

บทที่ 2



วรรณคดีที่เกี่ยวข้อง

การสอบในโรงเรียนมักเป็นกระบวนการที่เป็นลำดับขั้น นั่นคือสิ่งที่นักเรียนเรียน
 ในชั้นสองจะต้องอาศัยพื้นฐานที่เรียนมาจากชั้นหนึ่ง เรียกว่าเป็นกระบวนการที่
 ต่อเนื่องกัน กระบวนการรู้งี้จะมีประสิทธิภาพดีก็เมื่อสิ่งที่นำมาให้นักเรียนเรียน
 ควรจัดลำดับต่อเนื่องกันอย่างไคความหมาย ซึ่งเป็นสิ่งที่จำเป็นทั้งในดานการเตรียม
 การสอนและการตัดสินความก้าวหน้าของนักเรียนในการเรียนลำดับต่อไป¹

วิธีการที่จะประเมินความก้าวหน้านี้ได้คือ การทดสอบอิงเกณฑ์ เครื่องมือที่ใช้คือ
 แบบสอบอิงเกณฑ์ (Criterion-or Domain-Referenced Test) ซึ่ง ไฮฟลิ (Hively)
 วิจารณ์ไว้ว่า

คำว่า "เกณฑ์" ใน "แบบสอบอิงเกณฑ์" นี้ นำไปสู่การแปลความหมายของข้อมูล
 อย่างผิด ๆ และ เพื่อหลีกเลี่ยงความเข้าใจผิดดังกล่าวจึงได้เสนอให้ใช้คำว่า
 "โดเมน" (Domain) แทน โดยที่ในโดเมนหนึ่ง ๆ จะประกอบด้วยชุดย่อย ๆ
 ของความรู้ ทักษะ ความเข้าใจ หรือทัศนคติซึ่งจะบรรยายให้เห็นคุณสมบัติที่จำเป็น
 ของเนื้อหาที่คาดว่าจะเกิดขึ้นในตัวของผู้เรียน และบรรยายให้เห็นวัตถุประสงค์
 ซึ่งหวังว่านักเรียนจะแสดงออกมาว่าได้รับอะไรไปบ้าง²

¹C.M. Lindvall and A.J. Nitko, Measuring Pupil Achievement and Aptitude (New York : Harcourt Brace Jovanovich, 1975), p.14.

²Wells Hively et al., "Criterion - Referenced Testing," Educational Technology 14 (1974) : 10.

ได้มีนักวัดและประเมินผลหลายท่านให้คำนิยามของ แบบสอบอิง เกณฑ์หรือแบบสอบอิง โดเมนไว้ เช่น มิลแมน¹ ซึ่งใช้คำว่าโดเมนแทนเกณฑ์ กล่าวว่า "การสอบอิง โดเมนเป็นการวัดสภาพที่เป็นปัจจุบันของนักเรียนคนใดคนหนึ่ง โดยอ้างอิงถึงชุดของงานที่ทำที่ได้อธิบายไว้เรียบร้อยแล้ว เรียกว่า โดเมน แบบสอบอิง โดเมนคือ กลุ่มตัวอย่างของข้อสอบจากโดเมนซึ่งอาจได้มาจากการสุ่ม หรือการสุ่มแยกประเภท" ในขณะเดียวกัน เกลเซอร์และนิทโก² นิยามว่า, "แบบสอบอิง เกณฑ์เป็นแบบสอบที่สร้างขึ้นโดยมีเจตนาให้เป็นการวัดที่สามารถแปลความหมายออกมาได้ตรง ๆ ในรูปของมาตรฐานการกระทำที่เฉพาะ ซึ่งในที่นี้บังคับได้โดยให้นิยาม โดเมนของงานที่นักเรียนหรือผู้สอบควรทำได้ จากนั้นนำตัวอย่างที่เป็นตัวแทนของงานจากโดเมนนี้มาจัดเป็นแบบสอบ ผลจากการวัดจะแสดงถึงพฤติกรรมของแต่ละคนเพื่อเทียบกับ โดเมนที่นิยามไว้"

การวัดอิง เกณฑ์เป็นวิธีการวัดที่รู้จักกันมานานแล้ว แต่ไม่มีการศึกษาถึงการสร้างหรือพัฒนาเครื่องมือที่ใช้ในการวัด จนกระทั่งเมื่อไม่กี่ปีมานี้จึงได้มีนักวัดและประเมินผลบางท่านที่พยายามจะศึกษาเรื่องนี้ขึ้น โดยมีแรงจูงใจจากแนว โนม 4 ประการ อันเนื่องมาจากการใช้แบบสอบอิงกลุ่มในการวัดและประเมินผลการศึกษาครั้งที่ แอร่าเซียน และมาคอสกลาวไว้คือ

1. การวิพากษ์วิจารณ์ถึงเรื่องความหมายของกรวัด รวมทั้งการใช้แบบสอบมาตรฐานที่ให้ออกผลไม่เพียงพอและไม่เหมาะสมกับเนื้อหาบางประการที่ต้องการวัด

¹Jason Millman, "Criterion-Referenced Measurement," in Evaluation in Education, ed. W.J. Popham (Berkeley : McCutchan Publishing Corporation, 1974), p.327.

²R. Glaser and A.J. Nitko, "Measuring in Learning and Instruction," in Educational Measurement, ed. R.L. Thorndike (Washington : American Council on Education, 1971), p.653.

2. การวิพากษ์วิจารณ์เกี่ยวกับระดับคะแนน (Grade) ว่า ทำให้
จุดหมายของการศึกษาเปลี่ยนไป กลายเป็นการแข่งขันกันเพื่อจะให้
ได้ระดับคะแนนสูงๆ และกลายเป็นสิ่งตอรองในการเข้าศึกษา การสมัครงาน ฯลฯ
จนลงด้วยว่า ระดับคะแนนไม่ใช่ข้อมูลว่า เด็กทำอะไรไต่บ่าง บอกแค่ว่า
เขาดีกว่าหรือค้อยกว่าผู้อื่นในกลุ่มของเขาเท่านั้น

3. จากวิวัฒนาการการเคลื่อนไหวทางเทคนิคการสอนต่าง ๆ ที่ทำให้
พบว่า แบบสอบอิงกลุ่มไม่เพียงพอในการที่จะใช้ประเมินพฤติกรรมเป็นรายบุคคล
หรือแม้แต่วิธีการสอนที่ใช้ ว่าดี หรือไม่ เพียงใด .

4. ความเชื่อของนักการศึกษาส่วนมากที่ว่า คนทุกคนหรือคนส่วนมากจะ
สามารถเรียนรู้หรือสัมฤทธิ์ในวิชาต่าง ๆ ได้ ถ้ามีวิธีการที่ดีกว่า จึงทำให้การทดสอบ
เปลี่ยนจากการเปรียบเทียบในกลุ่ม เป็นการตรวจสอบ และให้รางวัลการเรียนรู้ในรูปของ
การกระทำ (เช่น ถ้าทุกคนทำได้ดี เกณฑ์ ทุกคนอาจได้คะแนนระดับ "ก")¹

กล่าวโดยสรุปคือ การวัดอิงกลุ่มนั้นไม่เหมาะจะนำมาใช้วัดสัมฤทธิ์ผลทางการ
ศึกษาบางอย่าง ทั้งนี้เนื่องจากว่า บอกเราได้ไม่ครบเท่าที่เราต้องการ นั่นคือใช้แบบ
สอบไม่ตรงกับจุดประสงค์ของการทดสอบที่เราต้องการกระทำ

กรอนลันด์ (Gronlund) ได้เสนอการตัดสินใจในเรื่องการใช้แบบสอบ โดย
พิจารณาจากวัตถุประสงค์ของการสอบ และลักษณะของแบบสอบวัดสัมฤทธิ์ผล 4 ชนิด
ดังตาราง²

¹Airasian, "Criterion-Referenced Testing in the Classroom,"
pp. 76-77.

²Norman E. Gronlund, Constructing Achievement Test (N.J.:
Prentice-Hall, 1977), p.19.

ตารางที่ 1 ลักษณะของแบบสอบวัดสัมฤทธิ์ผล 4 ชนิด

ชนิดของแบบสอบ	หน้าที่ของแบบสอบ	การเลือกตัวอย่างข้อสอบ	ลักษณะข้อสอบ
วางตัวบุคคล (Placement)	วัดทักษะเบื้องต้น คัดสรรการกระทำ เริ่มแรกเกี่ยวกับวัตถุ- ประสงค์ของวิชา	รวมไว้ด้วยพฤติกรรมที่ ต้องการวัดเบื้องต้นก่อน เรียน เลือกตัวอย่างที่เป็นตัว แทนของวัตถุประสงค์ของ วิชา	โดยทั่วไปจะง่าย และแปลผลแบบอิง เกณฑ์ มีความยากง่าย ต่าง ๆ (มีพิสัยของ ความยากกว้าง) และ อิงกลุ่ม
วัดความก้าวหน้า (Formative)	ให้ขอมูลย้อนกลับ แก่ผู้เรียนและผู้สอน ในคานความก้าวหน้า ในการเรียน	รวมไว้ด้วยทุกหน่วย ของวัตถุประสงค์ถ้าเป็น ไปได้ (หรือวัดสิ่งที่จำ เป็นที่สุด)	ข้อสอบยากหรือ ง่ายแล้วแต่วัตถุ ประสงค์ของแต่ละ หน่วย และอิงเกณฑ์
วัดเพื่อวินิจฉัย (Diagnostic)	เพื่อพิจารณาสาเหตุ ของความขัดข้องทาง การเรียนที่เกิดขึ้นซ้ำๆ	รวมไว้ด้วยตัวอย่าง ของงาน ซึ่งขึ้นอยู่กับ แหล่งของความผิดพลาด ในการเรียนที่มีร่วมกันอยู่	โดยทั่วไปจะง่าย และใช้เพื่อชี้จุด บกพร่องของนักเรียน และอิงเกณฑ์
จัดความรวมยอด (Summative)	ให้ระดับคะแนนหรือ รับรองความรู้หา ยหน่วยการสอน	เลือกตัวอย่างที่เป็น ตัวแทนของวัตถุประสงค์	มีพิสัยความยาก กว้างและอิงกลุ่ม

จะเห็นว่า กรอนลินด์มีความเห็นว่า วัตถุประสงค์ในการสอบต่างกัน แบบสอบที่ใช้ต่างกันไปด้วย ในขณะที่แบบสอบที่ใช้ในโครงการ I P I (Individually Prescribed Instruction)¹ ซึ่งเป็นแบบสอบที่ใช้วัดพัฒนาการของนักเรียนในโปรแกรมการสอนรายบุคคลวิชาคณิตศาสตร์ และวิชาอื่น ๆ ในชั้นประถมที่มีการจัดลำดับแบบสอบตามวัตถุประสงค์การสอนและตามหน่วยการสอนได้ใช้แบบสอบอิง เกณฑ์เพียงแบบเดียว (หลายฉบับ) เพื่อวัตถุประสงค์ในการวัด 4 ประการ คือ

1. การวางตัวบุคคล (Placement Testing) ใช้แบบสอบเพื่อออกนักเรียนว่า เขาควรจะเริ่มเรียนชั้นใด ระดับใด ของหลักสูตรโดยให้นักเรียนทำแบบสอบในตอนเริ่มปีการศึกษา

2. สอบเพื่อวินิจฉัย (Diagnostic Testing) ใช้แบบสอบก่อนเรียน (Pre-test) ที่เตรียมไว้ให้นักเรียนทำก่อนที่จะเริ่มเรียนหน่วยเรียนใหม่ เนื้อหาเป็นเนื้อหาที่นักเรียนถูกตัดสินให้ผ่านมาแล้ว

3. สอบหลังจากเรียน (Post-testing) นักเรียนจะเลือกได้ด้วยตนเองว่าจะเรียนหน่วยใดต่อไป เมื่อผ่านแต่ละหน่วยแล้ว เช่น เมื่อจบหน่วย D อาจเรียนหน่วย E หรือ F ต่อก็ได้ วิธีการก็คือ จะให้นักเรียนทำแบบสอบอีกครั้งหลังจากสอบไปแล้วหลายสัปดาห์ เพื่อดูว่ายังมีความรู้เหลืออยู่หรือไม่ (อาจสุ่มตัวอย่างมาให้ทำเป็นบางข้อ)

4. สอบเพื่อสำรวจความก้าวหน้า (Monitoring Progress) เพื่อตอบคำถามให้แก่เด็กเรียนที่ว่า "ฉันรอบรู้ทักษะนี้แล้วจริงหรือ?" จะใช้แบบสอบ C E T (Curriculum Embedded Test) ให้ข้อมูลเพิ่มเติมเกี่ยวกับความรู้อัน

ในขณะที่กรอนลินด์เสนอว่า ควรใช้แบบสอบอิงกลุ่มวัดความรู้รวบยอดนั้น โครงการ IPI ใช้แบบสอบอิง เกณฑ์วัดความรู้หลังจากเรียน (ซึ่งเป็นความรู้รวบยอด ✓ เช่นเดียวกัน) นั่นคือ ใช้แบบสอบอิง เกณฑ์วัดได้ทุกวัตถุประสงค์ที่ของการจะวัด

002615

A

¹Lindvall, Measuring Pupil Schievement..., p. 198.

