

บทที่ 2

วรรณคดีที่เกี่ยวข้อง

การศึกษาการใช้จีโออาร์เอ็ม และ จีพีซีเอ็ม ในการเปรียบเทียบฟังก์ชันสารสนเทศของมาตรฐานค่าที่มีวิธีให้คะแนนที่แตกต่างกัน ผู้วิจัยได้นำเสนอเนื้อหาที่เกี่ยวข้องเป็น 5 ตอน ดังนี้

- ตอนที่ 1 ความรู้ทั่วไปเกี่ยวกับแบบวัดและแบบสอบผลสัมฤทธิ์
- ตอนที่ 2 การตรวจให้คะแนนแบบทวิภาคและแบบพหุภาค
- ตอนที่ 3 มโนทัศน์เกี่ยวกับทฤษฎีการตอบสนองข้อสอบ
- ตอนที่ 4 มโนทัศน์เกี่ยวกับทฤษฎี Polytomous Item Response
- ตอนที่ 5 งานวิจัยที่เกี่ยวข้อง
- ตอนที่ 6 โปรแกรมคอมพิวเตอร์ที่ใช้วิเคราะห์มาตรฐานค่า

ตอนที่ 1 ความรู้ทั่วไปเกี่ยวกับแบบวัดและแบบสอบผลสัมฤทธิ์

เครื่องมือวัดผลทางการศึกษาแบ่งเป็น 2 ประเภท ที่สำคัญ คือ แบบวัดและแบบสอบ ผู้วิจัยได้เสนอความรู้ทั่วไปเกี่ยวกับแบบวัดที่เป็นประเภทมาตรฐานค่า และแบบสอบผลสัมฤทธิ์ดังนี้

1.1 มาตรฐานค่า (Rating Scale)

มาตรฐานค่าเป็นเครื่องมือวัดผลทางการศึกษาประเภทหนึ่งประกอบด้วยข้อคำถามหรือสิ่งเร้ากับตัวเลือกที่ให้ผู้ตอบตอบสนองเพื่อที่จะใช้ประมาณค่าคุณลักษณะสิ่งใดสิ่งหนึ่งของบุคคลหรือสิ่งของ (Wiersma and Jurs, 1990) โดยในแต่ละข้อกระทงจะกำหนดตัวเลขหรือตัวอักษรเป็นช่วงตั้งแต่ 2 ช่วงขึ้นไปเพื่อใช้เป็นมาตรวัด เครื่องมือประเภทนี้จะเหมาะกับการวัดหรือประเมินคุณลักษณะที่เล็ก แคบ เฉพาะ เดียว

มีความต่อเนื่องในทางบวกหรือทางลบก็ได้ (อุทุมพร จามรمان, 2537) ซึ่งโดยทั่วไปสามารถแบ่งมาตรฐานค่าออกได้เป็น 5 ประเภท (Guilford, 1954) ที่สำคัญคือ

ก. มาตรฐานค่าตัวเลข (numerical rating scale) เป็นมาตรฐานค่าที่ให้ผู้สังเกตเป็นผู้กำหนดตัวเลขที่เรียงลำดับกันให้สิ่งที่สังเกต เช่น :

ไม่พอใจ	พอใจเล็กน้อย	พอใจ	พอใจมากที่สุด
0	1	2	3

ข. มาตรฐานค่าแบบกราฟ (graphic rating scale) เป็นเครื่องมือที่ใช้กันมาก ซึ่งแต่เดิมมาตรฐานค่าประเภทนี้สร้างเพื่อใช้สำหรับการประเมินตนเอง เช่น :

ในการสนทนาทางสังคม	-----	-----	-----	-----
ท่านมีพฤติกรรมอย่างไร	ข้างพูด	ชอบคุย	พูดเมื่อจำเป็น	ชอบเป็นผู้ฟัง

ค. มาตรฐานค่าแบบสเกลมาตรฐาน (standard scale) มาตรฐานค่าประเภทนี้กำหนดเกณฑ์มาตรฐานไว้เปรียบเทียบ เช่น การวัดความเป็นผู้นำจะใช้ชื่อบุคคลที่สำคัญเป็นเกณฑ์มาตรฐานแล้วพิจารณาว่าคนที่ถูกวัดมีความเป็นผู้นำมากหรือน้อยกว่าเกณฑ์ดังกล่าว ตัวอย่างมาตรฐานค่าแบบนี้ คือ

(1) Man-to-Man Scale เป็นวิธีการที่กำหนดเกณฑ์มาตรฐานโดยการเรียงลำดับคะแนนจากการประเมินของกลุ่มบุคคลที่เกี่ยวข้องกับการวัดคุณลักษณะนั้น เช่น ให้กลุ่มนายทหารเขียนชื่อหัวหน้าระดับสูงที่ตนคิดว่ามีความเป็นผู้นำมากที่สุดมา 12 - 25 ชื่อ แล้วนำคะแนนของหัวหน้าระดับสูงมาเรียงลำดับประมาณ 5 ลำดับ และเมื่อต้องการจะวัดความเป็นผู้นำกับใครก็ให้เปรียบเทียบกับบุคคลทั้ง 5 ดังกล่าว

(2) Portrait-Matching-Scale เป็นมาตรฐานค่าที่ใช้ศึกษาเกี่ยวกับลักษณะคน โดยให้ผู้เชี่ยวชาญประมาณ 7 คน จัดกลุ่มข้อความเกี่ยวกับคุณลักษณะที่จะวัดจากคนจำนวนมากไว้ประมาณ 10 กลุ่มข้อความ จากนั้นก็ให้ผู้ตัดสินประมาณ 48 คน ตัดสินและจัดลำดับของข้อความทั้ง 10 เพื่อหาค่าเฉลี่ยของแต่ละคุณลักษณะหรือข้อความเพื่อใช้เป็นเกณฑ์ปกติต่อไป

ง. มาตรฐานค่าแบบแต้มสะสม (rating by cumulated points) เป็นมาตรฐานค่าที่ผู้ตอบเป็นผู้เลือกคุณลักษณะจากตัวเลือกหลาย ๆ ตัว และสามารถประเมินค่าได้ว่าผู้ตอบคุณลักษณะอะไรบางอย่างหรือส่วนใหญ่มีคุณลักษณะอย่างไร เครื่องมือประเภทนี้สามารถพบได้ 2 ลักษณะ คือ

(1) แบบ Check-List Method เป็นการประเมินคุณลักษณะโดยผู้ประเมินทำเครื่องหมาย ✓ ตรงกับคำที่แสดงคุณลักษณะแต่ละข้อในมาตรฐานค่า

(2) แบบ The Guess Who-Technique เป็นวิธีการประเมินคุณลักษณะนักเรียนโดยใช้คำถามสั้น ๆ แล้วให้เพื่อน ๆ เขียนชื่อ ตัวอย่าง เช่น :

ใครเอ่ย

(ก) เป็นคนที่มักแกล้งเพื่อนบ่อย ๆ

(ข) เป็นคนที่ชอบช่วยเหลือเพื่อน ๆ

จ. มาตรฐานค่าแบบตัวเลือกบังคับตอบ (forced-choice ratings) เป็นมาตรฐานค่าที่กำหนดตัวเลือก และค่าคะแนนให้กับตัวเลือกโดยผู้ตอบจะต้องเลือกตัวใดตัวหนึ่งโดยตัวเลือกดังกล่าวอาจใช้ข้อความทางบวกหรือทางลบก็ได้ เครื่องมือประเภทนี้มีการดัดแปลงและนำมาใช้กับแบบวัดคุณลักษณะทั่วไปเป็นจำนวนมากในปัจจุบัน

มาตรฐานค่าทั้ง 5 แบบ มีการนำมาใช้อย่างแพร่หลาย โดยมาตรฐานค่าแบบตัวเลือกบังคับตอบที่มีลักษณะข้อความเชิงบรรยายก็เป็นเครื่องมืออีกประเภทหนึ่งที่ทีมงานวิจัยส่วนใหญ่ใช้เป็นเครื่องมือวิจัย (พจนีย์ เจนพนัส, 2536)

จุฬาลงกรณ์มหาวิทยาลัย

1.2 แบบสอบผลสัมฤทธิ์

แบบสอบผลสัมฤทธิ์ (achievement test) เป็นเครื่องมือใช้วัดผลของการเรียนการสอน (learning outcomes) ตามวัตถุประสงค์ที่ตั้งไว้ ข้อสอบของเครื่องมือประเภทนี้แบ่งเป็น 2 ประเภท (Gronlund, 1993) ตามลักษณะการตอบ คือ ข้อสอบประเภทเลือกคำตอบ (selection type) และข้อสอบประเภทเสนอคำตอบ (supply type)

