่าที่เป็นไปได้มากขึ้นเช่น 10 ค่า จะได้ว่าปริภูมิมโนทัศน์จะยิ่งมีขนาดใหญ่ขึ้นมาก ($\approx 2.6 \times 10^{10}$)

6.4 เวย์ร์ชั้นสเปซ

วิธีการเรียนรู้เวย์ร์ชั้นสเปซจะใช้วิธีการแทนสเปซด้วยวิธีที่ประหยัดและมีประสิทธิภาพในการค้นหามากโดยจะใช้เซตย่อย 2 เซต เรียกว่าเซต G และเซต S

- เซต G ประกอบด้วยคำอธิบายมีนัยทั่วไปที่สุดที่ยังสอดคล้องกับตัวอย่างที่เคยพบมาทั้งหมด
 - เซต S ประกอบด้วยคำอธิบายจำเพาะสุดที่ยังสอดคล้องกับตัวอย่างที่เคยพบมาทั้งหมด
- เวย์ร์ชั้นสเปซจะอยู่ระหว่างเซต G กับ S ดังแสดงในรูปที่ 6-22



รูปที่ 6-22 เวย์ร์ชั้นสเปซ

6.4 เวอร์ชันสเปซ

หลักการของเวอร์ชันสเปซคือทุกครั้งที่เราได้รับตัวอย่างบวกตัวใหม่เราจะทำให้ S มีนัยทั่วไป (general) มากขึ้น และทุกครั้งที่ได้รับตัวอย่างลบเราจะทำให้ G จำเพาะ (specific) มากขึ้น จนในที่สุด S และ G ลู่เข้าสู่ค่าเดียวกันที่เป็นคำอธิบายโมโนทัศน์เป้าหมาย อัลกอริทึมการเรียนรู้ของเวอร์ชันสเปซเป็นดังตารางที่ 6-12 นี้

ตารางที่ 6-12 อัลกอริทึมการเรียนรู้เวอร์ชันสเปซ

Algorithm: Version-Space-Candidate-Elimination

1. $G := \{\text{most general description}\}$
2. $S := \{\text{first positive example}\}$
3. Accept a new example E
IF E is positive THEN
 - Remove from G any descriptions that do not cover the example.
 - Update S to contain the most specific set of descriptions in the version space that cover the example and the current elements of S.ELSE IF E is negative THEN
 - Remove from S any descriptions that cover the example.
 - Update G to contain the most general set of descriptions in the version space that do not cover the example.
4. IF S and G are both singleton sets and $S = G$ THEN
Output the element
ELSE IF S and G are both singleton sets and $S \neq G$ THEN
examples were inconsistent
ELSE goto 3.

6.4.1 ตัวอย่างการเรียนรู้โมเดล CAR

กำหนดเซตตัวอย่างสอนที่ประกอบด้วยตัวอย่างบวกและตัวอย่างลบดังรูปที่ 6-23
อัลกอริทึมในตารางที่ 6-12 จะเรียนรู้ดังต่อไปนี้

origin:	Japan
mfr:	Honda
color:	Blue
decade:	1980
type:	Economy

(+)

origin:	Japan
mfr:	Toyota
color:	Green
decade:	1970
type:	Sports

(-)

origin:	Japan
mfr:	Toyota
color:	Blue
decade:	1990
type:	Economy

(+)

origin:	USA
mfr:	Chrysler
color:	Red
decade:	1980
type:	Economy

(-)

origin:	Japan
mfr:	Honda
color:	White
decade:	1980
type:	Economy

(+)

รูปที่ 6-23 ตัวอย่างสอนของโมเดล car

6.4.2 ข้อจำกัดของเวอร์ชันสเปซ

องเวอร์ชันสเปซ

ดังที่แสดงในตัวอย่างด้านบนนี้ เวอร์ชันสเปซสามารถเรียนรู้ได้จากตัวอย่างที่สอน อย่างไรก็ตาม เวอร์ชันสเปซก็ยังมีข้อจำกัดดังต่อไปนี้

- อัลกอริทึมเรียนรู้นี้เป็นแบบทำน้อยสุด (least-commitment algorithm) กล่าวคือในแต่ละขั้นตอนเวอร์ชันสเปซจะถูกตัดเล็มให้เล็กลงน้อยที่สุดเท่าที่เป็นไปได้ ดังนั้นถึงแม้ว่าตัวอย่างบวกทุกตัวเป็น Japanese cars ก็ตาม อัลกอริทึมก็จะไม่ตัดความน่าจะเป็นที่มันทัศน์อาจจะรวม car อื่นๆ ที่จนกระทั่งพบตัวอย่างลบ ซึ่งหมายถึงเวอร์ชันสเปซจะเรียนรู้ไม่สำเร็จถ้าไม่มีตัวอย่างลบเลย
- กระบวนการค้นหาเป็นการค้นหาแนวกว้างแบบทั้งหมด (exhaustive breadth-firstsearch) ซึ่งเห็นได้จากการปรับค่าของเซต G ที่จะทดลองทำที่สล็อตทุกตัวให้ได้ทุกแบบที่เป็นไปได้ ดังนั้นทำให้อัลกอริทึมมีประสิทธิภาพต่ำในกรณีที่ปริภูมิใหญ่มากๆ ซึ่งอาจทำให้ดีขึ้นโดยใช้ฮิวริสติกเข้าช่วยในการค้นหาโดยลองเปลี่ยนตัวแปรเป็นค่าคงที่ในบางสล็อตที่น่าจะนำไปสู่คำตอบก่อน เป็นต้น
- เซต S ประกอบด้วยสมาชิกเพียงตัวเดียวเพราะว่าตัวอย่างบวก 2 ตัวใดๆ มีการวางนัยทั่วไปเพียงหนึ่งเดียว ดังนั้นเวอร์ชันสเปซจึงไม่สามารถเรียนมโนทัศน์แบบ‘หรือ’ (disjunctive concept) ซึ่งเป็นมโนทัศน์ที่อยู่ในรูปของ or เช่น "Japaneseconomy car or Japanese sport car"
- ข้อจำกัดอีกอย่างของเวอร์ชันสเปซคือไม่สามารถจัดการกับตัวอย่างมีสัญญาณรบกวน(noisy example) ซึ่งเป็นตัวอย่างที่มีข้อมูลบางส่วนผิดพลาด เช่นถ้าตัวอย่างตัวที่ 3 ในรูปที่ 6-23 (Japan Toyota Blue 1990 Economy) เราให้ประเภทผิดเป็นตัวอย่างลบ(-) อัลกอริทึมจะไม่สามารถเรียนมโนทัศน์ "Japanese economy car" ได้ถูกต้อง

6.5 การเรียนรู้ต้นไม้ตัดสินใจ

การเรียนรู้ต้นไม้ตัดสินใจ (*decision tree learning*) [Quinlan, 1986; Quinlan, 1993] เป็นการเรียนรู้ที่ใช้การแทนความรู้ที่อยู่ในรูปของต้นไม้ตัดสินใจ ใช้สำหรับจำแนกประเภทของตัวอย่าง วิธีการเรียนรู้คล้ายกับการเรียนรู้เวอร์ชันสเปซโดยเริ่มจากการป้อนตัวอย่างเข้าไปในระบบ ซึ่งตัวอย่างที่ป้อนให้เป็นตัวอย่างบวกกับตัวอย่างลบก็ได้และนอกจากนั้นเรายังสามารถป้อนตัวอย่างที่มากกว่า 2 ประเภท (*class*) ได้ กล่าวคือแทนที่จะมีแต่บวกกับลบ ก็สามารถมีได้หลายประเภท เช่นในการรู้จำตัวอักษร จะมีตัวอย่างมาจากหลายประเภทที่แตกต่างกันคือประเภท ‘ก’, ประเภท ‘ข’, ประเภท ‘ค’, ประเภท ‘ง’ ฯลฯ แต่เพื่อให้ง่ายต่อการอธิบาย ตัวอย่างที่จะยกให้ดูต่อไปนี้จะมียเพียง 2 ประเภทเท่านั้น โดยเราจะใช้ปัญหาการฝั่งแดดเป็นตัวอย่างอธิบาย

ปัญหาการฝั่งแดด : เราไปเที่ยวที่ชายทะเลและพบว่าคนที่ไปฝั่งแดดตามชายทะเล บางคนก็จะมีผิวเปลี่ยนเป็นสีแทน แต่บางคนต้องได้รับความทรมาณจากผิวไหม้ เราต้องการหาว่าอะไรคือปัจจัยที่ทำให้คนที่ไปฝั่งแดดตามชายทะเลแล้วผิวไหม้หรือไม่ไหม้ โดยข้อมูลที่สังเกตได้ประกอบด้วยความแตกต่างของสีผมน้ำหนัก ส่วนสูงของผู้ที่ไปฝั่งแดด และการใช้โลชั่น ซึ่งบางคนก็ใช้โลชั่น บางคนก็ไม่ใช้

6.5 การเรียน รู้ต้นไม้ตัดสินใจ

สมมติว่าเราบันทึกข้อมูลของตัวอย่างสอนได้ตามตารางที่ 6-13 เพื่อใช้สร้างต้นไม้ตัดสินใจ

ตารางที่ 6-13 ตัวอย่างสอนที่สังเกตได้

ประเภท
↓


	Name	Hair	Height	Weight	Lotion	Result
คุณสมบัติ ↓ ค่า	Sarah	blonde	average	light	no	sunburned
	Dana	blonde	tall	average	yes	none
	Alex	brown	short	average	yes	none
	Annie	blonde	short	average	no	sunburned
	Emily	red	average	heavy	no	sunburned
	Pete	brown	tall	heavy	no	none
	John	brown	average	heavy	no	none
	Katie	blonde	short	light	Yes	none

6.5 การเรียนรู้ต้นไม้ตัดสินใจ

แถวแรกสุดในตารางแสดง *คุณสมบัติ* (attribute) ของข้อมูลซึ่งประกอบด้วยชื่อ (Name) สีผม (Hair) ส่วนสูง (Height) น้ำหนัก (Weight) และการใช้โลชั่น (Lotion) ส่วนสดมภ์สุดท้ายแทนประเภทของตัวอย่าง คุณสมบัติ Name ไว้สำหรับอ้างอิงตัวอย่างและไม่มีผลต่อการจำแนกข้อมูล เราจึงจะไม่ใช้ Name ในการเรียนรู้ด้านล่างนี้ แต่ละแถวในตารางนอกเหนือจากแถวแรกแทนตัวอย่างหนึ่งตัว เช่นแถวที่สองแสดงตัวอย่างของคนที่ชื่อ Sarah ซึ่งมีสีผม ส่วนสูง น้ำหนัก และการใช้โลชั่น เป็น blond, average, light และ no ตามลำดับ ตัวอย่างนี้อยู่ในประเภท sunburned เป็นต้น เมื่อเราได้ข้อมูลตัวอย่างทั้ง 8 ตัวแล้ว สิ่งที่เราต้องการทำก็คือทำการวางนัยทั่วไปของตัวอย่างเพื่อสร้างเป็นโมเดลสำหรับทำนายประเภทของข้อมูลของคนอื่นที่ไม่ได้บันทึกไว้ วิธีที่ง่ายที่สุดก็คือการเรียนรู้โดยการจำ และเมื่อมีตัวอย่างในอนาคตที่เรายังไม่ทราบประเภทและถ้าต้องการทำนาย เราก็นำตัวอย่างนั้นมาเปรียบเทียบกับตัวอย่างสอนในตาราง ถ้าตัวอย่างที่นำมาเปรียบเทียบกับมีคุณสมบัติตรงกับข้อมูลในตาราง เราก็นำประเภทของตัวอย่างสอนที่ตรงกันทำนายให้กับตัวอย่างนั้น อย่างไรก็ตามวิธีการนี้ทำงานได้ไม่ดีนักเนื่องจากว่าโอกาสที่เราจะพบตัวอย่างทดสอบที่ตรงกับตัวอย่างสอนมีน้อย สมมติว่าสีผมมีค่าที่เป็นไปได้ทั้งหมด 3 ค่าคือ bronde, brown, red ส่วนสูงมีได้ 3 ค่าคือ tall, average, short น้ำหนักมีได้ 3 ค่าคือ heavy, average, light และการใช้โลชั่นมีได้ 2 ค่าคือ yes, no เราจะพบว่าความน่าจะเป็นที่ตัวอย่างทดสอบจะตรงกับตัวอย่างสอนมีค่าเท่ากับ $8/(3 \times 3 \times 3 \times 2) = 15\%$ (สมมติว่าความน่าจะเป็นที่ค่าแต่ละค่าสำหรับคุณสมบัติหนึ่งๆ มีความน่าจะเป็นที่จะเกิดขึ้นเท่ากัน)

6.5 การเรียน รู้ต้นไม้ตัดสินใจ

การเรียนรู้ต้นไม้ตัดสินใจจะทำการวางนัยทั่วไปของข้อมูลโดยสร้างเป็น โมเดลอยู่ในรูปต้นไม้ตัดสินใจ ตัวอย่างของต้นไม้ตัดสินใจแสดงในรูปที่ 6–24




รูปที่ 6–24 ตัวอย่างของต้นไม้ตัดสินใจ

ต้นไม้ตัดสินใจประกอบด้วย**บัพ** (*node*) และ**กิ่ง** (*link*) ที่ต่อกับบัพ บัพที่ปลายสุดเรียกว่า**บัพใบ** (*leaf node*) หรือเรียกย่อๆ ว่า**ใบ** บัพแสดงคุณสมบัติและกิ่งแสดงค่าของคุณสมบัตินั้น ใบ (*leaf*) แสดงประเภท การสร้างต้นไม้ตัดสินใจทำโดยสร้างบัพที่ละบัพเพื่อตรวจสอบคุณสมบัติของตัวอย่าง แล้วแยกตัวอย่างลงตามค่าของกิ่ง ทำจนกระทั่งตัวอย่างในใบแต่ละใบอยู่ในประเภทเดียวกันทั้งหมดสมมติว่าเราเลือกคุณสมบัติ *hair color* เป็นบัพแรกหรือบัพรากของต้นไม้ เราจะแยกตัวอย่างลงตามกิ่งของบัพ *hair color* ตัวอย่างใดที่มีค่าของ *hair color* เป็น *blonde* ก็แยกลงตามกิ่งซ้าย ถ้าเป็น *red* ก็แยกลงตามกิ่งกลาง และถ้าเป็น *brown* ก็แยกลงตามกิ่งขวา ผลที่ได้แสดงในรูปที่ 6–25

เครื่องหมาย + และ - แสดงประเภท *sunburned* และ *none*ตามลำดับ

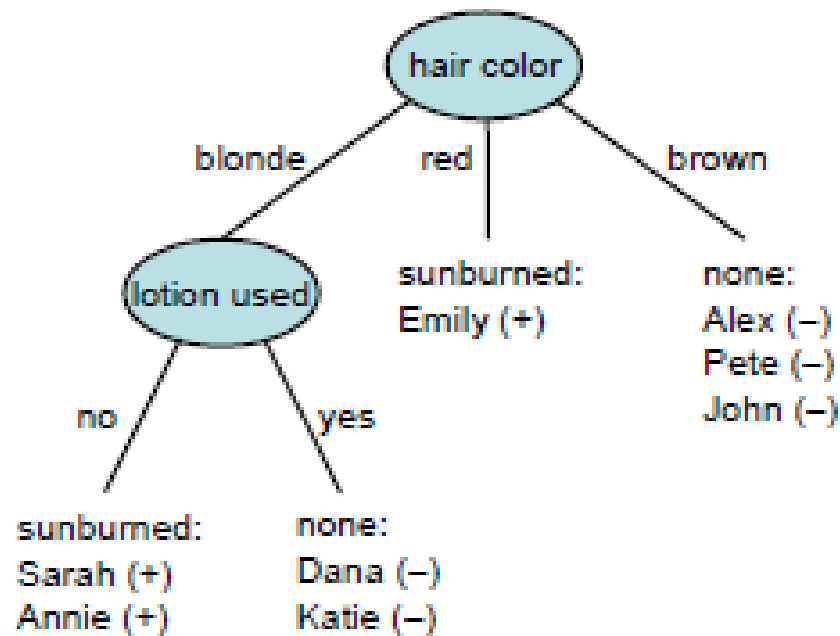
6.5 การเรียน รู้ต้นไม้ตัดสินใจ



รูปที่ 6-25 ผลการแยกตัวอย่างลงตามกิ่งของไม้พ 'hair color'