แฮมเบิลตันและเอ็กเนอร์ (Hambleton and Eignor)¹ ได้เสนอเกณฑ์ที่จะใช้ในการตัดสินคุณภาพของแบบสอบอิงเกณฑ์ เมื่อต้องการที่จะซื้อแบบสอบอิงเกณฑ์มาใช้ โดยมีแนวทางในการถามตามหัวข้อต่อไปนี้

วัตถุประสงค์

1. ได้มีการแสดงจุดมุ่งหมายของแบบสอบชัดแจ้งหรือไม่
2. แต่ละวัตถุประสงค์ที่แสดงไว้ชัดเจนพอที่จะชี้ให้เห็นถึงจักรวาลของข้อสอบหรือไม่
3. จุดประสงค์แสดงไว้ชัดเจนหรือไม่ว่า แบบสอบนั้นวัดอะไร
4. มีเหตุผลเหมาะสมหรือไม่ ในการบรรจุวัตถุประสงค์แต่ละข้อลงในแบบสอบ
5. ผู้นำแบบสอบไปใช้ที่มีศักยภาพสามารถปรับปรุงแบบสอบให้เหมาะสมกับความต้องการของท้องถิ่นหรือไม่ โดยเพียงแต่พิจารณาตัดสินว่า วัตถุประสงค์ใดบ้างในแบบสอบที่ควรจะวัดด้วยแบบสอบนั้น
6. มีการระบุเนื้อเรื่องที่จะวัดด้วยแบบสอบนั้น ๆ และสถานภาพที่จะใช้แบบสอบฉบับนั้นไว้คู่กันหรือไม่
7. ระบุชื่อผู้ที่เขียนวัตถุประสงค์ในแบบสอบหรือไม่
8. ชุดของวัตถุประสงค์ที่จะวัด โดยแบบสอบนั้น เป็นตัวแทนของชุดจากโดเมนเนื้อหาที่เราต้องการหรือไม่

¹Ronald K. Hambleton and Daniel R. Eignor "Guidelines for Evaluating Criterion-Referenced and Test Manuals," Journal of Educational Measurement 15 (1978) : 322-324.



ข้อสอบ

1. ใ้บรรยายถึงกระบวนการสร้างข้อสอบหรือไม่
2. ข้อสอบมีความตรงตามวัตถุประสงค์ที่จะวัดหรือไม่
3. เป็นตัวแทนของประชากรของข้อสอบที่วัดวัตถุประสงค์นั้นหรือไม่
4. มีข้อบกพร่องทางเทคนิคหรือไม่
5. รูปแบบเหมาะแก่กับวัตถุประสงค์ที่จะวัดหรือไม่
6. มีอคติหรือไม่ (เช่น คอเพศ เชื้อชาติ)
7. ใช้กลุ่มตัวอย่างที่เป็นวิวิธพันธ์ในการศึกษานำหรือไม่
8. การวิเคราะห์ ข้อมูลเป็นไปเพียงเพื่อหาข้อสอบที่บกพร่องหรือไม่

การบริหารการสอบ

1. ในคำสั่งมีข่าวสารเกี่ยวกับจุดประสงค์ของการสอบ เวลาที่ใช้ ตัวอย่างคำถาม ภาระงานคำตอบ และการให้คะแนนหรือไม่
2. คำสั่งในแบบสอบชัดเจนหรือไม่
3. สะดวกในการตรวจให้คะแนนหรือไม่
4. คู่มือแบบสอบชี้ถึงบทบาทและความรับผิดชอบของผู้คุมสอบหรือไม่

การวางรูปแบบของแบบสอบ

1. ตัวแบบสอบมีการวางรูปแบบให้ชวนสนใจหรือไม่
2. ให้ความสะดวกต่อผู้สอบหรือไม่

ความเที่ยง

1. ชนิดของความเที่ยงที่เสนอไว้เหมาะแก่การนำคะแนนจากแบบสอบไปใช้หรือไม่

2. กลุ่มตัวอย่างที่นำมาศึกษาเรื่องความเที่ยง มีขนาดและเป็นตัวแทนประชากรที่เหมาะสมกับผู้ที่ให้นำแบบสอบถามไปวัดหรือไม่
3. ความยาวของแบบสอบถามเหมาะสมที่จะให้แบบสอบถามที่มีระดับความเที่ยงของคะแนนพอหรือไม่
4. เสนอข้อวิจารณ์เกี่ยวกับความเที่ยงในคู่มือแบบสอบถามสำหรับวัตถุประสงค์ในการนำแบบสอบถามไปใช้หรือไม่

คะแนน เกณฑ์

1. แดง เหตุผล เหมาะสมในการเลือกวิธีการในการตัดสินใจใช้คะแนนเกณฑ์ตัดสินหรือไม่
2. อธิบายถึงวิธีการที่ใช้เลือก เกณฑ์ตัดสินหรือไม่ วิธีที่ใช้นั้นเหมาะสมหรือไม่
3. แสดงหลักฐานด้านความตรง ของคะแนน เกณฑ์ที่เลือกใช้หรือไม่

ความตรง

1. ความตรงที่เสนอไว้เหมาะสมกับการนำไปใช้หรือไม่
2. ได้วิจารณ์อย่างมีเหตุผลในองค์ประกอบที่มีผลต่อความตรงของคะแนนในคู่มือหรือไม่

ปกติวิสัย

1. เสนอปกติวิสัยในรูปที่เหมาะสมหรือไม่
2. บรรยายถึงกลุ่มตัวอย่างที่นำมาใช้ เป็นกลุ่มปกติวิสัยหรือไม่
3. มีค่าเค้นที่มีเหตุผลในการแปลความหมายคะแนนอย่างถูกต้องหรือไม่

การรายงานเกี่ยวกับคะแนนจากแบบสอบถาม

1. มีการรายงานคะแนนของผู้สอบแต่ละวัตถุประสงค์หรือไม่

2. มีวิธีการในการรายงานผลการสอบเสนอไว้หลายวิธีพอที่ผู้ใช้จะเลือกนำไปใช้หรือไม่ (เช่น รายงานตามชั้นและระดับชั้นภายในโรงเรียน)
3. มีวิธีการที่สะดวกในการตรวจให้คะแนนด้วยมือ และมีแบบฟอร์มในการรายงานคะแนนที่ได้จากแบบสอบหรือไม่

การแปลความหมายคะแนน

1. มีคำเตือนในการแปลความหมายคะแนนของแต่ละคนหรือกลุ่มไว้ในคู่มือหรือไม่
2. ได้มีการเสนอแนวทางที่เหมาะสมในการนำคะแนนจากแบบสอบไปใช้บรรยายถึงสถานภาพ การตัดสินใจในการสอน การประเมินโปรแกรมการสอน หรือเพื่อการอื่น ๆ หรือไม่

การประมาณค่าคะแนนโคเมน

คะแนนโคเมนหรือเรียกว่า คะแนนจริงในแบบสอบอิงกลุ่มมีวิธีการในการประมาณค่าต่างจากการประมาณค่าคะแนนจริงในแบบสอบอิงกลุ่มที่เห็นได้ชัดประการหนึ่งคือ จะต้องได้มาจากแบบสอบที่เป็นเอกพันธ์ในด้านเนื้อหา หรือผู้ทำให้เข้าใจง่าย ๆ คือ ได้จากแบบสอบที่วัดวัตถุประสงค์ข้อเดียว ถ้าแบบสอบทั้งฉบับวัดวัตถุประสงค์หลายข้อก็จะต้องแบ่งออกเป็นแบบสอบย่อย ๆ ตามวัตถุประสงค์ที่วัด แล้วประมาณค่าคะแนนโคเมนตามแบบสอบย่อยในขณะที่การประมาณค่าคะแนนจริงในแบบสอบอิงกลุ่มจะไม่คำนึงถึงความ เป็นเอกพันธ์ในด้านเนื้อหาของแบบสอบเลย การประมาณค่าคะแนนโคเมนมีหลายวิธี

แต่ละวิธีมีข้อจำกัดและ ข้อตกลงแตกต่างกันไปดังนี้¹

1. วิธีหาค่าส่วนความถูกต้อง (Proportion-Correct Score Estimate)

ถ้าแบบสอบอิง เกณฑ์นั้นสร้างอย่างใด ๆ ขอสอบทุกข้อมีความเป็นตัวแทนของข้อสอบทั้งหมดเท่าที่เป็นไปได้ใน โทเมนนั้นจริง และมีความยาวพอเพียง ค่าที่ได้จากการประมาณวิธีนี้จะเป็นค่าประมาณที่ไม่ลำเอียงของ คะแนน โดเมน แต่จะมีความเที่ยงต่ำมากถ้าจำนวนข้อสอบที่วัดแต่ละวัตถุประสงค์มีจำนวนน้อย

$$P_i = \frac{X_i}{n}$$

X_i คือ คะแนนที่แต่ละคนได้จากแบบสอบ

n คือ จำนวนข้อสอบ

P_i คือ คะแนนโดเมน

2. วิธีคลาสสิกแบบที่ 2 (Classical Model II) เป็นการประมาณ

ค่าคะแนนโดเมนที่ใช้ข้อมูลของกลุ่มเข้ามาคิดด้วย ผู้ที่คิดขึ้นคือ เคลลี (Kelly, 1972) เป็นวิธีประมาณค่าการถดถอยของ คะแนน โดเมน โดย เป็นผลรวมของน้ำหนักองค์ประกอบสองอย่าง อย่างหนึ่งขึ้นอยู่กับคะแนนของผู้สอบแต่ละคน อีกอย่างขึ้นกับค่ามัธยฐานเลขคณิตของกลุ่ม แจ็คสัน (Jackson, 1972) ได้แก้ไขวิธีการของเคลลีมาใช้กับข้อมูลแบบชาคทอนแบ่งสอง(Binary Data) โดยใช้สมการของฟรีแมน-ทิวกี (Freeman-Tukey Transformation) ดังนี้

¹Ronald K. Hambleton et al., "Criterion-Referenced Testing and Measurement : A Review of Technical Issues and Developments," Review of Educational Research '48 (1978) : 5 - 9.