1.2.1 ข้อสอบประเภทเลือกคำตอบ ได้แก่

ก. ข้อสอบแบบหลายตัวเลือก (multiple-choice) เป็นข้อสอบที่นิยมใช้กันมาก เพราะสามารถวัดความรู้ ความเข้าใจ การนำไปใช้ วิเคราะห์ สังเคราะห์ และการประเมินค่าของนักเรียนได้ และวัดได้ครอบคลุมเนื้อหา มีส่วนประกอบที่สำคัญ 2 ส่วน คือ ข้อคำถาม และตัวเลือก ตัวอย่าง เช่น :

(1) คำในข้อใดมีความหมายต่างกัน

- * ก. สังสรรค์ - รังสรรค์
- ข. ประจัญ - สัมประยุทธ์
- ค. มัจฉาน - หัสันยน์
- ง. ฤทัย - ฤทัย

ข. ข้อสอบแบบถูกผิด (true-false) เป็นข้อสอบที่ผู้ตอบสามารถเลือกได้ 2 อย่าง คือ ข้อความที่กำหนดให้นั้น ถูก หรือ ผิด , ใช่ หรือ ไม่ใช่ เหมาะกับการวัดความรู้ ความจำ ความเข้าใจ และการนำไปใช้ จุดอ่อนก็คือผู้สอบมีโอกาสสูงในการเดาข้อสอบได้ถูกต้อง เช่น :

ถูก *ผิด (1) ข้อสอบแบบถูก-ผิด จัดเป็นข้อสอบประเภทเสนอคำตอบ

ค. ข้อสอบแบบจับคู่ (matching) เป็นข้อสอบที่ผู้ตอบจะต้องจับคู่ระหว่างคำหรือข้อความ 2 ชุด ที่มีความสอดคล้องกัน เหมาะกับการวัดความรู้ ความจำ ของนักเรียน ตัวอย่าง เช่น :

เหตุการณ์	เกิดในปี พ.ศ.
...(ค)...1. การประกาศใช้รัฐธรรมนูญครั้งแรก	ก. 2448
...(ก) ..2. การเลิกทาส	ข. 2457
...(ง)...3. การขับไล่ 3 ทหาราช	ค. 2475
	ง. 2516

1.2.2 ข้อสอบประเภทเสนอคำตอบ เป็นข้อสอบที่ผู้สอบต้องเขียนหรือเสนอคำตอบขึ้นมาเองโดยใช้วิธีเขียนตอบ ข้อดีคือสะดวกในการเขียนข้อสอบ สามารถวัดความรู้ขั้นสูงโดยเฉพาะการวิเคราะห์ สังเคราะห์และประเมินค่า แต่จุดอ่อนคือไม่สะดวกในการตรวจให้คะแนนอาจทำให้ขาดความเป็นปรนัยในการตรวจให้คะแนนได้ ข้อสอบประเภทนี้ได้แก่

ก. ข้อสอบแบบตอบสั้น (short answer) เป็นข้อสอบที่ผู้สอบต้องเติมคำตอบขึ้นมาเอง แต่เป็นคำตอบสั้น ๆ เหมาะกับการวัดความรู้ความจำเกี่ยวกับกฎ หรือสูตร เช่น :

(1) สูตรของกรดกำมะถันคือ

ข. ข้อสอบแบบความเรียง (essay test) เป็นข้อสอบที่ผู้สอบต้องประมวลความรู้ แล้วเรียบเรียงเป็นคำตอบ เช่น :

(1) ให้ท่านอธิบายหลักและวิธีการวัดและประเมินผลในชั้นเรียนมาโดยละเอียด

1.3 การวิเคราะห์มาตรฐานประมาณค่าและแบบสอบผลสัมฤทธิ์ที่ตรวจให้คะแนนแบบพหุวิภาค ตามแนวทฤษฎีการทดสอบแบบดั้งเดิม

1.3.1 การวิเคราะห์มาตรฐานประมาณค่า

การวิเคราะห์มาตรฐานประมาณค่าตามแนวทฤษฎีการทดสอบแบบดั้งเดิม มีการวิเคราะห์ที่สำคัญมีดังนี้

ก. การวิเคราะห์ค่าอำนาจจำแนก สามารถทำได้ 2 วิธี คือ

(1) โดยการคำนวณค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างคะแนนรายข้อกับคะแนนรวม

(2) โดยการทดสอบค่าสถิติที (t-test) ระหว่างนักเรียนที่ได้คะแนนสูงและต่ำ ซึ่งปกติจะใช้เทคนิคการแบ่งกลุ่มสูง - กลุ่มต่ำแบบ 25 เปอร์เซนต์ (McIver and Carmines, 1981 อ้างใน บุญธรรม กิจปรีดาบริสุทธิ์ ,2534)

ข. การวิเคราะห์ความเที่ยง สามารถตรวจสอบได้หลายวิธีคือ

(1) การวิเคราะห์ความเที่ยงเชิงคงที่ (stability) โดยการใช้วิธีสอบซ้ำ (test - retest) คือ ใช้แบบวัดฉบับเดิมไปใช้กับผู้สอบกลุ่มเดิมเพื่อดูความสอดคล้องของผล การวัดทั้งสองครั้ง

(2) การวิเคราะห์ความเที่ยงแบบความสอดคล้อง (consistency) สามารถทำได้โดยพิจารณาความสอดคล้องของผลการสอบจากแบบวัดคู่ขนาน (parallel test) หรือการแบ่งครึ่งฉบับ (split-half) และดูความสอดคล้องภายในโดยการคำนวณค่าสัมประสิทธิ์แอลฟาด้วยสูตรของครอนบาคหรือการใช้วิธีวิเคราะห์ความแปรปรวนของฮอยท์ (บุญธรรม กิจปรีดาบริสุทธิ์, 2534)

ค. การวิเคราะห์คุณภาพด้านความตรง เป็นการตรวจสอบว่าแบบวัดที่สร้างขึ้นวัดในสิ่งที่ต้องการวัดได้มากเพียงใด สามารถตรวจสอบคุณภาพได้ดังนี้

(1) การตรวจสอบความตรงเชิงเนื้อหาซึ่งส่วนมากจะให้ผู้เชี่ยวชาญเป็นผู้ตรวจสอบและตัดสินใจว่าข้อกระทงแต่ละข้อวัดคุณลักษณะได้ครอบคลุมในสิ่งที่ต้องการวัดหรือไม่

(2) การตรวจสอบความตรงเชิงโครงสร้าง เป็นการตรวจสอบว่าเครื่องมือ ดังกล่าววัดได้ตรงตามโครงสร้างของตัวแปรคุณลักษณะหรือไม่ สามารถทำได้ โดยการวิเคราะห์องค์ประกอบ การเปรียบเทียบกับกลุ่มที่รู้แน่ชัด หรือการวิเคราะห์ความตรงเชิงจำแนก เป็นต้น

การวิเคราะห์มาตรฐานค่าตามแนวทฤษฎีการทดสอบแบบดั้งเดิมดังกล่าว จะให้ค่าสถิติที่มักแปรเปลี่ยนไปตามกลุ่มตัวอย่างที่สอบ เช่น ถ้ากลุ่มตัวอย่างมีความเป็นเอกพันธ์ (homogeneous) ค่าอำนาจจำแนกก็มีแนวโน้มที่จะต่ำกว่าการใช้กับกลุ่มตัวอย่างที่มีความหลากหลาย (heterogeneous) เป็นต้น ดังนั้นการนำผลการวิเคราะห์ดังกล่าวไปใช้กับผู้สอบทั่วไปจึงไม่ค่อยเหมาะสมนัก ในปัจจุบันนักวัดผลจึงได้พยายามพัฒนาทฤษฎีการตอบสนองข้อสอบ (IRT) เพื่อแก้ปัญหาดังกล่าว โดยมุ่งประมาณค่าพารามิเตอร์ของผู้สอบ และข้อสอบ เพื่อให้สามารถนำผลจากการวิเคราะห์ไปใช้กับกลุ่มตัวอย่างทั่วไปได้อย่างเหมาะสมมากขึ้น



1.3.2 การวิเคราะห์แบบสอบผลสัมฤทธิ์

การวิเคราะห์แบบสอบผลสัมฤทธิ์ที่ตรวจให้คะแนนแบบพหุวิภาค ผู้วิจัยได้เสนอการวิเคราะห์โดยยึดตามแบบการวิเคราะห์ข้อสอบประเภทความเรียง ซึ่งประยุกต์หลักการวิเคราะห์ข้อสอบประเภทเลือกตอบแบบหลายตัวเลือก (ศิริชัย กาญจนวาสี, 2535) ดังนี้