ต้นไม้ที่สร้างขึ้นนี้แยกตัวอย่างได้ในกรณีที่ hair color เป็น red (ตัวอย่างทุกตัวมีประเภทเป็น sunburned) และ brown (ตัวอย่างทุกตัวมีประเภทเป็น none) แต่ในกรณีที่ hair color เป็น blonde ยังแยกตัวอย่างไม่ได้ กล่าวคือมีตัวอย่างที่เป็นทั้ง sunburned และ noneปะปนกันอยู่ ในกรณีที่ hair color มีค่าเป็น brown เราสรุปได้ว่าตัวอย่างทุกตัวจะมีประเภทเป็น none หมดเนื่องจากตัวอย่างสอนทุกตัวที่ลักษณะเช่นนั้น หรือในกรณีที่ hair color มีค่าเป็น red เราก็สรุปได้ในทำนองเดียวกันว่าตัวอย่างจะมีประเภทเป็น sunburned แต่ในกรณีของ hair color เป็น blonde เราต้องการคุณสมบัติอื่นเข้าช่วยจำแนกประเภทตัวอย่างต่อไป ที่จุดนี้สมมติว่าเราใช้คุณสมบัติ lotion เพื่อแยกข้อมูลในกิ่งของ blonde ต่อไป ผลที่ได้แสดงในรูปที่ 6-26

6.5 การเรียน รู้ต้นไม้ตัดสินใจ

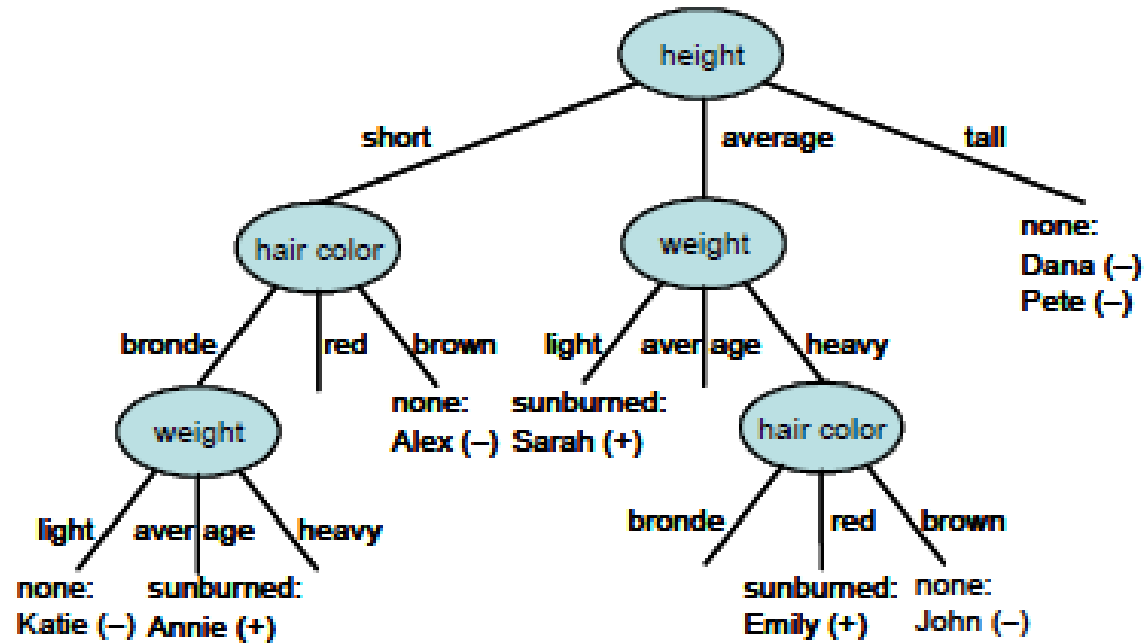


รูปที่ 6-26 ต้นไม้ตัดสินใจที่สอดคล้องกับตัวอย่างสอน

ต้นไม้ตัดสินใจในรูปที่ 6-26 ด้านบนนี้สอดคล้องกับตัวอย่างสอนทุกตัว หมายความว่าถ้านำตัวอย่างสอนมาตรวจสอบด้วยต้นไม้ตัดสินใจ ต้นไม้จะทำนายประเภทได้ถูกต้องทุกตัว การตรวจสอบทำโดยดูว่าตัวอย่างมี hair color เป็นค่าอะไร ถ้าเป็น brown จะทำนายประเภทเป็น none ถ้าเป็น red จะทำนายประเภทเป็น sunburned แต่ถ้าเป็น blonde จะดู lotion used ด้วยว่าถ้าเป็น no แสดงว่าประเภทเป็น sunburned แต่ถ้าเป็น yes แสดงว่าประเภทเป็น none

6.5 การเรียนรู้ต้นไม้ตัดสินใจ

โดยทั่วไปต้นไม้ตัดสินใจที่สอดคล้องกับตัวอย่างสอนมีได้มากกว่า 1 ต้น เช่น ต้นไม้ในรูปที่ 6-27 ก็เป็นต้นไม้อีกต้นหนึ่งที่สอดคล้องกับตัวอย่าง



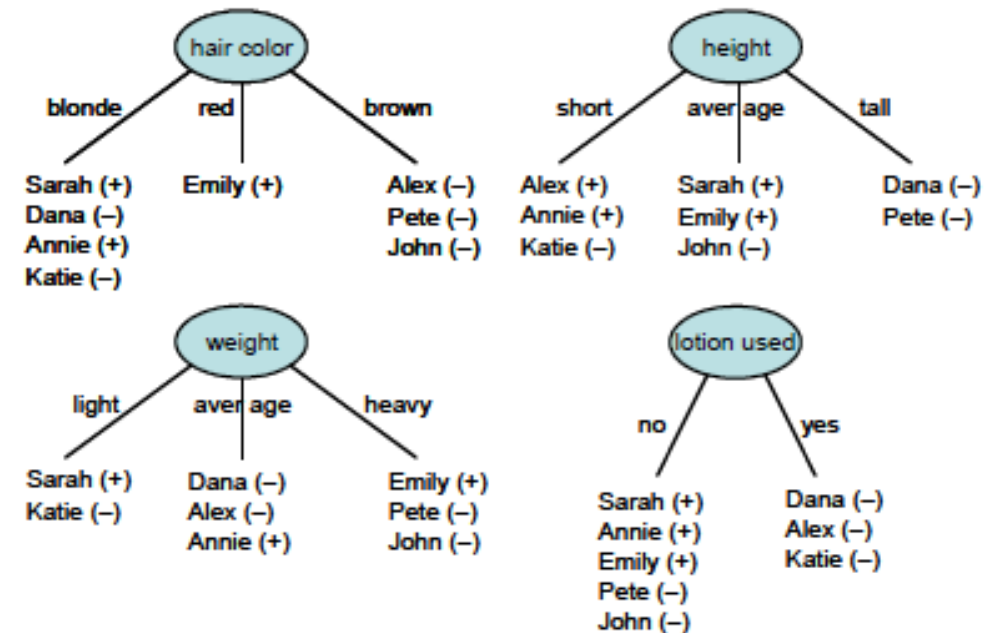
รูปที่ 6-27 ต้นไม้ตัดสินใจอีกต้นหนึ่งที่มีความซับซ้อนมากกว่าต้นแรก

6.5 การเรียนรู้ต้นไม้ตัดสินใจ

เมื่อเราพิจารณาต้นไม้ต้นแรกในรูปที่ 6-26 และต้นไม้ที่สองในรูปที่ 6-27 เราพบว่าต้นไม้ต้นแรกน่าจะถูกต้องมากกว่าต้นไม้ที่สอง เนื่องจากว่าในต้นไม้แรกนั้นใช้คุณสมบัติสีผมและการใช้โลชันในการจำแนกข้อมูล ซึ่งน่าจะเป็นไปได้เพราะสีผมมีความสัมพันธ์อย่างมากกับความแข็งแรงของผิวเรา คนที่มีผมสีน้ำตาลน่าจะผิวที่แข็งแรงไปฝั่งแดดแล้วมักจะไม่เป็นอะไรส่วนผมสีแดงมีผิวบอบบาง และผมสีบรอนซ์มีผิวปานกลางซึ่งจะขึ้นกับการใช้โลชันหรือไม่ใช้ ถ้าใช้ไปฝั่งแดดก็จะเป็นอะไร ถ้าไม่ใช้ไปฝั่งแดดแล้วผิวจะไหม้ ส่วนต้นไม้ที่สองเราไม่สามารถอธิบายได้ว่าทำไมส่วนสูงที่ใช้เป็นบัพหรือน้ำหนักที่บัพในระดับถัดมาจึงมีความสำคัญต่อการที่ผิวจะไหม้หรือไม่ไหม้ความแตกต่างที่เห็นได้เด่นชัดอีกประการของต้นไม้ทั้งสองคือจำนวนบัพภายในต้นไม้จะเห็นได้ว่าจำนวนบัพของต้นไม้ที่สองมีจำนวนมากกว่า หรือกล่าวอีกนัยหนึ่งคือต้นไม้ที่สองมีความซับซ้อนมากกว่า หรือกล่าวได้ว่าต้นไม้ต้นแรกมีขนาดเล็กกว่าต้นไม้ที่สองโดยที่ขนาดวัดจากจำนวนบัพภายในต้นไม้ในการเรียนรู้ของเครื่องนั้น เรามีฮิวริสติกตัวหนึ่งที่นิยมใช้กันและพบว่าทำงานได้อย่างดีในหลายกรณีเรียกว่า *มีดโกนของอ็อกแคม* (*occam's razor*) เมื่อเรานำมีดโกนของอ็อกแคมมาใช้ในการเลือกต้นไม้ตัดสินใจ เราก็จะได้ว่า “ต้นไม้ตัดสินใจขนาดเล็กที่สุดที่สอดคล้องกับตัวอย่างสอนคือต้นไม้ตัดสินใจที่ดีที่สุด” อย่างไรก็ตามถ้าเราจะหาต้นไม้ตัดสินใจที่มีขนาดเล็กที่สุดที่สอดคล้องกับตัวอย่างสอนก็ไม่สามารถทำได้โดยง่าย เราต้องสร้างต้นไม้ตัดสินใจจำนวนมาก โดยเริ่มจากต้นไม้ที่มีจำนวนบัพ 1 บัพทุกต้นที่เป็นไปได้แล้วดูว่ามีต้นไม้ไหนหรือไม่ที่สอดคล้องกับตัวอย่างสอน ถ้าไม่มีก็เพิ่มจำนวนบัพเป็น 2 บัพ ทำอย่างนี้ไปจนกระทั่งพบต้นไม้ตัดสินใจที่สอดคล้องกับตัวอย่าง เราพบว่าวิธีการนี้จะมีจำนวนต้นไม้ที่ต้องสร้างเป็นฟังก์ชันเลขยกกำลังของจำนวนคุณสมบัติซึ่งไม่เหมาะกับการใช้งานจริง

6.5.1 ฟังก์ชันเกณฑ์สำหรับการเลือกบัณฑิตสอบ

ส่วนนี้จะกล่าวถึงวิธีการเลือกบัณฑิตเพื่อสร้างต้นไม้ตัดสินใจโดยใช้หลักการว่า เนื่องจากจุดมุ่งหมายของการสร้างต้นไม้คือเพื่อจำแนกประเภทของข้อมูลเพื่อให้ตัวอย่างในแต่ละบัพโบอยู่ในประเภทเดียวกันทั้งหมด ดังนั้นบัพที่ดีควรเป็นบัพที่แยกตัวอย่างออกเป็นเซตย่อยตามกิ่งของบัพนั้นและเซตย่อยในแต่ละกิ่งประกอบด้วยสมาชิกที่ส่วนใหญ่เป็นประเภทเดียวกันมากที่สุด ตัวอย่างในรูปที่ 6-28 แสดงผลของบัพทดสอบแต่ละบัพ



รูปที่ 6-28 ผลของบัพทดสอบแต่ละบัพในการแยกตัวอย่างเพื่อเลือกบัพราก

6.5.1 ฟังก์ชันเกณฑ์สำหรับการเลือกข้อทดสอบ

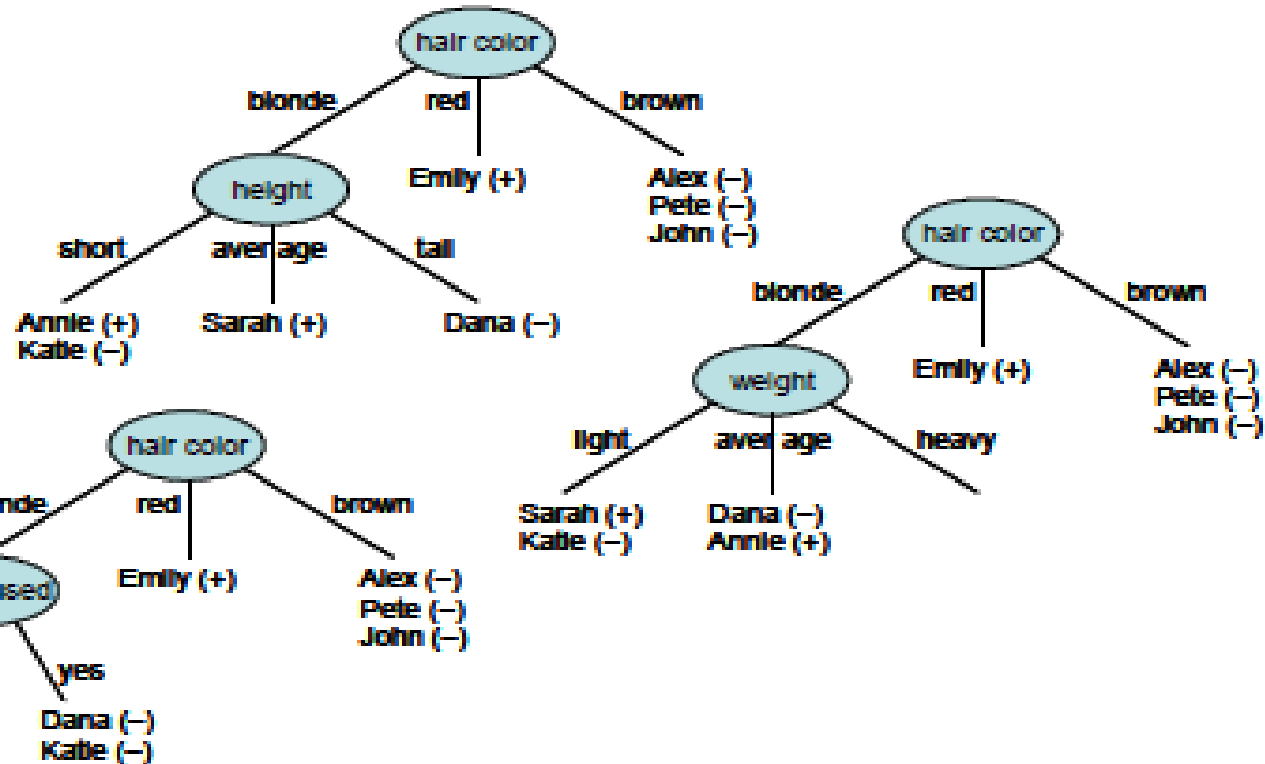
ดังแสดงในรูปด้านบน ข้อแต่ละข้อแยกตัวอย่างได้ดีต่างกันดังนี้