แปลงคะแนนดิบให้อยู่ในรูป g_i

$$g_i = \frac{1}{2} \left\{ \sin^{-1} \sqrt{\frac{X_i}{n+1}} + \sin^{-1} \sqrt{\frac{X_i+1}{n+1}} \right\} \dots (1)$$

แปลงคะแนนโคไซน์ (π_i) เป็น y_i

$$y_i = \sin^{-1} \sqrt{\pi_i} \dots (2)$$

เมื่อ π_i มีค่าอยู่ระหว่าง .15 ถึง .85 และจำนวนข้อสอบไม่ต่ำกว่า 8 ข้อ การแจกแจงของ g_i จะเป็นปกติโดยประมาณ โดยมีค่ามัธยฐานเลขคณิตเท่ากับ y_i โดยประมาณ และค่าความแปรปรวน (v) เท่ากับ $(4n+2)^{-1}$

และจะได้ค่าประมาณของ y_i จากสูตร.

$$\hat{y}_i = g_i \hat{\sigma} + (4n+2)^{-1} g. / [\hat{\sigma} + (4n+2)^{-1}] \dots (3)$$

เมื่อ $g.$ คือ ค่ามัธยฐานเลขคณิตของกลุ่มตัวอย่างหาได้จากสูตร

$$g. = N^{-1} \sum_{i=1}^N g_i \dots (4)$$

เมื่อ N คือจำนวนผู้สอบ

$\hat{\sigma}$ คือค่าความแปรปรวนของกลุ่มตัวอย่างของ y_i หาได้จากสูตร

$$\hat{\sigma} = (N-1)^{-1} \sum_{i=1}^N (g_i - g.)^2 - (4n+2)^{-1} \dots (5)$$

เมื่อหาก \hat{y}_i ได้ ก็จะประมาณค่าคะแนนโคไซน์ได้จากสูตร

$$\hat{\pi}_i = (1 + .5/n) \sin^2 \hat{y}_i - .25/n \dots (6)$$

3. วิธีประมาณค่าของ แบบที่ 2 (Bayesian Model II Estimate)

การประมาณค่าแบบข้อ 2 อาจไม่เป็นไปตามอุดมคติเพราะไม่ได้พิจารณาถึงข้อมูลเดิม (Prior Data) ของผู้สอบด้วยและค่าที่ ($\hat{\sigma}$) ที่ประมาณได้อาจให้ค่าเป็นลบได้ เพื่อหลีกเลี่ยงการได้ค่าที่เป็นลบ เบส์ (Bayes) ได้เสนอวิธีประมาณค่าคะแนนโคไซน์โดยใช้ข้อมูลสามอย่างคือ คะแนนที่ผู้สอบทำได้จากแบบสอบ คะแนนของกลุ่ม และข้อมูลของผู้สอบจากการสอบครั้งก่อน ๆ หรือจากการสอบที่วัดวัตถุประสงค์อื่น ๆ (Direct, Callateral and Prior Informations)

จากการประมาณค่าด้วยวิธีในข้อ 2 การแจกแจงของ ϵ_i นั้น เรา
 ทราบค่าความแปรปรวน แต่ไม่ทราบค่ามัธยิมเลขคณิต (y_i) การแจกแจงของ ϵ_i
 จึงเป็นการแจกแจงที่มีเงื่อนไข

$$(\epsilon_i / y_i) \sim N(y_i, \nu) \quad \dots (7)$$

เมื่อ $N(y_i, \nu)$ เป็นการแจกแจงปกติที่มีค่ามัธยิมเลขคณิตเท่ากับ y_i
 และความแปรปรวนเท่ากับ ν การประมาณค่าแบบนี้สรุปออกมาในรูปการแจกแจงภายหลัง
 ของค่าพารามิเตอร์

เพื่อที่จะได้การแจกแจงภายหลังของ y_i จึงต้องใช้ข้อตกลงว่า y_i คือ
 ตัวอย่างที่ได้จากการสุ่มจากการแจกแจงอันใดอันหนึ่ง (จากมวลประชากรเดียว) หรือ
 การแจกแจงเดิมของ y_i เป็นปกติด้วยค่ามัธยิมเลขคณิตที่ยังไม่ทราบค่าคือ แอลฟา (α)
 และความแปรปรวนที่ไม่ทราบค่าคือ σ^2 หมายความว่า การแจกแจงเดิมของ y_i ขึ้น
 อยู่กับค่าของแอลฟา และ σ^2

โนวิกและคณะ (1973) ได้ทำการศึกษาและเสนอว่า เป็นไปได้ที่จะทราบ
 ค่า σ^2 โดยใช้การแจกแจงแบบอินเวอร์สไคสแควร์ (Inverse-Chi-Square) ที่มีค่าชั้น
 ของความเป็นอิสระ ν และสเกลพารามิเตอร์ λ เมื่อทราบค่าของ ν และ λ ก็
 จะทราบรายละเอียดของ σ^2 และจากผลการศึกษาพบว่า ควรกำหนดค่า $\nu = 8$ ซึ่งจะได้ค่า
 $\bar{\sigma} = \lambda / (\nu - 2)$ โดยที่ $\bar{\sigma}$ คือค่ามัธยิมเลขคณิตของการแจกแจงแบบอินเวอร์สไคสแควร์
 ดังนั้นค่า $\lambda = (\nu - 2)\bar{\sigma}$ โดยที่ค่า $\bar{\sigma}$ มีค่าโดยประมาณ $= (4n + 2)^{-1}$

และจะได้ค่าประมาณรวม (Joint Estimate) ของ y_i จากสูตร

$$y_i = \frac{\epsilon_i \left[\frac{\lambda \cdot \sum (y_i - y.)^2}{n + \nu - 1} \right] + y. \left[\frac{1}{4n + 2} \right]}{\left[\frac{\lambda + \sum (y_i - y.)^2}{n + \nu - 1} \right] + \left[\frac{1}{4n + 2} \right]}$$

$$\text{เมื่อ } y. = \frac{1}{N} \sum_{i=1}^N y_i$$

4. การประมาณค่ามัธยิมโดยส่วนรวม (Marginal Mean Estimate) การประเมินแบบข้อ 3 เป็นประโยชน์ในการตัดสินผู้สอบทั้งกลุ่ม แต่การวัดแบบอิงเกณฑ์ เราควรต้องมีการตัดสินแยกแต่ละบุคคลด้วย โดยใช้การประมาณค่าคะแนนโดเมนอีกอย่าง เรียกว่า Separate (หรือ Marginal) Estimate of Domain Score

เลวิส แวง และ โนวิก (1973) ได้เสนอการประมาณค่าแบบนี้จากสูตร

$$y_i = g_i + \rho^*(g_i - g_i) \quad \dots (9)$$

ค่า ρ^* ขึ้นอยู่กับค่า ν และค่า λ ถ้าได้ค่า 2 ค่านี้ จะอ่านค่า ρ^* ได้จากตารางของ แวง (1973) และได้ค่าประมาณคะแนนโดเมนจากสูตร

$$\hat{\mu}_i = (1 + \frac{.5}{n}) \sin^2 y_i - \frac{.25}{n} \quad \dots (10)$$

และถ้าตั้งข้อตกลงว่า α มีการแจกแจงเป็นปกติ มีค่ามัธยิมเลขคณิตเท่ากับ θ และความแปรปรวนเท่ากับ ϕ/n แล้ว

$$y_i = \rho g_i + (1 - \rho) g_i + (1 - \rho) \theta \quad \dots (11)$$

และประมาณค่า $\hat{\mu}_i$ ได้จากสูตรที่ (10)

5. การประมาณแบบกึ่งวิธีการของเบส์ ("Quasi" Bayesian Estimate) จากข้อตกลงที่ว่า ความเชื่อเดิมเกี่ยวกับค่า α และ ϕ สามารถแสดงได้ในรูปของการแจกแจงนั้น อาจมีข้อเบี่ยงเบนไปได้หลายทางคือ ถ้าไม่สามารถระบุออกมาได้ในรูปของการแจกแจงก็ยังสามารถระบุได้ว่า

1) สามารถแสดงค่า α และ ϕ เดิมในรูปของการแจกแจงรูปสี่เหลี่ยมพื้นผ้า (A Uniform Distribution) และค่า ϕ เป็นค่าที่ระบุได้แน่นอน

2) ทั้งค่า α และ ϕ สามารถระบุได้แน่นอนทั้งสองค่า
ในกรณี 1) จะได้

$$y_i = \frac{g_i \phi + (4n + 2)^{-1} g_i}{\phi + (4n + 2)^{-1}} \quad \dots (12)$$

ในกรณี 2) จะได้

$$y_i = \frac{\epsilon_i \sigma + (4n + 2)^{-1}}{\sigma + (4n - 2)^{-1}} \dots (13)$$

จากการศึกษาเปรียบเทียบของ แอมเบิลตัน แสทตัน และสแวมมินาธาน ในวิธีการทั้งห้า โดยองค์ประกอบด้านขนาดของกลุ่มตัวอย่าง ความยาวของแบบสอบถาม เป็นเอกพันธ์ของการกระจายของคะแนนโคเมน คะแนนเกนท์ และรายละเอียด เกี่ยวกับข้อมูลเดิมแล้ว ถ้าได้ข้อมูลแน่นอนมาใช้ เช่น ทราบค่า α และ σ การประเมิน ที่ให้ค่าคลาดเคลื่อนสัมบูรณ์น้อยที่สุดคือวิธีที่ 5 โดยค่า y_i ได้จากสมการที่ 13 โดยจะมีค่าความคลาดเคลื่อน (e) เป็น

$$e = \sum_{i=1}^n |y_j - y_i|$$

ถ้าบอกค่าได้ไม่แน่นอน วิธีการที่ให้ค่าความคลาดเคลื่อนน้อยที่สุดคือ วิธีที่ 5 ที่ได้จากสมการที่ 12 วิธีที่ให้ค่าความคลาดเคลื่อนรองลงไปคือ วิธีที่ได้จากสมการที่ (10) (3), (8) และวิธีที่ 1 แต่เนื่องจากในทางปฏิบัติเราไม่ทราบค่า α และ σ ดังนั้นวิธี ที่ใช้ได้จริง ๆ คือวิธีของเบธ ซึ่งมิลแมน¹ ได้แสดงลำดับขั้นในการประมวลดังต่อไปนี้

1. แปลงคะแนนดิบของผู้สอบแต่ละคนให้อยู่ในรูปสัดส่วน โดยหารด้วย

จำนวนข้อสอบ
$$P_j = \frac{X_j}{n}$$

2. แปลงคะแนน P_j เป็น ϵ_j จากสูตร

$$\epsilon_j = \arcsin \sqrt{(X_j + 3/8) / (n + 3/4)}$$

เมื่อ n คือ จำนวนข้อสอบ

¹Millman, "Criterion-Referenced Measurement," pp.348-349.

3. หาค่ามัธยฐานเลขคณิตของคะแนนแปลง g_j

$$g. = \frac{\sum_{j=1}^m g_j}{m}$$

เมื่อ m คือจำนวนผู้สอบ

4. หาค่าความแปรปรวนของคะแนนแปลง g_j

$$s_g^2 = \frac{\sum (g_j - g.)^2}{m}$$

5. กำหนดค่า v ซึ่งจากการศึกษาของ เลวิสและคณะในปี 1973

พบว่า ค่าคือที่เหมาะสมคือ 8

6. กำหนดค่า t ซึ่งเป็นจำนวนข้อสอบที่เราคิดว่า เป็นจำนวนที่น่าพอใจในการที่จะใช้วัดความรู้ในวัตถุประสงค์นั้นหรือโดเมนนั้น

7. คำนวณหาค่า λ จากสูตร

$$\lambda = \frac{v - 2}{4(t + 1)}$$

8. ใช้ค่า s_g^2 , v , λ , n และ m หาค่า ρ^* จากตารางที่แนบ (Wang, 1973) ได้สร้างขึ้น

9. คำนวณหาค่า μ_j จากสูตร

$$\mu_j = \rho^* g_j + (1 - \rho^*) g.$$

10. ใช้ตาราง Arc Sin Transformation¹ เปลี่ยนค่า μ_j เป็น

$$\hat{\pi}_j \text{ โดยที่ } \mu_j = \rho = \text{arc sin } \sqrt{\hat{\pi}_j}$$

¹Ibid., p.349.