ก. การวิเคราะห์ค่าความยากและอำนาจจำแนก โดยหาค่าสัดส่วนของคะแนนนักเรียนในกลุ่มเก่ง และกลุ่มอ่อน แล้วคำนวณค่าดัชนีบ่งชี้ค่าความยาก และอำนาจจำแนก

ข. การวิเคราะห์ความเที่ยง สามารถตรวจสอบได้โดย วิเคราะห์ความเที่ยงแบบความสอดคล้องภายใน (internal consistency) โดยพิจารณาความสอดคล้องของผลการโดยการคำนวณค่าสัมประสิทธิ์แอลฟา ของครอนบาค

ค. การวิเคราะห์คุณภาพด้านความตรง เป็นการตรวจสอบว่าแบบวัดที่สร้างขึ้นวัดในสิ่งที่ต้องการวัดได้มากเพียงใด สามารถตรวจสอบคุณภาพได้โดยการตรวจสอบความตรงเชิงเนื้อหาซึ่งส่วนมากจะให้ผู้เชี่ยวชาญเป็นผู้ตรวจสอบและตัดสินว่าข้อกระทงแต่ละข้อวัดคุณลักษณะได้ครอบคลุมในสิ่งที่ต้องการวัดหรือไม่

การวิเคราะห์มาตรฐานค่าตามแนวทฤษฎีการทดสอบแบบดั้งเดิมดังกล่าวจะให้ค่าสถิติที่มักแปรเปลี่ยนไปตามกลุ่มตัวอย่างที่สอบ เช่น ถ้ากลุ่มตัวอย่างมีความเป็นเอกพันธ์ (homogeneous) ค่าอำนาจจำแนกก็มีแนวโน้มที่จะต่ำกว่าการใช้กับกลุ่มตัวอย่างที่มีความหลากหลาย (heterogeneous) เป็นต้น ดังนั้นการนำผลการวิเคราะห์ดังกล่าวไปใช้กับผู้สอบทั่วไปจึงไม่ค่อยเหมาะสมนัก ในปัจจุบันนักวัดผลจึงได้พยายามพัฒนาทฤษฎีการตอบสนองข้อสอบ (IRT) เพื่อแก้ปัญหาดังกล่าว โดยมุ่งประมาณค่าพารามิเตอร์ของผู้สอบและข้อสอบ เพื่อให้สามารถนำผลจากการวิเคราะห์ไปใช้กับกลุ่มตัวอย่างทั่วไปได้อย่างเหมาะสมมากขึ้น

ตอนที่ 2 การตรวจให้คะแนนแบบทวิภาคและแบบพหุภาค

คำว่า “ทวิภาค” ตรงกับภาษาอังกฤษว่า “dichotomous” และคำว่า “พหุภาค” ตรงกับภาษาอังกฤษว่า “polytomous” ซึ่ง Mellenbergh (1995, cited by Weiss, 1995) ได้อธิบายรากศัพท์ของคำทั้ง 2 ไว้ว่า dichotomous มาจากภาษากรีกว่า dichos (two) + tomous (a cut) หมายถึงการแบ่งเป็น 2 ส่วน และคำว่า polytomous มาจากภาษากรีกว่า polus (many) + tomous (a cut) หมายถึง การแบ่งออกเป็นหลาย ๆ ส่วน คำทั้ง 2 มีการนำมาใช้กับการตรวจให้คะแนนในการวัดผลทางการศึกษา และเรียกแตกต่างกันไป เช่น เรียกการตรวจให้คะแนนแบบ dichotomous ว่า “การตรวจให้คะแนนแบบดั้งเดิม” “การตรวจให้คะแนนแบบทวิภาค” และ “การตรวจให้คะแนนแบบทวิภาค” ส่วนการตรวจให้คะแนนแบบ polytomous มีผู้เรียกว่า “การตรวจให้คะแนนแบบหลายค่า” และ “การตรวจให้คะแนนแบบพหุภาค” ในการวิจัยนี้จะเรียกการตรวจให้คะแนนแบบแรกและแบบที่สองว่า “การตรวจให้คะแนนแบบทวิภาค” และ “การตรวจให้คะแนนแบบพหุภาค” ตามลำดับ

การตรวจให้คะแนนแบบทวิภาค (dichotomous) เป็นวิธีที่นิยมใช้กันมาก เพราะมีความสะดวก และรวดเร็ว เหมาะกับข้อสอบประเภทเลือกคำตอบ เช่น ข้อสอบแบบหลายตัวเลือก ข้อสอบถูก-ผิด และข้อสอบแบบจับคู่ (Wiersma and Jurs, 1990) นอกจากนี้ยังพบว่าแบบวัดคุณลักษณะชนิดมาตราส่วนค่าแบบตัวเลือกบังคับตอบ (forced-choice rating) มีผู้ใช้การตรวจให้คะแนนแบบนี้ด้วยเช่นกัน (บุษรินทร์ บุญรอด, 2536 ; วารี นิยมธรรม, 2536 ; นงเยาว์ พึ่งพา, 2529 ; สันติ สุขทรัพย์, 2528 ; ไสว ข้ออุดมมงคล, 2528) การตรวจให้คะแนนจะกำหนดตัวเลือกหรือคำตอบที่เหมาะสมและถูกที่สุดเป็น 1 คะแนน ส่วนคำตอบอื่น ๆ เป็น 0 คะแนน

สำหรับการตรวจให้คะแนนแบบพหุภาค (polytomous) เป็นวิธีที่นิยมใช้กันมากเช่นกัน วิธีนี้จะกำหนดคะแนนให้กับคำตอบของนักเรียนในแต่ละข้อได้มากกว่า 2 คำ รวมถึงการให้คะแนนในมาตราส่วนค่าที่ใช้วัดคุณลักษณะชนิดต่าง ๆ ด้วย ซึ่งใน

มาตรฐานค่าก็จะกำหนดให้คะแนนตามลำดับชั้นของคะแนนในเครื่องมือนั้น ๆ โดยถ้าเป็นแบบวัดคุณลักษณะคะแนนแต่ละค่ามักแสดงถึงระดับของคุณลักษณะ แต่ถ้าเป็นแบบสอบผลสัมฤทธิ์การให้คะแนนแต่ละค่าแสดงถึงระดับความสามารถของผู้สอบที่ตอบข้อกระทงนั้น อาจมีวิธีให้คะแนนแตกต่างกันไปเช่น การให้คะแนนตามระดับความมั่นใจในการตอบ การให้คะแนนตามความสามารถในการตัดตัววงของข้อกระทงนั้น และการให้คะแนนความรู้บางส่วน (partial knowledge) เป็นต้น การให้คะแนนความรู้บางส่วน เป็นวิธีที่มีผู้สนใจศึกษากันมาก (Smith, 1987, 1982; Frary, 1982; Hutchinson, 1984, Wright and Masters, 1982) ไรท์ และมาสเตอร์ส (Wright and Masters, 1982) ได้ยกตัวอย่างข้อสอบวิชาคณิตศาสตร์ที่ให้คะแนนความรู้บางส่วน เช่น :

โจทย์ $\sqrt{9.0/0.3-5} = ?$

การตรวจให้คะแนน

นักเรียนไม่ทำขั้นตอนใดเลย

ได้ 0 คะแนน

$$9.0 / 0.3 = 30$$

ได้ 1 คะแนน

$$3.0 - 5 = 25$$

ได้ 2 คะแนน

$$\sqrt{25} = 5$$

ได้ 3 คะแนน

จากตัวอย่างข้างต้นเป็นการตรวจให้คะแนนตามลำดับของความสำเร็จ การให้คะแนนในลักษณะนี้ ครูผู้สอนสามารถกำหนดเกณฑ์การให้คะแนนได้ตามความเหมาะสม สำหรับการวิจัยครั้งนี้ ผู้วิจัยใช้การตรวจให้คะแนนแบบสอบคณิตศาสตร์ตามความสามารถในการแก้โจทย์ปัญหาคณิตศาสตร์ โดยละข้อจะมี 3 ขั้นตอน คือ ความเข้าใจในวิธีการแก้โจทย์ปัญหา การคิดคำนวณ และการคำนึงถึงสภาพที่เป็นจริง นักเรียนไม่ตอบหรือตอบไม่ถูกต้องทั้ง 3 ตอน ให้คะแนนอยู่ในลำดับชั้นที่ 1 นักเรียนที่ตอบถูก 1 ขั้นตอนให้คะแนนอยู่ในลำดับชั้นที่ 2 นักเรียนที่ตอบถูก 2 ขั้นตอน ให้คะแนนอยู่ในลำดับชั้นที่ 3 และนักเรียนที่ตอบถูกต้องทั้ง 3 ตอน จะให้คะแนนอยู่ในลำดับชั้นที่ 4