- ในกรณีของข้อทดสอบเป็น hair color สามารถแยกตัวอย่างเป็น 3 เซตย่อย เซตย่อยแรก (blonde) มีตัวอย่างของ 2 ประเภทปนกันอยู่ ส่วนเซตย่อยที่ 2 (red) และ 3 (brown) มีตัวอย่างของประเภท sunburned และ none อยู่อย่างเดียวตามลำดับ ซึ่งกรณีนี้ hair color แยกตัวอย่างได้ดีเมื่อเทียบกับข้ออื่นด้านล่างนี้
- ในกรณีของข้อทดสอบเป็น height สามารถแยกตัวอย่างเป็น 3 เซตย่อย เซตย่อยแรก (short) และเซตย่อยที่ 2 (average) มีตัวอย่าง 2 ประเภทปนกันอยู่ในแต่ละเซต ส่วนเซตย่อยที่ 3 (tall) มีตัวอย่างของ none อยู่อย่างเดียว จะเห็นว่ากรณีนี้แยกตัวอย่างไม่ดีเท่ากรณีของ hair color
- ในกรณีของข้อทดสอบเป็น weight สามารถแยกตัวอย่างเป็น 3 เซตย่อย เซตย่อยทั้งสามเซต (light, average, heavy) ต่างก็มีตัวอย่าง 2 ประเภทปนกันอยู่ ซึ่งกรณีนี้เป็นกรณีที่แย่มากที่สุด
- ในกรณีของข้อทดสอบเป็น lotion used สามารถแยกตัวอย่างเป็น 2 เซตย่อย เซตย่อยแรก (no) มีตัวอย่างของ 2 ประเภทปนกัน ส่วนเซตย่อยที่ 2 (yes) มีตัวอย่างของ none อยู่อย่างเดียว และในเซตย่อยแรกสมาชิกส่วนใหญ่ของเซตนี้เป็น sunburned (+) เกือบทั้งหมด ซึ่งเมื่อเทียบกับกรณีแรกของข้อ hair color ถือได้ว่ามีความสามารถในการแยกตัวอย่างได้ใกล้เคียงกัน

6.5.1 ฟังก์ชันเกณฑ์สำหรับการเลือกบัณฑิตสอบ

ดังจะเห็นได้ในตัวอย่างด้านบนนี้ เราพอจะเปรียบเทียบได้ว่าบัณฑิตหนึ่งๆ มีความสามารถในการแยกตัวอย่างดีกว่าบัณฑิตอื่นหรือไม่ แต่ในบางกรณีเช่น hair color กับ lotion used เราอาจบอกความแตกต่างไม่ได้ ดังนั้นเราจำเป็นต้องหาการวัดที่สามารถบอกความต่างได้อย่างชัดเจนโดยการนิยามฟังก์ชันเพื่อวัดประสิทธิภาพของบัณฑิตออกเป็นค่าที่วัดได้อย่างละเอียด ซึ่งจะกล่าวต่อไป ณ จุดนี้ เพื่อให้เข้าใจถึงการสร้างต้นไม้ตัดสินใจจะขอสมมติว่าเรามีฟังก์ชันนั้นอยู่และสมมติว่าระหว่างบัณฑิต hair color กับ lotion used ค่าฟังก์ชันของ hair color ดีกว่าและได้รับเลือกเป็นบัณฑิต ในขั้นตอนต่อไปก็คือเราต้องพิจารณาต่อว่าในแต่ละกิ่งของบัณฑิต มีกิ่งใดหรือไม่ที่ยังมีตัวอย่างจากหลายประเภทปะปนกันอยู่ ถ้ามีเราต้องเพิ่มบัณฑิตอื่นเพื่อช่วยแยกตัวอย่างที่ยังปะปนกันอยู่ต่อไป ในกรณีของบัณฑิต hair color ในรูปที่ 6-28 กิ่ง blonde เท่านั้นที่ยังมีตัวอย่างจากหลายประเภทปนกัน เราจึงจำเป็นต้องเพิ่มบัณฑิตต่อไปโดยทดลองเพิ่มคุณสมบัติที่เหลือทั้งสาม (height, weight และ lotion used) ผลที่ได้แสดงในรูปที่ 6-29

6.5.1 ฟังก์ชันเกณฑ์สำหรับการเลือกบัพทดสอบ



รูปที่ 6-29 ผลของบัพทดสอบแต่ละบัพในการแยกตัวอย่างเพื่อเลือกบัพต่อจากกิ่ง blonde

จากรูปด้านบนจะเห็นได้ว่าบัพ lotion used เป็นบัพที่แยกตัวอย่างออกเป็นเซตย่อยโดยที่แต่ละเซตย่อยมีสมาชิกอยู่ในประเภทเดียวกัน ดังนั้นบัพ lotion used ถูกเลือกในขั้นตอนนี้

6.5.2 ฟังก์ชันเกน

ฟังก์ชันที่ใช้วัดความสามารถในการแยกตัวอย่างของบัพทดสอบที่มีประสิทธิภาพมากฟังก์ชันหนึ่งคือ *ฟังก์ชันเกน (Gain function)* ฟังก์ชันเกนนี้ใช้ในการตัดสินใจเลือกคุณสมบัติที่จะใช้เป็นรากหรือบัพในต้นไม้โดยการคำนวณค่าเกนของคุณสมบัติแต่ละตัวเมื่อทดลองใช้คุณสมบัตินั้นแบ่งตัวอย่าง แล้วเลือกคุณสมบัติที่มีค่าเกนสูงที่สุดมาเป็นรากหรือบัพ ค่าเกนนี้คำนวณได้โดยใช้ความรู้จาก *ทฤษฎีสารสนเทศ (information theory)* ซึ่งมีสาระสำคัญคือค่าสารสนเทศหรือของข้อมูลขึ้นอยู่กับค่าความน่าจะเป็นของข้อมูลซึ่งสามารถวัดอยู่ในรูปของบิต (bits) จากสูตร

6.5.2 ฟังก์ชันเกน

ค่าสารสนเทศของข้อมูล = $-\log_2$ (ความน่าจะเป็นของข้อมูล) (6.2) ถ้าให้ชุดของข้อมูล M ประกอบด้วยค่าที่เป็นไปได้ คือ $\{m_1, m_2, \dots, m_n\}$ และให้ความน่าจะเป็นที่จะเกิดค่า m_i มีค่าเท่ากับ $P(m_i)$ จะได้ว่าค่าเอนโทรปี (entropy) ของ M ซึ่งใช้วัดค่าสารสนเทศโดยเฉลี่ยเพื่อระบุประเภทของข้อมูลสามารถเขียนแทนด้วย $I(M)$ คำนวณได้จากสูตร

$$I(M) = \sum_i^n -P(m_i) \log_2 P(m_i)$$

6.5.3 การเปลี่ยนต้นไม้เป็นกฎ

ระบบปัญญาประดิษฐ์ส่วนใหญ่ใช้การแทนความรู้ในรูปของกฎ ดังนั้นเมื่อเราสร้างต้นไม้ตัดสินใจแล้วเราสามารถเปลี่ยนต้นไม้ให้อยู่ในรูปของกฎเพื่อใช้กับในกรณีที่ระบบของเราใช้การแทนความรู้ของกฎเป็นหลัก วิธีการแปลงต้นไม้เป็นกฎ "IF THEN" ทำได้โดยแสดงทุกเส้นทางเริ่มต้นจากบัพรากไปยังบัพใบและทุกครั้งที่เราพบบัพทดสอบก็ให้เพิ่มบัพทดสอบกับค่าของการทดสอบไว้ในส่วนของ IF และเมื่อพบบัพใบก็ให้ใส่ประเภทไว้ในส่วนของ THEN จากต้นไม้รูปที่ 6-24 เราเปลี่ยนเป็นกฎได้ดังนี้

6.5.3 การเปลี่ยนต้นไม้เป็นกฎ

- (1) IF the person's hair color is blonde AND the person uses lotion THEN nothing happens
- (2) IF the person's hair color is blonde AND the person uses no lotion THEN the person turns red
- (3) IF the person's hair color is red THEN the person turns red
- (4) IF the person's hair color is brown THEN nothing happens

6.5.3 การเปลี่ยนต้นไม้เป็นกฎ

ตารางที่ 6-14 เปรียบเทียบระบบผู้เชี่ยวชาญที่ใช้และไม่ใช้การเรียนรู้ของเครื่องเพื่อช่วยในการพัฒนาระบบ

	Application	No. of Rules	Develop (Man Ys)	Maintain (Man Ys)	Learning Tools
MYCIN	Medical Diagnosis	400	100	N/A	N/A
XCON	VAX computer configuration	8,000	180	30	N/A
GASOIL	Hydrocarbon separation system configuration	2,800	1	0.1	ExpertEase and Extran7
BMT	Configuration of fire-protection equipment in buildings	30,000	9	2.0	1st Class and Rulemaster


จากตารางจะเห็นได้ว่าระบบผู้เชี่ยวชาญที่ไม่ใช้เครื่องมือการเรียนรู้ (MYCIN และ XCON) ใช้แรงงานในการพัฒนาและดูแลระบบมากกว่าระบบผู้เชี่ยวชาญที่ใช้เครื่องมือเรียนรู้ (GASOIL และ BMT) หลายเท่าเมื่อเทียบโดยจำนวนกฎที่ใช้ในระบบ ตัวอย่างนี้แสดงให้เห็นถึงประโยชน์ของการเรียนรู้ของเครื่องได้อย่างชัดเจน

6.6 การเรียนรู้ โดยการอธิบาย

การเรียนรู้โดยการอธิบาย — อีบีแอล (*Explanation Based Learning — EBL*) [DeJong & Mooney, 1986; Mitchell, et al., 1986] เป็นการเรียนรู้ที่มีลักษณะเด่นคือสามารถเรียนรู้ได้จากตัวอย่างบวกเพียงอย่างเดียวไม่จำเป็นต้องใช้ตัวอย่างลบ และจำนวนตัวอย่างบวกที่ใช้ก็ใช้เพียงตัวเดียวก็สามารถทำการเรียนรู้ได้ โดยมีแนวคิดว่า การเรียนรู้สามารถทำได้โดยการให้ความรู้พื้นฐานของโดเมนที่เกี่ยวข้อง จากนั้นจะให้ตัวอย่างบวกที่เป็นตัวอย่างของมโนทัศน์ที่จะสอน กระบวนการเรียนรู้ก็คือการใช้ความรู้ในโดเมนนั้นมาอธิบายให้ได้ว่าทำไมตัวอย่างที่สอนจึงเป็นตัวอย่างของมโนทัศน์แล้วจึงทำการวางนัยทั่วไปให้ครอบคลุมกรณีอื่นๆ

ยกตัวอย่างการเรียนรู้มโนทัศน์ fork ในการเล่นหมากรุกสากล (chess) โดยให้ตัวอย่างบวกของ fork ดังด้านล่างนี้

6.6 การเรียนรู้โดยการอธิบาย



รูปที่ 6-31 ตัวอย่างบวกของ fork

ตัวอย่างด้านบนนี้แสดงสถานการณ์ที่ “ม้าขาวโจมตีคิงดำและควีนดำพร้อมกัน” ในกรณีนี้ฝ่ายดำต้องยอมเสียควีน ไม่เช่นนั้นจะแพ้ จากตัวอย่างบวกตัวเดียวด้านบน อีปีแอลจะเรียนรู้ได้กฎดังนี้ “ถ้าตัวหมาก x โจมตีคิงกับตัวหมาก y ของฝ่ายตรงข้ามพร้อมกันแล้ว ฝ่ายตรงข้ามจะเสีย y ” ซึ่งวิธีการเรียนรู้กฎจะกล่าวต่อไป กฎที่เรียนรู้ได้นี้สามารถใช้กับสถานการณ์อื่น ๆ นอกเหนือจากตัวอย่างสอนอีกด้วย กล่าวคือ x ไม่จำเป็นต้องเป็นม้า หรือ y ไม่จำเป็นต้องเป็นควีนนอกจากนั้นตำแหน่งของตัวหมากอื่น ๆ ที่ไม่เกี่ยวข้องกับมโนทัศน์นี้ก็จะไม่ปรากฏในกฎหมายความว่าตำแหน่งของตัวหมากอื่น ๆ จะอยู่ที่ใดก็ได้ที่ตรงกับตำแหน่งที่ตัวหมากเรากำลังโจมตีคิงและตัวหมากอีกตัวของฝ่ายตรงข้ามพร้อมกัน

6.6 การเรียนรู้โดยการอธิบาย

จะเห็นได้ว่าประสิทธิภาพของอ็อบีแอลสูงมากเพราะใช้ตัวอย่างแค่ตัวเดียวก็สามารถทำการวางนัยทั่วไปได้ สาเหตุที่สามารถทำได้เช่นนี้เนื่องจากว่าในอ็อบีแอลนี้เราต้องให้ความรู้ในโดเมนกับระบบเรียนรู้แบบนี้ด้วย ความรู้ในโดเมนของหมากรุกสากลก็อย่างเช่นกฎการเล่นหมากรุก ตัวหมากแต่ละตัวเดินอย่างไร ม้า คิง ควีน เดินอย่างไร การกินกันเกิดขึ้นได้เมื่อไร เกมจบเมื่อไร เป็นต้น ซึ่งกฎเหล่านี้เราสามารถให้ได้ไม่ยากนักเพราะมีเขียนไว้ในหนังสืออธิบายวิธีเล่นหมากรุกอยู่แล้ว อย่างไรก็ตามแม้ว่าเราจะให้ความรู้ในโดเมนแล้วก็ได้ไม่ได้หมายความว่าเราไม่ต้องสอนอ็อบีแอล เปรียบเสมือนการเรียนรู้ของนักเรียนมัธยม แม้ว่าเราจะยกทฤษฎีเกี่ยวกับการเท่ากันของสามเหลี่ยมไปครบทุกทฤษฎีบท ก็ไม่ได้หมายความว่านักเรียนจะพิสูจน์การเท่ากันของสามเหลี่ยมสองรูปใดๆ ได้ทันที ครูก็ยังคงต้องยกตัวอย่างการพิสูจน์แสดงสามเหลี่ยม 2 รูปคู่หนึ่งๆ แล้วอธิบายว่าต้องใช้ทฤษฎีบทใดบ้างเพื่อการพิสูจน์และทำไมทฤษฎีบทเหล่านี้จึงพิสูจน์การเท่ากันของสามเหลี่ยมที่ยกตัวอย่างให้ดูได้ซึ่งจะช่วยให้นักเรียนเข้าใจได้ดีขึ้น และเมื่อทำโจทย์การพิสูจน์สามเหลี่ยม 2 รูปที่ใช้ทฤษฎีบทซึ่งเหมือนกับครูยกตัวอย่างก็จะทำโจทย์ได้

6.6 การเรียนรู้โดยการอธิบาย

กระบวนการเรียนรู้ของอ็อบีแอลประกอบด้วย

2 ขั้นตอนหลักคือ

- ใช้ความรู้ในโดเมนอธิบายให้ได้ว่าทำไมตัวอย่างจึงเป็นตัวอย่างของมโนทัศน์ในรูปแบบของกฎ
 - ทำการวางนัยทั่วไปของกฎที่ได้เพื่อให้ใช้กับกรณีอื่นได้
- อินพุตและเอาต์พุตของอ็อบีแอลเป็นดังตารางที่ 6-15
ต่อไปนี่

ตารางที่ 6-15 อินพุตและเอาต์พุตของอ็อบีแอล

อินพุต:

- ตัวอย่างสอน (training example) – ตัวอย่างบวกของมโนทัศน์ที่จะสอน เช่นในกรณีของ fork ตัวอย่างสอนคือตำแหน่งตัวหมากบนกระดานที่เกิด fork
- มโนทัศน์เป้าหมาย (goal concept) – มโนทัศน์ที่จะสอนเช่นมโนทัศน์ fork
- เกณฑ์ดำเนินการ (operational criterion) – คำอธิบายที่สามารถนำไปใช้ได้ทันที เช่นในกรณีของ fork นั้น เพอคิตเคต attack-both(WK_n,BK,BQ) ไม่สามารถนำไปใช้ได้ทันทีที่ต้องแสดงในรูปแบบของตำแหน่งตัวหมากบนกระดาน เช่น position(WK_n,f7), position(BK,h8), position(BQ,d8) เป็นต้น
- ความรู้ในโดเมน (domain knowledge) – กฎต่างๆ ที่ใช้แสดงความสัมพันธ์ของวัตถุและการกระทำต่างๆ ในโดเมนนั้น เช่น กฎการเล่นหมากรุกกลาก เป็นต้น


เอาต์พุต:

- การวางนัยทั่วไปของตัวอย่างสอนซึ่งเพียงพอสำหรับอธิบายมโนทัศน์เป้าหมายและสอดคล้องกับเกณฑ์ดำเนินการ