การวิเคราะห์รายข้อ

ซุ (Hsu, 1971) กล่าวว่า ข้อสอบที่ดีตามแนวอิงเกณฑ์ควรมีอำนาจจำแนกคือโดยที่ผู้ที่เรียนรู้แล้วควรทำได้เป็นจำนวนมากกว่าผู้ที่ยังไม่ได้เรียน ค่าอำนาจจำแนกที่ซุเสนอคือ $D\%$ ¹ ซึ่งเป็นความแตกต่างระหว่างระดับความยากของข้อสอบก่อนและหลังเรียนที่ได้มาจากการวิเคราะห์แบบอิงกลุ่ม และด้วยแนวความคิดคล้ายคลึงกัน ครีสปินและเฟลด์ฮุส² (Kryspin and Feldhusen, 1974) ได้เสนอดัชนีเอส (Sensitivity Index - S) โดยมีสูตรว่า

$$S = \frac{R_{\text{pos}} - R_{\text{pre}}}{T}$$

R_{pos} คือ จำนวนผู้ที่ตอบถูกหลังจากเรียน

R_{pre} คือ จำนวนผู้ที่ตอบถูกก่อนเรียน

T คือ จำนวนผู้เข้าสอบ

¹Thomas M. Haladyna, "Effects of Different Samples on Item and Test Characteristics of Criterion-Referenced Test," Journal of Educational Measurement, 11 (1974) : 94. Citing T. Hsu, Empirical Data on Criterion-Referenced Tests. Paper Presented at the Annual Meeting of the American Educational Research Association, New York : 1971.

²สมศักดิ์ สินธุระเวชญ์, "การประเมินผลแบบอิงกลุ่ม และอิงเกณฑ์," วารสารวิจัยการศึกษา 8 (มิถุนายน 2521) : 84 อ้างจาก William J. Kryspin and John F. Feldhusen, Developing Classroom Test (Minneapolis, Minnesota : Burgess Publishing Company, 1974).

ถ้ามองในแง่ของการวัดอิงกลุ่มแล้ว สูตรนี้ก็เปรียบได้กับค่าอำนาจจำแนกนั่นเอง แต่เปลี่ยนจากกลุ่มสูงเป็นกลุ่มหลังเรียน และจากกลุ่มต่ำเป็นกลุ่มก่อนเรียน ข้อสอบที่ต้องการ คือ ข้อสอบที่มีค่าดัชนีเอสสูงและเป็นบวก (ระหว่าง 0.00 - 1.00) ซึ่งแสดงว่าข้อสอบนั้น สามารถจำแนกผู้ที่เรียนแล้วและผู้ที่ยังไม่ได้เรียนออกจากกัน



ความเที่ยงของแบบสอบอิงเกณฑ์

ในการตัดสินใจเกี่ยวกับความเที่ยงของแบบสอบอิงเกณฑ์ ได้มีผู้เสนอวิธีการในการประมาณค่าสัมประสิทธิ์ความเที่ยงไว้หลายวิธี แบ่งออกตามแนวความคิดเป็นสองฝ่าย ฝ่ายแรก ประยุกต์วิธีคลาสสิกมาใช้ โดยมองความแปรปรวนของการวัดอิงเกณฑ์เป็นความเบี่ยงเบนของคะแนนผู้สอบแต่ละคนจากคะแนนเกณฑ์ ยิ่งความเบี่ยงเบนนี้มีค่ามากเท่าไรความถูกต้องของการตัดสินใจให้ผู้สอบได้หรือตกก็ยิ่งมากขึ้นเท่านั้น ผู้ที่เสนอสูตรนี้มาเป็นที่ยอมรับกันในฝ่ายที่สนับสนุนความคิดนี้คือ สีฟิงสตัน เสนอวิธีการประมาณค่าความเที่ยง โดยมีข้อตกลงเบื้องต้นว่า¹ "วัตถุประสงค์ของการวัดอิงเกณฑ์ก็เพื่อจะแยกคะแนน (โคเมน) ของแต่ละคนออกจากคะแนนเกณฑ์" จากสูตร²

$$r_{cc} = \frac{r_{xx} s_x^2 + (\bar{X} - c)^2}{s_x^2 + (\bar{X} - c)^2} *$$

r_{xx} คือ ความเที่ยงของแบบสอบอิงกลุ่ม

s_x^2 คือ ความแปรปรวนของคะแนน

\bar{X} คือ ค่าเฉลี่ยเลขคณิต

c คือ คะแนนเกณฑ์

r_{cc} คือ ค่าความเที่ยงอิงเกณฑ์

¹Hambleton, "Criterion-Referenced Testing....," p.16.

²William A. Mehrens and Irvin J. Lehmann, Measurement and Evaluation in Psychology (New York : Holt, Rinehart and Winston, 1973), p.121.

หรือ¹

$$K^2(x_i, T_X) = \frac{\rho^2(x, T_X) \sigma^2(x) + (\mu_X - c_X)^2}{\sigma^2(x) + (\mu_X - c_X)^2} \dots\dots (b)$$

$\sigma^2(x)$ คือ ค่าความแปรปรวนของคะแนนดิบ

μ_X คือ ค่ามัธยฐานเลขคณิต

c_X คือ คะแนนเกณฑ์

$\rho^2(x, T_X)$ คือ ความเที่ยงที่ได้จากอิงกลุ่ม

หรือ²

$$K^2(\hat{\pi}, \pi) = \frac{\sigma^2(\pi) + (\bar{\pi} - \pi_0)^2}{\sigma^2(\hat{\pi}) + (\bar{\pi} - \pi_0)^2} \dots\dots (c)$$

$\hat{\pi}$ คือ ค่าประมาณคะแนนโดเมน

π คือ คะแนนโดเมน

π_0 คือ คะแนนเกณฑ์ (สัดส่วน)

$\bar{\pi}$ คือ ค่ามัธยฐานเลขคณิตของคะแนนโดเมน

สูตรทั้งสาม [(a), (b) และ (c)] ความจริงคือสูตรเดียวกัน แต่สัญลักษณ์และชนิดของคะแนนที่ใช้ต่างกัน เมื่อลองเปรียบเทียบสูตรการหาความเที่ยงของดีฟวิงสตันกับความเที่ยงแบบคลาสสิกแล้ว พบว่าค่าประมาณความเที่ยงตามสูตรของดีฟวิงสตันจะสูงกว่าแบบคลาสสิก และแม้ว่าความแปรปรวนของคะแนนโดเมนจะเป็นศูนย์

จุฬาลงกรณ์มหาวิทยาลัย

¹Samuel A. Livingston, "Criterion-Referenced Application of Classical Test Theory," Journal of Educational Measurement 9 (1972) : 17 - 18.

²Hambleton, Criterion-Referenced Testing....", p.16.

³Ibid.

ค่าประมาณความเที่ยงที่ได้ก็จะไม่เป็นศูนย์เหมือนวิธีคลาสสิก ถ้าความแปรปรวนของคะแนน จากแบบสอบถามเป็นศูนย์ คือทุกคนทำคะแนนได้เท่ากัน ค่าความเที่ยงจะเป็น 1.00 และ ถ้าคะแนนเฉลี่ยของกลุ่มมีค่าเท่ากับคะแนนเกณฑ์แล้ว ค่าความเที่ยงของแบบสอบถามจะมีค่า เท่ากับความเที่ยงอิงกลุ่ม ลีฟวิงสตันกล่าวว่า "ถ้าคะแนนของคนสองกลุ่ม มีค่าความแปรปรวน และความเที่ยงอิงกลุ่มเท่ากันแล้ว กลุ่มที่มีคะแนนมัชฌิมเลขคณิตเบี่ยงเบน จากคะแนนเกณฑ์มากกว่า จะมีค่าความเที่ยงอิงเกณฑ์สูงกว่า" และ "เป็นไปได้ที่จะ กล่าวไว้ว่า ค่าความเที่ยงอิงกลุ่มเป็นกรณีพิเศษกรณีหนึ่งของความเที่ยงอิงเกณฑ์คือ กรณีที่ ค่าความเที่ยงค่าสุด"

เชฟเวลสัน, บล็อก และเรวิทซ์ (Shavelson, Block and Ravitch, 1972) แนะนำ การตัดสินใจให้ผู้สอบแต่ละคนได้หรือตกนั้นควรพิจารณาความคลาดเคลื่อน มาตรฐานในการวัดด้วย โดยเฉพาะพวกที่มีคะแนนอยู่ใกล้จุดตัดมาก ๆ ควรพิจารณาองค์ ประกอบอย่างอื่นด้วย นอกจากนี้ได้พิจารณาการหาความเที่ยงของลีฟวิงสตันว่า ควรจะ แบ่งแบบสอบถามเป็นแบบสอบถามย่อย ๆ แล้วให้คะแนนและหาความเที่ยงตามแบบสอบถามย่อย

แอริส (1972) ซึ่งเห็นด้วยกับเชฟเวลสัน บล็อก และเรวิทซ์ กล่าวว่า ใน ทางพีชคณิตแล้ว สูตรที่ลีฟวิงสตันพัฒนาขึ้นมาใช้นั้นไม่มีที่ผิดพลาด แต่จุดสำคัญอยู่ที่ว่า ค่า ความแปรปรวนของความคลาดเคลื่อนในการวัดน่าจะเป็นค่านี้นี้ดีกว่าในการที่จะให้ความ มั่นใจในการประเมินผลว่าแต่ละคนได้คะแนนสูงหรือต่ำกว่าเกณฑ์ โดยให้เหตุผลว่า แม้ว่า คำนี้อิงลีฟวิงสตันจะสูงกว่าแบบคลาสสิกก็ไม่มีความหมายว่า แบบสอบถามนั้นจะมีความเที่ยง สูงกว่าจริง ๆ เพราะค่าความคลาดเคลื่อนมาตรฐานในการวัดก็ยังมีค่าเท่ากัน นอกจากนี้ แล้ว ลีฟวิงสตันยังไม่ได้นำถึงคะแนนจริงของผู้สอบว่าอยู่ทั้งสูงกว่า และต่ำกว่าเกณฑ์ซึ่ง ทำให้ดูเหมือน เป็นค่าค่านี้อิงของประชากรสองกลุ่มที่มีค่ามัชฌิมเลขคณิตอยู่ห่างจากคะแนน เกณฑ์ เท่ากันทั้งต่ำกว่าและสูงกว่า

¹Livingston, "Criterion-Referenced Application...", p.18.