ตอนที่ 3 มโนทัศน์เกี่ยวกับทฤษฎีการตอบสนองข้อสอบ (IRT)

ทฤษฎีการตอบสนองข้อสอบ (item response theory: IRT) เป็นทฤษฎีทางการวัดผลที่อธิบายความสัมพันธ์ระหว่างคุณลักษณะภายในของบุคคลกับพฤติกรรม การตอบสนองข้อสอบแต่ละข้อว่ามีความน่าจะเป็นในการตอบถูกเพียงใด ทฤษฎีนี้ตั้งอยู่บนหลักพื้นฐานที่สำคัญ 2 ประการ (Hambleton, Swaminathan and Roger, 1991) คือ

1. ความสามารถของบุคคลในการตอบข้อสอบได้ถูกหรือผิด สามารถอธิบายได้ด้วยคุณลักษณะภายในหรือความสามารถ (latent trait or ability) ของบุคคลนั้นๆ
2. ความสัมพันธ์ระหว่างความสามารถในการตอบข้อสอบได้ถูกต้องกับความสามารถของผู้สอบที่วัดจากแบบสอบสามารถอธิบายได้ด้วยโค้งลักษณะข้อสอบ (item characteristic curve : ICC)

พัฒนาการของทฤษฎีนี้เริ่มมาจากการที่ ลอว์ลี (Lawley) ได้เสนอบทความเกี่ยวกับปัญหาการสร้างและการเลือกข้อสอบ ในปี ค.ศ.1943 (ศิริชัย กาญจนวาสี , 2535) โดยเขาได้เสนอแนวคิดในรูปของโมเดลนอร์มัลโอจีฟ (normal ogive model) ผู้ที่พัฒนาต่อมาในปี ค.ศ.1950 คือ ราสช์ (Rasch) นักคณิตศาสตร์ชาวเดนมาร์กซึ่งได้เสนอโมเดลราสช์ (rasch model) แบบ 1 พารามิเตอร์ โดยมีแนวคิดว่าความยากของข้อสอบ (bj) เป็นสิ่งเดียวที่มีอิทธิพลต่อการตอบสนองข้อสอบ

ในปี ค.ศ.1952 ลอร์ด (Lord) ได้เสนอฟังก์ชันนอร์มัลโอจีฟ แบบ 2 พารามิเตอร์ โดยเพิ่มพารามิเตอร์อำนาจจำแนก (aj) และในปี ค.ศ. 1968 เบิร์นบอม (Birnbaum) ได้พัฒนาโมเดลโลจิสติก (logistic model) เป็นฟังก์ชันที่สามารถคำนวณได้ง่ายขึ้น ในปี ค.ศ.1974 ลอร์ด (Lord) ได้เสนอโมเดลโลจิสติก แบบ 3 พารามิเตอร์ โดยเพิ่มพารามิเตอร์โอกาสการเดาข้อสอบ (ci) ในการประมาณค่าพารามิเตอร์ของผู้สอบด้วย

ปัจจุบันทฤษฎีการตอบสนองข้อสอบได้พัฒนาไปมากโดย บาร์ตัน และ ลอร์ด (Barton and Lord) ได้เสนอโมเดลโลจิสติก แบบ 4 พารามิเตอร์ขึ้น โดยเขาเชื่อว่า นักเรียนที่มีความสามารถสูงมากไม่จำเป็นที่จะต้องตอบข้อสอบถูกเสมอไปแม้ข้อสอบจะง่ายหรือจะระมัดระวังอย่างมากแล้วก็ตามก็ยังไม่สามารถใช้สารสนเทศที่มีตอบข้อสอบได้ถูกต้องตามเจตนาของผู้ออกข้อสอบได้เสมอไป เขาเสนอแนวคิดในรูปสมการดังนี้ (Hambleton , 1982)

$$P_j(\theta) = c_j + (\gamma_j - c_j) \frac{\exp^{[Da_j(\theta - b_j)]}}{1 + \exp^{[Da_j(\theta - b_j)]}}$$

- เมื่อ j คือ ข้อสอบข้อที่ 1,2,3,...,n
 γ_j คือ ค่าพารามิเตอร์ตัวแปรแฝงในข้อกระทง
 c_j คือ ค่าพารามิเตอร์ของโอกาสการเดา
 \exp คือ ค่าคงที่มีค่า 2.7183
 D คือ ค่าคงที่มีค่า 1.702
 a_j คือ ค่าพารามิเตอร์อำนาจจำแนกข้อ j
 b_j คือ ค่าพารามิเตอร์ความยากของข้อ j

โมเดลนี้ต่างจากโมเดล 3 พารามิเตอร์ เพราะ γ_j สมมติให้มีค่าต่ำกว่า 1 เล็กน้อย ดังนั้นโค้ง ICC ที่ตำแหน่งสูงสุดมีค่าต่ำกว่า 1 โมเดลนี้ให้ความสนใจศึกษาเชิงทฤษฎีเท่านั้น โดยผู้เสนอเองก็ยังไม่ได้ศึกษาในเชิงปฏิบัติหรือนำไปใช้ สำหรับการนำแนวคิดของ IRT ไปใช้กับการวิเคราะห์หามาตรประเมินค่าหรือข้อสอบที่ตรวจให้คะแนนแบบพหุวิภาค (polytomous) ในปัจจุบันใช้แบบ 1 หรือ 2 พารามิเตอร์ เท่านั้น

ตอนที่ 4 มโนทัศน์เกี่ยวกับทฤษฎี Polytomous Item Response

โมเดล IRT ที่พัฒนาในระยะแรกจะใช้กับแบบสอบที่ให้คะแนนแบบทวิภาค (dichotomous) เป็นส่วนใหญ่ ต่อมาได้มีผู้พัฒนาโมเดล IRT เพื่อใช้กับแบบสอบและแบบวัดทัศนคติที่ตรวจให้คะแนนแบบพหุวิภาค (polytomous) หรือลักษณะมาตราบรรณค่า (rating data) โมเดลในแนวทฤษฎีนี้ทั้งหมดเรียกว่า Polytomous Item Response Models (Muraki, 1992, 1993 ; Donoghue , 1994 ; Hambleton and Zaal, 1991) มีโมเดลที่สำคัญ คือ

1. Graded Response Model (GRM) พัฒนาโดย ซาเมจิม่า (Samejima) ในปี ค.ศ.1960
2. Nominal Response Model (NRM) พัฒนาโดย บอค (Bock) ในปี ค.ศ.1972
3. Continuous Model (CM) พัฒนาโดย ซาเมจิม่า ในปี ค.ศ. 1973
4. Rating Scale Model (RSM) พัฒนาโดย แอนดริช (Andrich) ปี ค.ศ.1978
5. Partial Credit Model (PCM) พัฒนาโดย มาสเตอร์ส (Masters) ปี ค.ศ.1982
6. Successive Interval Model (SIM) พัฒนาโดย รอสท์ (Rost) ในปี ค.ศ.1988
7. Generalized Partial Credit Model :GPCM พัฒนาโดย มูรากิ (Muraki) ในปี ค.ศ. 1992

โมเดลที่มีผู้ศึกษากันมากในปัจจุบัน ไม่เข้มงวดเกี่ยวกับข้อตกลงเบื้องต้น และสามารถใช้ได้กับแบบสอบและแบบวัดหลายลักษณะคือ GRM และ GPCM (Donoghue, 1994; De Ayala ,1994 ; Muraki , 1992, 1993 ; Reise and Yu ,1990 ; Dodd and De Ayala , 1989 ; Koch , 1983)

ซาเมจิม่า (Samejima) ได้พัฒนา GRM จากโมเดลโลจิสติก 2 พารามิเตอร์ เพื่อใช้กับแบบสอบและแบบวัดทัศนคติที่ตรวจให้คะแนนแบบพหุวิภาค (polytomous) ในขณะที่ มูรากิ (Muraki) ได้พัฒนา GPCM จาก PCM ของ ไรท์ และมาสเตอร์ส (Wright and Masters, 1982) ให้สามารถใช้ได้กับแบบสอบและแบบวัดที่มีลักษณะเป็นพหุมิติ โดยรวมค่าอำนาจ