6.7 ข่ายงานประสาทเทียม

ข่ายงานประสาทเทียม (Artificial Neural Network) เป็นการจำลองการทำงานบางส่วนของสมองมนุษย์ เซลล์ประสาท (neuron) ในสมองของเราประกอบด้วยนิวเคลียส (nucleus) ตัวเซลล์ (cell body) โยประสาทนำเข้า (dendrite) แกนประสาทนำออก (axon) แสดงในรูปที่ 6-34


เดนไดรต์ทำหน้าที่รับสัญญาณไฟฟ้าเคมีซึ่งส่งมาจากเซลล์ประสาทใกล้เคียง เซลล์ประสาทตัวหนึ่งๆ จะเชื่อมต่อกับเซลล์ตัวอื่นๆ ประมาณ 10,000 ตัว เมื่อสัญญาณไฟฟ้าเคมีที่รับเข้ามาเกินค่าค่าหนึ่ง เซลล์จะถูกกระตุ้นและส่งสัญญาณไปทางแกนประสาทนำออกไปยังเซลล์อื่นๆ ต่อไป ประมาณกันว่าสมองของคนเรามีเซลล์ประสาทอยู่ทั้งสิ้นประมาณ 10¹¹ ตัว



รูปที่ 6-34 เซลล์ประสาท

6.7.1 เพอร์เซปตรอน


เพอร์เซปตรอน (perceptron) เป็นขบวนการประสาทเทียมแบบง่ายมีหน่วยเดียวที่จำลองลักษณะของเซลล์ประสาทดังรูปที่ 6-35




รูปที่ 6-35 เพอร์เซปตรอน

6.7.1 เพอร์เซปตรอน

เพอร์เซปตรอนรับอินพุตเป็นเวกเตอร์จำนวนจริงแล้วคำนวณหาผลรวมเชิงเส้น (linear combination) แบบถ่วงน้ำหนักของอินพุต (x_1, x_2, \dots, x_n) โดยที่ค่า w_1, w_2, \dots, w_n ในรูปเป็นค่าน้ำหนักของอินพุตและให้เอาต์พุต (o) เป็น 1 ถ้าผลรวมที่ได้มีค่าเกินค่าขีดแบ่ง (θ) และ เป็น -1 ถ้าไม่เกิน ส่วน w_0 ในรูปเป็นค่าลบของค่าขีดแบ่งดังจะได้อธิบายต่อไป และ x_0 เป็นอินพุตเทียมกำหนดให้มามีค่าเป็น 1 เสมอ



ในรูปแสดงฟังก์ชันกระตุ้น (activation function) ชนิดที่เรียกว่าฟังก์ชันสองขั้ว (bipolar function) ซึ่งแสดงผลของเอาต์พุตเป็น 1 กับ -1 ฟังก์ชันกระตุ้นอื่นๆ ที่นิยมใช้ก็อย่างเช่น ฟังก์ชันไบนารี (binary function) ซึ่งแสดงผลของเอาต์พุตเป็น 1 กับ 0 และเขียน



แทนด้วยรูป

เราสามารถแสดงเอาต์พุต (o) ในรูปของฟังก์ชันของอินพุต (x_1, x_2, \dots, x_n) ได้ดังนี้

$$o(x_1, x_2, \dots, x_n) = \begin{cases} 1 & \text{if } w_1x_1 + w_2x_2 + \dots + w_nx_n > \theta \\ -1 & \text{if } w_1x_1 + w_2x_2 + \dots + w_nx_n < \theta \end{cases} \quad (6.7)$$

6.7.1 เพอร์เซปตรอน

เอาต์พุตเป็นฟังก์ชันของอินพุตในรูปของผลรวมเชิงเส้นแบบถ่วงน้ำหนัก น้ำหนักจะเป็นตัวกำหนดว่าในจำนวนอินพุตนั้น อินพุต (X_i) ตัวใดมีความสำคัญต่อการกำหนดค่าเอาต์พุตตัวที่มีความสำคัญมากจะมีค่าสัมบูรณ์ของน้ำหนักมาก ส่วนตัวที่มีความสำคัญน้อยจะมีค่าใกล้ศูนย์ ในกรณีที่ผลรวมเท่ากับค่าขีดแบ่งค่าเอาต์พุตไม่นิยาม (จะเป็น 1 หรือ -1 ก็ได้) จากฟังก์ชันในสูตรที่ (6.7) เราจัดรูปใหม่โดยย้าย θ ไปรวมกับผลรวมเชิงเส้นแล้วแทน $-\theta$ ด้วย w_0 เราจะได้ฟังก์ชันของเอาต์พุตดังด้านล่างนี้

$$o(x_1, x_2, \dots, x_n) = \begin{cases} 1 & \text{if } w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n > 0 \\ -1 & \text{if } w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n < 0 \end{cases} \quad (6.8)$$

กำหนดให้ $g(\vec{x}) = \sum_{i=0}^n w_i x_i = \vec{w} \cdot \vec{x}$ โดยที่ \vec{x} แทนเวกเตอร์อินพุต เราสามารถเขียนฟังก์ชันของเอาต์พุตได้ใหม่ดังนี้

$$o(x_1, x_2, \dots, x_n) = \begin{cases} 1 & \text{if } g(\vec{x}) > 0 \\ -1 & \text{if } g(\vec{x}) < 0 \end{cases} \quad (6.9)$$

6.7.1 เพอร์เซปตรอน

สมมติว่าเรามีอินพุตสองตัวคือ x_1 และ x_2 ซึ่งแสดงค่าส่วนสูงและน้ำหนักของเด็กนักเรียนประถมและหลังจากที่แพทย์ตรวจร่างกายของเด็กโดยละเอียดแล้วได้จำแนกนักเรียนออกเป็นสองกลุ่มคือเด็กอ้วนและเด็กไม่อ้วน เราให้เอาต์พุตเป็นค่าที่แสดงเด็กอ้วนแทนด้วย +1 กับไม่อ้วนแทนด้วย -1 ดังตารางที่ 6-16

ตารางที่ 6-16 ข้อมูลเด็กอ้วนและเด็กไม่อ้วน

เด็กคนที่	ส่วนสูง (ซม.)	น้ำหนัก (กก.)	อ้วน/ไม่อ้วน
1	100.0	20.0	-1
2	100.0	26.0	1
3	100.0	30.4	1
4	100.0	32.4	1
5	101.6	27.0	1
6	101.6	32.0	1
7	102.0	21.0	-1
8	103.6	29.6	1
9	104.4	30.4	1
10	104.9	22.0	-1
11	105.2	20.0	-1
12	105.6	34.4	1
13	107.2	32.4	1
14	109.9	34.9	1
15	111.0	25.4	-1
16	114.2	23.5	-1
17	115.5	36.3	1
18	117.8	26.9	-1

6.7.2 ตัวอย่างการเรียนรู้ฟังก์ชัน **AND** และ **XOR** ด้วยกฎการเรียนรู้เพอร์เซปตรอน

พิจารณาตัวอย่างการเรียนรู้ของเพอร์เซปตรอนโดยจะให้เรียนรู้ฟังก์ชัน 2 ฟังก์ชัน ฟังก์ชันแรกคือฟังก์ชัน AND แสดงในตารางที่ 6-18 ในกรณีนี้เราใช้ฟังก์ชันไบนารีเป็นฟังก์ชันกระตุ้น

ตารางที่ 6-18 ฟังก์ชัน AND(x_1, x_2)

x_1	x_2	เอาต์พุตเป้าหมาย
0	0	0
0	1	0
1	0	0
1	1	1

ฟังก์ชัน AND ตามตารางด้านบนนี้จะให้ค่าที่เป็นจริงก็ต่อเมื่อ x_1 และ x_2 เป็นจริงทั้งคู่ (ดูที่สดมภ์เอาต์พุตเป้าหมาย) ผลการใช้กฎการเรียนรู้เพอร์เซปตรอนกับฟังก์ชัน AND แสดงในตารางที่ 6-19

ตารางที่ 6-19 ผลการเรียนรู้ฟังก์ชัน AND โดยกฎการเรียนรู้เพอร์เซปตรอน

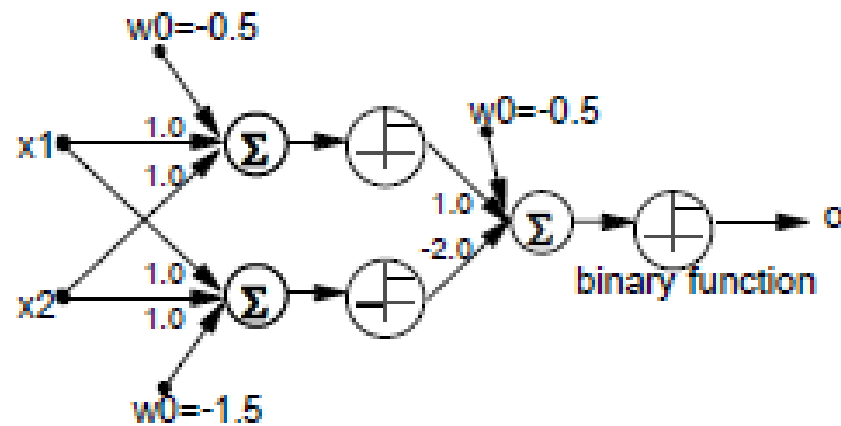
Perceptron Learning Example - Function AND											
		Bias Input $x_0=+1$					Alpha = 0.5				
Input	Input				Net Sum	Target	Actual	Alpha*	Weight Values		
x_1	x_2	$1.0*w_0$	x_1*w_1	x_2*w_2	Input	Output	Output	Error	w_0	w_1	w_2
									0.1	0.1	0.1
0	0	0.10	0.00	0.00	0.10	0	1	-0.50	-0.40	0.10	0.10
0	1	-0.40	0.00	0.10	-0.30	0	0	0.00	-0.40	0.10	0.10
1	0	-0.40	0.10	0.00	-0.30	0	0	0.00	-0.40	0.10	0.10
1	1	-0.40	0.10	0.10	-0.20	1	0	0.50	0.10	0.60	0.60
0	0	0.10	0.00	0.00	0.10	0	1	-0.50	-0.40	0.60	0.60
0	1	-0.40	0.00	0.60	0.20	0	1	-0.50	-0.90	0.60	0.10
1	0	-0.90	0.60	0.00	-0.30	0	0	0.00	-0.90	0.60	0.10
1	1	-0.90	0.60	0.10	-0.20	1	0	0.50	-0.40	1.10	0.60
0	0	-0.40	0.00	0.00	-0.40	0	0	0.00	-0.40	1.10	0.60
0	1	-0.40	0.00	0.60	0.20	0	1	-0.50	-0.90	1.10	0.10
1	0	-0.90	1.10	0.00	0.20	0	1	-0.50	-1.40	0.60	0.10
1	1	-1.40	0.60	0.10	-0.70	1	0	0.50	-0.90	1.10	0.60
0	0	-0.90	0.00	0.00	-0.90	0	0	0.00	-0.90	1.10	0.60
0	1	-0.90	0.00	0.60	-0.30	0	0	0.00	-0.90	1.10	0.60
1	0	-0.90	1.10	0.00	0.20	0	1	-0.50	-1.40	0.60	0.60
1	1	-1.40	0.60	0.60	-0.20	1	0	0.50	-0.90	1.10	1.10
0	0	-0.90	0.00	0.00	-0.90	0	0	0.00	-0.90	1.10	1.10
0	1	-0.90	0.00	1.10	0.20	0	1	-0.50	-1.40	1.10	0.60
1	0	-1.40	1.10	0.00	-0.30	0	0	0.00	-1.40	1.10	0.60
1	1	-1.40	1.10	0.60	0.30	1	1	0.00	-1.40	1.10	0.60
0	0	-1.40	0.00	0.00	-1.40	0	0	0.00	-1.40	1.10	0.60
0	1	-1.40	0.00	0.60	-0.80	0	0	0.00	-1.40	1.10	0.60
1	0	-1.40	1.10	0.00	-0.30	0	0	0.00	-1.40	1.10	0.60
1	1	-1.40	1.10	0.60	0.30	1	1	0.00	-1.40	1.10	0.60

6.7.2 ตัวอย่างการเรียนรู้ฟังก์ชัน **AND** และ **XOR** ด้วยกฎการเรียนรู้เพอร์เซปตรอน

ขั้นตอนแรกเริ่มจากการสุ่มค่า w_0 จนถึง w_2 ในที่นี้กำหนดให้เป็น 0.1 ทั้งสามตัว จากนั้นก็เริ่มป้อนตัวอย่างเข้าไป (ทีละแถว) ตัวอย่างแรกได้ผลรวมเชิงเส้น (Net Sum) เป็น 0.10 ซึ่งมากกว่า 0 ดังนั้นเพอร์เซปตรอนจะให้เอาต์พุตจริง (Actual Output) ออกมาเป็น 1 ซึ่งผิดเพราะเอาต์พุตเป้าหมาย (Target Output) จะต้องได้เป็น 0 ทำให้อัตราการเรียนรู้คูณค่าผิดพลาด (Alpha x Error) ได้ -0.50 หลังจากนั้นก็นำไปปรับน้ำหนักตาม $w_i \leftarrow w_i + \Delta w_i$ และ $\Delta w_i \leftarrow \alpha(t-o)x_i$ ดังนั้นจะได้เป็น $w_0 \leftarrow w_0 + \alpha(t-o)x_0 = w_0 + 0.50(-1) \times 1 = 0.10 + (-0.5) = -0.4$ ต่อก็ปรับค่า w_1 ในทำนองเดียวกัน $w_1 \leftarrow w_1 + \alpha(t-o)x_1 = w_1 + 0.50(-1) \times 0$ ดังนั้น w_1 จะเท่ากับ 0.10 คือไม่เปลี่ยนแปลง เช่นเดียวกับ w_2 ที่ไม่เปลี่ยนแปลง จะเห็นได้ว่าแม้มีค่าผิดพลาดแต่ไม่มีการปรับค่า w_1 และ w_2 เนื่องจากอินพุตที่ใส่เข้าไปเป็น 0 ทำให้ผลคูณเป็น 0 จึงไม่ได้ปรับ และเป็นข้อเสียของฟังก์ชันกระตุ้นแบบไบนารีซึ่งถ้าผลออกมาเป็น 0 จะไม่มีการปรับค่าให้ (ถ้าเราเปลี่ยน 0 เป็น -1 การปรับค่าจะดีขึ้น w_i จะถูกปรับทันทีตั้งแต่รอบแรก)

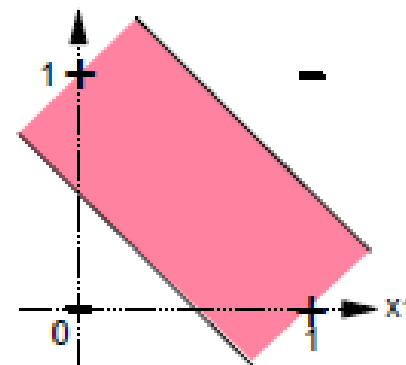
6.7.3 ข่ายงานหลายชั้นและการแพร่กระจายย้อนกลับ

จากข้างต้นจะเห็นว่าเพอร์เซปตรอนสามารถเรียนรู้ฟังก์ชันแยกได้เชิงเส้นเท่านั้น ในส่วนนี้จะอธิบายการนำเพอร์เซปตรอนหลายๆ ตัวมาเชื่อมต่อกัน เพื่อสร้างเป็นข่ายงานประสาทหลายชั้น (multilayer neural network) ที่สามารถแสดงผิวตัดสินใจไม่เชิงเส้น (non-linear decision surface) เพื่อให้เห็นถึงประสิทธิภาพของข่ายงานหลายชั้น จะยกตัวอย่างการต่อเพอร์เซปตรอน 3 ตัวเข้าด้วยกันเพื่อเรียนรู้ฟังก์ชัน XOR ดังแสดงในรูปที่ 6-41