ในกรณีที่มีความยาวของข้อสอบเพิ่มขึ้นและต้องการดูว่า ค่าความเที่ยงของแบบสอบจะเพิ่มขึ้นเป็นเท่าไร สปีริงสตันได้เสนอให้ใช้สูตรของ สเพียร์แมน-บราวน์ คือ¹

$$\frac{n K^2(X, T_X)}{1 + (n-1) K^2(X, T_X)}$$

เมื่อ n คือ จำนวนเทาะของข้อสอบที่เพิ่มขึ้นจากเดิม

ในกรณีข้อมูล ที่ได้ไม่ใช่ข้อมูลแบบแบ่งสอง (Binary Data) สปีริงสตันเสนอให้ใช้สัมประสิทธิ์ แอลฟา² (α)

$$\alpha = \frac{\frac{I}{(I-1)} \sigma^2(x) - \sum \sigma^2(i) + (\mu_x - c_x)^2}{\sigma^2(x) + (\mu_x - c_x)^2}$$

เมื่อ I คือ จำนวนข้อสอบ และ $\sigma^2(i)$ คือความแปรปรวนของข้อสอบแต่ละข้อ

ความเที่ยงของแบบสอบอิงเกณฑ์ในทัศนะของอีกฝ่ายหนึ่ง มองในแง่ความคงที่ของการตัดสิน เช่น ถ้าให้ผู้สอบสองกลุ่มทำแบบสอบเดียวกัน (หรือให้ผู้สอบกลุ่มเดียวทำแบบสอบคู่ขนาน) แล้ว แบบสอบที่มีความเที่ยงน่าจะเป็นแบบสอบที่สามารถแบ่งผู้เรียนออกเป็นพวกรอบรู้ หรือไม่รอบรู้ เป็นร้อยละ เท่ากันทั้งสองกลุ่ม (หรือทั้งสองแบบสอบ) โดยที่ผู้สอบสองกลุ่มนี้ต้อง เป็นกลุ่มที่เท่าเทียมกันด้วย ค่าความเที่ยงอยู่ที่ความใกล้เคียงกันของอัตราร้อยละที่แบ่งผู้เรียนออกเป็นผู้รอบรู้หรือไม่รอบรู้ทั้งสอง ครั้ง ได้มีผู้เสนอสูตรตามแนวความคิดนี้ไว้หลายสูตรดังนี้

คาร์เวอร์³ (Carver, 1970) ได้เสนอการประมาณค่าความเที่ยงโดยการเปรียบเทียบสัดส่วนของความคงที่ในการตัดสินได้ตก โดยใช้กลุ่มตัวอย่างกลุ่มเดียว

¹Ibid., p.-19.

²Ibid.

³Crehen, "Item Analysis,....," p. 256. Citing R.P. Carver, "Special Problems in Measuring Change with Psychometric Devices," in Evaluation Research : Strategies and Methods (Pittsburgh : American Institutes for Research, 1970).

ทำแบบสอบถามหลังจากเรียนผลออกมาเป็นรูปของความถี่ในการตัดสินใจแต่ละครั้ง
ดังตาราง

ฉบับ ก. ฉบับ ข.	ตก	ได้
ได้	b	a
ตก	c	d

ค่าความเที่ยงได้จาก $(a + c)/N$ เมื่อ $N = a + b + c + d$

สแควมมินนาชาน แคม เบ็ดตัน และอัลกินา¹ ได้เสนอค่าสัมประสิทธิ์แคปป่า
(Kappa-K) ของ โคเฮน เป็นดัชนีความเที่ยง โดยใช้สูตร

$$K = (P - P_c) / (1 - P_c)$$

เมื่อ P คือ สัดส่วนที่ตัดสินให้ผู้เรียนได้และตกซ้ำกันสองครั้ง

P_c คือ สัดส่วนในการตัดสินที่คาดหวัง

ฮวน² (Huynh, 1976) แนะนำเมื่อคะแนนเกณฑ์มีค่าสูงใกล้ค่า n
(จำนวนข้อ) ควรใช้สูตรต่อไปนี้

$$K = (P_{11} - P_1^2) / (P_1 - P_1^2)$$

และเมื่อคะแนนเกณฑ์มีค่าต่ำห่างจาก n มาก

¹Huynh Huynh, "On the Reliability of Decisions in Domain-Referenced Testing," Journal of Educational Measurement, 13 (1976), p.253.

²Ibid., p.256.

$$K = (P_{00} - P_0^2) / (P_0 - P_0^2)$$

$$\text{เมื่อ } P_{11} = \sum_{x,y=c}^n f(x,y)$$

$$P_1 = \sum_{x=c}^n f(x)$$

$$P_{00} = \sum_{x,y=0}^{c-1} f(x,y)$$

$$P_0 = \sum_{x=0}^{c-1} f(x)$$

แฮมเบิลตันและ โนวิก¹ (1973) เสนอสูตรเมื่อต้องการจำแนกผู้เรียนให้อยู่ในระดับการสอบรู้อยู่ m ระดับดังนี้

$$P_0 = \sum_{k=1}^m P_{kk}$$

เมื่อ P_0 คือ ดัชนีความเที่ยง

P_{kk} คือ สัดส่วนของผู้สอบที่ถูกตัดสินให้อยู่ระดับสอบรู้อยู่ที่ k

ค่า P_0 ของแฮมเบิลตันและ โนวิกนี้ สวมมีหน้าทาน แฮมเบิลตันและอัลกินี² (1974) แย้งว่าอาจเป็นค่าที่มากเกินไป เพราะรวมการตัดสินตรงกันซึ่งเกิดโดยบังเอิญไว้ด้วย เขาแนะนำให้ใช้ค่าแก้ จากสูตร

$$K = (P_0 - P_c) / (1 - P_c)$$

$$\text{เมื่อ } P_c = \sum_{k=1}^m P_{k.} \cdot P_{.k}$$

โดยที่ $P_{k.}$ และ $P_{.k}$ คือ สัดส่วนของผู้สอบรู้อยู่ที่ถูกตัดสินให้อยู่ในระดับสอบรู้อยู่ที่ k ในการสอบครั้งที่ 1 และ 2 ตามลำดับ

¹ Hambleton, "Criterion-Referenced Testing...", p.21.

² Ibid.

ซึ่งมีความเที่ยงของ ฮวน เป็นวิธีเดียวที่ได้จากการบริหารการสอบครั้งเดียว
นอกนั้นต้องบริหารการสอบสองครั้ง แต่ใช้แบบสอบคู่ขนานเช่นเดียวกัน แต่วิธีของ ฮวน
เป็นวิธีที่ขึ้นอยู่กับความรู้ทางสถิติในด้าน การแจกแจงมาก และมีข้อจำกัดว่า ถ้าจำนวน
ข้อสอบนอยกว่าที่จะมีความเที่ยงไม่เท่าที่ควร วิธีอีกวิธีที่มีความยุ่งยากและข้อจำกัดน้อย
กว่าคือ วิธีของซบ์โคเวียค ซึ่งมีสูตรว่า¹

$$P_c = n^{-1} \sum_{i=1}^N P_c^{(i)}$$

เมื่อ $P_c^{(i)} = \text{Prob}(X_i \geq c) \cdot \text{Prob}(X'_i \geq c) + \text{Prob}(X_i < c) \cdot \text{Prob}(X'_i < c)$

x_i คือ คะแนนของผู้สอบคนที่ i จากแบบสอบฉบับที่ 1

x'_i คือ คะแนนของผู้สอบคนที่ i จากแบบสอบฉบับที่ 2

c คือ คะแนนเกณฑ์

ข้อตกลงในการประมาณค่าวิธีนี้คือ²

1. คะแนนจากแบบสอบคู่ขนานของผู้สอบแต่ละคนต้องเป็นอิสระต่อกัน
และมีการแจกแจงแบบเดียวกัน
2. คะแนนจากแบบสอบทั้งสองแบบของผู้สอบ ต้องมีการแจกแจงแบบ

ไบโนเมียล

การตั้งข้อตกลงดังกล่าวก่อให้เกิดปัญหาแม้ว่ากรรมการให้คะแนนจะเป็น
แบบ 0-1 และการทำแบบสอบจะเป็นอิสระต่อกันก็ตาม เพราะจะต้องยอมรับด้วยว่า
ข้อกระทงในแบบสอบแต่ละข้อมีความยากง่ายเท่ากัน ภายหลังจึงใช้แบบจำลองทวินามผสม
(Compound Binomial Model) แทน

¹ Michael J. Subkovich, "Estimating Reliability from a Single Administration of A Criterion-Referenced Test," Journal of Educational Measurement 13 (1976) : 267.

² Hambleton, "Criterion-Referenced Testing," p.22.

จากข้อตกลงสองข้อนี้จึงสามารถแสดงได้ว่า¹

$$P(X_i \geq c) = \sum_{x_i=c}^n \binom{n}{x_i} p_i^{x_i} (1-p_i)^{n-x_i} \quad \dots (1)$$

$$P_c^{(i)} = [P(X_i \geq c)]^2 + [1 - P(X_i \geq c)] \quad \dots (2)$$

เมื่อประมาณค่า p_i ได้ ก็นำมาแทนค่า p_i ในสูตร (1)

$P_c^{(i)}$ คือ ความน่าจะเป็นของการคงที่ในการตัดสินผู้สอบคนที่ i
ค่าประมาณของสัดส่วนของการตัดสินตรงกันของกลุ่มคือ $N^{-1} \sum_{i=1}^N P_c^{(i)}$

ค่าประมาณของข้อใดข้อหนึ่งที่มีจุดอ่อนตรงที่ทั้งข้อตกลงเบื้องต้นว่า

ข้อสอบทุกข้อมีความยากเท่ากัน และวิธีประมาณค่าแบบนี้อาจให้ค่าความเที่ยงสูงไปเนื่อง
มาจากรวมการตัดสินตรงกันโดยบังเอิญไว้ด้วย

นอกจากนี้ แอริส² (1972 a) ได้เสนอค่าสัมประสิทธิ์ในกรณีที่กำหนด
สภาพการรอบรู้เพียงสองระดับ ($k = 2$) เป็นค่าสหสัมพันธ์กำลังสองระหว่างระดับ
การรอบรู้กับคะแนนรวม (โดยให้ 0 เมื่อผู้สอบสอบตก และให้ 1 เมื่อผู้สอบสอบได้)

$$M_c^2 = \frac{SS_B}{SS_B + SS_W}$$

เมื่อ SS_B = ผลบวกกำลังสองระหว่างกลุ่ม

SS_W = ผลบวกกำลังสองภายในกลุ่ม

¹Ibid., p.23.

²Subkovich, Estimating Reliability from..., pp.265-266.

Citing C.W. Harris, "An Index of Efficiency for Fixed-Length Mastery Tests," Paper Presented at the Annual Meeting of the American Educational Research Association (Chicago : 1972. (ab)).

มาร์แชล และเฮอ์ทอลล์ (Marshall and Haertel, 1975) ได้เสนอ
การหา P_0 เดลิ้วโดยบริหารการสอบ 1 ครั้ง แบ่งแบบสอบเป็นแบบสอบกู่ชานแล้ว
ใช้สูตรของสเพียร์แมน-บราวน์ หาค่าสัมประสิทธิ์ความเที่ยงของแบบสอบทั้งฉบับ¹

ความตรง

ความตรงของแบบสอบอิง เกณฑ์มีรากฐานอยู่บนมโนคติ เกี่ยวกับทฤษฎีของการ
วัดอิง เกณฑ์ที่ว่าเครื่องมือที่ใช้ควร เป็นเครื่องมือที่สามารถจะแยกผู้ที่ยัง
ไม่ได้เรียนออกจากกันได้ เช่น ถ้าเครื่องมือที่ใช้คือแบบสอบ เมื่อนำแบบสอบไปทดสอบ
คนสองกลุ่ม คือ กลุ่มที่ยังไม่เคยเรียนเนื้อหาในแบบสอบ และกลุ่มผู้ที่เคยเรียนมาแล้ว
ผู้สอบกลุ่มหลังควรจะทำข้อสอบนั้นได้มากกว่าผู้สอบกลุ่มแรก จากความคิดนี้ ความตรง
ในความหมายของกรวัดอิง เกณฑ์ก็คือ ความตรงตามทฤษฎี หรือความตรงในการตัดสิน
ผู้สอบนั่นเอง คุณภาพของแบบสอบอิง เกณฑ์ในด้านนี้มีผู้ศึกษาไม่มากนัก จึงไม่ยุ่งยากซับซ้อน
หรือขึ้นอยู่กับการคาดคะเนเหมือนความเที่ยง เหตุผลส่วนหนึ่งอาจเนื่องมาจากดัชนีที่ใช้เลือก
ข้อสอบในการวิเคราะห์รายข้อก็เป็นตัวชี้ถึงความตรง โดยส่วนรวมของข้อสอบเป็นข้อ ๆ
อยู่แล้วก็อาจเป็นได้ ดัชนีนี้แสดงความตรงในการตัดสินตัวแรกเสนอโดย คาร์เวอร์²

¹Ibid., p.266. Citing J.L. Marshall and E.H. Haertel, "A
Single-Administration Reliability Index for Criterion-Referenced Tests:
The Mean Split-Half Coefficient of Agreement," Paper Presented at the
Annual Meeting of the American Educational Research Association
(Washington D.C. : 1975).