จำแนกข้อระหวงในการประมาณค่าพารามิเตอร์ของฟังก์ชันด้วย โมเดลทั้ง 2 เมื่อพิจารณา ดูแล้วคล้ายคลึงกันมาก เพียงแต่มีในทัศนเกี่ยวกับฟังก์ชันลักษณะเชิงปฏิบัติ (operating characteristic function : OCF) และพัฒนาการที่แตกต่างกัน รูปแบบทั่วไปของโมเดลในแนวคิดนี้พัฒนามาจากสูตร

$$P_i(u_j = 1 / \theta) = \frac{\exp^{[a_j(\theta - b_j)]}}{1 + \exp^{[a_j(\theta - b_j)]}}$$

เมื่อ $P_j(u_j = 1 / \theta)$ คือ ความน่าจะเป็นของคนที่ i มีความสามารถ θ สามารถ
ตอบข้อสอบข้อ j ($U=1$) ได้ถูกต้อง

a_j คือ ค่าพารามิเตอร์อำนาจจำแนก

b_j คือ ค่าพารามิเตอร์ของความยากข้อสอบ

\exp คือ ค่าคงที่ 2.7183

ถ้าเรามีข้อตกลงว่าข้อสอบทุกข้อมีอำนาจจำแนกแตกต่างกันโมเดลนี้ก็คือโมเดลโลจิสติกแบบ 2 พารามิเตอร์ และถ้าให้ข้อตกลงว่าข้อสอบทุกข้อมีอำนาจจำแนกเท่ากัน ค่า a_j จะเท่ากับ 1 โมเดลนี้ก็คือ Rasch's Dichotomous Response Model

ฟังก์ชันของโมเดลราสชดังกล่าวที่เสนอขึ้นมาจะมีความสอดคล้องกับพฤติกรรม การตอบสนองข้อสอบตามหลักทางจิตวิทยาว่าผู้ที่มีความสามารถหรือมีคุณลักษณะที่ ต้องการวัดสูง มีความน่าจะเป็นในการตอบได้คะแนนที่สูงกว่าผู้ที่มีคุณลักษณะหรือความสามารถต่ำ

3.1 GRM (Graded Response Model)

GRM มีข้อตกลงว่าการตอบสนองข้อกระทง j ของผู้ตอบสามารถแบ่งคะแนนออกเป็น m_{j+1} ลำดับชั้น (categories) คะแนนแต่ละลำดับ (j_k) กำหนดให้เป็น $0,1,2,\dots,m_j$ ตามลำดับ (Donoghue , 1994 ; Koch , 1983) เขียนสมการทั่วไปได้ดังนี้

$$P_{jk}(\theta) = \frac{\exp^{[Da_j(\theta-b_{jk})]}}{1 + \exp^{[Da_j(\theta-b_{jk})]}}$$

เมื่อ $P_{jk}(\theta)$ คือ ความน่าจะเป็นที่ผู้ที่มีคุณลักษณะ θ จะตอบข้อกระทง j ได้คะแนน k

D คือ ค่าคงที่ของสเกล (scaling constant) เมื่อปรับโค้งฟังก์ชันของโมเดลโลจิสติก และโมเดล นอร์มอล ฮอใจฟ์ มีค่าเท่ากับ 1.70

a_j คือ ค่าอำนาจจำแนกของข้อความ j

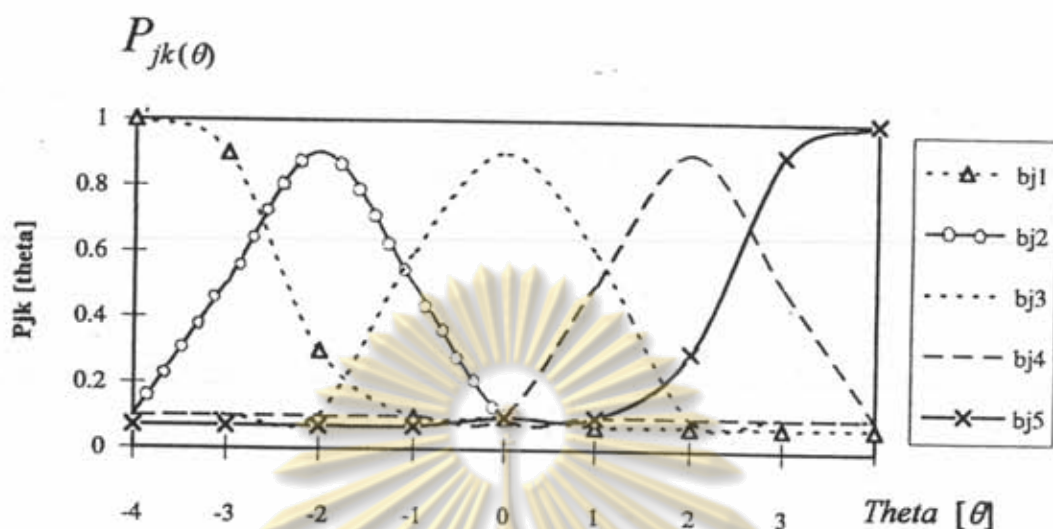
θ คือ ความสามารถหรือคุณลักษณะภายในของผู้ตอบ

b_{jk} คือ ค่าความยากของข้อความ j ในลำดับชั้นที่ jk เมื่อ $jk = 0,1,\dots,k$

\exp คือ ค่าคงที่ มีค่าเท่ากับ 2.7183

ฟังก์ชันทางคณิตศาสตร์ดังกล่าวสามารถเขียนแทนด้วยโค้งฟังก์ชันสารสนเทศได้ดังภาพที่ 1 (koch, 1983:18)

ในโมเดลนี้แสดงถึงความสัมพันธ์ของคนที่มีคุณลักษณะภายใน (θ) สูง มีความน่าจะเป็นในการตอบลำดับชั้นคะแนนที่สูงกว่าคนที่มีคุณลักษณะภายในต่ำ ซึ่งนักวัดผลได้มีการประยุกต์ใช้โมเดลนี้กับแบบสอบชนิดปรับเหมาะ (Adaptive Testing) (Koch and Dodd, 1989) และแบบวัดทัศนคติต่างๆ (Koch ,1983 ; Dodd ,1985)



ภาพที่ 1 โค้งฟังก์ชันสารสนเทศของ GRM

ลักษณะเฉพาะฟังก์ชันของโมเดล GRM สรุปได้ดังนี้

1. ฟังก์ชันสารสนเทศของแบบวัด (TIF) เขียนแทนด้วยสมการดังนี้

$$I(\theta) = \sum_{j=1}^m I_j(\theta)$$

เมื่อ $I(\theta)$ คือ ฟังก์ชันสารสนเทศของข้อกระทงตั้งแต่ข้อ 1 ถึงข้อที่ m

2. ฟังก์ชันสารสนเทศของข้อกระทง (IIF) สามารถแทนด้วยสมการดังนี้

$$I_j(\theta) = \sum_{jk=0}^k \frac{[P'_{jk}(\theta)]^2}{P_{jk}(\theta)}$$

เมื่อ $P'_{jk}(\theta)$ คือ ความน่าจะเป็นสำหรับคนที่มีความสามารถ θ จะตอบข้อกระทง j ได้คะแนน 1 มากกว่าคะแนน k ใดๆ

$P_{jk}(\theta)$ คือ ความน่าจะเป็นสำหรับคนที่มีความสามารถ θ จะตอบข้อกระทง j ได้คะแนน k

3. ฟังก์ชันสารสนเทศของแต่ละลำดับชั้นคะแนน (ICIFs) เขียนแทนด้วยสมการ
ดังนี้

$$I_{jk}(\theta) = \frac{[P'_{jk}(\theta)]^2}{P_{jk}(\theta)}$$

เมื่อ $P'_{jk}(\theta)$ คือ ความน่าจะเป็นสำหรับคนที่มีความสามารถ θ จะตอบข้อกระทง j ใน
ลำดับชั้นคะแนน ที่ 1 ได้ถูกต้อง มากกว่าคะแนน k ใดๆ

$P_{jk}(\theta)$ คือ ความน่าจะเป็นสำหรับคนที่มีความสามารถ θ จะตอบข้อกระทง j ใน
ลำดับชั้นคะแนน k ได้ถูกต้อง

3.2 GPCM (Generalized Partial Credit Model)

GPCM (Generalized Partial Credit Model) พัฒนาจาก PCM ให้มีการตรวจ
ให้คะแนนความรู้งานส่วนในการแก้โจทย์ปัญหาคณิตศาสตร์ โดยพิจารณาให้คะแนนตาม
ลำดับชั้นความสำเร็จของการแก้โจทย์ปัญหาเป็นคะแนนเรียงลำดับ 0, 1, 2, 3 (Masters,
1982) จากนั้นก็มีการนำไปใช้กับแบบวัดทัศนคติที่มีคะแนนเรียงลำดับหลายค่า (Dodd
and Koch, 1989)