6.7.3 ข่ายงานหลายชั้นและการแพร่กระจายย้อนกลับ

รูปที่ 6-41 แสดงการเชื่อมต่อเพอร์เซปตรอน 3 ตัวเข้าด้วยกัน เพอร์เซปตรอนสองตัวแรกรับอินพุตโดยตรงส่วนเพอร์เซปตรอนตัวที่สามรับอินพุตจากเอาต์พุตของเพอร์เซปตรอนสองตัวแรก จะเห็นได้ว่าเพอร์เซปตรอนตัวแรกที่อยู่ด้านซ้ายบนของรูปนั้นแทนฟังก์ชันเชิงเส้น $x_1 + x_2 = 0.5$ ส่วนเพอร์เซปตรอนตัวที่สองที่อยู่ด้านซ้ายล่างของรูปนั้นแทนฟังก์ชันเชิงเส้น $x_1 + x_2 = 1.5$ ฟังก์ชันเชิงเส้นทั้งสองมีความชันเท่ากันเท่ากับ -1 แต่มีจุดตัดแกนต่างกันดังแสดงในรูปที่ 6-42 ส่วนเพอร์เซปตรอนตัวที่สามทำหน้าที่รวมผลลัพธ์จากเพอร์เซปตรอนสองตัวแรก และโดยการกำหนดเวกเตอร์น้ำหนักที่เหมาะสมของเพอร์เซปตรอนตัวที่สามทำให้ได้ผลลัพธ์ที่อยู่ที่ระหว่างเส้นตรงทั้งสองเป็นตัวอย่างบวกและที่อยู่ด้านนอกเป็นตัวอย่างลบ




x_1	x_2	$x_1 \text{ XOR } x_2$
0	0	0
0	1	1
1	0	1
1	1	0

รูปที่ 6-42 ผิดตัดสินใจของข่ายงานในรูปที่ 6-41


6.7.3 ข่ายงานหลายชั้นและการแพร่กระจายย้อนกลับ

ในการเชื่อมต่อครั้งนี้ใช้ฟังก์ชันกระตุ้นแบบไบนารีเพื่อให้
ง่ายต่อการทำความเข้าใจ แต่การคำนวณหาอนุพันธ์เรียนรู้สำหรับ
ข่ายงานหลายชั้นต้องใช้ฟังก์ชันกระตุ้นที่หาอนุพันธ์ได้ดังนั้นเราจะ
ไม่ใช้ฟังก์ชันไบนารีกับข่ายงานหลายชั้น แต่จะใช้ฟังก์ชันเชิงเส้นหรือ
อาจใช้ฟังก์ชันซิกมอยด์ (sigmoid function) ดังแสดงในรูปที่ 6-43



รูปที่ 6-43 ฟังก์ชันซิกมอยด์

เพอร์เซปตรอนที่ใช้ฟังก์ชันกระตุ้นเป็นฟังก์ชันซิกมอยด์แสดงในรูปที่ 6-44




รูปที่ 6-44 เพอร์เซปตรอนที่ใช้ฟังก์ชันซิกมอยด์

6.7.3 ข่ายงานหลายชั้นและการแพร่กระจายย้อนกลับ

คุณสมบัติหนึ่งของฟังก์ชันซิกมอยด์ก็คือสามารถแสดงอนุพันธ์ของฟังก์ชันในรูปของเอาต์พุตได้อย่างง่าย กล่าวคือ

$$\frac{d\sigma(y)}{dy} = \sigma(y)(1 - \sigma(y))$$

อัลกอริทึมการแพร่กระจายย้อนกลับ(backpropagation algorithm) [Rumelhart & McClelland, 1986] เรียนรู้ค่าเวกเตอร์น้ำหนักสำหรับข่ายงานป้อนไปหน้าแบบหลายชั้น (multilayer feedforward network) โดยใช้ในการเคลื่อนลงตามความชันเพื่อหาค่าต่ำสุดของค่าผิดพลาดระหว่างเอาต์พุตของข่ายงานกับเอาต์พุตเป้าหมาย ตัวอย่างของข่ายงานป้อนไปหน้าแบบหลายชั้นแสดงในรูปที่ 6-45



รูปที่ 6-45 ตัวอย่างข่ายงานป้อนไปหน้าแบบหลายชั้น

6.7.3 ข่ายงานหลายชั้นและการแพร่กระจายย้อนกลับ

ตัวอย่างในรูปแบบบนแสดงข่ายงานป้อนไปหน้าแบบหลายชั้นซึ่งประกอบด้วยชั้นอินพุตชั้นฮิดเดนหรือชั้นซ่อน และชั้นเอาต์พุต ในรูปแสดงชั้นฮิดเดนเพียงชั้นเดียวแต่อาจมีมากกว่าหนึ่งชั้นก็ได้ เส้นเชื่อมจะเชื่อมต่อเป็นชั้นๆ ไม่ข้ามชั้น จากชั้นอินพุตไปชั้นฮิดเดน ถ้ามีชั้นฮิดเดนมากกว่าหนึ่งชั้นก็เชื่อมต่อกันไป และสุดท้ายจากชั้นฮิดเดนไปชั้นเอาต์พุต ข่ายงานป้อนไปหน้าแบบหลายชั้นนี้จะไม่มีการเชื่อมต่อย้อนกลับจะมีแต่เส้นเชื่อมไปข้างหน้าอย่างเดียวเช่นไม่มีเส้นเชื่อมจาก บัพในชั้นเอาต์พุตส่งกลับมายังบัพในชั้นฮิดเดนหรือชั้นอินพุต เป็นต้น

6.8 การเรียนรู้แบบเบย์

การเรียนรู้แบบเบย์ (Bayesian learning) เป็นวิธีการเรียนรู้ที่ใช้ทฤษฎีความน่าจะเป็นซึ่งมีพื้นฐานมาจากทฤษฎีของเบย์ (Bayes theorem) เข้ามาช่วยในการเรียนรู้ จุดมุ่งหมายก็เพื่อต้องการสร้างโมเดลที่อยู่ในรูปของความน่าจะเป็น ซึ่งเป็นค่าที่บันทึกได้จากการสังเกตจากนั้นนำโมเดลมาหาว่าสมมติฐานใดถูกต้องที่สุดโดยใช้ความน่าจะเป็นเข้ามาช่วย ข้อดีก็คือเราสามารถใช้อุปกรณ์และความรู้ก่อนหน้า (prior knowledge) เข้ามาช่วยในการเรียนรู้ได้ด้วย ความรู้ก่อนหน้าหมายถึงความรู้ที่เรามีเกี่ยวกับสมมติฐานแต่ละตัวก่อนที่เราจะเก็บข้อมูล เมื่อใช้งานเราจะนำความน่าจะเป็นของข้อมูลที่เก็บได้มาปรับสมมติฐานซ้ำอีกครั้ง ซึ่งพบว่าวิธีนี้ให้ประสิทธิภาพในการเรียนรู้ได้ดีไม่ด้อยกว่าวิธีการเรียนรู้ประเภทอื่น

6.8.1 ทฤษฎีของเบย์

กำหนดให้ A และ B เป็นเหตุการณ์ใดๆ ความน่าจะเป็นของ A เมื่อรู้ B (ความน่าจะเป็นที่จะเกิดเหตุการณ์ A โดยมีเงื่อนไขว่าเหตุการณ์ B ได้เกิดขึ้นแล้ว) เขียนแทนด้วย $P(A|B)$ สามารถคำนวณได้ด้วยทฤษฎีของเบย์ดังนี้

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

กล่าวคือความน่าจะเป็นของ A เมื่อรู้ B (โดยมีเงื่อนไขว่า B เกิดขึ้นแล้ว) สามารถคำนวณได้จากผลคูณของความน่าจะเป็นของ B เมื่อรู้ A กับความน่าจะเป็นของ Aหารด้วยความน่าจะเป็นของ B เราเรียก $P(A)$ ว่าเป็นความน่าจะเป็นก่อน (*prior probability*) และเรียก $P(A|B)$ ว่าเป็นความน่าจะเป็นภายหลัง (*posterior probability*) ความน่าจะเป็นก่อนเป็นค่าที่ได้จากข้อมูลเบื้องต้น ส่วนความน่าจะเป็นภายหลังเป็นค่าความน่าจะเป็นก่อนที่ถูกปรับด้วยข้อมูลที่เพิ่มขึ้น

6.8.1 ทฤษฎีของเบส์

ในกรณีของการเรียนรู้ของเครื่องนั้น สิ่งที่เราสนใจก็คือเมื่อเรามีชุดข้อมูลหรือเซตของตัวอย่างสอน D เราต้องการหาค่าความน่าจะเป็นที่สมมติฐาน (h) ที่เราสนใจว่ามีโอกาสจะเกิดขึ้นเท่าไร เราก็สามารถใช้ทฤษฎีของเบส์ในการคำนวณได้ดังนี้

$$P(h|D) = \frac{P(D|h)P(h)}{P(D)}$$

โดยที่ $P(h)$ คือความน่าจะเป็นก่อนซึ่งเป็นความน่าจะเป็นที่สมมติฐาน h จะเป็นจริงโดยที่เรายังไม่ได้ดูข้อมูลตัวอย่างสอน ส่วน $P(h|D)$ เป็นความน่าจะเป็นภายหลังซึ่งเป็นความน่าจะเป็นที่สมมติฐาน h จะเป็นจริงโดยมีเงื่อนไขว่า D เป็นจริง (เราเห็นข้อมูลตัวอย่างสอน D แล้ว) ในการเรียนรู้ของเครื่อง เราต้องการคำนวณความน่าจะเป็นภายหลังนี้ ซึ่งมักจะหาไม่ได้โดยตรง แต่ถ้าเราใช้ทฤษฎีของเบส์ข้างต้นความน่าจะเป็นนี้จะคำนวณได้ง่ายขึ้นโดยใช้นิพจน์ทางด้านขวามือของสูตรที่ (6.16)

6.8.1 ทฤษฎีของเบส์

ยกตัวอย่างเช่นถ้าเรามีต้นไม้ตัดสินใจหลายๆ ต้นและอยากทราบว่าแต่ละต้นมีโอกาสเกิดขึ้นหรือมีความถูกต้องเท่าไร ก็คือเราต้องการหา $P(h|D)$ นั่นเอง โดยที่ h แทนต้นไม้ตัดสินใจต้นหนึ่งที่เรากำลังพิจารณา เราอาจจะมีมติว่าต้นไม้ต้นเล็กมีโอกาสที่จะเป็นจริงมากกว่าต้นไม้ใหญ่ (คล้ายกับกฎของอ็อกแคม) นั่นคือเรามีความน่าจะเป็นก่อน $P(h)$ ที่ต้นไม้จะเป็นจริงโดยยังไม่ได้ดูตัวอย่างสอน ซึ่งจะให้ค่าความน่าจะเป็นของต้นไม้ต้นเล็กมีค่ามากกว่าของต้นไม้ต้นใหญ่ เมื่อเรารับตัวอย่างสอนแล้วนำมาปรับค่าความน่าจะเป็นก่อน ได้เป็นความน่าจะเป็นภายหลัง ส่วน $P(D|h)$ เป็นความน่าจะเป็นที่ D จะเป็นจริงเมื่อรู้ว่า h เป็นจริง ความน่าจะเป็นค่านี้สามารถวัดได้โดยนำตัวอย่างสอนมาตรวจสอบกับต้นไม้ h ว่าในจำนวนตัวอย่างสอนทั้งหมดนั้นมีอัตราส่วนของตัวอย่างที่ตรงหรือสอดคล้องกับต้นไม้เท่าไร ส่วน $P(D)$ เป็นความน่าจะเป็นที่เซตตัวอย่างสอนจะเป็นจริง ซึ่งในการหา h ที่ดีที่สุดนั้นโดยมากเรามักละค่านี้ได้โดยไม่ต้องนำมาคำนวณดังจะกล่าวต่อไป ดังนั้นจะเห็นได้ว่าการใช้ทฤษฎีของเบส์สามารถใช้คำนวณความน่าจะเป็นของสมมติฐานแต่ละตัว เมื่อรู้ว่าเซตตัวอย่างสอนเป็นจริงซึ่งจะช่วยให้เราเลือกสมมติฐานที่ดีที่สุดได้

6.8.1 ทฤษฎีของเบส์

เราเรียกสมมติฐานที่ดีที่สุดว่า **สมมติฐานภายหลังมากที่สุด** - เอ็มเอพี (Maximum A Posterior hypothesis - MAP) ซึ่งนิยามให้เป็นดังนี้

$$\begin{aligned} h_{MAP} &= \arg \max_{h \in H} P(h | D) \\ &= \arg \max_{h \in H} \frac{P(D | h)P(h)}{P(D)} \end{aligned} \quad (6.17)$$

$$h_{MAP} = \arg \max_{h \in H} P(D | h)P(h) \quad (6.18)$$

โดยที่ H เป็นปริภูมิของสมมติฐานทั้งหมด $\arg \max f(x)$ เป็นฟังก์ชันที่คืนค่า x ที่ทำให้ $f(x)$ สูงสุด สมการที่ (6.17) ได้จากการใช้ทฤษฎีของเบส์และเนื่องจากว่าสำหรับ $h \in H$ ทุกตัวมีค่า $P(D)$ เท่ากันหมด ดังนั้นเราจึงสามารถละ $P(D)$ ได้และได้สมการที่ (6.18) กล่าวคือ h ที่ดีที่สุดตามเอ็มเอพีคือ h ที่ทำให้ค่า $P(D|h)P(h)$ มีค่าสูงสุด เทคนิคการเรียนรู้ของเครื่องหลายวิธีไม่ได้หาค่า h_{MAP} แต่มักหา h_{ML} (Maximum Likelihood hypothesis) ตั้งในสมการที่ (6.19) ด้านล่างนี้ ซึ่งหมายถึงสมมติฐานที่ตรงหรือสอดคล้องกับข้อมูลสอนมากที่สุดจะเป็นสมมติฐานที่ดีที่สุดโดยไม่ได้พิจารณาความน่าจะเป็นก่อน

$$h_{ML} = \arg \max_{h \in H} P(D | h)$$

6.8.2 สูตรพื้นฐานของความน่าจะเป็น

สูตรพื้นฐานเกี่ยวกับความน่าจะเป็น ที่จะใช้บ่อยครั้งในการเรียนรู้แบบเบย์มีดังต่อไปนี้

1. กฎผลคูณ (product rule): ความน่าจะเป็น $P(A \cap B)$ ที่สองเหตุการณ์ A และ B จะเกิดพร้อมกัน (หรือเขียนย่อเป็น $P(A, B)$) มีค่าเท่ากับ $P(A \cap B) = P(A|B)P(B) = P(B|A)P(A)$

2. กฎผลรวม (sum rule): ความน่าจะเป็น $P(A \cup B)$ ที่เหตุการณ์ A หรือ B เหตุการณ์ใดเหตุการณ์หนึ่งจะเกิดหรือเกิดพร้อมกันมีค่าเท่ากับ $P(A \cup B) = P(A) + P(B) - P(A \cap B)$

3. ทฤษฎีความน่าจะเป็นทั้งหมด (theorem of total probability) ถ้าเหตุการณ์ A_1, \dots, A_n ไม่เกิดร่วมกันและ $\sum_{i=1}^n P(A_i) = 1$ แล้ว ความน่าจะเป็น $P(B)$ มีค่าเท่ากับ

$$P(B) = \sum_{i=1}^n P(B | A_i) P(A_i)$$

4. กฎลูกโซ่ (chain rule): A_1, \dots, A_n เป็นเหตุการณ์ n เหตุการณ์จะได้ว่าความน่าจะเป็นรวม $P(A_1, \dots, A_n)$ มีค่าเท่ากับ

$$P(A_1, A_2, \dots, A_n) = \sum_{i=1}^n P(A_i | A_1, \dots, A_{i-1})$$

6.8.3 การจำแนกประเภทที่น่าจะเป็นที่สุดสำหรับตัวอย่าง

ดังที่กล่าวข้างต้น ในกรณีที่กำหนดให้เราใช้สมมติฐานได้เพียงข้อเดียวในการจำแนกประเภทของตัวอย่าง จะได้ว่า hMAP เป็นสมมติฐานที่ดีที่สุด แต่การจำแนกประเภทของตัวอย่างด้วย hMAP ไม่ใช่การจำแนกประเภทที่น่าจะเป็นที่สุด (*most probable classification*) สำหรับตัวอย่างนั้น ในบางกรณีที่เราสามารถใช้อสมมติฐานหลายข้อ เราสามารถจำแนกประเภทของตัวอย่างได้ดีกว่าการใช้ hMAP ตัวเดียว สมมติว่าเรามีสมมติฐาน 3 ข้อ แต่ละข้อมีค่าความน่าจะเป็นภายหลังดังต่อไปนี้ $P(h_1|D) = 0.4$ $P(h_2|D) = 0.3$ $P(h_3|D) = 0.3$ และเมื่อให้ตัวอย่าง x ผลการจำแนกประเภทของสมมติฐานเป็นดังนี้ $h_1(x) = +$ $h_2(x) = -$ $h_3(x) = -$