²K.D. Crehen, "Item Analysis for...", p.256. Citing R.P.
Carber, "Special Problems in Measuring Change with Psychometric
Devices," in Evaluation Research : Strategies and Methods," (Pitt-
burgh : American Institutes for Research, 1970).

ได้ค่าความตรงจากข้อมูลที่ได้จากแบบสอบของกลุ่มผู้เรียนแล้ว และยังไม่เคยเรียนตั้ง
ตาราง

	ยังไม่เรียน	เรียนแล้ว
ผ่าน	b a	a b
ไม่ผ่าน	c	d

ค่าสัมประสิทธิ์ความตรงได้จาก $(a+c) / (a+b+c+d)$

สัมประสิทธิ์ความตรงของคาร์เวออร์จะมากหรือน้อยขึ้นอยู่กับจำนวนผู้สอบที่
สอบไม่ผ่านก่อนเรียน และที่สอบผ่านหลังจากเรียน ดังนั้น องค์ประกอบที่ควรจะมีผลต่อ
ความตรงของคาร์เวออร์ ก็น่าจะเป็นความตรงตามเนื้อหาของข้อสอบแต่ละข้อและประสิทธิภาพ
ในการสอน

ดัชนีความตรงอีกตัวได้มาจากค่าสัมประสิทธิ์สหสัมพันธ์แบบพี¹ ซึ่งมีลักษณะ
รวมทั้งองค์ประกอบที่มีผลต่อค่าที่ได้คล้ายกับของคาร์เวออร์ มีสูตรว่า λ

$$\lambda = \frac{ad - bc}{\sqrt{(a+b)(c+d)(a+c)(b+d)}}$$

เมื่อ a คือ จำนวนผู้ที่สอบผ่านหลังจากเรียน

b คือ จำนวนผู้ที่สอบผ่านก่อนเรียน

c คือ จำนวนผู้ที่สอบไม่ผ่านหลังจากเรียน

d คือ จำนวนผู้ที่สอบไม่ผ่านก่อนเรียน

¹Millman, "Criterion-Referenced Measurement," pp.370-371.

ความยาวของแบบสอบ การกำหนดคะแนนเกณฑ์ และการตัดสินผู้สอบ

การพิจารณาในเรื่องเหล่านี้มีองค์ประกอบอย่างหนึ่งที่เกี่ยวข้องกับอุบายคือ อัตราความสูญเสีย (Loss Ratio) ซึ่งเกิดจากความคลาดเคลื่อนสองชนิดคือ ความคลาดเคลื่อนอันเกิดจากการยอมรับที่ผิด และความคลาดเคลื่อนอันเกิดจากการปฏิเสธที่ผิด การพิจารณาในเรื่องความยาวของแบบสอบ คะแนนเกณฑ์ และการตัดสินผู้สอบที่เหมาะสม จึงทำโดยพยายามไม่ให้มีความคลาดเคลื่อนสองประการนี้เกิดขึ้นได้ แต่ในทางปฏิบัติแล้ว เป็นไปไม่ได้ที่จะป้องกันไม่ให้เกิดขึ้นเลยได้ จึงมีความพยายามในอันที่จะทำให้เกิดน้อยที่สุดเท่าที่จะเป็นไปได้ (Threshold Loss)

ในค่านความยาวของแบบสอบ มิลแมน¹ ได้สร้างตารางเพื่อหาความยาวที่เหมาะสมโดยเปรียบเทียบระหว่างค่าคะแนน โดเมนที่ประมาณไว้ กับคะแนนตัดสินระดับความรอบรู้ (Advancement Score) โดยใช้การทดสอบทวินาม (Binomial Test) เราสามารถหาความน่าจะเป็น หรือโอกาสของการตัดสินที่ผิดพลาดได้ (ตามน้ำหนักที่เราจะให้แก่ความคลาดเคลื่อนแต่ละแบบ) โดยดูจากตารางซึ่งประกอบด้วยคะแนนเกณฑ์ คะแนนตัดสินระดับความรอบรู้ คะแนนประมาณของคะแนน โดเมน และจำนวนข้อสอบ เราสามารถเลือกความยาวของข้อสอบและคะแนนตัดสินระดับความรอบรู้ได้ โดยที่ดูจากค่าความสูญเสียเปล่าที่เรากำหนดไว้

ตารางของมิลแมนมีปัญหาอยู่บ้าง ประการแรกคือค่าที่ได้ขึ้นอยู่กับความถูกต้องของค่าประมาณคะแนน โดเมน และอีกปัญหาคือการพิจารณาคะแนนตัดสินระดับความรอบรู้ร่วมกับ

¹Hambleton, "Criterion-Referenced Testing...", p. 24. Citing J. Millman, "Criterion-Referenced Measurement," in Evaluation in Education : Current Practices (Berkeley, California : McCutchan Publisher, 1974).

ความยาวของแบบสอบเพื่อลดโอกาสของความคลาดเคลื่อนในการตัดสินผู้เรียนที่อยู่เหนือจุดตัด จะไปเพิ่มโอกาสของความคลาดเคลื่อนของการตัดสินของผู้ที่อยู่ต่ำกว่าจุดตัด

ในเรื่องเกี่ยวกับการตั้ง เกณฑ์ตัดสินผู้สอบ มิลแมน (1973) กล่าวว่า การพิจารณาเรื่องนี้ควรพิจารณาหลาย ๆ ด้านประกอบกัน เช่น

1. คะแนนของคนอื่น ๆ (Performance of Others) เช่น กำหนดจากที่กลุ่มก่อน ๆ ทำได้ หรืออาจกำหนดจำนวนนักเรียนที่จะให้ผ่านไว้ (แต่วิธีหลังนี้คงไม่ดีนัก เพราะจะทำให้ทฤษฎีการวัดต้อง เกณฑ์เปลี่ยนไป)
2. เนื้อหาของข้อสอบ (Item Content) พิจารณาข้อสอบแต่ละข้อแล้วนำมา รวมกัน เช่น ใหญ่ผู้เชี่ยวชาญตัดสินว่าข้อสอบแต่ละข้อควรมีส่วนสำคัญของข้อสอบเท่าใดเท่าไร แล้วนำสัดส่วนทุกข้อมาบวกกันจะได้เป็นคะแนนเกณฑ์
3. ผลทางการศึกษาที่ตามมา (Educational Consequences) คำถามที่เกี่ยวข้องคือ คะแนนเกณฑ์เท่าใดจึงจะทำให้เกิดประโยชน์ทางการศึกษามากที่สุด
4. คุณค่าทางจิตวิทยา และทาง เศรษฐกิจที่มีต่อผู้สอนและผู้เรียน เช่น ถ้าค่าใช้จ่ายในการสอนซ่อมเสริมสูงมากของกำหนดเกณฑ์ให้ต่ำลง เป็นต้น ทั้งนี้ต้อง คิดถึงความสูญเสียไปทางอื่นด้วย
5. ความคลาดเคลื่อนจากการเดา และการเลือกตัวอย่างข้อสอบ ถ้ามีปัญหาระบบนี้เกิดมาก ควรกำหนดเกณฑ์สูงขึ้น

ปัญหาอันเกิดจากการเดาในข้อ 5 นี้ กรอนลันด์¹ (Gronlund) กล่าวว่า "การที่เราบอกให้นักเรียนตอบข้อสอบให้ครบทุกข้อเป็นความพยายามที่จะทำให้ความแปรปรวนระหว่างผู้สอบในแนว โนมของการเดามีเท่า ๆ กัน จึงไม่จำเป็นจะต้องมีการแก้การเดา" และ "ยังมีข้อขัดแย้งอยู่เหมือนกันในเรื่องการที่จะแก้การเดาหรือไม่ แต่โดยมากจะเป็นเรื่อง

¹Norman E. Gronlund, Constructing Achievement Test (Englewood Cliffs, N.J. : Prentice-Hall, 1977), p.107.

ของแบบสอบมาตรฐานซึ่งมีข้อกระทงบางข้อไม่เหมาะสมกับกลุ่มผู้สอบบางกลุ่ม และผู้สอบอาจไม่ได้รับโอกาสที่จะทำแบบสอบได้ทุกข้อ... โดยทั่วไปการวัดสัมฤทธิ์ผลที่ไม่ได้ใช้แบบสอบมาตรฐานไม่ควรมีการยกเลิก เพราะเนื้อหาในแบบสอบมีความสัมพันธ์กันมากกับประสบการณ์การเรียนรู้ของผู้สอบ และเวลาที่กำหนดไว้ก็มากพอที่จะให้ผู้สอบมีเวลาทำทุกข้อ"

จากการศึกษาของบล็อก¹ (Block, 1972) พบว่า การกำหนดเกณฑ์ตัดสินมีผลต่อสัมฤทธิ์ผลทางการศึกษา ว่าทั้งเกณฑ์ตัดสินสูงสัมฤทธิ์ผลก็สูง ว่าทั้งเกณฑ์ตัดสินต่ำสัมฤทธิ์ผลก็ต่ำ

เบอร์ค² (Berk, 1976) เสนอว่าควรพิจารณาเกณฑ์จากผู้ทำแบบสอบ

เกี่ยวกับสองกลุ่ม คือกลุ่มผู้ที่เรียนมาแล้วและกลุ่มที่ยังไม่ได้เรียน ข้อเสนอของเขายู่ที่การที่เขาตั้งเกณฑ์ว่าคุณภาพของแบบสอบอิง เกณฑ์ขึ้นอยู่กับอำนาจของมันในอันที่ไปขอมูลที่เพียงพอในการที่จะตัดสินแบ่งผู้เรียนได้ถูกต้อง ฉายาที่ขอตกลงว่าผู้สอบกลุ่มที่เรียนมาแล้วเป็นผู้รอบรู้ กลุ่มที่ไม่ได้เรียนเป็นผู้ไม่รอบรู้ เขาก็ตั้งเกณฑ์ตัดสินผู้สอบออกเป็นผู้รอบรู้และผู้ไม่รอบรู้บ้าง เป็นอิสระต่อกัน ผู้สอบกลุ่มแรกจะถูกตัดสินแบ่งเป็นสองพวกคือ ผู้รอบรู้จริง (True Master) และพวกเรียนแล้วแต่ไม่รอบรู้ (False Nonmaster) ผู้สอบกลุ่มที่สองจะถูกตัดสินแบ่งเป็นสองพวก พวกรอบรู้ไม่จริง (False Master) และพวกไม่รอบรู้จริง (True Nonmaster) การกระจายของคนสองกลุ่มนี้จะขึ้นกับว่าเกณฑ์ขอบเขตตัวแรกว่าผู้สอบจะเป็นพวกรอบรู้จริงหรือไม่รอบรู้จริง เกณฑ์จะได้จากการตรวจสอบความน่าจะเป็นของผลในคะแนน

¹Hambleton, "Criterion-Referenced Testing...", p.29, Citing J.H. Block, "Student Learning and the Setting of Mastery Performance Standard," Educational Horizons, (1972):50, 183-190.