มูรากิ (Muraki) ได้พัฒนาโมเดลดังกล่าวมาเป็น GPCM โดยแก้ไขข้อจำกัดเกี่ยว
กับความเป็นเอกมิติของเครื่องมือที่ใช้วัดคุณลักษณะ และใช้ค่าอำนาจจำแนกที่แปรเปลี่ยน
ไปในแต่ละข้อมารวมประมาณค่าพารามิเตอร์ด้วย โดยมีข้อตกลงว่าบุคคลที่มีความ
สามารถหรือมีคุณลักษณะที่ต้องการวัดสูงมีความน่าจะเป็นที่จะตอบคำตอบลำดับคะแนนที่
 K มากกว่า $K-1$ สามารถแทนด้วยสมการทั่วไปได้ดังนี้

$$C_{jk}(\theta) = P_{jk|k-1}(\theta) = \frac{P_{jk}(\theta)}{P_{j,k-1}(\theta) + P_{jk}(\theta)} = \frac{\exp^{[a_j(\theta-b_{jk})]}}{1 + \exp^{[a_j(\theta-b_{jk})]}}$$

เมื่อ k คือ ลำดับชั้นคะแนนที่ $2, 3, \dots, m_j$

$$P_{jk}(\theta) = \frac{C_{jk}}{1 - C_{jk}} P_{j,k-1}(\theta)$$

$P_{jk}(\theta)$ คือ ความน่าจะเป็นของคนที่มีความสามารถจะตอบได้คะแนน k
(กรณี $k-1$ ก็เช่นกัน)

$C_{jk} / (1 - C_{jk})$ คือ อัตราส่วนความน่าจะเป็นของสองเงื่อนไข ซึ่งอาจแสดงในรูปสมการ
 $\exp^{[a_j(\theta-b_{jk})]}$

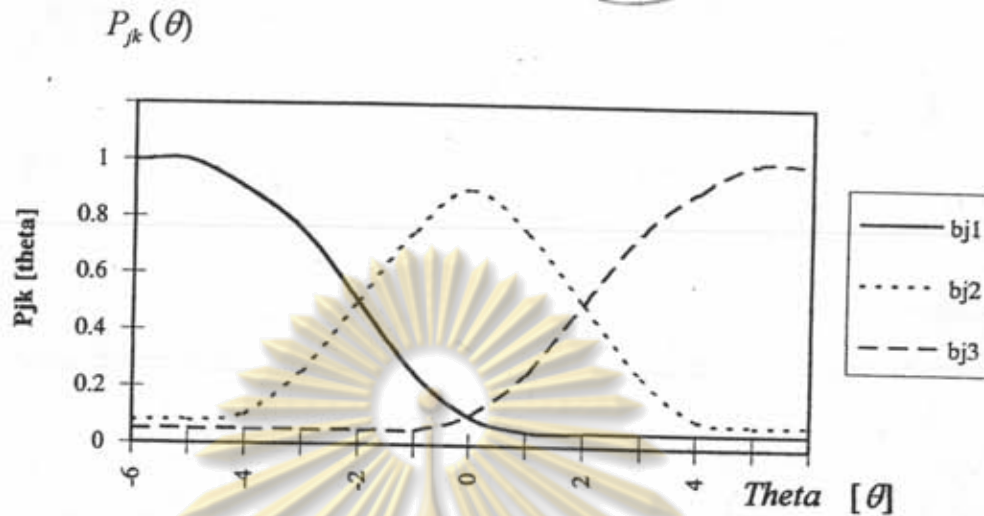
มาสเตอร์ (Masters) เรียก b_{jk} ว่าเป็นค่าพารามิเตอร์ความยากในแต่ละ
ลำดับชั้น เป็นจุดบนแกน θ ที่ฟังก์ชันของ $P_{j,k-1}(\theta)$ และ $P_{jk}(\theta)$ ตัดกัน ซึ่งโค้งทั้ง 2 เป็น
ฟังก์ชันของการตอบ (item category response function : ICRFs) ใน 2 ลำดับค่าคะแนนที่ตัด
กันเพียงจุดเดียวบนค่า θ ใดๆ คือ

$$\text{ถ้า } \theta = b_{jk}, \quad P_{jk}(\theta) = P_{j,k-1}(\theta);$$

$$\text{ถ้า } \theta > b_{jk}, \quad P_{jk}(\theta) > P_{j,k-1}(\theta);$$

$$\text{และถ้า } \theta < b_{jk}, \quad P_{jk}(\theta) < P_{j,k-1}(\theta);$$

ซึ่งอยู่บนข้อตกลงว่า $a_j > 0$ และ b_{jk} ไม่จำเป็นต้องเรียงกันในข้อสอบ j เพราะ
ค่าพารามิเตอร์จะแสดงถึงขนาดของความน่าจะเป็นในการตอบ $P_{j,k-1}(\theta)$ และ $P_{jk}(\theta)$ ใน
ลำดับที่อยู่ติดกัน ดังภาพที่ 2



ภาพที่ 2 โค้งฟังก์ชันสารสนเทศของ GPCM

การพิจารณาจุดตัดของโค้งฟังก์ชันการตอบแต่ละลำดับชั้น (item category response functions: ICRFs) ของโมเดล PCM แม้จะง่ายต่อการตีความหมายก็ตาม แต่จุดยอดของโค้งก็ไม่ใช่ว่าจะอยู่ตรงกลางของช่วงค่าคะแนนเสมอไป ซึ่งที่มาของค่าฟังก์ชันการตอบสนองของข้อกระทงแต่ละลำดับชั้น ($P_{jk}(\theta)$) แสดงได้ดังนี้ (Muraki, 1992)

$$\frac{\partial}{\partial(\theta)} P_{jk}(\theta) = a_j P_{jk}(\theta) [k - \sum_{k=1}^{mj} k P_{jk}(\theta)]$$

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

โดยกำหนดสมการเป็น 0; $\sum_{k=1}^{mj} cP_j(\theta) = k$ สมการนี้จะแสดงโค้ง ICRFs ของ $P_{jk}(\theta)$ เมื่อ $k = 1, 2, 3, \dots, k-1, k, k+1, \dots, mj$.

พารามิเตอร์ a_j คือพารามิเตอร์อำนาจจำแนกของข้อ j โดยค่า a_j มีพิสัยที่เป็นไปได้ในช่วง $-\infty$ ถึง $+\infty$ ซึ่งไม่เหมือนใน Dichotomous Model เพราะใน Polytomous Item Response Model อำนาจจำแนกในแต่ละลำดับชั้นคะแนนจะขึ้นอยู่กับผลรวมของ

พารามิเตอร์อำนาจจำแนกและค่าพารามิเตอร์เทรซโฮลด์ แต่ใน GPCM จะรวมค่าอำนาจจำแนกไว้ในโมเดลด้วย ซึ่งค่าอำนาจจำแนกนี้จะบอกถึงระดับการตอบในแต่ละลำดับค่าคะแนนที่เปลี่ยนไปในแต่ละข้อเช่นเดียวกับที่ค่า θ เปลี่ยนไปด้วย (Muraki, 1992)

ได้ดังนี้

จากแนวคิดดังกล่าวสามารถสรุปฟังก์ชันสารสนเทศที่สำคัญของ GPCM

1. ฟังก์ชันสารสนเทศของแบบวัด (TIF) แทนด้วยสมการดังนี้

$$I(\theta) = \sum_{j=1}^m I_j(\theta)$$

เมื่อ $I_j(\theta)$ คือ ฟังก์ชันสารสนเทศของข้อกระทง (IIF)

2. ฟังก์ชันสารสนเทศของข้อกระทง (IIF) ซึ่งสามารถแทนด้วยสมการ

$$I_j(\theta) = D^2 \alpha_j^2 \sum_{c=1}^{mj} [T_k - \bar{T}_j(\theta)]^2 P_{jk}(\theta)$$

เมื่อ $\bar{T}_j = \sum_{k=1}^{mj} T_k P_{jk}(\theta)$

D คือ ค่าคงที่ของสเกลมีค่าเท่ากับ 1.70

α_j คือ ค่าอำนาจจำแนกของข้อ j

T_k คือ ค่าคะแนนใดๆ ใน $T_j = (1, 2, \dots, mj)$

$P_{jk}(\theta)$ คือ ความน่าจะเป็นของคนที่มีความสามารถ θ จะตอบข้อ j ได้คะแนน k

k คือ ลำดับชั้นคะแนนที่ $1, 2, \dots, k-1, k, k+1, \dots, mj$

3. ฟังก์ชันสารสนเทศของลำดับค่าคะแนนในแต่ละข้อ (ICIFs) แทนด้วยสมการ

ดังนี้

$$I_{jk}(\theta) = P_{jk}(\theta) I_j(\theta)$$

เมื่อ $P_{jk}(\theta)$ คือ ความน่าจะเป็นของผู้ตอบที่มีความสามารถ θ จะทำข้อสอบ
ข้อ j ได้คะแนน k
 $I_j(\theta)$ คือ ฟังก์ชันสารสนเทศข้อกระทง