6.8.4 ตัวจำแนกประเภทเบส์อย่างง่าย

ตัวจำแนกประเภทเบส์อย่างง่าย (*naive Bayes classifier*) เป็นตัวจำแนกประเภทแบบหนึ่งที่ใช้งานได้ดี เหมาะกับกรณีของเซตตัวอย่างมีจำนวนมากและคุณสมบัติ (attribute) ของตัวอย่างไม่ขึ้นต่อกัน มีการนำตัวจำแนกประเภทเบส์อย่างง่ายไปประยุกต์ใช้งานในด้านการจำแนกประเภทข้อความ (text classification) การวินิจฉัย (diagnosis) และพบว่าใช้งานได้ดีไม่ต่างจากการจำแนกประเภทวิธีการอื่น เช่นการเรียนรู้ต้นไม้ตัดสินใจ ข่ายงานประสาทเป็นต้น

6.8.4 ตัวจำแนกประเภทเบสอย่างง่าย

สมมติให้ A_1, A_2, \dots, A_n เป็นคุณสมบัติของตัวอย่าง เราจะได้ว่าค่า (ประเภท) ที่น่าจะเป็นที่สุดของตัวอย่าง x คือ

$$\begin{aligned} v_{MAP} &= \arg \max_{v_j \in V} P(v_j | a_1, a_2, \dots, a_n) \\ &= \arg \max_{v_j \in V} \frac{P(a_1, a_2, \dots, a_n | v_j) P(v_j)}{P(a_1, a_2, \dots, a_n)} \\ v_{MAP} &= \arg \max_{v_j \in V} P(a_1, a_2, \dots, a_n | v_j) P(v_j) \end{aligned}$$

โดยที่ a_i ในสมการเป็นค่าของคุณสมบัติ A_i V เป็นเซตของประเภทหรือค่าที่เป็นไปได้ของ x สมการที่ (6.23) แสดงการหาประเภทที่ดีที่สุดของตัวอย่าง x แต่เราจะพบว่าสมการนี้ใช้งานไม่ได้อย่างมีประสิทธิภาพ เนื่องจากการคำนวณค่าของ $(, , , |) 1 2 n j P a a L a v$ ทำได้ยากลำบากมากเพื่อให้ได้ค่าที่น่าเชื่อถือในเชิงสถิติ ที่เป็นเช่นนี้เพราะว่าถ้าให้คุณสมบัติ A_i แต่ละตัวของตัวอย่างมีค่าที่เป็นไปได้ 10 ค่า และคุณสมบัติทั้งหมดมี 10 ตัว เราจะได้ว่ามีลำดับ a_1, a_2, \dots, a_n ที่เป็นไปได้ทั้งสิ้นเท่ากับ 10^{10} รูปแบบ ซึ่งหมายถึงว่าเราต้องหาตัวอย่างทั้งสิ้น 10^{10} ตัว จึงจะมีโอกาสพบรูปแบบหนึ่งๆ ของ a_1, a_2, \dots, a_n สักหนึ่งครั้งโดยประมาณ ดังนั้นถ้าต้องการให้ค่า $(, , , |) 1 2 n j P a a L a v$ มีความน่าเชื่อถือเชิงสถิติ เราต้องการตัวอย่างมากกว่า 10^{10} ตัวหลายเท่า ซึ่งการที่จะหาตัวอย่างจำนวนมากขนาดนั้นแทบจะทำได้จริงในทางปฏิบัติ เราจึงต้องการโมเดลที่จะคำนวณ $(, , , |) 1 2 n j P a a L a v$ ให้ได้ในเชิงปฏิบัติ

6.8.4 ตัวจำแนกประเภทเบสส์อย่างง่าย

มมตฐฐานของตัวจำแนกประเภทเบสส์อย่างง่ายคือ เรากำหนดให้คุณสมบัติแต่ละตัวไม่ขึ้น (เป็นอิสระ) กับคุณสมบัติอื่นๆ ซึ่งทำให้เราสามารถเขียนแทน $(a_1, a_2, \dots, a_n | v_j)$ ด้วยผลคูณของค่าความน่าจะเป็นด้านล่างนี้ที่หาค่าได้ง่ายขึ้น

$$P(a_1, a_2, \dots, a_n | v_j) = \prod_{i=1}^n P(a_i | v_j)$$

โดยที่ \prod หมายถึงการนำค่า $P(a_i | v_j)$ ทั้งหมดมาคูณกัน สูตรนี้ถ้าใช้กฎลูกโซ่มาคำนวณค่าความน่าจะเป็นที่ด้านซ้ายของสูตรจะได้เท่ากับ $P(a_1 | v_j) \times P(a_2 | a_1, v_j) \times P(a_3 | a_2, a_1, v_j) \times \dots \times P(a_n | a_{n-1}, a_{n-2}, \dots, a_1, v_j)$ ดังนั้นค่าความน่าจะเป็นทางด้านซ้ายของสมการจะเท่ากับผลคูณค่าความน่าจะเป็นทางด้านขวาก็คือต่อเมื่อคุณสมบัติ a_1, a_2, \dots, a_n ไม่ขึ้นต่อกัน เช่นสีผมไม่ขึ้นกับส่วนสูง ฯลฯ แต่ในความเป็นจริงแล้วคุณสมบัติส่วนใหญ่มักจะมีความสัมพันธ์กัน เช่นส่วนสูงกับน้ำหนัก เพราะถ้าตัวสูงน้ำหนักก็จะมากตามไปด้วย แต่อย่างไรก็ตามการใช้สมมติฐานความไม่ขึ้นต่อกัน (conditional independence assumption) นี้จะช่วยให้เราคำนวณค่าความน่าจะเป็นในสูตรที่ (6.24) ได้ง่ายขึ้น เพราะค่าความน่าจะเป็นของ a_i เมื่อรู้ v_j หาได้ง่ายกว่า เช่นถ้าจะหาคนผมสีน้ำตาล ส่วนสูงมาก น้ำหนักมากและไม่ใช้โลชั่นไปผึ่งแดดแล้วผิวจะไหม้หรือไม่

6.8.4 ตัวจำแนกประเภทเบส์อย่างง่าย

เมื่อเอาไปหาดูในฐานข้อมูลอาจจะมีโอกาสพบข้อมูลที่มีค่าครบทั้ง 4 ค่านี้น้อยมากๆ หรือต้องใช้จำนวนตัวอย่างมากมายมหาศาลถึงจะพบข้อมูลที่มีค่าครบตรงที่ต้องการ แต่ถ้าเราแยกคุณสมบัติออกจากกันเช่นหากคนผมสีน้ำตาลที่เป็นตัวอย่างบวก หรือหากคนไม่ใช่โลชั่นที่เป็นตัวอย่างบวก ทำให้ใช้ตัวอย่างไม่มากและได้คำตอบ ถึงแม้ว่าคำตอบที่ได้อาจจะไม่ถูกต้องสมบูรณ์แต่ก็พบว่าทำงานได้ดีในทางปฏิบัติดังนั้นเราจะได้ว่าตัวจำแนกประเภทแบบเบส์อย่างง่ายคือ

$$v_{NB} = \arg \max_{v_j \in V} P(v_j) \times \prod_{i=1}^n P(a_i | v_j) \quad (6.25)$$

จากสมการด้านบนนี้เราจะได้อัลกอริทึมการเรียนรู้เบส์อย่างง่ายดังตารางที่ 6-24

ตารางที่ 6-24 อัลกอริทึมการเรียนรู้เบส์อย่างง่าย

Algorithm: Naïve-Bayes

• **Naive_Bayes_Learn(examples)**

FOR EACH target value v DO

$\bar{P}(v_j) \leftarrow$ estimate $P(v_j)$

FOR EACH attribute value a_i of each attribute DO

$\bar{P}(a_i | v_j) \leftarrow$ estimate $P(a_i | v_j)$

• **Classify_New_Example(x)**

$$v_{NB} = \arg \max_{v_j \in V} \bar{P}(v_j) \times \prod_{i=1}^n \bar{P}(a_i | v_j)$$

ยกตัวอย่างการใช้อัลกอริทึมการเรียนรู้เบส์อย่างง่าย โดยใช้ชุดตัวอย่างสอนในตารางที่ 6-25 ต่อไปนี้

6.8.4 ตัวอย่างแจกประเภทเบสอย่างง่าย

ตารางที่ 6-25 ตัวอย่างสอนสำหรับการเรียนรู้เบสอย่างง่าย (เหมือนกับตารางที่ 6-13)

	Name	Hair	Height	Weight	Lotion	Result
<i>attribute</i> → <i>value</i> {	Sarah	blonde	average	light	no	Sunburned
	Dana	blonde	tall	average	yes	none
	Alex	brown	short	average	yes	none
	Annie	blonde	short	average	no	sunburned
	Emily	red	average	heavy	no	sunburned
	Pete	brown	tall	heavy	no	none
	John	brown	average	heavy	no	none
	Katie	blonde	short	light	yes	none

class ↓

สมมติว่าตัวอย่างที่ต้องการจำแนกประเภทคือ

Name	Hair	Height	Weight	Lotion	Result
Judy	blonde	average	heavy	no	?

คำนวณ $v_{NB} = \arg \max_{v_j \in V} P(v_j) \times \prod_{i=1}^n P(a_i | v_j)$ โดย $V = \{+, -\}$ เราจะได้ดังต่อไปนี้

กรณี $v_j = +$ ได้ว่า

$$P(+)\text{P}(\text{blonde}|+)\text{P}(\text{average}|+)\text{P}(\text{heavy}|+)\text{P}(\text{no}|+) = \frac{3}{8} \times \frac{2}{3} \times \frac{2}{3} \times \frac{1}{3} \times \frac{3}{3} = \frac{1}{18}$$

ส่วนกรณี $v_j = -$ ได้ว่า

$$P(-)\text{P}(\text{blonde}|-)\text{P}(\text{average}|-)\text{P}(\text{heavy}|-)\text{P}(\text{no}|-) = \frac{5}{8} \times \frac{2}{5} \times \frac{1}{5} \times \frac{2}{5} \times \frac{2}{5} = \frac{1}{125}$$

ดังนั้นได้ $v_{NB} = +$

6.8.4 ตัวจำแนกประเภทเบสส์อย่างง่าย

การเรียนรู้เพื่อจำแนกประเภทข้อความโดยเบสส์อย่างง่าย

ในการเรียนรู้เพื่อจำแนกประเภทข้อความโดยใช้เบสส์อย่างง่ายนี้ สมมติว่าเรามีข้อความที่เราสนใจกับไม่สนใจ เมื่อทำการเรียนรู้แล้ว เราต้องการทำนายว่าเอกสารหนึ่งๆ จะเป็นเอกสารที่เราสนใจหรือไม่ สามารถนำประยุกต์ใช้งานเช่นการกรองข่าวสารเลือกเฉพาะข่าวที่สนใจ เป็นต้น

ก่อนอื่นเราให้เอกสารหนึ่งๆ คือตัวอย่างหนึ่งตัว และเราแทนเอกสารแต่ละฉบับด้วยเวกเตอร์ของคำโดยใช้คำที่ปรากฏในเอกสาร เป็นคุณสมบัติของเอกสาร กล่าวคือคำที่หนึ่งในเอกสารเป็นคุณสมบัติตัวที่หนึ่ง คำที่สองในเอกสารเป็นคุณสมบัติตัวที่สอง ตามลำดับดังนั้นจะได้ว่า a_1 คือคำที่หนึ่ง a_2 คือคำที่สองตามลำดับ จากนั้นก็ทำการเรียนรู้โดยใช้ตัวอย่างสอนเพื่อประมาณค่าความน่าจะเป็นต่อไปนี้เป็นคือ

1. $P(+)$
2. $P(-)$
3. $P(doc|+)$
4. $P(doc|-)$

จากสมมติฐานเรื่องความไม่ขึ้นต่อกันของคุณสมบัติของเบสส์อย่างง่ายทำให้เราได้ว่า

$$P(doc | v_j) = \prod_{i=1}^{length(doc)} P(a_i = w_k | v_j)$$

6.8.4 ตัวจำแนกประเภทเบสส์อย่างง่าย

เมื่อ a_i คือคุณสมบัติตัวที่ i ส่วนค่าของมันคือ w_k (ค่าที่ k ในรายการของค่าที่เรามีอยู่) $P(a_i = w_k | v_j)$ คือความน่าจะเป็นที่ค่าในตำแหน่งที่ i เป็น w_k เมื่อรู้ v_j แต่พบว่าสูตรนี้ก็ยังไม่สามารถนำไปคำนวณยากเนื่องจากเหตุผลในทำนองเดียวกันกับสมมติฐานความไม่ขึ้นต่อกันข้างต้น จึงสร้างสมมติฐานเพิ่มเติมดังสมการที่ (6.27) เพื่อให้การคำนวณทำได้มีประสิทธิภาพในทางปฏิบัติ

$$P(a_i = w_k | v_j) = P(a_m = w_k | v_j), \forall i, m$$

หมายความว่าโอกาสที่เราจะเห็นค่าที่หนึ่งไปปรากฏที่ตำแหน่งใดๆ มีค่าเท่ากันหมด ทำให้การคำนวณง่ายขึ้น เพราะไม่ต้องสนใจว่าค่าหนึ่งๆ จะไปปรากฏในตำแหน่งใด หรือค่าแต่ละค่าจะไม่ขึ้นกับตำแหน่ง อัลกอริทึมสำหรับการจำแนกประเภทข้อความโดยใช้การเรียนรู้เบสส์อย่างง่ายเป็นดังตารางที่ 6-26 ต่อไปนี้

ตารางที่ 6-26 อัลกอริทึมการเรียนรู้แบบง่ายสำหรับจำแนกประเภทข้อความ

Algorithm: Learn_naive_Bayes_text(*Examples*, *V*)

1. Collect all words and other tokens that occur in *Examples*.
 - *Vocabulary* \leftarrow all distinct words and other tokens in *Examples*.
2. Calculate the required $P(v_j)$ and $P(w_k|v_j)$:
 - FOR EACH target value v_j in *V* DO
 - $docs_j \leftarrow$ subset of *Examples* for which the target value is v_j
 - $P(v_j) = \frac{|docs_j|}{Examples}$
 - $Text_j \leftarrow$ a single document created by concatenating all members of $docs_j$
 - $n \leftarrow$ total number of words in $Text_j$ (counting duplicate words multiple times)
 - FOR EACH word w_k in *Vocabulary* DO
 - $n \leftarrow$ number of times word w_k occurs in $Text_j$
 - $P(w_k | v_j) = \frac{n_k + 1}{n + |Vocabulary|}$

Algorithm: Classify_naive_Bayes_text(*Doc*)

- *positions* \leftarrow all word positions in *Doc* that contain tokens found in *Vocabulary*
- Return v_{NB}

$$v_{NB} = \arg \max_{v_j \in V} P(v_j) \times \prod_{i \in positions} P(a_i | v_j)$$

6.8.5 ข่ายงานความเชื่อเบสส์

ข่ายงานความเชื่อเบสส์ (Bayesian belief network) หรือเรียกโดยย่อว่าข่ายงานเบสส์ (Bayesnet) เป็นวิธีการเรียนรู้ที่ลดข้อจำกัดของการเรียนรู้เบสส์อย่างง่ายในสมมติฐานของความไม่ขึ้นต่อกันระหว่างคุณสมบัติ ในวิธีการเรียนรู้เบสส์อย่างง่ายในหัวข้อที่แล้วจะตั้งสมมติฐานว่าคุณสมบัติใดๆ ไม่ขึ้นต่อกัน แต่ในความเป็นจริงเราพบว่าคุณสมบัติบางตัวจะขึ้นต่อกันบ้างและควรที่จะนำความขึ้นต่อกันนี้เข้ามาใส่ไว้ในโมเดลด้วย เราจึงใช้ข่ายงานความเชื่อเบสส์ในการอธิบายความไม่ขึ้นต่อกันอย่างมีเงื่อนไข (condition independent) ระหว่างตัวแปร (ในบริบทของข่ายงานความเชื่อเบสส์นิยมใช้คำว่า ‘ตัวแปร’ (variable) แทนคำว่า ‘คุณสมบัติ’) และในโมเดลนี้เราสามารถใส่ (1) ความรู้ก่อน (prior knowledge) เกี่ยวกับความ(ไม่)ขึ้นต่อกันระหว่างตัวแปร ร่วมกับ (2) ตัวอย่างสอน เพื่อให้กระบวนการเรียนรู้มีประสิทธิภาพโดยเราสามารถใส่ความรู้ก่อนในข่ายงานความเชื่อเบสส์ให้อยู่ในรูปของโครงสร้างข่ายงานและตารางความน่าจะเป็นมีเงื่อนไข ดังจะกล่าวต่อไป