²Hambleton, "Criterion-Referenced Testing...", p.31, Citing R.A. Berk, "Determination of Optional Cutting Scores in Criterion-Referenced Measurement," Journal of Experimental Education, (1976): 45. 4-9.

จุดคัดแต่ละประเภท คะแนนจุดคัดที่เหมาะสมคือ ค่าที่ให้สัดส่วนในการตัดสินนิคผลากนอยที่สุด
ค่าที่ให้สัดส่วนในการตัดสินโคถูกทองในการไขจุดคัดใดๆคือสัดส่วนของผู้สอบที่เรียนมาแล้ว
และถูกคัดสินให้เป็นพวกรอบรู ร่วมกับสัดส่วนของผู้ที่ไม่ได้เรียน และถูกคัดสินให้เป็นพวก
ไม่รอบรู

วิธีของเบอร์ค คล้ายกับวิธีการหาความตรงของ คาร์เวอร์ และจัดได้ว่าเป็นวิธี
ที่ให้ประโยชน์มาก รวมทั้งสามารถนำไปใช้ได้ไม่ยุ่งยากในทางปฏิบัติ โดยเฉพาะในการเรียน
ที่เรียงหน่วยการเรียนการสอนต่อเนื่องกันไป เกณฑ์ของแต่ละหน่วยก็คัดสินได้โดยพิจารณาถึง
สัมฤทธิ์ผลที่ต้องการนำไปใช้ในหน่วยต่อ ๆ ไปด้วย วิธีของเบอร์คนี้ สมหวัง พิธิยานุวัฒน์
ได้นำไปศึกษาโดยให้กลุ่มผู้สอบกลุ่มเดียวทำแบบสอบก่อนเรียนและหลังเรียน เพื่อหาเกณฑ์
ที่ทำให้เกิดความสูญเสียน้อยที่สุด

รายงานการวิจัยที่เกี่ยวข้อง

เอ็มริค¹ ได้ทำการศึกษาถึงความสูญเสียสองแบบ คือ แอลฟา และ เบต้า โดย
ใช้ข้อมูลจากแบบสอบ IPI Math Placement Test "Numerical D" ซึ่งมีความยาว 16
ข้อ คำนวณหาเกณฑ์ที่เหมาะสม เมื่อกำหนดให้ $\beta = 3\alpha$, $RR = 10$ จากสูตร

$$K = \frac{\log \frac{\beta}{1 - \alpha} + n^{-1} (\log RR)}{\log \frac{\alpha \beta}{(1 - \alpha)(1 - \beta)}}$$

¹John A. Emrick, "An Evaluation Model for Mastery Testing,"
Journal of Educational Measurement 8 (1971) : 321-326.

- เมื่อ K คือ เกณฑ์ที่อยู่ในรูปของร้อยละ
 n คือ ความยาวของแบบสอบถาม
 β คือ ค่าประมาณความน่าจะเป็นของความผิดพลาดในการยอมรับ
 ที่ผิด
 α คือ ค่าประมาณความน่าจะเป็นของความผิดพลาดในการปฏิเสธ
 ที่ผิด

ค่า α และ β หาได้จากสูตร

$$\alpha + \beta = 1 - \sqrt{\bar{r}_i}$$

เมื่อ \bar{r}_i คือ ค่าความเที่ยงของข้อกระทง คำนวณได้โดยใช้สูตรของ
 สเพียร์แมน-บราวน์

RR คือ อัตราส่วนของความรุนแรงของความคลาดเคลื่อน β
 ต่อ α (Ratio of Regret of β to α)

ได้ค่า $K = 56.25\%$ นั่นคือจะต้องทำข้อสอบได้อย่างน้อย 9 ข้อ จาก 16
 ข้อ จึงจะถือว่าผ่าน

สวามินาธาน, แฮมเบิลตัน และ อัลกินา¹ ได้แสดงการประมาณค่าความสูญเสีย
 ที่น้อยที่สุด (Threshold Loss) ในการตัดสินใจวิธีของเบส์ โดยกำหนดค่า $\alpha = 1$ หน่วย
 และ $\beta = 2$ หน่วย พบว่าเมื่อกำหนดเกณฑ์เป็น .8 ความยาวของแบบสอบถามเป็น 10 และ
 จำนวนผู้สอบ 25 คน ค่าความสูญเสียที่น้อยที่สุดเมื่อให้ผู้ทำข้อสอบได้ 9 ข้อขึ้นไปสอบได้

¹ Hariharan Swaminathan; Ronald K. Hambleton; and James Algina,
 "A Bayesian Decision-Theoretic Procedure for Use with Criterion-Re-
 ferenced Test," Journal of Educational Measurement, 12 (1975):87-98.

และผู้ที่ทำได้กว่า 9 ข้อ สอบตก และเมื่อกำหนดจุดตัดใหม่เป็น .6 และ .8 โดยแบ่งระดับ การรอบรู้เป็น 3 ระดับ คือรอบรู้ทั้งหมด รอบรู้เป็นบางส่วน และไม่รอบรู้ ปรากฏว่าค่า ความสูญเสียจะต่ำสุด เมื่อคัดลีนผู้ที่ทำข้อสอบได้ 10 ข้อขึ้นไปผ่าน ผู้ที่ทำได้ 7 ถึง 9 ข้อ ต้องสอบทบทวนอีกเล็กน้อย และผู้ที่ทำได้ 6 ข้อลงไปต้องเรียนใหม่

* * * เกรเฮน¹ ได้ศึกษาเปรียบเทียบผลของความเที่ยงและความตรงของแบบสอบอิง เกณฑ์ โดยใช้แบบสอบคู่ขนานซึ่งใช้วิธีการเลือกข้อกระทงเพื่อแบ่ง เป็นแบบสอบคู่ขนาน 6 วิธีคือ

1. วิธีของค็อกซ์-แวกาส (Cox-Vagas)
2. วิธีของ เบรนนัน (Brennan)
3. เรียงลำดับตามสัดส่วนในการตอบของผู้สอบหลังจากเรียน
4. เรียงตามที่ครูผู้สร้างแบบสอบเลือก
5. เรียงตามค่าสัมประสิทธิ์สหสัมพันธ์แบบพอยท์ไบซีเรียล
6. เรียงตามลำดับการสุ่ม

พบว่าไม่มีวิธีใดให้ผลต่อความเที่ยงต่างจากวิธีอื่น ๆ อย่างเห็นได้ชัดนัก ในด้านความตรงได้
เลือกเกณฑ์คัดลีนที่ให้ค่าความประมาณความตรงสูงสุด โดยใช้จุดเดียวกันทั้งสองฉบับ ปรากฏ
ว่าวิธีของค็อกซ์-แวกาส และ เบรนนัน ให้ความตรงสูงสุด ในปีเดียวกันนี้ ฮาลาดินา²

(Haladyna) ได้ศึกษาผลของการใช้กลุ่มตัวอย่างต่าง ๆ ที่มีต่อลักษณะของข้อกระทงและ แบบสอบ กลุ่มตัวอย่างที่ใช้เป็นนิสิตเรียนทางการศึกษาเรียนรายวิชาการวัดและประเมินผล การศึกษาระดับปริญญาตรี 189 คน ซึ่งเป็นตัวอย่างที่เทียบเท่ากับประชากรในระดับอุดมศึกษา ทั่ว ๆ ไป ทั้งเกรดเฉลี่ยและคะแนนจาก American College Test ให้กลุ่มตัวอย่างเรียน เรื่อง Mastery Learning ของบลูม (Bloom, 1968) ซึ่งมีอยู่สองหน่วย ใช้เวลาสอน

¹Crehen, "Item Analysis...", pp.255-262.

²Haladyna, "Effects of Different Samples...", pp.93-99.

7 ชั่วโมง ผลทำให้ทำแบบสอบถาม 3 แบบ ซึ่งสร้างให้ข้อสอบในแบบสอบวัดจุดมุ่งหมายที่กำหนดไว้เพื่อจำแนกระหว่างผู้รอบรู้และไม่รอบรู้ แล้วสุ่มข้อกระทงใส่ในแบบสอบ นำแบบสอบไปวัดก่อนและหลังเรียน วิชาเกณฑ์ตัดสินร้อยละ 70 หลังจากนั้นกำหนดค่าสถิติจากกลุ่มตัวอย่างสามกลุ่มคือ กลุ่มก่อนเรียน กลุ่มหลังเรียนและกลุ่มผสมจากสองกลุ่ม ใช้สูตรของคูเคอร์-ริชาร์ดสัน สูตรที่ 20 คำนวณความเป็นเอกพันธ์ภายในของแบบสอบ พบว่า ค่ามัธยเลชคณิตของกลุ่มหลังเรียนสูงกว่ากลุ่มก่อนเรียนมาก ($p < .01$) ความแปรปรวนของคะแนนจะเพิ่มขึ้นตามประสิทธิภาพของการสอน และจากการรวมคะแนนก่อนและหลังเรียนเข้าด้วยกัน ความเป็นเอกพันธ์จะเป็นโมโนมิติที่ใช้การได้เมื่อใช้กลุ่มผสม และมีจำนวนหัวข้อที่จะวัดในแต่ละหน่วยค่า คำนวณอำนาจจำแนกแบบ พอยท์ ไบซีเรียล ให้ค่าใกล้เคียงกับ $D\%$ ของชู (Hsu) ในขณะที่ค่า $D\%$ ต้องใช้การคำนวณสองครั้ง ค่าที่ได้จากพอยท์ ไบซีเรียล ใช้การคำนวณเพียงครั้งเดียว ฮาลาไดนา กล่าวว่า ในแง่ของการสอนแล้ว $D\%$ ตรงกับความหมายของแบบสอบอิงเกณฑ์มากกว่า ในขณะที่ค่าที่ได้จากพอยท์ ไบซีเรียล มีประสิทธิภาพที่สุดในการให้ข้อมูลเกี่ยวกับความครบถ้วนถูกต้อง (Adequacy) ของข้อกระทงในแบบสอบอิงเกณฑ์

ฮวน¹ ได้ใช้ข้อมูลจากแบบสอบเลขคณิตซึ่งมีความยาว 5 ข้อ กลุ่มตัวอย่างที่ใช้ 91 คน คำนวณหาค่าแคปป์ (K) ได้ข้อสรุปว่า ทั้งความเป็นวิวิธพันธ์ของคะแนนและคะแนนเกณฑ์ที่ต่างกันมีผลต่อค่าแคปป์ ความแปรปรวนของคะแนนมีสหสัมพันธ์ทางบวกกับค่าความเที่ยง และค่าความเที่ยงจะเพิ่มขึ้นตามความยาวของแบบสอบ อัตราการเพิ่มจะลดลงเมื่อแบบสอบยาวมาก ๆ ในปีเดียวกันนี้ ซับโคเวียค² ได้ทำการประมาณค่าความเที่ยงโดยบริหารการสอบเพียง 1 ครั้ง ใช้สูตรในการประมาณค่าคะแนนจริงสามวิธีคือ ใช้ค่า P_0 ของ

¹ Huynh, "On the Reliability of...", pp. 253-264.

² Subkoviak, "Estimating Reliability...", pp. 265-276.

แฮมเบิลตัน และ โนวิก (1973) ค่า P_0 ของซบโคเวียค และ \hat{P}_i ซึ่งใช้สูตรของคูเกอร์-ริชาร์ดสัน สูตรที่ 21 คือ

$$\hat{P}_i = \alpha_{21/x} \left(\frac{x_i}{n} \right) + (1 - \alpha_{21/x}) \left(\frac{M_X}{n} \right)$$

$$\text{เมื่อ } \alpha_{21/x} = \frac{n}{n-1} \left[1 - \frac{M_X (n - M_X)}{n \sigma_X^2} \right]$$

เกณฑ์ที่ใช้มีตั้งแต่ 12 ถึง 24 พบว่าค่าความเที่ยงที่ได้จาก P_0 มากกว่า \hat{P}_i และ \hat{P}_i มากกว่า P_0 ผลที่เกิดจากจุดตัดที่ต่างกันต่อค่าสัมประสิทธิ์ความเที่ยงทั้งสามแบบคล้ายคลึงกัน กล่าวคือมีค่าสูงสุดเมื่อเกณฑ์มีค่าต่ำสุดและสูงสุด และมีค่าต่ำสุดเมื่อเกณฑ์อยู่ตรงกลาง ๆ

ซบโคเวียค¹ ได้ศึกษาเปรียบเทียบค่าดัชนีความเที่ยงเมื่อคำนวณด้วยวิธีต่าง ๆ

4 วิธีคือ

1. บริหารการสอบสองครั้ง คือวิธีของสแวมมินนาธาน, แฮมเบิลตัน และ อัลกินา (1974, 1975)

2. บริหารการสอบหนึ่งครั้ง คือวิธีของ

2.1 ฮวน (Huynh, 1976)

2.2 มาร์แชล และ แฮร์เทล (Marshall and Haertel, 1976)

2.3 ซบโคเวียค (Subkoviak, 1976)

เปรียบเทียบค่าความเที่ยง 4 วิธีที่ได้จากตัวอย่างกับที่ได้จากประชากรโดยตรง โดยใช้นักเรียนจำนวน 1586 คน เป็นประชากร แล้วทำการสุ่มแบบแทนที่เป็นกลุ่มตัวอย่างกลุ่มละ 30 คน รวม 50 กลุ่ม ให้ทุกคนทำแบบสอบวัดความถนัดทางวิชาการ (Scholastic Aptitude Test) ที่เป็นแบบสอบคุณนามีความยาว 10, 30 และ 50 ข้อ ใช้เกณฑ์ตัดสิน

¹Michael J. Subkoviak, "Empirical Investigation of Procedures for Estimating Reliability for Mastery Test," Journal of Educational Measurement 15 (1978) : 111 - 116.



4 เกณฑ์ คือ ร้อยละ 50, 60, 70 และ 80 พบว่า ถ้าแบบสอบถามยาวขึ้น ค่าความคลาดเคลื่อนมาตรฐานจะลดลง และค่าประมาณที่ได้จะคงที่และถูกต้องมากขึ้นเมื่อค่าความเที่ยงที่ได้จากประชากรมีค่าสูงมากหรือต่ำมาก และพบว่าแม้ว่าจะใช้ข้อมูลจากแบบสอบถามที่เป็นวิธีวิพันธ์ แต่ไม่มีข้อจำกัดที่สำคัญมากนัก และที่น่าสนใจคือ ค่าประมาณของมาร์แชล, ซับโคเวียค และฮวนกลับให้ค่าประมาณที่ถูกต้อง เมื่อเปรียบเทียบวิธีการทั้งสี่แล้ว วิธีของฮวนให้ค่าประมาณที่ถูกต้องที่สุด เมื่อพิจารณาจากหลาย ๆ ด้านรวมกัน ในปีเดียวกัน อัลกินา และ โน¹ ได้ศึกษาถึงความเชื่อถือได้ของความเที่ยงในการตัดสินใจเมื่อใช้ค่าประมาณคะแนนโคเมน ความเที่ยงของแบบสอบถาม จำนวนผู้สอบและเกณฑ์ตัดสินต่าง ๆ กัน สูตรที่ใช้คำนวณค่าประมาณคะแนนโคเมนคือ สัดส่วนความถูกต้อง (P_i) และ \hat{T}_i ซึ่งคำนวณจากสูตร

$$\hat{T}_i = \hat{\beta} P_i + (1 - \hat{\beta}) \hat{\mu}_p \quad (i = 1, 2, \dots, N),$$

เมื่อ

P_i คือ สัดส่วนความถูกต้อง

$\hat{\beta}$ คือ ค่าสัมประสิทธิ์จากสูตรคูเคอร์-ริชาร์ดสัน สูตรที่ 20

$\hat{\mu}_p$ คือ ค่ามัชฌิมเลขคณิตในรูปของสัดส่วน

ปรากฏข้อค้นพบสรุปได้ดังนี้

1. เมื่อคะแนนเกณฑ์มีค่าใกล้เคียงมัชฌิมเลขคณิตของคะแนนดิบ ค่าสัมบูรณ์ของความคลาดเคลื่อนในการประมาณจะมีค่าสูงสุด (มีค่าเป็นลบเมื่อใช้ \hat{T}_i และเป็นบวกเมื่อใช้ P_i) และจะลดลงเมื่อคะแนนเกณฑ์ทางออกมาทั้งสองข้าง จนกระทั่งเครื่องหมายเปลี่ยนไป

¹James Algina and Michael J. Noe, "A Study of The Accuracy of Subkoviak's Single - Administration Estimate of the Coefficient of Agreement Using Two True - Score Estimates," Journal of Educational Measurement 15 (1978) : 101 - 110.

แล้วจึงเพิ่มขึ้นเรื่อย ๆ แล้วลดลงอีก ความเปลี่ยนแปลงนี้เห็นได้ชัดในแบบสอบที่มีความยาวที่สุด

2. ค่าความเที่ยงของแบบสอบต่างกันจะให้ผลต่อความเที่ยงในการตัดสินต่างกัน และเมื่อใช้ค่าประมาณคะแนนจริงต่างกันก็ให้ผลเช่นเดียวกัน เมื่อค่าความเที่ยงของแบบสอบเกิน .50 ควรใช้ P_u ประมาณค่าคะแนนจริง และถ้าใช้ T_u ประมาณค่าคะแนนจริงแล้วทำให้ค่าความเที่ยงในการตัดสินสูงมากไป วิธีที่ดีคือใช้ค่าเฉลี่ยของสองแบบรวมกัน

3. ความแปรปรวนจากตัวประมาณค่าทั้งสองตัวเพิ่มขึ้นเมื่อลดจำนวนผู้สอบแต่ไม่มากนัก

สมหวัง พิธิยานุวัฒน์¹ ได้ศึกษาเรื่องจุดแบ่งที่พอดีของแบบสอบอิง เกณฑ์ทางสถิติศาสตร์ เพื่อระบุหาจุดแบ่งที่พอดีของแบบสอบอิง เกณฑ์ทางสถิติศาสตร์โดยเริ่มค้นหาจุดแบ่งขั้นต่ำ ซึ่งเป็นจุดตัดระหว่างการแจกแจงของคะแนนกลุ่มที่มีความรู้พื้นฐานทางสถิติอย่างนำไปใช้การได้ กับกลุ่มที่ขาดความรู้พื้นฐานทางสถิติ และหาจุดแบ่งขั้นสูงซึ่งประมวลจากความเห็นของบลูม (P.loom) และ บล็อก (Block) จากจุดแบ่งขั้นต่ำและจุดแบ่งขั้นสูงดังกล่าวนำมาระบุหาจุดแบ่งที่พอดีของแบบสอบอิง เกณฑ์ทางสถิติศาสตร์ประจำหน่วยบทเรียนที่ดี คิดเป็นคะแนนร้อยละ

70

* * จากงานคนควาและวิจัยที่เกี่ยวข้อง พบว่า ในขณะที่การศึกษาเกี่ยวกับแบบสอบอิง เกณฑ์ในประเทศไทยยังอยู่ในระยะเริ่มต้นนั้น นักวัดและประเมินผลในสหรัฐอเมริกากำลังให้ความสนใจศึกษาในเรื่องนี้กันอย่างกว้างขวางและนำไปใช้ในการทดสอบหลายสาขา และเพื่อจุดประสงค์หลายอย่าง มิใช่เพียงในด้านการวัดสัมฤทธิ์ผลทางการศึกษาเท่านั้น ดังที่ แฮมเบิลตัน และ เอกเนอร์² กล่าวว่า "ในสองสามปีที่ผ่านมาในประเทศสหรัฐอเมริกาได้

¹สมหวัง พิธิยานุวัฒน์, "จุดแบ่งที่พอดีของแบบสอบอิง เกณฑ์ทางสถิติศาสตร์ : การศึกษาเบื้องต้น," ใน เอกสารประกอบการประชุมชมโปเซียม, (กรุงเทพมหานคร : สำนักพิมพ์จุฬาลงกรณ์มหาวิทยาลัย, 2520), หน้า 13.

²Hambleton, "Guidelines for Evaluating...", p.321.

มีการสร้างแบบสอบอิงเกณฑ์ขึ้นมาใช้ทั่วไป ไม่ว่าจะในระดับรัฐ ท้องถิ่น โรงเรียนและหน่วยงานต่าง ๆ ที่มีหน้าที่เกี่ยวกับการทดสอบหรือการแนะแนว การออกแบบก็เพื่อสำรวจความก้าวหน้าในโปรแกรมการสอนในโรงเรียนเพื่อวินิจฉัยหาข้อบกพร่องของนักเรียน เพื่อรายงานความก้าวหน้าของนักเรียนแก่ผู้ปกครอง เพื่อประเมินโปรแกรมการศึกษาต่าง ๆ หรือเพื่อให้การรับรอง หรือให้อนุญาตในการประกอบอาชีพในสาขาต่าง ๆ มากมาย" พร้อมกันนี้ก็ได้เสนอรายชื่อแบบสอบอิงเกณฑ์ที่มีอยู่ในปัจจุบันจำนวนหนึ่งดังต่อไปนี้¹



ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

¹Hambleton, "Guidelines for Evaluating....," p.324.

ตารางที่ 2 รายชื่อแบบทดสอบอิงเกณฑ์ที่พัฒนาขึ้นใช้ในประเทศสหรัฐอเมริกา

รหัส (Code)	ชื่อแบบทดสอบ (Name of Test)	ระดับชั้น (Grades)	ระดับ (Le- vels)	ฟอร์ม (Forms)	ปีที่พิมพ์ (Publica- tion Date)	ผู้พิมพ์ (Publisher)
1	1976 Stanford Diag- nostic Mathematics Test	1-12	4	2	1976	Harcourt Brace Jovanovich
2	1976 Stanford Diag- nostic Reading Test	1-12	4	2	1976	Harcourt Brace Jovanovich
3	Skills Monitoring	3-5	3	1	1975	Harcourt Brace Jovanovich
4	Individual Pupil Monitoring System- Mathematics	1-6	6	2	1974	Houghton- Mifflin
5	Individual Pupil Monitoring System- Mathematics	1-8	8	2	1974	Houghton- Mifflin
6	Diagnostic Mathe- matics Inventory	1.5-7,5	7	1	1977	CTB/McGraw- Hill
7	Prescriptive Read- ing Inventory	K-6.5	6	1	1977	CTB/McGraw- Hill
8	Diagnosis : An Instructional Aid- Mathematics and Reading	1-6	2	2	1974	Science Research Associates
9	Mastery : An Evalua- tion Tool-SOBAR Reading	K-9	10	2	1975	Science Research Associates
10	Mastery : An Evalua- tion Tool-Mathema- tics	K-8	9	2	1974	Science Research Associates
11	Fountain Valley Support System in Mathematics	K-8	9	1	1974	Richard L. Zweig Associates