ตอนที่ 5 งานวิจัยที่เกี่ยวข้อง

การศึกษาเปรียบเทียบความเหมาะสมของวิธีการตรวจให้คะแนนแบบวัดชนิด
มาตรฐานค่าที่เป็นแบบเลือกตอบยังไม่เคยมีการศึกษามาก่อน แต่มีงานวิจัยที่เกี่ยวข้อง
ศึกษาเพื่อเปรียบเทียบความเหมาะสมของวิธีตรวจให้คะแนน แบบพหุวิภาคซึ่งการศึกษา
เพื่อเปรียบเทียบวิธีตรวจให้คะแนนดังกล่าวส่วนมากจะใช้เครื่องมือที่เป็นแบบสอบวัด
ผลสัมฤทธิ์ (achievement test) (Smith, 1987; De-Ayala, 1993; Yamamoto and Kulick, 1992
cited by Donoghue, 1994; Wainer and Thissen, 1993; cited by Donoghue, 1994;
Donoghue, 1994) มีผลการวิจัยที่ได้ข้อค้นพบเป็น 2 ประเด็นที่สำคัญ คือ

ประเด็นแรก ให้ข้อสนับสนุนว่าการตรวจให้คะแนนแบบพหุวิภาคมีความเที่ยง
และความตรงเชิงสภาพ (concurrent validity) สูงกว่าการตรวจให้คะแนนแบบทวิวิภาค
(Smith, 1987) และในการเปรียบเทียบค่าฟังก์ชันสารสนเทศก็พบว่าให้ค่าฟังก์ชันสารสนเทศ
สูงกว่าการตรวจให้คะแนนแบบทวิวิภาค (Samejima, 1976 cited by Donoghue, 1994;
Donoghue, 1994) และนอกจากนี้ยังพบว่าค่าพารามิเตอร์มีความคงที่ แม่นยำกว่าการตรวจ
ให้คะแนนแบบทวิวิภาคด้วย (Smith, 1976 cited by Donoghue, 1994) ในส่วนของการศึกษา
เกี่ยวกับการตรวจให้คะแนนความรู้บางส่วน (partial knowledge) ที่มีลักษณะการตรวจให้
คะแนนแบบพหุวิภาคแบบหนึ่ง พบว่าเป็นวิธีที่มีความเที่ยงและความตรงสูงกว่าวิธีการตรวจ
ให้คะแนนแบบทวิวิภาค (Frery and Hutchinson, 1982; Smith, 1987)

ผลการวิจัยอีกประเด็นหนึ่งที่ศึกษากับแบบสอบวัดผลสัมฤทธิ์ ได้ข้อค้นพบว่า การตรวจให้คะแนนแบบทวิภาคให้ค่าฟังก์ชันสารสนเทศสูงกว่าการตรวจให้คะแนนแบบ พหุภาค เช่น การศึกษาของ ยามาโมโต และคูลิก (Yamamoto and Kulick, 1992 cited by Donoghue, 1994) เวเนอร์ และทิสเซน (Wainer and Thissen, 1993 cited by Donoghue, 1994) อย่างไรก็ตาม โดโนฮู (Donoghue, 1994) ได้ให้ข้อสังเกตว่าการศึกษาของ ยามาโมโต และคูลิก ดัง กล่าวเป็นการตรวจให้คะแนนที่ไม่เหมาะสม เนื่องจากใช้แบบสอบที่สร้างขึ้นเพื่อการตรวจให้ คะแนนแบบทวิภาคมาปรับเป็นการตรวจให้คะแนนแบบพหุภาค ส่วน เวเนอร์ และทิสเซน จะมุ่งศึกษาถึงความคุ้มค่าของเวลาและการใช้จ่าย (time and expense) มากกว่าจะพิจารณาถึง ความตรง (validity) และความเชื่อถือได้ (authenticity) ซึ่ง มูรากิ (Muraki, 1993) ได้ให้ข้อสังเกต ว่า แบบสอบที่ตรวจให้คะแนนแบบพหุภาคไม่จำเป็นที่จะต้องให้ค่าฟังก์ชันสารสนเทศสูงกว่า การตรวจให้คะแนนแบบทวิภาคเสมอไป แต่โดยทั่วไปจะมีโอกาสให้ค่าฟังก์ชันสารสนเทศ ครอบคลุมช่วงพิสัยของคุณลักษณะ (theta) มากกว่าการตรวจให้คะแนนแบบทวิภาค

จากงานวิจัยดังกล่าวข้างต้น เป็นการศึกษาเพื่อตอบคำถามว่าการใช้แบบสอบ ที่ตรวจให้คะแนนแบบทวิภาคกับแบบพหุภาค วิธีใดจะมีความเที่ยง ตรงกว่ากัน โดยมี ผลการศึกษาที่ค่อนข้างชัดเจนว่าแบบสอบที่ตรวจให้คะแนนแบบพหุภาค ถึงแม้จะต้องเสีย เวลาไปกับการตรวจให้คะแนนมากกว่าแบบสอบที่ตรวจให้คะแนนแบบทวิภาค แต่จะให้ คุณภาพด้านความเที่ยงและความตรงที่สูงกว่าการตรวจให้คะแนนแบบทวิภาค ซึ่งจะเห็นได้ว่า ผลการศึกษาดังกล่าวส่วนใหญ่ล้วนศึกษากับแบบสอบประเภทวัดผลสัมฤทธิ์ (achievement test) ยังไม่เคยศึกษาในแบบวัดคุณลักษณะที่มีลักษณะเป็นมาตร ปรมาณค่าที่มีลักษณะแบบตัวเลือกตอบอย่างจริงจัง นอกจากนี้ยังไม่เคยมีการศึกษาเพื่อ เปรียบเทียบความเหมาะสมของโมเดลประเภท Polytomous Item Response ว่าโมเดลใดมี ความเหมาะสมกว่ากัน ผู้วิจัยจึงเห็นว่าการศึกษาเพื่อเปรียบเทียบฟังก์ชันสารสนเทศ ของ แบบวัดคุณลักษณะและแบบสอบประเภทวัดผลสัมฤทธิ์ที่มีวิธีการตรวจให้คะแนนที่แตกต่างกัน และการวิเคราะห์ด้วยโมเดลที่ต่างกันน่าจะเป็นประโยชน์สำหรับการศึกษาด้านการวัดผลทาง การศึกษาต่อไป

ตอนที่ 6 โปรแกรมคอมพิวเตอร์ที่ใช้วิเคราะห์มาตรฐานค่า

การวิเคราะห์มาตรฐานค่าตามแนวคิดของทฤษฎีการตอบสนองข้อสอบ โดย
ใช้โปรแกรมคอมพิวเตอร์มี 2 แบบ คือ

5.1 การวิเคราะห์เพื่อคัดเลือกผู้ตอบที่เหมาะสม (person-fit) และข้อกระทงที่
เหมาะสม (item-fit) และการวิเคราะห์ค่าน้ำหนักคะแนนที่เหมาะสม (optimal weight)
ซึ่งในที่นี้จะกล่าวถึงเฉพาะการวิเคราะห์ผู้ตอบและข้อกระทงที่เหมาะสมเท่านั้น การวิเคราะห์
ดังกล่าวสามารถทำได้โดยใช้โปรแกรมคอมพิวเตอร์สำเร็จรูป BIGSTEPS ที่พัฒนาโดย โลนาเคร
และไรท์ (Linacre and Wright) ในปี ค.ศ. 1994 โปรแกรมนี้สามารถวิเคราะห์ ผู้ตอบที่
เหมาะสมและข้อกระทงที่เหมาะสม โดยมีหลักการที่สำคัญคือ