6.8.5 ข่ายงานความเชื่อเบสส์

นิยามที่ 5.1 ความไม่ขึ้นต่อกันอย่างมีเงื่อนไข

X ไม่ขึ้นกับ Y อย่างมีเงื่อนไขเมื่อรู้ Z ถ้าความน่าจะเป็นของ X ไม่ขึ้นกับค่าของ Y เมื่อรู้ค่าของ Z นั่นคือ

$$(\forall x_i, y_j, z_k) P(X=x_i | Y=y_j, Z=z_k) = P(X=x_i | Z=z_k)$$

หรือในรูปง่าย

$$P(X | Y, Z) = P(X | Z)$$

นิยามด้านบนนี้หมายความว่าสำหรับ x_i, y_j, z_k ใดๆ ความน่าจะเป็นที่ X จะมีค่าเป็น x_i (X เป็นตัวแปรส่วน x_i คือค่าของมัน) เมื่อรู้ว่า Y มีค่าเป็น y_j และ Z มีค่าเป็น z_k จะมีค่าเท่ากับความน่าจะเป็นของ X จะมีค่าเป็น x_i เมื่อรู้ว่า Z มีค่าเป็น z_k ในกรณีที่ความน่าจะเป็นทั้งสองเท่ากันเช่นนี้ เราเรียกว่าค่าของ X ไม่ขึ้นกับค่าของ Y อย่างมีเงื่อนไขเมื่อรู้ค่าของ Z เราจึงสามารถตัด Y ทิ้งไปได้

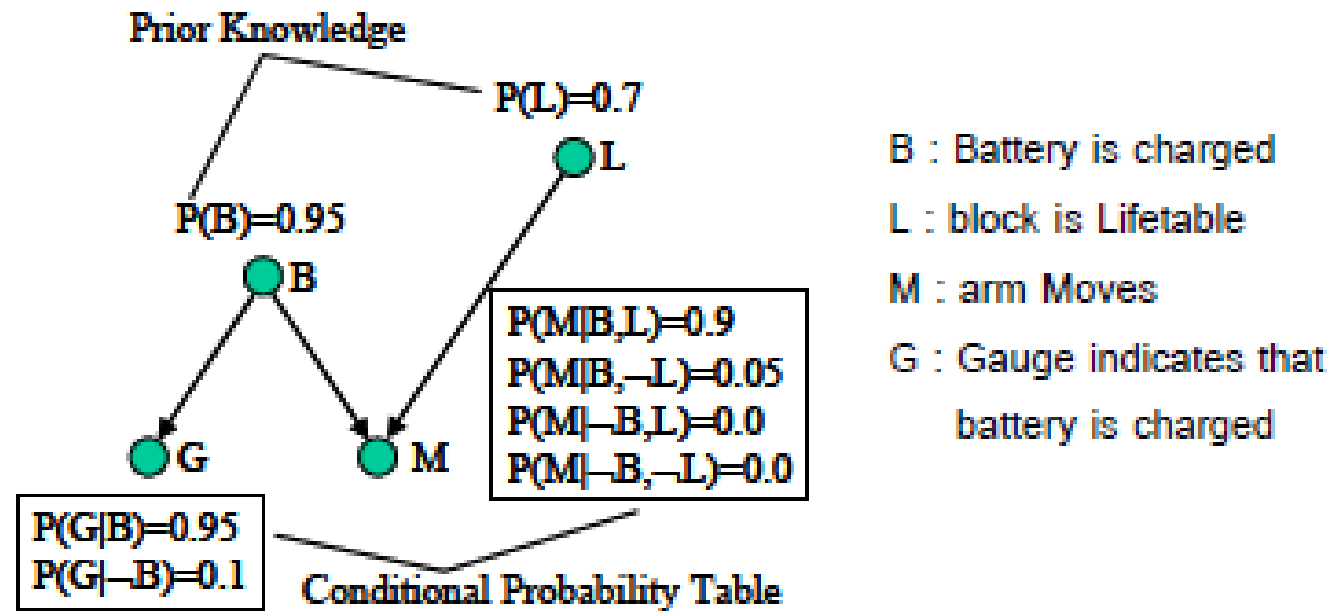
ตัวอย่างเช่นฟ้าร้องไม่ขึ้นกับฝนตกถ้ารู้ว่าฟ้าแลบ หรือเขียนได้เป็น

$$P(\text{Thunder} | \text{Rain, Lightning}) = P(\text{Thunder} | \text{Lightning})$$

ดังนั้นถ้ามีฟ้าแลบสามารถบอกได้เลยว่าจะต้องได้ยินเสียงฟ้าร้องด้วยความน่าจะเป็นเท่าไร โดยไม่ต้องสนใจว่าเกิดฝนตกหรือไม่

6.8.5 ข่ายงานความเชื่อเบสส์

จากความไม่ขึ้นต่อกันอย่างมีเงื่อนไขข้างต้น เราสร้างข่ายงานของเบสส์ได้ดังตัวอย่างในรูปที่ 6-46 ต่อไปนี้



รูปที่ 6-46 ตัวอย่างของข่ายงานเบสส์

6.8.6 การเรียนรู้ข่ายงานเบส

การเรียนรู้ข่ายงานเบสคือการหาโครงสร้างข่ายงานและ/หรือซีพีทีที่สอดคล้องกับตัวอย่างสอนมากที่สุด ปัญหาการเรียนรู้ข่ายงานเบสแบ่งออกเป็นกรณีดังต่อไปนี้

1. โครงสร้างไม่รู้ (structure unknown)
2. โครงสร้างรู้ (structure known)
 - 2.1 ข้อมูลมีค่าครบ (no missing value data)
 - 2.2 ข้อมูลมีค่าหาย (missing value data)

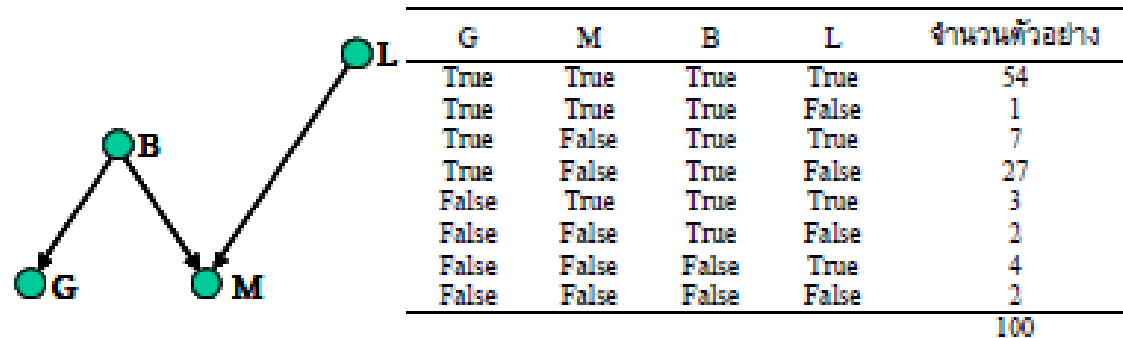
6.8.6 การเรียนรู้ข่ายงานเบสส์

กรณีที่ 1 เป็นกรณียากที่สุด เพราะเราไม่รู้ว่าโครงสร้างของข่ายงานเบสส์มีรูปร่างเป็นอย่างไรมีการเชื่อมต่อระหว่างบัพอย่างไร และแน่นอนว่าเราไม่รู้ค่าในซีพียูที่อีกด้วย ดังนั้นการเรียนรู้ต้องคำนวณหาทั้งโครงสร้างข่ายงานและซีพียูที่ ส่วนกรณีที่สองเป็นกรณีที่รู้โครงสร้างแล้ว ซึ่งบ่อยครั้งผู้เขียนข่ายงานเบสส์เป็นผู้เชี่ยวชาญในปัญหานั้นสามารถบอกโครงสร้างได้อย่างชัดเจน รู้ความสัมพันธ์ระหว่างตัวแปรในปัญหานั้นแต่อาจไม่รู้ค่าที่ถูกต้องและแม่นยำในตารางซีพียู ดังนั้นกรณีนี้การเรียนรู้เป็นการหาค่าในซีพียูที่โดยอาศัยตัวอย่างสอน กรณีที่สองนี้ยังแบ่งเป็นกรณีย่อยอีกสองกรณีคือ กรณีที่ข้อมูลหรือตัวอย่างสอนทุกตัวมีค่าครบถ้วน กับ อีกกรณีที่ตัวอย่างสอนบางตัวหรือทุกตัวมีค่าบางส่วนหายไป เช่นไม่มีค่าของคุณสมบัติบางตัว เป็นต้น กรณีที่ 2.1 เป็นกรณีที่ง่ายที่สุดสามารถทำการเรียนรู้ได้ในลักษณะเดียวกับการเรียนรู้ของตัว จำแนกประเภทเบสส์อย่างง่าย โดยนับจำนวนครั้งที่เกิดขึ้นของข้อมูลเพื่อไปคำนวณซีพียูที่ของแต่ละบัพว่ามีค่าเท่าไรดังจะ แสดงต่อไปนี้ ส่วนกรณีที่ 1 ไม่ขออธิบายในที่นี้

6.8.6 การเรียนรู้ข่ายงานเบส

การเรียนรู้ข่ายงานเบสในกรณีที่เราไม่รู้โครงสร้างและข้อมูลครบ

ดูตัวอย่างต่อไปนี้ เรานับความถี่ของการเกิดค่าต่างๆ ของ G, M, B, L ว่าเกิดขึ้นกี่ครั้งได้ดังรูปที่ 6-47 โดยที่สมมติว่าโครงสร้างถูกกำหนดแล้วดังรูปที่ 6-47



รูปที่ 6-47 ตัวอย่างสอนสำหรับเรียนรู้ซึ่พีทีในกรณีข้อมูลครบ

$$\text{จาก } P(V_i=v_i | \text{Parents}(V_i)=P_i) = \frac{\text{จำนวนตัวอย่างที่มี } V_i=v_i}{\text{จำนวนตัวอย่างที่มี Parents}(V_i)=P_i}$$

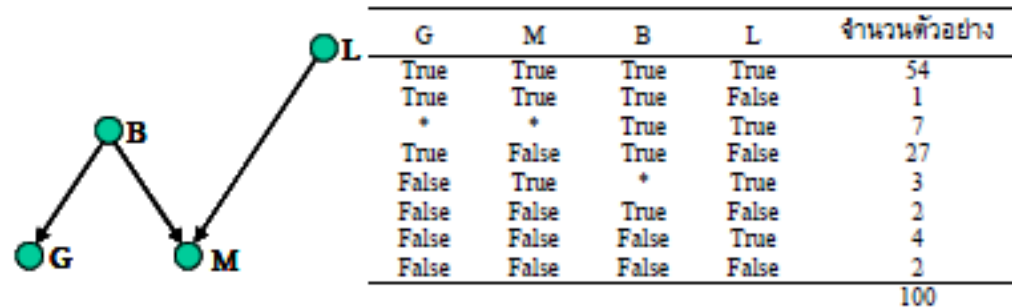
ดังนั้นจะได้ค่าความน่าจะเป็นต่างๆ ดังนี้

$$P(B=true) = (54+1+7+27+3+2)/100 = 0.94$$

6.8.6 การเรียนรู้ข่ายงานเบส

การเรียนรู้ข่ายงานเบสในกรณีที่โครงสร้างรู้และข้อมูลมีค่าหาย

กรณีต่อไปที่จะพิจารณาก็คือกรณีที่ข้อมูลบางตัวมีค่าบางค่าหายไปดังแสดงในรูปที่ 6-48 โดยที่สมมติว่ารู้โครงสร้างของข่ายงานเบสแล้ว



รูปที่ 6-48 ตัวอย่างสอนสำหรับเรียนรู้ซึฟิทีในกรณีข้อมูลมีค่าหาย

‘*’ ในตารางหมายถึงค่าหายไป พิจารณาแถวที่ห้าของข้อมูลในรูปซึ่งเป็นกรณีของตัวอย่าง 3 ตัวที่มีค่า $G=false$, $M=true$, $L=true$ ในกรณีนี้เราไม่รู้ค่าของ B แต่อาจคำนวณ $P(B|\neg G, M, L)$ หรือ $P(\neg B|\neg G, M, L)$ ได้ถ้าหากเรารู้ซึฟิที (แต่เรายังไม่รู้) สมมติว่าเรารู้ซึฟิทีซึ่งจะทำให้เราหาความน่าจะเป็นที่ B จะเป็นจริง (หรือเท็จ) ของตัวอย่างทั้ง 3 ตัวได้จากนั้นเราจะแทนที่ตัวอย่างทั้งสามนี้ด้วยตัวอย่างมีน้ำหนัก (weighted example) 2 ตัวดังนี้

- ตัวแรกคือตัวอย่างที่ $B=true$ มีน้ำหนักเท่ากับ $P(B|\neg G, M, L)$
- ตัวที่สองคือตัวอย่างที่ $B=false$ มีน้ำหนักเท่ากับ $P(\neg B|\neg G, M, L)$

6.8.6 การเรียนรู้ข่ายงานเบสส์

ในทำนองเดียวกัน กรณีของตัวอย่าง 7 ตัวในแถวที่สองที่มีค่า $B=true$, $L=true$ ส่วน G และ M ไม่รู้ค่านั้น เราสามารถแทนที่ตัวอย่างทั้งเจ็ดตัวด้วยตัวอย่างมีน้ำหนัก 4 ตัว ดังนี้

- ตัวอย่างที่ 1 คือตัวอย่างที่ $G=true$, $M=true$ มีน้ำหนักเท่ากับ $P(G,M|B,L)$
- ตัวอย่างที่ 2 คือตัวอย่างที่ $G=true$, $M=false$ มีน้ำหนักเท่ากับ $P(G,\neg M|B,L)$
- ตัวอย่างที่ 3 คือตัวอย่างที่ $G=false$, $M=true$ มีน้ำหนักเท่ากับ $P(\neg G,M|B,L)$
- ตัวอย่างที่ 4 คือตัวอย่างที่ $G=false$, $M=false$ มีน้ำหนักเท่ากับ $P(\neg G,\neg M|B,L)$

ดังที่ได้กล่าวข้างต้นว่าเราสามารถหาค่าน้ำหนักทั้งสองค่าของตัวอย่าง 3 ตัวด้านบนกับค่าน้ำหนักทั้งสี่ค่าของตัวอย่าง 7 ตัวนี้ได้ถ้าเรารู้ค่าความน่าจะเป็นในซีพีที จากนั้นเราจะใช้ตัวอย่างมีน้ำหนักเหล่านี้ร่วมกับตัวอย่างที่เหลือในรูปแบบที่ 6-48 เพื่อคำนวณซีพีทีซึ่งเป็นสิ่งที่เราต้องการเรียน (ตัวอย่างที่ไม่รู้ค่าถูกแทนที่ด้วยตัวอย่างมีน้ำหนัก) แต่อย่างไรก็ดีเราจะทำเช่นนี้ได้โดยมีเงื่อนไขว่าเราต้องรู้ค่าในซีพีทีก่อน ซึ่งเรายังไม่รู้

6.8.6 การเรียนรู้ข่ายงานเบส

วิธีการทำก็คือเราจะสมมติค่าความน่าจะเป็นในซีพียูโดยสุ่มค่าเริ่มต้นเข้าไปในซีพียู ซึ่งก็จะเสมือนว่าเรามีค่าในซีพียูแล้ว และเราจะสามารถหาน้ำหนักของตัวอย่างไม่ทราบค่าได้ทุกตัว ก็จะทำให้เซตตัวอย่างเดิมที่มีตัวอย่างไม่รู้ค่าเป็นเซตตัวอย่างที่เรารู้ค่าทุกตัว การเรียนรู้ก็จะเหมือนกับกรณีที่ตัวอย่างมีข้อมูลครบแน่นอนว่าการคำนวณค่าน้ำหนักจะไม่ได้ค่าน้ำหนักที่ถูกต้องเพราะว่าเราสุ่มซีพียูเริ่มต้นที่ไม่ใช่ซีพียูที่ถูก แต่เนื่องจากว่าเมื่อเราได้น้ำหนักแล้วนำตัวอย่างไปรวมกับตัวอย่างที่เหลือที่เป็นตัวอย่างมีข้อมูลครบก็จะทำให้การประมาณค่าซีพียูที่ครั้งใหม่มีความถูกต้องเพิ่มขึ้นกว่าซีพียูเริ่มต้น เพราะว่าตัวอย่างส่วนใหญ่ของเราเป็นตัวอย่างที่ถูกต้อง จะมีตัวอย่างมีน้ำหนักเท่านั้นที่ไม่ถูกต้องสมบูรณ์ แสดงว่าการปรับค่าซีพียูทำให้ได้ซีพียูใหม่ที่ดีขึ้น และถ้าเราทำซ้ำกระบวนการเดิมด้วยซีพียูที่ดีขึ้นก็จะทำให้การหาค่าน้ำหนักมีความแม่นยำยิ่งขึ้น และส่งผลให้การปรับซีพียูในรอบต่อไปดีขึ้นอีกเมื่อวนซ้ำไปเรื่อยๆ ก็จะได้ซีพียูที่ดีขึ้นเรื่อยๆ จนกระทั่งซีพียูไม่เปลี่ยนแปลง เราก็หยุดกระบวนการเรียนรู้ได้ อัลกอริทึมการเรียนรู้แบบนี้เรียกว่า *อัลกอริทึมอีเอ็ม (EM – expectation maximization algorithm)* [Dempster, et al., 1977; McLachlan & Krishnan, 1996] ซึ่งแสดงในตารางที่ 6-27 ต่อไปนี้

6.8.6 การเรียนรู้ข่ายงานเบสส์

ตารางที่ 6-27 อัลกอริทึมอีเอ็มสำหรับคำนวณค่าน้ำหนักของตัวอย่างไม่รู้ค่า

Algorithm: EM

1. Initialize all entries in all CPTs to some random values.
2. UNTIL the termination condition is met DO
 - 2.1 Use the CPTs to calculate weights of the weighted examples.
 - 2.2 Use the calculated weighted to estimate new CPTs.

อัลกอริทึมอีเอ็มนี้โดยทั่วไปจะใช้เวลาในการลู่เข้าไม่มาก ดังจะได้แสดงในตัวอย่างการเรียนรู้ซีพีทีของตัวอย่างสอนในรูปที่ 6-48 ดังนี้

6.8.6 การเรียนรู้ข่ายงานเบสส์

(1) สุ่มค่าสำหรับตารางซีพีที

- $P(L) = 0.5$

$$(P(\neg L) = 1 - P(L))$$

- $P(B) = 0.5$

$$(P(\neg B) = 1 - P(B))$$

- $P(M|B,L) = 0.5$

$$(P(\neg M|B,L) = 1 - P(M|B,L))$$

$$P(M|B,\neg L) = 0.5$$

$$(P(\neg M|B,\neg L) = 1 - P(M|B,\neg L))$$

$$P(M|\neg B,L) = 0.5$$

$$(P(\neg M|\neg B,L) = 1 - P(M|\neg B,L))$$

$$P(M|\neg B,\neg L) = 0.5$$

$$(P(\neg M|\neg B,\neg L) = 1 - P(M|\neg B,\neg L))$$

- $P(G|B) = 0.5$

$$(P(\neg G|B) = 1 - P(G|B))$$

$$P(G|\neg B) = 0.5$$

$$(P(\neg G|\neg B) = 1 - P(G|\neg B))$$

6.8.6 การเรียนรู้ข่ายงานเบย์

G	M	B	L	จำนวนตัวอย่าง
*	*	True	True	7
False	True	*	True	3

ในกรณีของ 7 ตัวอย่างแรกเราต้องการหา $P(G,M|B,L)$, $P(G,\neg M|B,L)$, $P(\neg G,M|B,L)$ และ $P(\neg G,\neg M|B,L)$

- $P(G,M|B,L) = P(G|B) \times P(M|B,L) = 0.5 \times 0.5$
- $P(G,\neg M|B,L) = P(G|B) \times P(\neg M|B,L) = 0.5 \times 0.5$
- $P(\neg G,M|B,L) = P(\neg G|B) \times P(M|B,L) = 0.5 \times 0.5$
- $P(\neg G,\neg M|B,L) = P(\neg G|B) \times P(\neg M|B,L) = 0.5 \times 0.5$

6.8.6 การเรียนรู้ข่ายงานเบย์

ดังนั้นสำหรับตัวอย่าง 7 ตัวแรก เราสามารถใส่น้ำหนักให้เป็นตัวอย่างมีน้ำหนักดังต่อไปนี้

G	M	B	L	จำนวนตัวอย่าง
True	True	True	True	$7 \times 0.5 \times 0.5 = 1.75$
True	False	True	True	$7 \times 0.5 \times 0.5 = 1.75$
False	True	True	True	$7 \times 0.5 \times 0.5 = 1.75$
False	False	True	True	$7 \times 0.5 \times 0.5 = 1.75$

ในกรณีของ 3 ตัวอย่าง

G	M	B	L	จำนวนตัวอย่าง
False	True	*	True	3

เราต้องหา $P(B|-G,M,L)$ และ $P(-B|-G,M,L)$ ซึ่งทำได้ดังนี้

$$\begin{aligned}
 P(B|-G,M,L) &= \frac{P(B,-G,M,L)}{P(-G,M,L)} \\
 &= \frac{P(-G|B,M,L)P(M|B,L)P(B|L)P(L)}{P(-G,M,L,B) + P(-G,M,L,-B)} \\
 &= \frac{P(-G|B,M,L)P(M|B,L)P(B|L)P(L)}{P(-G|B,M,L)P(M|B,L)P(B|L)P(L) + P(-G|-B,M,L)P(M|-B,L)P(-B|L)P(L)} \\
 &= \frac{P(-G|B)P(M|B,L)P(B)}{P(-G|B)P(M|B,L)P(B) + P(-G|-B)P(M|-B,L)P(-B)}
 \end{aligned}$$

$$\text{ดังนั้น } P(B|-G,M,L) = \frac{0.5 \times 0.5 \times 0.5}{0.5 \times 0.5 \times 0.5 + 0.5 \times 0.5 \times 0.5} = 0.5$$

$$P(-B|-G,M,L) = 0.5$$

6.8.6 การเรียนรู้ข่ายงานเบสส์

ดังนั้นสำหรับตัวอย่าง 3 ตัว เราสามารถใส่น้ำหนักให้เป็นตัวอย่างมีน้ำหนักดังต่อไปนี้

G	M	B	L	จำนวนตัวอย่าง
False	True	True	True	$3 \times 0.5 = 1.5$
False	True	False	True	$3 \times 0.5 = 1.5$

จะได้ว่าตัวอย่างทั้งหมดเป็นดังนี้

G	M	B	L	จำนวนตัวอย่าง
True	True	True	True	54
True	True	True	False	1
True	True	True	True	1.75
True	False	True	True	1.75
False	True	True	True	1.75
False	False	True	True	1.75
True	False	True	False	27
False	True	True	True	1.5
False	True	False	True	1.5
False	False	True	False	2
False	False	False	True	4
False	False	False	False	2

6.8.6 การเรียนรู้ข่ายงานเบย์

(3) ใช้ตัวอย่างมีน้ำหนักที่คำนวณได้ เพื่อประมาณซีพีทีใหม่

- $P(L) = 68/100 = 0.680$ ($P(\neg L) = 1 - P(L)$)
- $P(B) = 92.5/100 = 0.925$ ($P(\neg B) = 1 - P(B)$)
- $P(M|B,L) = 59/62.5 = 0.944$ ($P(\neg M|B,L) = 1 - P(M|B,L)$)
- $P(M|B,\neg L) = 1/30 = 0.033$ ($P(\neg M|B,\neg L) = 1 - P(M|B,\neg L)$)
- $P(M|\neg B,L) = 1.5/5.5 = 0.273$ ($P(\neg M|\neg B,L) = 1 - P(M|\neg B,L)$)
- $P(M|\neg B,\neg L) = 0/2 = 0.000$ ($P(\neg M|\neg B,\neg L) = 1 - P(M|\neg B,\neg L)$)
- $P(G|B) = 85.5/92.5 = 0.924$ ($P(\neg G|B) = 1 - P(G|B)$)
- $P(G|\neg B) = 0/7.5 = 0.000$ ($P(\neg G|\neg B) = 1 - P(G|\neg B)$)

(2) ใช้ซีพีทีเพื่อคำนวณน้ำหนักของตัวอย่างไม่รู้ค่าใหม่

ในกรณีของ 7 ตัวอย่างแรก

- $P(G,M|B,L) = P(G|B) \times P(M|B,L) = 0.924 \times 0.944 = 0.872$
- $P(G,\neg M|B,L) = P(G|B) \times P(\neg M|B,L) = 0.924 \times 0.056 = 0.052$
- $P(\neg G,M|B,L) = P(\neg G|B) \times P(M|B,L) = 0.076 \times 0.944 = 0.072$
- $P(\neg G,\neg M|B,L) = P(\neg G|B) \times P(\neg M|B,L) = 0.076 \times 0.056 = 0.004$

ได้ตัวอย่างมีน้ำหนักเป็น

G	M	B	L	จำนวนตัวอย่าง
True	True	True	True	$7 \times 0.872 = 6.11$
True	False	True	True	$7 \times 0.052 = 0.36$
False	True	True	True	$7 \times 0.072 = 0.50$
False	False	True	True	$7 \times 0.004 = 0.03$

ในกรณีของ 3 ตัวอย่าง

- $P(B|\neg G,M,L) = \frac{0.076 \times 0.944 \times 0.925}{0.076 \times 0.944 \times 0.925 + 1.000 \times 0.273 \times 0.075} = 0.764$
- $P(\neg B|\neg G,M,L) = 1 - P(B|\neg G,M,L) = 0.236$

6.8.6 การเรียนรู้ข่ายงานเบส

ได้ตัวอย่างมีน้ำหนักเป็น

G	M	B	L	จำนวนตัวอย่าง
False	True	True	True	$3 \times 0.764 = 2.29$
False	True	False	True	$3 \times 0.236 = 0.71$

ทุกตารางซีพีที่มีค่าเปลี่ยนแปลงน้อยกว่า 0.001)

- $P(L) = 0.680$
- $P(B) = 0.940$
- $P(M|B,L) = 1.000$
- $P(M|B,\neg L) = 0.033$
- $P(M|\neg B,L) = 0.005$
- $P(M|\neg B,\neg L) = 0.000$
- $P(G|B) = 0.943$
- $P(G|\neg B) = 0.000$

แบบฝึกหัด

- กำหนดให้ความรู้ในโดเมนและตัวอย่างสอนเป็นดังต่อไปนี้

ความรู้ในโดเมน:

$a(X,X,Y), b(\text{red},Z) \rightarrow c(W,X,Y,Z)$

$d(Z,Z), d(Y,X), e(X,Y) \rightarrow a(X,Y,Z)$

$f(Y,X) \rightarrow b(X,Y)$

$g(X,X) \rightarrow d(X,Y)$

ตัวอย่างสอน:

$e(\text{eyes},\text{eyes})$

$e(\text{eyes},\text{ears})$

$e(\text{eyes},\text{nose})$

$f(\text{fire},\text{red})$

$f(\text{tree},\text{green})$

$f(\text{snow},\text{white})$

$g(2,2)$

$g(2,1)$

$g(3,2)$

$g(\text{eyes},\text{eyes})$

$g(\text{eyes},\text{ears})$

$g(\text{eyes},\text{nose})$

- จงแสดงให้เห็นว่า $c(\text{white},\text{eyes},2,\text{fire})$ เป็นตัวอย่างที่ถูกโดยใช้ต้นไม้พิสูจน์
- กำหนดให้เกณฑ์ดำเนินการประกอบด้วยเพรดิเคต 3 ตัวคือ e, f และ g จงเขียนกฎที่เรียนได้จากตัวอย่างด้านบน

แบบฝึกหัด

2. ในการเรียนมโนทัศน์ของ “EnjoySport” เราสังเกตว่าเพื่อนของเราคนหนึ่งจะสนุกกับการเล่นกีฬาทางน้ำหรือไม่ โดยได้พิจารณาถึงปัจจัย 6 อย่างคือ Sky (ท้องฟ้า), AirTemp (อุณหภูมิอากาศ), Humidity (ความชื้น), Wind (ลม), Water (น้ำ), Forecast(คำพยากรณ์) และได้บันทึกตัวอย่างบวก (3 ตัว) และตัวอย่างลบ (1 ตัว) ดังแสดงด้านล่าง

(Sunny, Warm, Normal, Strong, Warm, Same) +

(Sunny, Warm, High, Strong, Warm, Same) +

(Rainy, Cold, High, Strong, Warm, Change) –

(Sunny, Warm, High, Strong, Cool, Change) +

หมายเหตุ: ตัวอย่างแต่ละตัวแสดงอยู่ในรูป (x1,x2,x3,x4,x5,x6) โดยที่ x1 เป็นค่าของSky, x2 เป็นค่าของ AirTemp, x3 เป็นค่าของ Humidity, x4 เป็นค่าของ Wind, x5 เป็นค่าของ Water, x6 เป็นค่าของ Forecast และเครื่องหมายบวกแสดงตัวอย่างบวก เครื่องหมายลบแสดงตัวอย่างลบ กำหนดภาษาที่ใช้แสดงเป็นดังต่อไปนี้

แบบฝึกหัด

- ค่าของ Sky ที่เป็นไปได้คือ Sunny, Cloudy, Rainy
- ค่าของ AirTemp ที่เป็นไปได้คือ Warm, Cold
- ค่าของ Humidity ที่เป็นไปได้คือ Normal, High
- ค่าของ Wind ที่เป็นไปได้คือ Strong, Weak
- ค่าของ Water ที่เป็นไปได้คือ Warm, Cool
- ค่าของ Forecast ที่เป็นไปได้คือ Same, Change

จงตอบคำถามต่อไปนี้

- ปริภูมิโนทัศน์ในกรณีนี้มีขนาดเท่าไร
 - จงแสดงเซต S และ G เมื่อรับตัวอย่างเข้าไปทีละตัวตามลำดับ
 - เมื่อรับตัวอย่างทั้ง 4 ตัวเข้าไปหมดแล้ว เวอร์ชันสเปซจะประกอบด้วย
- สมมติฐานที่เป็นไปได้ทั้งหมดกี่ตัว อะไรบ้าง (สมมติฐานทั้งหมดที่อยู่ระหว่าง S และ G (รวม S และ G ด้วย))

แบบฝึกหัด

3. ตารางด้านล่างนี้เป็นข้อมูลของผู้ที่มาขอทำบัตรเครดิตจากธนาคารแห่งหนึ่ง ข้อมูลของคนหนึ่งๆ ประกอบด้วย account, employed, cash ธนาคารใช้ข้อมูลเหล่านี้สำหรับกำหนดว่าจะทำบัตรให้หรือไม่ ถ้าทำให้จะมีประเภท (class) เป็น accept ถ้าไม่ทำให้จะมีประเภทเป็น reject จงสร้างต้นไม้ตัดสินใจเพื่อจำแนกประเภทข้อมูลของประเภททั้งสองนี้

Attribute			
account	employed	cash	class
bank	yes	3000	accept
bank	no	3000	accept
bank	no	40000	accept
none	yes	40000	accept
none	yes	3000	reject
none	no	40000	reject
none	no	3000	reject
other	yes	3000	reject
other	no	3000	reject
other	no	40000	accept



THANK YOU
FOR
YOUR ATTENTION

จบบทที่ 4