5.1.1 การวิเคราะห์ผู้ตอบที่เหมาะสม (person-fit) เป็นการวิเคราะห์เพื่อ
คัดเลือกผู้ตอบที่มีแบบแผนการตอบเหมาะสมนำไปใช้ในการวิเคราะห์ต่อไป โดยมีหลักการ
ง่ายๆ คือ ผู้ที่มีความสามารถสูงควรจะตอบข้อกระทงที่ง่ายและยากได้ถูกต้องมากกว่าผู้ที่มี
ความสามารถต่ำ ผู้ตอบที่ไม่เหมาะสมก็คือผู้ตอบที่มีแบบแผนการตอบที่ไม่เป็นไปตาม
แนวคิดนี้ โดยสามารถพิจารณาคัดเลือกบุคคลที่ไม่เหมาะสมได้จากการพิจารณาค่าสถิติ
Person Infit , Person Outfit และค่า Mean Square Outfit (MNSQ) โดยผู้ตอบที่
เหมาะสมควรมีค่าสถิติ INFIT และ OUTFIT ไม่เกิน $1/2$ และค่า MNSQ ไม่เกิน 1.20
(Linacre and Wright, 1994 :89) ผู้ตอบที่ไม่เหมาะสมอาจเกิดจากการตอบแบบเดาสุ่มหรือ
ไม่ตั้งใจทำ หากนำผลการตอบมารวมในการวิเคราะห์ด้วยอาจทำให้การสรุปผลมีความ
คลาดเคลื่อนสูงได้

5.1.2 การวิเคราะห์ข้อกระทงที่เหมาะสม (item-fit) เป็นการวิเคราะห์เพื่อ
คัดเลือกข้อกระทงที่สามารถจำแนกคนที่มีระดับคุณลักษณะสูงและต่ำออกจากกันได้
ซึ่งมีหลักการในการคัดเลือกค่าสถิติ INFIT , OUTFIT และ MNSQ คล้ายกับการวิเคราะห์
ผู้ตอบที่เหมาะสม โดยการวิเคราะห์ข้อกระทงที่เหมาะสมควรจะวิเคราะห์หลังจากได้คัด

คัดเลือกผู้ตอบที่ไม่เหมาะสมออกไปแล้ว เพราะถ้าหากเราเชื่อว่าเครื่องมือสร้างมา มีคุณภาพดี ความคลาดเคลื่อนจากตัวผู้ตอบน่าจะมากกว่าเครื่องมือ จึงควรคัดคนที่ไม่เหมาะสมออกก่อน

5.2 การวิเคราะห์เพื่อประมาณค่าพารามิเตอร์ของข้อกระทงและของผู้สอบ การวิเคราะห์เพื่อประมาณค่าพารามิเตอร์ของข้อกระทงและของผู้ตอบจากการใช้แบบวัดประเภทมาตรฐานค่า หรือแบบสอบที่ตรวจให้คะแนนแบบหลายค่า สามารถวิเคราะห์ได้โดยใช้โปรแกรมคอมพิวเตอร์ MULTILOG ซึ่งพัฒนาโดย ทิชเซน (Thissen) ในปี ค.ศ.1991 และโปรแกรม PARSCALE ที่พัฒนาโดย มูรากิ และบอค (Muraki and Bock) ในปี ค.ศ.1994 ซึ่งมีรายละเอียดโดยย่อ ดังนี้

5.2.1 โปรแกรม MULTILOG เป็นโปรแกรมที่ใช้สำหรับการวิเคราะห์แบบวัด หรือแบบสอบที่ตรวจให้คะแนนแบบพหุวิภาค สามารถใช้ได้กับผู้สอบและข้อกระทงจำนวนมาก เนื่องจากมีการสร้างไฟล์สำรองจำนวนมากในขณะที่โปรแกรมทำงาน หากมีข้อมูลมากเกินไป โปรแกรมจะเตือนและสามารถใส่คำสั่งย่อย > ESTimate BIG. ช่วยได้

โปรแกรมนี้สามารถใช้วิเคราะห์ตาม Graded Response Model (GRM), Bock Nominal Model (BNM) และมีโปรแกรมย่อยสำหรับวิเคราะห์ Logistic Model แบบ 1,2 และ 3 พารามิเตอร์สำหรับแบบสอบที่ตรวจให้คะแนนแบบพหุวิภาคได้ด้วย วิธีประมาณค่าพารามิเตอร์จะมีวิธีให้เลือก 2 วิธี คือ Marginal Maximum Likelihood (MML) และวิธี Fixed- θ Estimation ในการวิจัยครั้งนี้เลือกใช้วิธี MML ผลการวิเคราะห์จะให้ค่าพารามิเตอร์อำนาจจำแนก (a) ค่าพารามิเตอร์ความยากในแต่ละลำดับชั้นคะแนน (b_{jk}) ค่าฟังก์ชันสารสนเทศรายข้อกระทง (IIF) และค่าฟังก์ชันสารสนเทศของแบบวัดทั้งฉบับ (TIF)

5.2.2 โปรแกรม PARSCALE เป็นโปรแกรมที่ใช้สำหรับการวิเคราะห์แบบวัด หรือ แบบสอบที่ตรวจให้คะแนนแบบพหุวิภาค โปรแกรมนี้สามารถใช้วิเคราะห์ตาม Graded Response Model (GRM) , Partial Credit Model (GRM) และ Generalized Partial Credit Model (GPCM) การประมาณค่าพารามิเตอร์ใช้วิธี Marginal Maximum Likelihood

(MML) ผลการวิเคราะห์ให้ค่าพารามิเตอร์อำนาจจำแนก (a) ค่าพารามิเตอร์ความยาก ในแต่ละลำดับขั้นคะแนน (bjk) ค่าฟังก์ชันสารสนเทศรายข้อกระทง (IIF) แต่การให้ค่า ฟังก์ชันสารสนเทศเสนอเฉพาะโมเดล PCM และ GPCM เท่านั้น

การวิเคราะห์ผลในการวิจัยนี้จะเน้นการวิเคราะห์ค่าฟังก์ชันสารสนเทศจาก โปรแกรม MULTILOG และ PARSCALE เป็นสำคัญ ดังนั้นผู้วิจัยจึงได้สรุปลักษณะและการ นำโปรแกรมคอมพิวเตอร์ทั้งดังกล่าวไปใช้ได้ดังตารางที่ 2

ตารางที่ 2 ลักษณะของโปรแกรม MULTILOG และ PARSCALE

โปรแกรม	การตรวจให้คะแนน	โมเดลที่สามารถวิเคราะห์	ผลจากการวิเคราะห์					
			ค่าพารามิเตอร์วิเคราะห์		ค่าฟังก์ชันสารสนเทศ			
			a _j	b _i	c _k	θ	IIF	TIF
1. MULTILOG (version 6.0)	1.1 ทวิภาค	Logistic1 PL	-	/	-	/	/	/
		2 PL	/	/	-	/	/	/
		3 PL	/	/	/	/	/	/
	1.2 พหุภาค	GRM	/	/	-	/	/	/
GPCM		-	-	-	-	-	-	
2. PARSCALE (version 2.2)	2.1 ทวิภาค	Logistic 1 PL	-	-	-	-	-	-
		2 PL	-	-	-	-	-	-
		3 PL	-	-	-	-	-	-
	2.2 พหุภาค	GRM	/	/	-	/	-	-
GPCM		/	/	-	/	/	/	

หมายเหตุ

- / หมายถึง ผลจากการวิเคราะห์ ที่โปรแกรมคอมพิวเตอร์สามารถทำได้
- หมายถึง ผลจากการวิเคราะห์ ที่โปรแกรมคอมพิวเตอร์ไม่สามารถทำได้

จากตารางที่ 2 จะเห็นว่าโปรแกรม MULTILOG สามารถวิเคราะห์ข้อมูลการตรวจให้คะแนนทั้งแบบทวิภาคและแบบพหุภาค คือสามารถวิเคราะห์ด้วยโมเดลโลจิสติก 1,2 และ 3 พารามิเตอร์ และ GRM ซึ่งการวิเคราะห์ดังกล่าวจะให้ค่าพารามิเตอร์ของผู้ตอบ ของข้อกระทง และค่าฟังก์ชันสารสนเทศของข้อกระทงและรวมทั้งฉบับ ส่วนโปรแกรม PARSCALE ไม่มีโปรแกรมย่อยสำหรับการวิเคราะห์การตรวจให้คะแนนแบบทวิภาค แต่สามารถวิเคราะห์การตรวจให้คะแนนแบบพหุภาคได้ทั้ง GRM และ GPCM แต่การวิเคราะห์ GRM จะไม่แสดงผลของค่าฟังก์ชันสารสนเทศ ดังนั้นในการวิจัยครั้งนี้ผู้วิจัยจึงจำเป็นต้องวิเคราะห์ค่าฟังก์ชันสารสนเทศของแบบวัดคุณลักษณะและแบบสอบ ซึ่งใช้วิธีการตรวจให้คะแนนแบบทวิภาคและแบบพหุภาคด้วยโปรแกรมคอมพิวเตอร์ MULTILOG และ PARSCALE



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย