

บทที่ 2

วรรณคดีที่เกี่ยวข้อง

ผู้วิจัยได้ศึกษาและรวบรวมวรรณคดีจากหนังสือ เอกสาร และวารสารต่าง ๆ โดยแบ่งการนำเสนอออกเป็น 3 ตอน คือ

ตอนที่ 1 การทดสอบแบบอิงเกณฑ์ แบ่งเป็น

1. แนวคิดทั่วไปของแบบสอบอิงเกณฑ์
2. ความเที่ยงของแบบสอบอิงเกณฑ์
3. การกำหนดเกณฑ์หรือคะแนนจุดตัด
4. เกณฑ์ในการประเมินวิธีกำหนดคะแนนจุดตัด

ตอนที่ 2 ทฤษฎีการตอบสนองข้อสอบ แบ่งเป็น

1. ข้อตกลงเบื้องต้นของทฤษฎีการตอบสนองข้อสอบ
2. รูปแบบการตอบข้อสอบ
3. การประมาณคะแนนความสามารถ
4. ความสัมพันธ์ของคะแนนความสามารถ (θ) กับคะแนนโคเมน (T)
5. แบบสอบอิงเกณฑ์กับทฤษฎีการตอบสนองข้อสอบ
6. การใช้ทฤษฎีการตอบสนองข้อสอบ กับวิธีกำหนดคะแนนจุดตัดที่ใช้

คุณพิมพ์ของผู้เชี่ยวชาญตัดสิน

ตอนที่ 3 งานวิจัยที่เกี่ยวข้อง

ตอนที่ 1 การทดสอบแบบอิงเกณฑ์

แนวคิดทั่วไปของแบบสอบอิงเกณฑ์

ผู้ที่ริเริ่มแนวคิดเกี่ยวกับการทดสอบแบบอิงเกณฑ์เป็นคนแรกในปี 1963 คือ กลเซอร์ (Glaser 1963: 519-520) โดยให้ความสามารถของการเรียนรู้ในเรื่องใดเรื่องหนึ่งมีลักษณะเป็นแบบต่อเนื่องอยู่ในช่วงระหว่างไม่มีความรู้เลยถึงมีความรู้อย่างสมบูรณ์ และความสามารถของผู้สอบจะตกอยู่ในช่วงของความต่อเนื่องนี้ นวัตกรรมความสามารถของผู้สอบนี้เทียบกับเกณฑ์ที่กำหนดขึ้น เพื่อตัดสินว่าผู้สอบมีความสามารถอยู่ในระดับที่น่าพอใจหรือไม่ ในระยะเวลาใกล้เคียงกันนั้น เมเจอร์ (Mager, cited by Glass 1978 : 240) ก็เผยแพร่ความคิดเกี่ยวกับการเพิ่มเกณฑ์การปฏิบัติไว้ในการเขียนจุดประสงค์การเรียนการสอน แนวคิดของ 2 ท่านนี้เองทำให้เกิดการพัฒนาการทดสอบแบบอิงเกณฑ์ขึ้น ในปี 1969 ปอปแฮมและฮุสเสก (Popham & Husek 1969 : 2) ได้อธิบายการวัดแบบอิงเกณฑ์ว่า ใช้สำหรับบอกสถานะของผู้สอบโดยเทียบกับเกณฑ์ ต่อมาในปี 1971 กลเซอร์และนิตโก (Glaser & Nitko 1971:653) ให้ความหมายของแบบสอบอิงเกณฑ์ไว้ว่า เป็นแบบสอบที่สร้างขึ้นเพื่อให้ผลการทดสอบสามารถแปลความหมายได้โดยตรง โดยเปรียบเทียบกับเกณฑ์การปฏิบัติ และ ปอปแฮม (Popham 1978:31) ให้นิยามแบบสอบอิงเกณฑ์ไว้ว่า เป็นแบบสอบที่ใช้บ่งถึงสถานภาพของผู้สอบเป็นรายบุคคล ซึ่งอ้างอิงถึงคะแนนโดเมน ภายใต้ขอบเขตของเนื้อหาที่ได้รับการกำหนดอย่างชัดเจน

การทดสอบแบบอิงเกณฑ์ มักจะเน้นถึงขอบเขตของเนื้อหาที่ต้องกำหนดอย่างชัดเจน การแปลความหมายของคะแนนที่ได้จากแบบสอบอิงเกณฑ์ กระทำโดยเปรียบเทียบระดับความสามารถของแต่ละบุคคลกับเกณฑ์ที่กำหนดขึ้น และมุ่งที่จะประเมินว่านักเรียนสามารถหรือไม่สามารถ รอบรู้หรือไม่รอบรู้ภายใต้ขอบเขตของเนื้อหาที่กำหนด

ลินด์วอลล์และนิตโก (Lindvall & Nitko 1975:76) ระบุถึงลักษณะของแบบสอบอิงเกณฑ์ไว้ 4 ประการ คือ

1. มีการกำหนดพฤติกรรมเฉพาะที่แสดงออกถึงระดับผลสัมฤทธิ์ได้อย่างเด่นชัดก่อนการดำเนินการสร้างแบบสอบ
2. พฤติกรรมจะถูกระบุในรูปของสถานการณ์ของการสอบที่จะทำให้พฤติกรรมทั้งหมดซึ่งต้องการศึกษาสามารถปรากฏออกมาได้
3. วางแผนการลุ่มข้อสอบ เพื่อให้ได้ข้อสอบซึ่งเป็นตัวแทนของข้อสอบที่เป็นไปได้ทั้งหมด

4. คะแนนที่ได้จากการสอบจะสามารถแปลความหมายได้อย่างเป็นปรนัย และมีความหมายในตัวของมันเอง ในการที่จะแสดงถึงความสามารถของผู้สอบแต่ละคนในพฤติกรรมที่มุ่งวัดทั้งหมด

ความเที่ยงของแบบสอบอิงเกณฑ์

แฮมเบิลตัน และคณะ (Hambleton, et al. cited by Berk 1980 : 323-349) ได้แบ่งแนวคิดเกี่ยวกับความเที่ยงของแบบสอบอิงเกณฑ์ออกเป็น 3 แนวคิด ดังนี้

1. ความเที่ยงที่แสดงถึงความเที่ยงของการตัดสินใจในการแบ่งผู้สอบออกเป็น 2 กลุ่ม คือ กลุ่มที่รอบรู้ และกลุ่มที่ไม่รอบรู้ (Reliability of mastery classification decisions) โดยการสอบซ้ำด้วยแบบสอบฉบับเดียวกัน หรือแบบสอบคู่ขนาน วิธีการหาความเที่ยงตามแนวคิดนี้มีหลายวิธี คือ

- 1.1 วิธีของคาร์เวอร์ (Carver Method)
- 1.2 วิธีของแฮมเบิลตัน และ โนวิก (Hambleton and Novick)
- 1.3 วิธีของสวามินาธาน แฮมเบิลตัน และอัลจิงา (Swaminathan, Hambleton and Algina)
- 1.4 วิธีของสับโคเวียก (Subkoviak)
- 1.5 วิธีของฮวน (Huynh)
- 1.6 วิธีของมาร์แชลและแฮร์เทล (Marshall and Haevtel)

วิธีการหาความเที่ยง 3 วิธีแรก ข้างต้นอาศัยการสอบ 2 ครั้ง แต่วิธีการหาความเที่ยงที่เหลืออาศัยการสอบเพียงครั้งเดียว

2. ความเที่ยงที่แสดงถึงความเที่ยงของคะแนนจากการสอบด้วยแบบสอบอิงเกณฑ์ (Reliability of Criterion-Referenced Test Scores) โดยการหาดัชนีความสอดคล้องของคะแนนของผู้สอบแต่ละคนที่เบี่ยงเบนไปจากคะแนนจุดตัดจากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ การหาความเที่ยงตามแนวคิดนี้มีอยู่ 2 วิธี คือ

- 2.1 วิธีของลิฟิงสตัน (Livingston)
- 2.2 วิธีของเบรนนอนและเคน (Brennan and Kane)

3. ความเที่ยงที่แสดงถึง ความเที่ยงของการประมาณค่าคะแนนมาลาความรู้ หรือ คะแนนจริง (Reliability of domain score estimate) โดยการหาดัชนีความสอดคล้องของคะแนนจริงของผู้สอบแต่ละคนจากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ การประมาณค่าความเที่ยงของแบบสอบตามแนวคิดนี้ไม่ต้องใช้จุดตัดเพื่อเป็นเกณฑ์ความรอบรู้ แต่จะพิจารณาความเคลื่อนไหวมาตรฐานของการวัด ซึ่งแบ่งได้เป็น 4 วิธี คือ

- 3.1 วิธีของเบอร์ก (Berk)
- 3.2 วิธีของลอร์ด (Lord)
- 3.3 วิธีของลอร์ดและโนวิก (Lord and Novick)
- 3.4 วิธีของเบรนนอน (Brennan)

สำหรับการวิจัยครั้งนี้ผู้วิจัยหาความเที่ยงของแบบสอบถึงเกณฑ์ซึ่งแสดงถึงความเที่ยงของการตัดสินใจในการแบ่งผู้สอบออกเป็น 2 กลุ่ม คือ กลุ่มที่รอบรู้และกลุ่มที่ไม่รอบรู้ รายละเอียดของวิธีต่าง ๆ ตามแนวคิดนี้มีดังต่อไปนี้ คือ

วิธีของคาร์เวอรี่ (Carver, กล่าวในบทเชิด วิทยุไญอนันตพงษ์ 2527 : 165)
เป็นวิธีการหาความเที่ยงของการตัดสินจำแนกผู้สอบออกเป็น ผู้รอบรู้ และผู้ไม่รอบรู้จากการสอบนักเรียนกลุ่มเดียวด้วยแบบสอบคู่ขนาน 2 ฉบับ โดยหาสัดส่วนของความสอดคล้องของการตัดสินที่ตรงกันทั้ง 2 ฉบับ ได้ดังนี้

ฉบับ ก.

		ไม่รอบรู้	รอบรู้
ฉบับ ข.	รอบรู้	b	a
	ไม่รอบรู้	c	d

$$P_o = (a + c) / (a + b + c + d)$$

- เมื่อ P_o คือ ความเที่ยงของการตัดสินความรอบรู้
- a คือ จำนวนผู้สอบที่รอบรู้ทั้งฉบับ ก. และฉบับ ข.
- b คือ จำนวนผู้สอบที่รอบรู้ฉบับ ข. แต่ไม่รอบรู้ฉบับ ก.
- c คือ จำนวนผู้สอบที่ไม่รอบรู้ทั้งฉบับ ก. และฉบับ ข.
- d คือ จำนวนผู้สอบที่รอบรู้ฉบับ ก. แต่ไม่รอบรู้ฉบับ ข.

วิธีของแฮมเบิลตันและโนวิก (Hambleton and Novick, cited by subkoviak 1976 : 266) เป็นการหาความเที่ยงของการตัดสินจำแนกผู้สอบออกเป็นผู้รอบรู้ระดับต่าง ๆ จากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ โดยหาสัดส่วนของความสอดคล้องของการตัดสินที่ตรงกันทั้ง 2 ฉบับ ซึ่งสามารถเขียนเป็นสูตรได้ ดังนี้

$$P_o = \sum_{i=1}^m P_{ii}$$

เมื่อ P_o คือ ความเที่ยงของการตัดสินความรอบรู้
 P_{ii} คือ สัดส่วนของผู้สอบที่ถูกตัดสินว่าเป็นผู้รอบรู้ในระดับที่ i ตรงกันจากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ

วิธีของสวามินาธาน แฮมเบิลตัน และอัลจินา (Swaminathan Hambleton and Algina 1974 : 263-267) วิธีนี้อาศัยแนวคิดของแฮมเบิลตันและโนวิก ดังกล่าวข้างต้น มาปรับแก้โดยหักค่าความสอดคล้องของการตัดสินโดยบังเอิญออกไป ดังนี้

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

เมื่อ K คือ ค่าความเที่ยงของการตัดสินซึ่งได้หักความสอดคล้องของการตัดสินโดยบังเอิญออกไปแล้ว

P_o คือ สัดส่วนของความสอดคล้องของการตัดสินความรอบรู้

P_c คือ สัดส่วนของความสอดคล้องของการตัดสินความรอบรู้ที่คาดว่าเกิดขึ้นโดยบังเอิญ

โดยที่ $P_o = \sum_{i=1}^m P_{ii}$

$$P_c = \sum_{i=1}^m P_i \cdot P_j$$

วิธีของสับโคเวียก (Subkoviak 1976 : 265-276) เป็นวิธีการหาความเที่ยงของการตัดสินจำแนกผู้สอบออกเป็นผู้รอบรู้-ผู้ไม่รอบรู้ จากการสอบเพียงครั้งเดียว โดยอาศัยหลักการหาสัมประสิทธิ์ของความสอดคล้องในการตัดสินความรอบรู้ของผู้สอบแต่ละคน ซึ่งแสดงถึงความน่าจะเป็นที่ผู้สอบแต่ละคนจะถูกตัดสินให้เป็นผู้รอบรู้-ผู้ไม่รอบรู้ ได้ตรงกันจากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ

ข้อตกลงเบื้องต้นของวิธีสับโคเวียก คือ

- (1) ข้อสอบแต่ละข้อเป็นอิสระกัน
- (2) ผลการสอบทั้ง 2 ครั้ง เหมือนกัน

ค่าความเที่ยงของการตัดสินตามวิธีนี้หาได้จากสูตร

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

เมื่อ P_c คือ ค่าความเที่ยงของการตัดสิน หรือสัมประสิทธิ์ของความสอดคล้องในการตัดสิน
ความรอบรู้ของผู้สอบ N คน

N คือ จำนวนผู้สอบ

โดยที่
$$P_c^{(i)} = [P(x_i \geq c)]^2 + [1 - P(x_i \geq c)]^2$$

เมื่อ
$$P(x_i \geq c) = \sum_{x_i=c}^n \binom{n}{x_i} P_i^{x_i} (1 - P_i)^{n-x_i}$$

P_i คือ ความน่าจะเป็นที่จะตอบข้อสอบได้ถูกของผู้สอบคนที่ i ซึ่งหาได้จาก

$$P_i = X_i/n$$

เมื่อ X_i คือ จำนวนข้อที่ตอบถูก

n คือ จำนวนข้อสอบทั้งหมดในแบบสอบ

วิธีของฮวิน (Huynh 1976 : 253-263) เป็นวิธีการประมาณค่าความเที่ยงของการตัดสินจากการสอบเพียงครั้งเดียว โดยพัฒนาสูตรมาจากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ ซึ่งข้อสอบจะต้องสุ่มมาจากประชากรของข้อสอบในขอบเขตของเนื้อหาเดียวกัน แบบสอบประกอบด้วยข้อสอบจำนวน n ข้อ คะแนนสอบ X ซึ่งเป็นไปได้ตั้งแต่ 0 ถึง n ของผู้สอบคนหนึ่ง ที่มีระดับความสามารถ θ (ซึ่งแสดงถึงสัดส่วนของจำนวนข้อสอบที่สามารถตอบถูกจากประชากรข้อสอบทั้งหมดในจักรวาล) สมมติได้ว่าการกระจายแบบไบนอมิเยล (Binomial Density) ดังนี้

$$f(x/\theta) = \binom{n}{x} \theta^x (1-\theta)^{n-x} ; x = 0, 1, \dots, n$$

โดยที่ความสามารถ θ จะมีการกระจายแบบเบต้า (Beta Density) ซึ่งมีพารามิเตอร์ α และ β ที่คำนวณได้จากโมเมนต์ 2 ตัวแรก ของการกระจายคะแนนสอบ ถ้า μ และ σ^2 เป็นค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของการกระจายคะแนนสอบ และถ้าความเที่ยงแบบคอเคอร์รี่ชาร์ดสันสูตร 21 ซึ่งหาได้จากสูตร

$$\alpha_{21} = \frac{n}{n-1} \frac{1 - \mu(n-\mu)}{n\sigma^2}$$

แล้วทำให้

$$\alpha = (-1 + 1/\alpha_{21}) \mu$$

$$\beta = -\alpha + n / \alpha_{21} - n$$

ทำให้ได้การกระจายของคะแนนสอบ x เป็นแบบ เบต้า-ไบโนเมียล (Beta - Binomial) ดังนี้

$$f(x) = \binom{n}{x} B(\alpha+x, n+\beta-x) / B(\alpha, \beta)$$

เมื่อ B แทนฟังก์ชันของเบต้า

ถ้า x เข้าใกล้ 0 จะหา $f(x)$ ได้จากสูตร

$$f(0) = \frac{n}{\pi} \prod_{i=1}^n \frac{n+\beta-i}{n+\alpha+\beta-i}$$

และ

$$f(x+1) = f(x) \frac{(n-x)(\alpha+x)}{(x+1)(n+\beta-x-1)} \quad ; x=0,1,\dots,n-1$$

ถ้า x เข้าใกล้ n จะหา $f(x)$ ได้จากสูตร

$$f(n) = \frac{n}{\pi} \prod_{i=1}^n \frac{n+\alpha-i}{n+\alpha+\beta-i}$$

และ

$$f(x-1) = f(x) \frac{x(n+\beta-x)}{(n-x+1)(\alpha+x-1)} \quad ; x=1,\dots,n$$

ขั้นต่อมาพิจารณาถึงแบบสอบคู่ขนาน 2 ฉบับ ที่เป็นอิสระกัน ซึ่งประกอบด้วยข้อสอบ n ข้อ ที่สุ่มมาจากประชากรข้อสอบในขอบเขตของเนื้อหาที่กำหนด ทำให้ได้คะแนนสอบจากแบบสอบคู่ขนาน 2 ฉบับใด ๆ ที่เป็นอิสระกันด้วย

กำหนดให้ x และ y แทนคะแนนที่ได้จากการสอบแบบสอบฉบับ X และ Y โดยที่ x และ y เป็นอิสระกัน ทำให้ได้การกระจาย ดังนี้

$$f(x,y) = \frac{\binom{n}{x} \binom{n}{y}}{B(\alpha,\beta)} B(\alpha+x,y, 2n+\beta-x-y)$$

การกระจายนี้เป็นแบบสมมาตร (Symmetric) คือ $f(x,y) = f(y,x)$

ถ้า x และ y เข้าใกล้ 0 จะหา $f(x,y)$ ได้จากสูตร

$$f(0,0) = \frac{2n}{\pi} \frac{2n+\beta-i}{2n+\alpha+\beta-i} = f(0) \cdot \frac{n}{\pi} \frac{2n+\beta-i}{2n+\alpha+\beta-i}$$

และ $f(x+1,y) = f(x,y) \cdot \frac{(n-x)(\alpha+x+y)}{(x+1)(2n+\beta-x-y-1)}$

ถ้า x และ y เข้าใกล้ n

$$f(n,n) = \frac{2n}{\pi} \frac{2n+\alpha-i}{2n+\alpha+\beta-i} = f(n) \cdot \frac{n}{\pi} \frac{2n+\alpha-i}{2n+\alpha+\beta-i}$$

และ $f(x-1,y) = f(x,y) \cdot \frac{x(2n+\beta-x-y)}{(n-x+1)(2n+\beta-x-y-1)}$

ในขั้นการตัดสินใจแก่ผู้สอบออกเป็นผู้รอบรู้-ผู้ไม่รอบรู้ โดยเทียบคะแนน x กับ คะแนนจุดตัด (c) ซึ่งเป็นไปได้ตั้งแต่ 1 ถึง n ผู้สอบที่มีคะแนน $x \geq c$ จะถูกตัดสินให้เป็นผู้รอบรู้ และ $x < c$ จะถูกตัดสินให้เป็นผู้ไม่รอบรู้ จากแบบสอบคู่ขนาน 2 ฉบับ จะจำแนกผู้สอบออกได้ดังแสดงในตารางต่อไปนี้

ฉบับ X \ ฉบับ Y	ไม่รอบรู้	รอบรู้	สัดส่วนแยก
ไม่รอบรู้	P_{00}		P_0
รอบรู้		P_{11}	P_1
สัดส่วนแยก	P_0	P_1	

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

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

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

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

$$P = P_{00} + P_{11}$$

- เมื่อ P_1 คือ สัดส่วนของผู้สอบที่ถูกตัดสินว่ารอบรู้ จากการสอบด้วยแบบสอบฉบับเดียว
- P_{11} คือ สัดส่วนของผู้สอบที่ถูกตัดสินตรงกันว่ารอบรู้ จากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ
- P_0 คือ สัดส่วนของผู้สอบที่ถูกตัดสินว่าไม่รอบรู้ จากการสอบด้วยแบบสอบฉบับเดียว
- P_{00} คือ สัดส่วนของผู้สอบที่ถูกตัดสินตรงกันว่าไม่รอบรู้ จากการสอบด้วยแบบสอบคู่ขนาน 2 ฉบับ
- P คือ ค่าความเที่ยงของการตัดสิน ที่รวมค่าความสอดคล้องโดยบังเอิญของการตัดสิน

การหาค่าความเที่ยงของการตัดสินจำแนกผู้สอบออกเป็น ผู้รอบรู้-ผู้ไม่รอบรู้ ด้วยดัชนีแคปบา (K) ซึ่งหักความสอดคล้องโดยบังเอิญของการตัดสินออก โดยแบ่งออกเป็น 2 กรณี ดังนี้

1. กรณีที่คะแนนจุดตัดมีค่าต่ำ หรือใกล้ 0

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

2. กรณีที่คะแนนจุดตัดมีค่าสูง หรือใกล้ n

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

การประมาณค่า K เมื่อข้อสอบมีจำนวนข้อมาก

เมื่อข้อสอบมีจำนวนข้อมาก คือมากกว่า 10 ข้อ จะทำให้การคำนวณค่า K ยุ่งยากมาก ฮวินจึงเสนอวิธีคำนวณใหม่โดยอาศัยแนวคิดของคีตส์และลอร์ด (Keats and Lord) เกี่ยวกับการแปลงคะแนนจากสูตร $x' = \sin^{-1} \sqrt{x/n}$ และมีการกระจายแบบปกติ ซึ่งมีค่าเฉลี่ย และส่วนเบี่ยงเบนมาตรฐาน ดังนี้

$$\mu_{x'} = \sin^{-1} \sqrt{x/n}$$

$$\sigma_{x'} = [(\alpha_{21} + 1) / (\alpha + n)]^{1/2}$$

ถ้า x และ y เป็นคะแนนแปลงที่ได้จากแบบสอบคู่ขนาน 2 ฉบับ แล้วค่าสหสัมพันธ์ของคะแนนทั้งสองจะมีค่าประมาณ ดังนี้

$$\rho = \alpha_{21} [(n - 1) / (n + \alpha_{21})]^{1/2}$$

การประมาณค่าการแจกแจงปกติจะสามารถประมาณได้ดีเมื่อ μ/n มีค่าอยู่ระหว่าง .15 ถึง .85 และ n มีค่าน้อยที่สุดเท่ากับ 8 ข้อ

เนื่องจากฟังก์ชัน \sin^{-1} จะมีเส้นกราฟสูงขึ้นแบบ monotonic ดังนั้นจึงตัดเส้นความรอบรู้จาก $x' \geq c'$ เมื่อ $c' = \sin^{-1} \sqrt{(c - .5)/n}$ และใช้ตาราง Univariate and Bivariate Normal Distribution ของกุปตา (Gupta 1963) ช่วย จะสามารถคำนวณค่า P_0 และ P_{00} ได้

ขั้นตอนในการคำนวณค่า K เมื่อข้อสอบมีจำนวนข้อมาก

1. คำนวณค่า \bar{x} และ s^2 ของคะแนนสอบ
2. ประมาณค่า $\mu_{x'}$, $\sigma_{x'}$ และ ρ โดยแทนค่า μ ด้วย \bar{x} และแทนค่า σ ด้วย s
3. คำนวณค่า $Z = (c' - \mu_{x'}) / \sigma_{x'}$
4. ประมาณค่า P_0 จากค่าความน่าจะเป็นของการกระจายแบบปกติที่น้อยกว่า Z
5. ประมาณค่า P_{00} จากค่าความน่าจะเป็นของตัวแปรปกติมาตรฐาน 2 ตัว ที่มีความสัมพันธ์กันเท่ากับ ρ ซึ่งน้อยกว่า Z โดยเปิดตารางของกุปตา (Gupta)
6. คำนวณค่า P และ K จากสูตร

$$P = 1 + 2 (P_{00} - P_0)$$

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

เบ็งและสับโคเวียก (Peng and Subkoviak 1980 : 359-368) ได้เสนอวิธีการประมาณความเที่ยงตามวิธีของฮวินเมื่อข้อสอบมีจำนวนมาก วิธีการคล้ายกับการแปลงคะแนนแบบอาร์คไซน์ที่ฮวินเสนอ โดยให้ชื่อว่าการประมาณค่าแบบปกติอย่างง่าย (Simple Normal Approximation) มีวิธีการดังนี้คือ

1. คำนวณค่าคะแนนเฉลี่ย (μ) ส่วนเบี่ยงเบนมาตรฐาน (σ) และ สัมประสิทธิ์ความเที่ยง KR21 (α_{21}) ของคะแนนสอบ

$$2. \text{ คำนวณ } Z = (c - .5 - \mu) / \sigma$$

เมื่อ c คือ คะแนนจุดตัด

μ คือ ค่าเฉลี่ยของคะแนนสอบใช้ \bar{x} แทน

σ คือ ส่วนเบี่ยงเบนมาตรฐานใช้ s แทน

3. ประมาณค่า P_0 จากค่าความน่าจะเป็นของการกระจายแบบปกติ ที่น้อยกว่า Z

4. ประมาณค่า P_{00} จากค่าความน่าจะเป็นของตัวแปรปกติมาตรฐาน 2 ตัว ที่มีความสัมพันธ์กันเท่ากับ α_{21} ซึ่งน้อยกว่า Z โดยการเปิดตารางของกูปตา

5. คำนวณค่า P และ K จากสูตร

$$P = 1 + 2 (P_{00} - P_0)$$

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

วิธีของมาร์แชลและแฮร์เทล (Marshall-Haertel, cited by Subkoviak 1980 : 145-147) วิธีนี้จะมีกระบวนการคล้าย ๆ กับวิธีการของฮวิน และวิธีการของ สิบโคเวียก คือ ใช้ข้อมูลจากการสอบครั้งเดียว และมีข้อตกลงเบื้องต้นว่าการกระจายของ คะแนนของผู้สอบคนหนึ่งจะเป็นแบบไบโนเมียล (Binomial)

หาความเที่ยงของการตัดสินจำแนกผู้สอบโดยการแบ่งครึ่งแบบสอบฉบับเดียวให้เป็น 2 ฉบับ ๆ ละ n ข้อ แล้วหาค่า P_0 ซึ่งเป็นสัดส่วนของความสอดคล้องในการจำแนกผู้สอบจากแบบสอบ 2 ฉบับ ดังมีขั้นตอนการหาดังต่อไปนี้

1. กำหนดความถี่ (N_x) ของคะแนน (x) จากการสอบด้วยแบบสอบฉบับ ก. ที่มีจำนวน n ข้อ แล้วหาความถี่ (N_w) ของคะแนน (w) จากการสอบด้วยแบบสอบที่มีความยาวเป็น 2 เท่าของฉบับ ก. จากสูตร

$$N_w = \sum_{x=0}^n N_x \binom{2n}{w} \left(\frac{x}{n}\right)^w \left(1-\frac{x}{n}\right)^{2n-w}$$

2. คำนวณค่าความน่าจะเป็นของความสอดคล้องกันในการตัดสินจำแนกผู้สอบ จากการสอบด้วยแบบสอบที่แบ่งครึ่ง 2 ฉบับ สำหรับผู้สอบที่มีคะแนน w บนแบบสอบที่ยาวเป็น 2 เท่า คำนวณได้จากสูตร

$$\phi_w(a,b) = \sum_{j=a}^b \frac{\binom{w}{j} \binom{2n-w}{n-j}}{\binom{2n}{n}}$$

3. คำนวณค่าความเที่ยงของการตัดสิน (P_o) จากสูตร

$$P_o = \frac{1}{N} \left[\sum_{w=0}^{c-1} N_w + \sum_{w=c}^{2c-2} N_w \cdot \phi_w(w-(c-1), c-1) + \sum_{w=2c}^{n+c-1} N_w \cdot \phi_w(c, w-c) + \sum_{w=n+c}^{2n} N_w \right]$$

เมื่อ N คือ จำนวนผู้สอบ

n คือ จำนวนข้อสอบ

c คือ คะแนนจัตตของข้อสอบ n ข้อ

N_w คือ ความถี่ของคะแนน w

$\phi_w(a,b)$ คือ ความน่าจะเป็นของความสอดคล้องกันในการตัดสินจำแนกผู้สอบ

การกำหนดเกณฑ์หรือคะแนนจุดตัด

การกำหนดเกณฑ์ในยุคเริ่มต้น เกิดจากความเคลื่อนไหวของการเขียนวัตถุประสงค์การเรียนการสอนในรูปวัตถุประสงค์เชิงพฤติกรรม

เมเจอร์ (Mager, cited by Glass 1978:238) อธิบาย การกำหนดเกณฑ์ว่าเป็นส่วนหนึ่งของการเขียนวัตถุประสงค์การเรียนการสอน โดยกล่าวว่า

" ถ้าเราสามารถกำหนดผลการปฏิบัติขั้นต่ำสุดที่ยอมรับได้สำหรับวัตถุประสงค์แต่ละข้อ เราจะมีเกณฑ์การปฏิบัติที่ใช้เปรียบเทียบในการทดสอบโปรแกรมการสอนของเรา ; เราจะสามารถบอกได้ว่า โปรแกรมการสอนของเราประสบความสำเร็จตามวัตถุประสงค์การสอนหรือไม่ สิ่งที่ต้องทำก็คือ การอธิบายว่าผลการปฏิบัติที่ยอมรับได้เป็นอย่างไรในวัตถุประสงค์การเรียนการสอนเพื่อใช้เป็นเกณฑ์ของความสำเร็จ "

และยกตัวอย่างวัตถุประสงค์เชิงพฤติกรรมที่ใช้เป็นเกณฑ์ ดังนี้

" นักเรียนต้องสามารถแก้สมการเส้นตรงได้ถูกต้องอย่างน้อย 7 ข้อ ในเวลา 30 นาที

นักเรียนต้องสามารถสะกดคำได้ถูกต้องอย่างน้อย 80 % ของคำทั้งหมดที่ใช้ในการสอบ "

بوبแฮม (Popham 1973:3) กล่าวว่า ควรตั้งเกณฑ์การปฏิบัติโดยกำหนดเป็นระดับผลสัมฤทธิ์ขั้นต่ำสุดของนักเรียนในรูปของวัตถุประสงค์การเรียนการสอน เพื่อช่วยให้ครูสามารถวางแผนและประเมินผลการเรียนการสอน และยกตัวอย่างเกณฑ์ในรูปของวัตถุประสงค์การเรียนการสอน ดังนี้

" นักเรียนสามารถแก้โจทย์ปัญหาเกี่ยวกับเส้นรอบรูปได้ถูกต้อง 10 ข้อใน 15 ข้อ "

นอกจากนั้นไทเลอร์ (Tyler, cited by Glass 1978:238) ก็ได้อธิบายถึงเกณฑ์การปฏิบัติที่ใช้ตัดสินความรอบรู้ในรูปของวัตถุประสงค์เชิงพฤติกรรมเช่นกัน ยกตัวอย่างเช่น "นักเรียนที่รอบรู้ในเนื้อหาใด เนื้อหาหนึ่งนั้น จะต้องสามารถตอบปัญหาที่กำหนดให้ ได้ถูกต้อง 85 % ของทั้งหมด ภายในเวลาที่กำหนด "

การกำหนดเกณฑ์การปฏิบัติในวัตถุประสงค์การเรียนการสอนดังกล่าวมาแล้ว ยังไม่ เป็นค่าเชิงปริมาณที่แท้จริง ต่อมาได้มีการพัฒนาเกณฑ์ให้เป็นค่าเชิงปริมาณที่แท้จริง โดยการนิยาม เกณฑ์ที่ว่าอาจหมายถึง จำนวน หรือเปอร์เซ็นต์ของข้อสอบที่ตอบถูกในแบบสอบที่ใช้ทดสอบวัตถุประสงค์การเรียนการสอนหรือในขอบเขตของเนื้อหาหนึ่ง จำนวนของข้อสอบที่ตอบถูก มักหมายถึง คะแนนจุดตัดซึ่งจะแบ่งการกระจายคะแนนของผู้สอบออกเป็น 2 พวก คือ พวกที่รอบรู้ และพวกที่ไม่รอบรู้คะแนนจุดตัดนี้หาได้จากการทดสอบนักเรียนด้วยข้อสอบชุดหนึ่งเท่านั้น ส่วน เปอร์เซ็นต์ของข้อสอบที่ตอบถูกจะเป็นเกณฑ์ที่แท้จริง ของการทดสอบวัตถุประสงค์การเรียนการสอนหรือในขอบเขตของเนื้อหาที่กำหนดโดยพิจารณาจากข้อสอบที่เป็นไปได้ทั้งหมดในวัตถุประสงค์การเรียนการสอน หรือในขอบเขตของเนื้อหาที่กำหนดนั้น (Berk 1986:138)

แต่คะแนนจุดตัดหรือเปอร์เซ็นต์ของข้อสอบที่ตอบถูก ก็ยังมีปัญหาเกี่ยวกับความไม่เป็นปรนัยในการกำหนดคะแนนจุดตัด จึงมีการนำเอาวิธีทางคณิตศาสตร์มาหาคะแนนจุดตัดและคะแนนของผู้สอบแต่ละคนในรูปคะแนนโดเมน หรือคะแนนจริง (π) เช่น แฮมเบิลตันและโนวิก (Hambleton & Novick 1973:159-170) กำหนดให้ π และ π_0 แทนคะแนนโดเมน และคะแนนจุดตัดตามลำดับ แล้วถ้า $\pi < \pi_0$ จะตัดสินให้เป็นผู้ไม่รอบรู้ และถ้า $\pi \geq \pi_0$ จะตัดสินให้เป็นผู้รอบรู้ นอกจากนี้ ยังมีการกำหนดคะแนนจุดตัดซึ่งพิจารณาจากความคลาดเคลื่อนในการวัด และความคลาดเคลื่อนในการจำแนกประเภทผู้สอบผิด คือ ทำให้เกิดผู้รอบรู้ไม่จริง และผู้ไม่รอบรู้ไม่จริง การคัดเลือกคะแนนจุดตัดที่เหมาะสมวิธีนี้ คือ การหาจุดตัดที่ทำให้เกิดความคลาดเคลื่อนในการจำแนกประเภทผู้สอบผิดที่ต่ำที่สุด

ในการพิจารณาเกณฑ์หรือคะแนนจุดตัดของแบบสอบอิงเกณฑ์นั้น มิลล์แมน (Millman 1973:205-215) ได้สรุปปัจจัยที่ต้องคำนึงถึงไว้ ดังนี้

1. ผลการสอบของผู้สอบคนอื่น ๆ (Performance of others) หรือผลการสอบของกลุ่มที่ผ่านการยอมรับแล้ว
2. เนื้อหาสาระของข้อสอบ (Item Content) โดยให้ผู้เชี่ยวชาญพิจารณาเนื้อหาข้อสอบแล้วกำหนดจำนวนข้อสอบที่น้อยที่สุดที่ผู้สอบต้องตอบได้ถูกต้อง หรือให้ผู้เชี่ยวชาญประมาณความน่าจะเป็นของผู้สอบที่มีความสามารถขั้นต่ำสุดที่ยอมรับได้จะตอบข้อสอบแต่ละข้อได้ถูก คะแนนจุดตัดจะเท่ากับผลบวกของความน่าจะเป็นนั้น

3. ผลทางการศึกษาที่ตามมา (Educational Consequences) คือ ถ้ากำหนดคะแนนจุดตัดต่ำเกินไปก็อาจทำให้นักเรียนไม่สามารถเรียนบทเรียนต่อไปที่ยากกว่าได้ แต่ถ้ากำหนดคะแนนจุดตัดสูงเกินไปก็จะทำให้เสียเวลาทั้งครูและนักเรียน รวมทั้งทรัพยากรต่าง ๆ

4. ผลทางด้านจิตใจและสภาพทางการเงิน (Psychological and Financial Costs) ควรคำนึงถึงผลทางด้านจิตใจที่เกิดขึ้นกับผู้สอบ เช่น แรงจูงใจ ความเบื่อหน่าย การทำลายอัตมโนทัศน์ และรวมทั้งค่าใช้จ่ายในการสอนซ่อมเสริมให้ผู้สอบที่ไม่ผ่านเกณฑ์

5. ความคลาดเคลื่อนที่เกิดจากการเดาและการสุ่มข้อสอบ (Error Due to Guessing and Item Sampling) ควรจะมีการปรับแก้การเดา และข้อสอบที่ใช้ทดสอบมีความเป็นตัวแทนของข้อสอบที่เป็นไปได้ทั้งหมดในโดเมนที่ต้องการวัด

วิธีการกำหนดเกณฑ์ที่มีผู้เสนอขึ้นใช้นั้น แกลส (Glass 1978:237-261) สรุปและรวบรวมแนวคิดของวิธีการต่าง ๆ ออกเป็น 6 แนว ดังนี้

1. การใช้ผลการสอบของคนอื่น ๆ เป็นเกณฑ์ (Performance of Others as a Criterion)

ระดับเกณฑ์สร้างขึ้นโดยอ้างอิงพารามิเตอร์ของประชากรผู้เข้าสอบ ดังนั้นเกณฑ์อาจกำหนดด้วยคะแนนมัธยฐานของคะแนนจากแบบสอบ หรือกำหนดเป็นตำแหน่งเปอร์เซ็นต์ที่เหมาะสมขึ้นมาก่อน แล้วนำไปเทียบกับคะแนนผลการสอบที่สอดคล้องกับตำแหน่งเปอร์เซ็นต์วิธีนี้นักทฤษฎีเกี่ยวกับแบบสอบอิงเกณฑ์ เห็นว่าไม่เหมาะสมกับการวัดแบบอิงเกณฑ์

2. การนับถอยหลังจาก 100% (Counting Backwards from 100%)

จากการสร้างข้อสอบให้สอดคล้องกับจุดประสงค์เชิงพฤติกรรม และจุดประสงค์เชิงพฤติกรรมมีความสำคัญ ดังนั้น เกณฑ์การสอบผ่านที่พึงปรารถนา คือ 100% แต่จากเหตุผลและประสบการณ์พบว่า จะให้ได้ผลโดยสมบูรณ์นั้นย่อมเป็นไปได้ยากเนื่องจากนักเรียนอาจมีความบกพร่องในด้านต่าง ๆ เช่น ความสะเพร่าในการคิดหรือเขียนตอบ จึงยอมให้ลดเกณฑ์ลงมาจาก 100% เหลือ 95% ถึง 80% หรืออาจลดต่ำลงมากกว่านี้ การกำหนดเกณฑ์ด้วยวิธีนี้มีปัญหาว่า เป็นไปตามอำเภอใจ และไม่มีหลักการ

3. การปรับตามเกณฑ์ภายนอกอื่น ๆ (Bootstrapping on other Criterion Scores)

วิธีการนี้อาศัยเกณฑ์ภายนอกมากำหนดว่า " สำเร็จ " หรือ " รอบรู้ " เช่น ใช้เกณฑ์ว่าผู้ได้รับประกาศนียบัตรในอาชีพต่าง ๆ หรือผู้ได้รับใบขับขี่แล้ว เป็นผู้ที่มีความสามารถ ส่วนผู้ที่ได้รับประกาศนียบัตรนั้น ๆ ก็ถือว่าเป็นผู้ไม่มีความสามารถหาคะแนนจุดตัดพิจารณาจากการกระจายของคะแนนที่ได้จากการสอบของคนเหล่านี้ แล้วกำหนดคะแนนจุดตัดที่สามารถแบ่งผู้มีความสามารถออกจากผู้ไม่มีความสามารถได้สอดคล้องกับเกณฑ์ภายนอกมากที่สุด วิธีการกำหนดจุดตัดตามแนวคิดนี้ ได้แก่ วิธีของเบอร์ก (Berk)

4. การใช้คุณพินิจตัดสินความสามารถขั้นต่ำสุด (Judging Minimal Competence)

เป็นวิธีการที่ให้ผู้เชี่ยวชาญเนื้อหาวิชาหรือครูประจำวิชา กำหนดคะแนนจุดตัดโดยศึกษาข้อสอบแล้วระบุว่านักเรียนที่มีความสามารถขั้นต่ำสุดที่ยอมรับได้ ต้องมีคะแนนสอบผ่านเท่ากับเท่าไร การกำหนดคะแนนจุดตัดตามแนวคิดนี้ ได้แก่ วิธีของนีเดิลสกี (Nedelsky) วิธีของแองกอฟ (Angoff) และวิธีของอีเบล (Ebel)

5. การใช้วิธีวิจัยเชิงปฏิบัติ (Operations Research Methods)

เป็นวิธีการหาคะแนนจุดตัดที่เหมาะสมจากผลการทดลองที่ตามมาโดยใช้คุณลักษณะที่เกิดจากการสอนอย่างใดอย่างหนึ่ง เช่น ความคงทนของการเรียนรู้ การถ่ายโยงการเรียนรู้ ความสำเร็จในการทำงาน เป็นต้น เป็นเกณฑ์ภายนอก อาศัยโครงการแจกแจงทางคณิตศาสตร์หรือกราฟ ช่วยในการตัดสินใจความสัมพันธ์ของคะแนนจุดตัดจากแบบสอบกับเกณฑ์ภายนอกที่กำหนดขึ้น วิธีกำหนดจุดตัดตามแนวคิดนี้ ได้แก่ วิธีของบล็อก (Block)

6. การใช้ทฤษฎีการตัดสินใจประกอบ (Decision Theoretic Procedure)

การกำหนดคะแนนจุดตัดตามแนวคิดนี้ เน้นการใช้คณิตศาสตร์มาช่วยในการคำนวณ และใช้ในการตัดสินใจอย่างจริงจัง ซึ่งมีอยู่หลายวิธี เช่น วิธีของเบย์ส (Bayesian) พิจารณาคะแนนจุดตัดโดยอาศัยฟังก์ชันการสูญเสียที่คาดหวังของการตัดสินใจให้ผ่าน และไม่ผ่านคะแนนระดับต่าง ๆ ความสูญเสียที่คาดหวังของการตัดสินใจให้ผ่านและไม่ผ่านที่น้อยที่สุดจะเป็นตัวกำหนดคะแนนจุดตัด และวิธีของแกลส (Glass 1978:251-253) ซึ่งอาศัยวิธีการทดลองเชิงประจักษ์ พิจารณาคะแนนจุดตัดโดยอาศัยฟังก์ชันซึ่งเป็นความสัมพันธ์ของคะแนนจุดตัดกับเกณฑ์ภายนอก ได้แก่ ผู้ที่ได้รับการเรียนการสอนกับผู้ที่ไม่ได้รับการเรียนการสอน คะแนนจุดตัดที่เหมาะสมจะทำให้เกิดการจำแนกผิดน้อยที่สุด นั่นคือ นักเรียนที่ไม่ได้รับการเรียนการสอนจะถูกตัดสินให้เป็นผู้รอบรู้ที่น้อยที่สุด และนักเรียนที่ได้รับการเรียนการสอนจะถูกตัดสินให้เป็นผู้ไม่รอบรู้ที่มีจำนวนน้อยที่สุดด้วย

แต่แฮมเบิลตันและอีกเนอร์ (Hambleton and Eignor, cited by Hambleton 1980:103-107) รวบรวมวิธีกำหนดเกณฑ์และแบ่งออกเป็น 3 กลุ่มใหญ่ ๆ คือ

1. กลุ่มที่ใช้คุณพินิจในการตัดสินใจ (Judgment method) ซึ่งแบ่งการตัดสินใจได้ 2 แบบ คือ

1.1 การตัดสินใจตามเนื้อหาข้อสอบ (Item content) ได้แก่ วิธีนีเดิลสกี วิธีแองกอฟ และวิธีที่พัฒนาขึ้นจากวิธีแองกอฟ (Modified Angoff)

1.2 การตัดสินใจโดยการเดา (Guessing)

2. กลุ่มที่ใช้การทดลองสอบ (Empirical model) กลุ่มนี้ยังแบ่งออกเป็น 2 วิธีคือ

2.1 กำหนดเกณฑ์จากผลการสอบ (Data Criterion measure) ได้แก่ วิธีของลิฟิงสตัน (Livingston) และวิธีของแวนเดอร์ลินเดน และเมลเลนเบอร์ก (VanderLindon & Mellenbergh)

2.2 ใช้ทฤษฎีการตัดสินใจ (Decision Theoretic) เช่น วิธีของไครวาล (Kriewal)

3. กลุ่มที่ใช้ดุลพินิจในการตัดสินใจและการทดลองสอบผสมผสานกัน (Combination model) ซึ่งแบ่งออกได้เป็น 3 แนวคิด ดังนี้

3.1 การตัดสินใจโดยอาศัยข้อมูลเชิงประจักษ์ (Judgmental empirical) แนวคิดนี้แบ่งได้ 3 วิธีการ คือ

3.1.1 วิธีการเปรียบเทียบระหว่างกลุ่มผู้สอบ (Contrasting groups) ได้แก่ วิธีของลิฟิงสตันและซายกี (Livingston & Zieky)

3.1.2 วิธีการสอบกับกลุ่มคาบเส้น (Borderline groups) ได้แก่ วิธีของลิฟิงสตันและซายกี

3.1.3 วิธีการใช้เกณฑ์ภายนอกประกอบ (Criterion groups) ได้แก่ วิธีของเบอร์ก (Berk)

3.2 การพิจารณาถึงผลการศึกษาที่ตามมา (Education Consequence) ได้แก่ วิธีของบลอก (Block)

3.3 ใช้วิธีการของเบส์ (Bayesian method) ได้แก่ วิธีของแฮมเบิลตัน และโนวิก (Hambleton & Novick)

เบอร์ก (Berk 1986:137-172) รวบรวมวิธีการกำหนดเกณฑ์วิธีต่าง ๆ โดยแบ่งออกเป็น 2 รูปแบบ ซึ่งสอดคล้องกับเมสกอสกัส (Meskauskas 1976:133-158) ดังนี้

1. รูปแบบสถานะของตำแหน่ง (State Model) รูปแบบนี้จะตัดสินผู้สอบว่ามีความรอบรู้ / มีความสามารถ หรือยังไม่รอบรู้ / ไม่มีความสามารถเลย เกณฑ์มาตรฐานในอดีตคือ 100% แต่เนื่องจากในทางปฏิบัติอาจมีความคลาดเคลื่อนเกิดขึ้นในการตัดสินว่าผู้สอบมีความรอบรู้ / มีความสามารถ หรือยังไม่รอบรู้ / ไม่มีความสามารถ จึงลดเกณฑ์มาตรฐานลงมาจาก 100% วิธีการเหล่านี้กำหนดเกณฑ์มาตรฐานได้โดย

1.1 การทดลองสอบ (Empirical-judgmental) วิธีการเหล่านี้จะหาเกณฑ์มาตรฐานจากผลการสอบของนักเรียนกลุ่มหนึ่งหรือหลาย ๆ กลุ่ม และใช้วิธีวิเคราะห์ทางสถิติ ประมาณความคลาดเคลื่อนของการแบ่งผู้สอบออกเป็น ผู้รอบรู้ไม่จริงและผู้ไม่รอบรู้ไม่จริงที่น้อยที่สุด เป็นวิธีการปรับเกณฑ์มาตรฐานที่เหมาะสม (Adjusting standard) วิธีเหล่านี้ ได้แก่

- 1.1.1 วิธีของเบอร์ก (Berk)
- 1.1.2 วิธีของเบอร์แกน, แคนเซลลีและลูเทิน (Bergan, Cancelli, & Luiten)
- 1.1.3 วิธีของเอมริค (Emrick)
- 1.1.4 วิธีของแนป (Knapp)
- 1.1.5 วิธีของมาเรดี้และเดทอน (Maeredy & Dayton)
- 1.1.6 วิธีของโรดาบัส (Roudabush)
- 1.1.7 วิธีของวิลคอกซ์ (Wilcox)

2. รูปแบบต่อเนื่อง (Continuum Model) รูปแบบนี้เชื่อว่าความสามารถของบุคคลมีการกระจายแบบต่อเนื่อง ซึ่งสามารถกำหนด ความรอบรู้ / ความสามารถ เป็นแบบช่วงได้ โดยแบ่งวิธีการหาเกณฑ์มาตรฐานออกเป็น 3 แนวคิด คือ

2.1 ใช้ดุลพินิจของผู้เชี่ยวชาญตัดสิน (Judgmental) อาจเป็นการตัดสินของผู้เชี่ยวชาญคนเดียวหรือหลายคนก็ได้ ทำการตัดสินอย่างเป็นอิสระกัน หรือมีการประชุมกันก็ได้ โดยไม่มีข้อมูลจากการทดลองสอบนักเรียนมาก่อน ซึ่งมีอยู่ 11 วิธี คือ

- 2.1.1 วิธี Adjust/modified M.C. Angoff
- 2.1.2 วิธีแองกอฟ (Angoff)
- 2.1.3 วิธี Angoff-Nedelsky combination
- 2.1.4 วิธี Difficulty-importance estimate
- 2.1.5 วิธี Difficulty-relevance Ebel
- 2.1.6 วิธี Difficulty-taxonomy Ebel
- 2.1.7 วิธี Item specifications
- 2.1.8 วิธี Modified M-C Angoff
- 2.1.9 วิธีเนเดลสกี (Nedelsky)
- 2.1.10 วิธี Relevance-taxonomy Ebel
- 2.1.11 วิธีแองกอฟ 2 ตัวเล็ก (Two-choice Angoff)

2.2 ใช้ดุลพินิจของผู้เชี่ยวชาญตัดสิน โดยมีข้อมูลการทดลองสอบเป็นตัวชี้หน้าในการตัดสิน (Judgmental-empirical) อาจทำการตัดสินอย่างเป็นอิสระกัน หรือมีการประชุมกันก็ได้ วิธีการเหล่านี้ ได้แก่

2.2.1 วิธีหาจุดสมมูลย์ระหว่างเกณฑ์สัมบูรณ์และเกณฑ์สัมพัทธ์ แบบที่ 1 (Absolute-relative compromise I)

2.2.2 วิธีหาจุดสมมูลย์ระหว่างเกณฑ์สัมบูรณ์และเกณฑ์สัมพัทธ์ แบบที่ 2 (Absolute-relative compromise II)

2.2.3 วิธี Angoff-contrasting groups plus composite

2.2.4 วิธีการใช้ดุลพินิจตัดสินโดยอาศัยสารสนเทศประกอบ (Informed judgment)

2.2.5 วิธี Iterative Angoff

2.2.6 วิธี Iterative two-choice Angoff

2.2.7 วิธี Modified Angoff-empirical

2.3 ใช้การทดลองสอบ (Empirical-judgmental) ซึ่งสามารถแบ่งออกเป็น 2 แนวทาง คือ

2.3.1 ใช้ข้อมูลการทดลองสอบมาหาเกณฑ์มาตรฐานโดยการวิเคราะห์ทางสถิติ วิธีการเหล่านี้ ได้แก่

2.3.1.1 วิธีสอบกับเด็กคาบเส้น (Borderline group) เช่น วิธีของลิฟิงส์ตันและซายกี (Livingston and Zieky)

2.3.1.2 วิธีการเปรียบเทียบระหว่างกลุ่มผู้สอบ (Contrasting groups) เช่น วิธีลิฟิงส์ตันและซายกี (Livingston & Zieky)

2.3.1.3 วิธีใช้เกณฑ์ภายนอก (Criterion groups) เช่น วิธีของเบอร์ก (Berk)

2.3.1.4 วิธีพิจารณาผลทางการศึกษาที่ตามมา (Educational consequences) เช่น วิธีของบลอก (Block)

2.3.1.5 วิธีใช้ผลการสอบของคนอื่น ๆ เป็นเกณฑ์ (Norm-referenced criterion)

2.3.2 ใช้ข้อมูลการทดลองสอบประมาทความคลาดเคลื่อนของการแบ่งผู้สอบออกเป็นผู้รอบรู้ไม่จริง หรือผู้ไม่รอบรู้ไม่จริงที่น้อยที่สุด เป็นวิธีการปรับเกณฑ์มาตรฐานที่เหมาะสม วิธีการเหล่านี้ ได้แก่

2.3.2.1 วิธีของฮาน (Hugnh)

2.3.2.2 วิธีของไครวอลล์ (Kriewall)

2.3.2.3 วิธีของลิฟวิงสตัน (Livingston)

2.3.2.4 วิธีของลิฟวิงสตัน 1980 (Livingston)

2.3.2.5 วิธีของโนวิกและลิวอิส (Novick & Lewis)

2.3.2.6 วิธีของแวนเดอร์ลินเดนและเมลเลนเบอร์ก (Van

der Linden & Mellenbergh)

2.3.2.7 วิธีของวิลคอกซ์ (Wilcox)

เมื่อพิจารณาวิธีการหาคะแนนจุดตัดวิธีต่าง ๆ ที่มีผู้รวบรวมและสรุปดังกล่าวมาแล้วข้างต้น ปรากฏว่ามีการจัดกลุ่มวิธีต่าง ๆ อย่างสอดคล้องกัน ผู้วิจัยจึงรวบรวมวิธีการหาคะแนนจุดตัดวิธีต่าง ๆ และแบ่งออกเป็น 2 รูปแบบ ตามที่เบอร์กสรุปไว้ ดังนี้ คือ

1. รูปแบบสถานะของตำแหน่ง เป็นวิธีการหาคะแนนเกณฑ์โดยการทดลองสอบ

เอมริค (Emrick 1971 : 321-326) เสนอวิธีคำนวณหาเกณฑ์ที่อยู่ในรูปร้อยละ โดยอาศัยการประมาณความผิดพลาดในการยอมรับที่ผิด (β) และความผิดพลาดในการปฏิเสธที่ผิด (α) เมื่อกำหนดให้ $\beta = 3\alpha$ และ $RR = 10$ จากสูตร

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

เมื่อ K คือ เกณฑ์ที่อยู่ในรูปของร้อยละ

n คือ ความยาวของแบบสอบ

β คือ ค่าประมาณความน่าจะเป็นของความผิดพลาดในการยอมรับที่ผิด

α คือ ค่าประมาณความน่าจะเป็นของความผิดพลาดในการปฏิเสธที่ผิด

ค่า α และ β หาได้จากสูตร

$$\alpha + \beta = 1 - \sqrt{r_i}$$

เมื่อ \bar{r}_i คือ ค่าความเที่ยงของข้อสอบ คำนวณได้โดยใช้สูตรของเสเปียร์แมน-บราวน์
 RR คือ อัตราส่วนของความรุนแรงของความคลาดเคลื่อน β ต่อ α
 (Ratio of Regret of β to α)

2. รูปแบบต่อเนื่อง สามารถแบ่งวิธีการกำหนดเกณฑ์ออกเป็น 3 แนวคิด คือ

2.1 วิธีการหนดจุดตัดที่อาศัยคุณลักษณะของผู้เชี่ยวชาญตัดสิน ดังเช่นวิธีต่าง ๆ
 ต่อไปนี้

วิธีของนีเดิลสกี (Nedelsky 1954 : 3-19) เป็นเทคนิคในการหา
 คะแนนผ่านต่ำสุด (minimum passing score) ดังนี้ ก่อนนำแบบสอบไปให้นักเรียนทำให้ครู
 ผู้สอนทุกคนพิจารณาข้อสอบแต่ละข้อว่าตัวเลือกใดที่นักเรียนในระดับต่ำสุดที่จะผ่าน (พวก D
 student) บอกได้ว่าผิด ระดับการผ่านต่ำสุดของข้อสอบแต่ละข้อคือส่วนกลับของจำนวนตัวเลือก
 ที่เหลืออยู่ เช่น ในข้อสอบที่มี 5 ตัวเลือก ถ้ามี 1 ตัวเลือกที่นักเรียนระดับต่ำสุดที่จะผ่านรู้ว่าผิด
 ส่วนกลับของจำนวนตัวเลือกที่เหลือคือ $1/4$ นำค่าเศษส่วนนี้จากทุกข้อมารวมกันแล้วหาค่าเฉลี่ย
 ของผลที่ได้จากการพิจารณาของผู้สอนแต่ละคน เป็นค่าเฉลี่ยของคะแนนเดาของนักเรียนที่อยู่
 ระหว่างเกรด F และ D (F - D student) แทนด้วย M_{FD} เพื่อนำไปหาค่าคะแนนต่ำสุด
 จากสูตร

$$\text{คะแนนผ่านต่ำสุด} = M_{FD} + k \sigma_{FD}$$

k เป็นค่าคงที่ ซึ่งกำหนดขึ้นจากการพิจารณาหลาย ๆ ครั้ง

σ_{FD} เป็นค่าส่วนเบี่ยงเบนมาตรฐานของค่าผลรวมเศษส่วนจากข้อสอบทุกข้อ
 ของผู้สอนแต่ละคน

ผู้สอนส่วนใหญ่ที่ใช้เทคนิควิธีนี้เห็นว่าคะแนนผ่านต่ำสุด ควรทำให้นักเรียนที่อยู่ระหว่าง
 เกรด F และ D ส่วนใหญ่สอบตก ถ้าให้ k เป็น $-1, 0, 1$ และ 2 จะให้พวกที่อยู่ระหว่าง
 เกรด F และ D สอบตก 16%, 50%, 84%, และ 98%, ตามลำดับการพิจารณาตัดสินใจ
 เลือกค่า k ครั้งสุดท้าย จะได้หลังจากที่ผู้สอนหลาย ๆ คน เลือกคำตอบที่นักเรียนระดับต่ำสุดที่
 จะผ่านรู้ว่าผิดแล้ว แต่ตามการกำหนดค่ามาตรฐานสัมบูรณ์ (absolute standard) นั้น ค่า
 k ควรกำหนดก่อนที่จะคำนวณค่า M_{FD} และก่อนที่จะรู้คะแนนการสอบของนักเรียน

คำตอบที่นักเรียนต่ำสุดที่จะผ่านรู้ว่าผิด จะมีทั้งคำตอบที่ผิดอย่างชัดเจน และคำตอบ ผิดปานกลาง ซึ่งผู้ที่จะปฏิเสธได้จะต้องมีความรู้ถึงขั้นนั้นแล้ว ถ้าในแบบสอบมีคำตอบชนิดแรก มาก สามารถแก้ได้โดยการกำหนดค่า k ให้สูง แต่ถ้าชนิดหลังมากจะกำหนดค่า k ให้ต่ำใน การเปลี่ยนแปลงค่า k นั้น ไม่ควรเปลี่ยนมากกว่า $+ 0.5$ จาก ค่า k ที่กำหนดขึ้นเพื่อทดลอง ใช้ การตัดสินใจตามทฤษฎีไม่ค่อยปรากฏว่า k จะสูงถึง 2 สำหรับแบบสอบส่วนมาก ค่า $k = 0$ อาจจะต่ำเกินไป ข้อเสนอแนะในการพิจารณาค่า k คือควรเริ่มที่ $k = 1$ ก่อน และช่วงของ ค่า k ที่จะเปลี่ยนไปจะอยู่ระหว่าง .5 ถึง 1.5

วิธีของแองกอฟ (Angoff, cited by Glass 1978 : 248)

เสนอวิธีการโดยใช้ค่าความน่าจะเป็นที่นักเรียนที่สอบผ่านในระดับต่ำสุด ควรตอบได้อย่างถูกต้อง ในแบบสอบแบบเลือกตอบมาเป็นคะแนนที่จุดตัดที่ยอมรับผ่าน (passing score) วิธีการคือ ให้ ผู้ตัดสินแต่ละคนเสนอค่าความน่าจะเป็นที่ผู้สอบที่มีความสามารถจะยอมรับได้ระดับต่ำสุด ควรจะ ตอบแต่ละข้อได้ถูกต้อง ที่จริงแล้วผู้ตัดสินจะคิดถึงจำนวนคนที่จะยอมรับได้ในระดับต่ำสุด (แทนที่ จะคิดเฉพาะเพียงคนเดียว) และจะประมาณค่าสัดส่วนของผู้ที่จะยอมรับได้ในระดับต่ำสุด ซึ่งจะ ตอบแต่ละข้ออย่างถูกต้อง ผลรวมของความน่าจะเป็นหรือสัดส่วนเหล่านี้จะใช้เป็นคะแนนจุดตัดที่ ยอมรับขั้นต่ำสุด

วิธี Modified multiple-choice Angoff (ETS, cited by Berk 1986 :48) วิธีนี้จะขอร้องให้ผู้ตัดสินเลือกเปอร์เซ็นต์ของผู้สอบซึ่งมีความสามารถขั้นต่ำ สุดที่จะตอบข้อสอบได้ถูก โดยมีให้เลือก 7 ค่า คือ 5%, 20%, 40%, 60%, 75%, 90% และ 95% หรือ "ไม่ทราบ"

วิธี Two - choice Angoff (Nassif, cited by berk 1986 : 148) วิธีนี้จะถามผู้ตัดสินว่าผู้สอบที่มีความสามารถขั้นต่ำสุดสามารถตอบข้อสอบได้ถูกหรือไม่ คำตอบของผู้ตัดสินจะเป็น "ได้" "ไม่ได้" และ "ไม่ทราบ" เกณฑ์หาได้จากคำตอบของผู้ตัดสิน ที่ตอบว่า "ได้" ตรงกัน เปอร์เซ็นต์ของข้อสอบที่ผู้ตัดสินตอบว่า "ได้" คือ เกณฑ์ที่ต้องการ

วิธี Adjusted/modified multiple-choice Angoff (Know- ledge estimation panel) (Bernknopf, Curry, and Bashaw, cited by berk 1986 : 151) วิธีนี้จะขอร้องให้ผู้ตัดสินเลือก "เปอร์เซ็นต์ของผู้สอบซึ่งมีความสามารถขั้นต่ำสุด ที่จะตอบข้อสอบได้ถูก" สำหรับข้อสอบแต่ละข้อ จากตัวเลือก 9 ตัว แล้วปรับเปอร์เซ็นต์ที่ทำให้ การจำแนกผู้สอบผิด คือ รอบรู้ไม่จริง หรือไม่รอบรู้ไม่จริง มีค่าต่ำสุด และปรับแก้ ความคลาดเคลื่อนที่เกิดจากการเดาเกณฑ์หาได้จากผลบวกของค่าเฉลี่ยของเปอร์เซ็นต์ในการตอบข้อสอบได้ ถูกจากผู้ตัดสินทุกคน

วิธี Angoff-Nedelsky combination (Reid, cited by berk 1986 : 152) เกณฑ์คำนวณจากค่าเฉลี่ยของเกณฑ์ที่ได้จากวิธีแองกอฟและวิธีเนเดลสกี

วิธีของอีเบล (Ebel, cited by Glass 1978 : 247-248)

อีเบลมีความเห็นว่า นิยามของคะแนนจุดตัด (passing score) ในลักษณะที่เป็นเปอร์เซ็นต์ของคะแนนสอบทั้งหมดอาจมีข้อบกพร่อง เนื่องจากข้อสอบอาจยากเกินไป ง่ายเกินไปหรืออำนาจจำแนกน้อยกว่าที่ผู้สร้างแบบสอบตั้งใจไว้ การสอบผ่านหรือตกของผู้เข้าสอบอาจเป็นการตัดสินใจโดยใช้คำถามในแบบสอบมากกว่าใช้ระดับความสามารถของเขายีเบลจึงเสนอให้ใช้การพิจารณาคุณลักษณะของข้อสอบในแง่ของความเกี่ยวข้อง (relevance) และความยาก (difficulty) ในแง่ของความเกี่ยวข้อง แบ่งเป็น 4 ประเภท คือ จำเป็น (Essential) สำคัญ (Important) พอจะยอมรับได้ (Acceptable) และยังไม่แน่ใจ (Questionable) ส่วนค่าความยากมี 3 ระดับ คือ ง่าย ปานกลาง และยาก และเสนอเปอร์เซ็นต์ ที่คาดหวังซึ่งเป็นปริมาณของผู้สอบซึ่งมีความสามารถขั้นต่ำสุดที่ยอมรับได้น่าจะสอบผ่าน

ระดับ	ระดับ				
	ความเกี่ยวข้อง	ความยาก	ง่าย	ปานกลาง	ยาก
จำเป็น					
สำคัญ					
ยอมรับได้					
ไม่แน่ใจ					

วิธี difficulty - taxonomy Ebel. (Skakun & Kling 1980 : 229-235) วิธีนี้อาศัยการพิจารณาข้อสอบใน 2 ประเด็น ดังนี้

1. ความยากของข้อสอบ คือ ง่าย ปานกลาง ยาก
2. ลำดับชั้นการเรียนรู้ของบลูม (Bloom Taxonomy) คือชั้นความจำ ความเข้าใจ และการนำไปใช้

ลำดับชั้นการเรียนรู้	ระดับ ความยาก	ง่าย	ปานกลาง	ยาก
ชั้นความจำ				
ชั้นความเข้าใจ				
ชั้นการนำไปใช้				

สามารถกำหนดความยากของข้อสอบโดยใช้ผลการทดสอบนักเรียน และให้ผู้สร้างข้อสอบเป็นผู้กำหนดลำดับชั้นการเรียนรู้ของข้อสอบ แล้วจัดแบ่งข้อสอบลงในตารางข้างต้นตามความยาก และลำดับชั้นการเรียนรู้ คณะแผนกฯ หาได้โดยการตัดสินใจส่วนตัวของข้อสอบที่ผู้สอบซึ่งมีความสามารถขั้นต่ำสุด สามารถตอบได้ถูกต้องในแต่ละช่องของตารางข้างต้น

วิธี Relevance - taxonomy Ebel (Skakun &Kling 1980 : 229-235) วิธีนี้เหมือนกับวิธี Difficulty - Taxonomy Ebel ต่างกันที่การพิจารณาข้อสอบในด้านลำดับชั้นการเรียนรู้เปลี่ยนเป็น พิจารณาข้อสอบในด้านลักษณะข้อสอบที่ตรงกับประเด็นปัญหา จำแนกเป็น 3 ระดับ คือ 1. ระดับที่ตรงกับปัญหาและจำเป็นอย่างมาก 2. ระดับที่ตรงกับปัญหาและสำคัญ 3. ระดับที่ยอมรับว่าตรงกับปัญหา

วิธีพิจารณาลักษณะเฉพาะข้อสอบ (Item specifications) (Mills & Barr, cited by berk 1986 : 149) ให้ผู้ตัดสินใจอ่านลักษณะเฉพาะของข้อสอบแต่ละลักษณะ ซึ่งประกอบด้วยพฤติกรรมที่ต้องการวัด รายละเอียดของเนื้อหา และเงื่อนไขที่จะทำให้เกิดพฤติกรรมนั้น หลักในการสร้างตัวเลือก และตัวอย่างข้อสอบ

หลังจากการอ่านลักษณะเฉพาะของข้อสอบแล้ว ผู้ตัดสินจะมีโน้ตส์เกี่ยวกับข้อสอบทั้งหมดที่เป็นไปได้ ซึ่งแทนได้ด้วยลักษณะเฉพาะของข้อสอบ ดังนั้นจึงสามารถกำหนดเกณฑ์ได้ โดยการประมาศตัดสินของข้อสอบในจักรวาลที่ผู้สอบ ซึ่งมีความสามารถขั้นต่ำสุดจะสามารถตอบได้ถูก

วิธีการประมาณตามความสำคัญของความยาก (Difficulty - importance estimate) (Cangelosi, cited by berk 1986 : 149) ทำตามลำดับชั้นได้ดังนี้

1. ให้ผู้ตัดสินพิจารณาวัตถุประสงค์การเรียนรู้แต่ละข้อ แล้วประมาณระดับผ่านต่ำสุด และกำหนดน้ำหนักความสำคัญของวัตถุประสงค์การเรียนรู้แต่ละข้อ
2. หาค่าเฉลี่ยของผลคูณระหว่างระดับผ่านต่ำสุด กับน้ำหนักความสำคัญของวัตถุประสงค์การเรียนรู้แต่ละข้อ
3. คำนวณคะแนนเกณฑ์โดยการหาผลคูณระหว่างค่าเฉลี่ยที่ได้จากขั้นที่ 2 กับจำนวนข้อในแบบสอบ


2.2 วิธีการจุดตัดที่อาศัยการทดลองสอบดังเช่นวิธีต่าง ๆ ต่อไปนี้

วิธีใช้กลุ่มคาบเส้น (Borderline group) (Livingston & Zieky, cited by berk 1986 : 161) วิธีการคือเลือกนักเรียนที่มีความสามารถอยู่ในระดับคาบเส้นมาทดสอบ แล้วคะแนนจุดตัดเท่ากับ ค่ามัธยฐานของคะแนนสอบของนักเรียนกลุ่มนี้

วิธีใช้การเปรียบเทียบระหว่างกลุ่มผู้สอบ (Contrasting groups) (Livingston & Zieky, cited by berk 1986 : 162) ทำการจัดประเภทผู้สอบออกเป็น "พวกรอบรู้" และ "พวกไม่รอบรู้" โดยการทดสอบ การคัดเลือกเกณฑ์จะคำนึงถึงความรู้หรือความชำนาญอย่างหนึ่งอย่างใดของผู้สอบที่นอกเหนือจากคะแนนสอบด้วย วิธีการหาคะแนนจุดตัดกำหนดจากความคลาดเคลื่อนในการจำแนกประเภทผู้สอบผิดที่มีค่าต่ำสุด

วิธีอาศัยเกณฑ์ภายนอก (Criterion groups) เบิร์ค (Berk 1978 : 4-9) ประยุกต์วิธีนี้มาใช้โดยใช้เกณฑ์ภายนอก คือ ได้รับการสอนหรือไม่ได้รับการสอนตามวัตถุประสงค์ที่ต้องการวัดมาแบ่งนักเรียนออกเป็น 2 กลุ่ม คือ กลุ่มที่ได้รับการสอนให้เป็นพวกรอบรู้ (Master : M) กลุ่มที่ไม่ได้รับการสอนให้เป็นพวกไม่รอบรู้ (Nonmaster : N) แล้วทำการสอบกับนักเรียนทั้ง 2 กลุ่ม นี้ด้วยแบบสอบชุดเดียวกัน นำการแจกแจงของคะแนนการสอบของนักเรียนทั้ง 2 กลุ่ม ไปเขียนกราฟร่วมกัน ดังนี้

จำนวนคน



จุดที่กราฟ หรือฟังก์ชันทั้งสองตัดกันจะกำหนดให้เป็นคะแนนจุดตัดนักเรียนที่ได้คะแนนเท่ากับหรือสูงกว่าคะแนนจุดตัด จัดเป็นพวกรอบรู้โดยการทำนาย (Predicted Master : PM) ส่วนนักเรียนที่ได้คะแนนต่ำกว่าคะแนนจุดตัด จัดเป็นพวกไม่รอบรู้โดยการทำนาย (Predicted Nonmaster : PN) จากการแบ่งโดยใช้เกณฑ์ภายนอก และคะแนนจุดตัดที่กำหนดขึ้น จะได้นักเรียน 4 พวก คือ

1. พวกรอบรู้จริง (True Master : TM) คือนักเรียนที่ได้รับการสอนซึ่งได้คะแนนเท่ากับ หรือมากกว่าคะแนนจุดตัด
2. พวกรอบรู้ไม่จริง (False Master : FM) คือนักเรียนที่ไม่ได้รับการสอน ซึ่งได้คะแนนมากกว่าหรือเท่ากับคะแนนจุดตัด
3. พวกไม่รอบรู้จริง (True Nonmaster : TN) คือนักเรียนที่ไม่ได้รับการสอน ซึ่งได้คะแนนต่ำกว่าคะแนนจุดตัด
4. พวกไม่รอบรู้ไม่จริง (False Nonmaster : FN) คือนักเรียนที่ได้รับการสอน ซึ่งได้คะแนนต่ำกว่าคะแนนจุดตัด

แสดงในรูปตาราง 2 x 2 ได้ดังนี้

		เกณฑ์ภายนอก	
		ได้รับการสอน	ไม่ได้รับการสอน
คะแนนจุดตัด	รอบรู้โดยการทํานาย	รอบรู้จริง (TM)	รอบรู้ไม่จริง (FM)
	ไม่รอบรู้โดยการทํานาย	ไม่รอบรู้ไม่จริง (FN)	ไม่รอบรู้จริง (TN)

เมื่อทดลองกำหนดคะแนนจุดตัดหลาย ๆ จุด จะได้จำนวนนักเรียนแต่ละพวกแตกต่างกันตามค่าของคะแนนจุดตัด นำผลที่ได้จากการกำหนดคะแนนจุดตัดต่าง ๆ กันมาหาค่าความน่าจะเป็นของแต่ละประเภท โดยใช้สูตร ดังนี้

$$P (TM) = TM / (M + N)$$

$$P (TN) = TN / (M + N)$$

$$P (FM) = FM / (M + N)$$

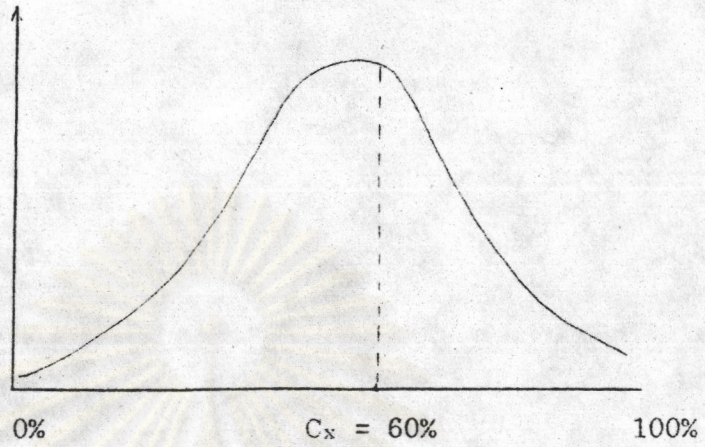
$$P (FN) = FN / (M + N)$$

คะแนนจุดตัดที่เหมาะสม คือ จุดตัดที่ทำให้ความน่าจะเป็นในการตัดสินประเภทบุคคลได้ถูกต้อง คือ $P (TM) + P (FN)$ มีค่าสูงสุด หรือทำให้ความน่าจะเป็นในการตัดสินประเภทบุคคลผิด คือ $P (FM) + P (TN)$ มีค่าต่ำสุด

วิธีพิจารณาผลทางการศึกษาที่ตามมา (Educational Consequences)

วิธีนี้อาศัยผลด้านคุณค่าอย่างใดอย่างหนึ่งมาช่วยในการพิจารณาเกณฑ์ โดยใช้ผลคุณค่าสูงสุดมาเป็นเครื่องชี้กำหนดคะแนนจุดตัด ซึ่งพิจารณาจากลักษณะกราฟคะแนนที่ตรงกับจุดสูงสุดของกราฟจะถือเป็นคะแนนจุดตัด บล็อก (Block 1972 : 183-190) ประยุกต์วิธีการนี้มาใช้ โดยทำการสอนนักเรียนกลุ่มต่าง ๆ ที่มีความเท่าเทียมกัน จนมีผลสัมฤทธิ์จากการทำแบบสอบอิงเกณฑ์ระดับต่าง ๆ กัน เช่น 10%, 15%, 20%, ..., 95%, 100% แล้ววัดผลด้านคุณค่าอย่างใดอย่างหนึ่งที่มีความสัมพันธ์กับคะแนนจากแบบสอบอิงเกณฑ์ของแต่ละกลุ่มที่มีผลสัมฤทธิ์ระดับต่าง ๆ กันนั้น นำผลที่ได้มาเขียนกราฟแสดงความสัมพันธ์เพื่อพิจารณาคะแนนจุดตัด ถ้ากราฟมีจุดโค้งกลับ (Non - monotonic) คะแนนจุดตัดจะเป็นไปได้ตั้งแต่ 0% - 100% ดังแสดงในรูปกราฟต่อไปนี้


ผลด้านคุณค่า



คะแนน CRT

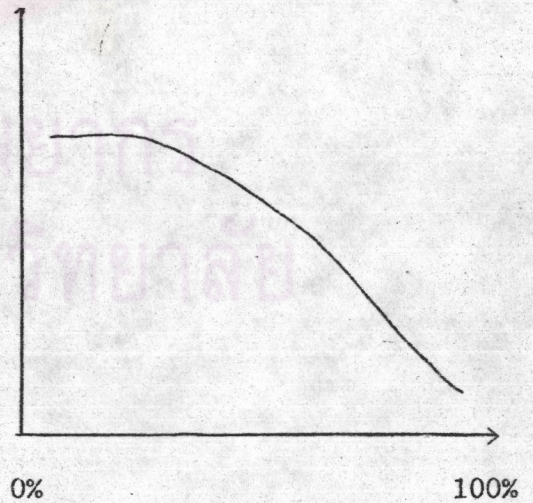
ถ้ากราฟมีลักษณะขึ้นทางเดียว (monotonic) คือไม่มีจุดโค้งกลับ คะแนนเกณฑ์จะเป็น 100% ถ้าเป็นเช่นนั้น ควรวัดผลคุณค่าด้านอื่น ๆ ที่สัมพันธ์กับคะแนนจากแบบสอบถามเชิงเกณฑ์มาประกอบการพิจารณา เช่น วัดความสนใจ หรือทัศนคติต่อวิชานั้น ๆ เมื่อรวมผลด้านคุณค่าทั้ง 2 ด้าน เข้ากันแล้ว ใช้ระดับคะแนนที่ให้ผลลัพธ์ทางค่ารวมสูงสุดเป็นคะแนนจุดตัด

คุณค่าด้านความรู้

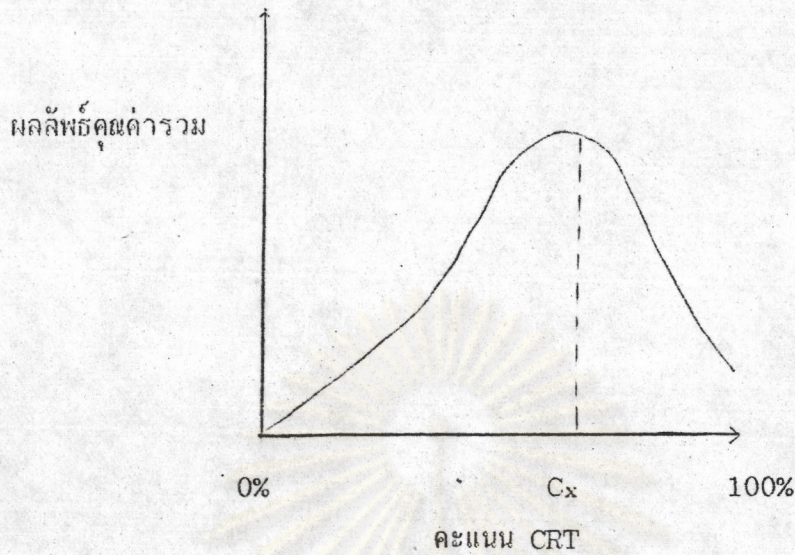


คะแนน CRT

คุณค่าด้านความรู้สึก



คะแนน CRT



การพิจารณาคุณค้ำรวม ควรมีการพิจารณากำหนดน้ำหนักของค่าการจำแนกผิดทางลบ (α) และค่าการจำแนกผิดทางบวก (β) แล้วแทนในสมการ

$$\text{ผลลัพธ์คุณค้ำรวม} = \alpha (\text{คุณค้ำด้านความรู้}) + \beta (\text{คุณค้ำด้านความรู้สึก})$$

วิธีการของแกลส (Decision Theoretic Approach) (Glass 1978 : 251-253) วิธีนี้อาศัยการทดลองสอบ และเกณฑ์ภายนอกได้แก่ นักเรียนที่ไม่ได้รับการเรียนการสอน กับนักเรียนที่ได้รับการเรียนการสอน โดยมีการสมมุติคะแนนจุดตัด C_x เพื่อจำแนกผู้สอบเป็นผ่านหรือไม่ผ่าน

คะแนนจุดตัดที่เหมาะสมจะทำให้เกิดการจำแนกผิดน้อยที่สุด นั่นคือ นักเรียนที่ไม่ได้รับการเรียนการสอนจะถูกตัดสินให้ผ่านมีจำนวนน้อยที่สุด และนักเรียนที่ได้รับการเรียนการสอนจะถูกตัดสินให้ตกหรือไม่ผ่าน มีจำนวนน้อยที่สุดด้วย คะแนนจุดตัดสามารถหาได้จากฟังก์ชันความสัมพันธ์ของคะแนนจุดตัดกับเกณฑ์ภายนอกที่มีค่าต่ำสุด ดังนี้

$$f(C_x) = (P_A + P_D) / (P_B + P_C)$$

- เมื่อ P_A แทนสัดส่วนจำนวนคนที่ได้รับการเรียนการสอน แต่ถูกตัดสินให้ไม่ผ่าน
 P_D แทนสัดส่วนจำนวนคนที่ไม่ได้รับการเรียนการสอนแต่ถูกตัดสินให้ผ่าน
 P_B แทนสัดส่วนจำนวนคนที่ไม่ได้รับการเรียนการสอนและไม่ผ่าน
 P_C แทนสัดส่วนจำนวนคนที่ได้รับการเรียนการสอนและผ่าน

เกณฑ์ภายนอก
ได้รับการเรียนการสอน ไม่ได้รับการเรียนการสอน

ไม่ผ่าน	P_A	P_B
C_x		
ผ่าน	P_C	P_D

วิธีการของเบย์ (Bayesian Decision Theoretic Procedure)

(Swaminathan, Hambleton & Algina 1975 : 87-98) วิธีนี้จะประมาณคะแนนโดเมนของผู้สอบจากคะแนนสอบ แล้วพิจารณาคะแนนจุดตัดโดยอาศัยฟังก์ชันการสูญเสียที่คาดหวังของการตัดสินใจให้ผ่านและไม่ผ่านที่ระดับคะแนนต่าง ๆ ความสูญเสียที่คาดหวังที่น้อยที่สุดจะเป็นตัวกำหนดคะแนนจุดตัด (π_0) โดยที่

1. ถ้าผู้สอบไม่รอบรู้แต่ตัดสินใจให้ผ่าน ความสูญเสียที่คาดหวัง
 $= l_{12} \text{ Prob} (\pi \leq \pi_0)$
2. ถ้าผู้สอบเป็นผู้รอบรู้แต่ตัดสินใจให้ตก ความสูญเสียที่คาดหวัง
 $= l_{21} \text{ Prob} (\pi \geq \pi_0)$

แต่ในสภาพความเป็นจริง ไม่มีโอกาสที่จะทราบได้ว่าการตัดสินใจถูกหรือผิด เพราะเราไม่สามารถหาค่าที่แท้จริงของผู้สอบแต่ละคน จึงถือเอาว่า

1. ให้ผู้สอบสอบผ่าน และถือเป็นผู้รอบรู้ ถ้า
 $= l_{21} \text{ Prob} (\pi \leq \pi_0) < l_{12} \text{ Prob} (\pi \geq \pi_0)$
2. ให้ผู้สอบสอบตก และถือเป็นผู้ไม่รอบรู้ ถ้า
 $= l_{21} \text{ Prob} (\pi > \pi_0) < l_{12} \text{ Prob} (\pi \leq \pi_0)$

2.3 วิธีการกำหนดจุดตัด โดยอาศัยดุลพินิจของผู้เชี่ยวชาญตัดสินใจกับการทดลองสอบ ผสมผสานกัน ดังเช่นวิธีต่อไปนี้

วิธีหาจุดสมดุลระหว่างเกณฑ์สัมบูรณ์และเกณฑ์สัมพัทธ์แบบที่ 1

(Absolute - relative compromise I) (Beuk 1984 : 147-152) วิธีการนี้ผู้เชี่ยวชาญต้องเสนอ เกณฑ์ 2 ประเภท คือ

1. เกณฑ์สัมบูรณ์ (k) อยู่ในรูปของเบอร์เซนต์ของข้อสอบที่น้อยที่สุด ที่ผู้สอบควรตอบได้ถูก
2. เกณฑ์สัมพัทธ์ (v) อยู่ในรูปของเบอร์เซนต์ของผู้สอบที่คาดว่าจะสอบผ่าน


ความสัมพันธ์ระหว่าง v และ k เขียนได้ดังนี้

$$v = (S_v/S_k) (k - \bar{k}) + \bar{v}$$

การปรับเกณฑ์ขึ้นอยู่กับอัตราส่วนของค่าเบี่ยงเบนมาตรฐานของเกณฑ์สัมพัทธ์ และ เกณฑ์สัมบูรณ์ (S_v/S_k)

นำแบบสอบไปทดสอบกับนักเรียน เพื่อหาความสัมพันธ์ระหว่างคะแนนสอบ (x) กับ เบอร์เซนต์ (y) ของผู้สอบที่จะเป็นผู้สอบได้ ถ้า x คือ คะแนนเกณฑ์ ซึ่งจะทำให้ y เป็น ฟังก์ชันที่ลดลงของ x

พล็อตกราฟของความสัมพันธ์ระหว่าง v กับ k และความสัมพันธ์ระหว่าง x กับ y เพื่อหาจุดสมดุล (i) ระหว่างเกณฑ์สัมบูรณ์และเกณฑ์สัมพัทธ์



วิธีหาจุดสมดุลระหว่างเกณฑ์สัมบูรณ์และเกณฑ์สัมพัทธ์แบบที่ 2

(Absolute - relative compromise II) (Hofstee cited by Gruijter 1985 : 263-269.) ผู้ตัดสินต้องกำหนดค่า 4 ค่า คือ

1. เปอร์เซนต์ของข้อสอบที่มากที่สุดที่ผู้สอบควรตอบได้ถูก (K_{max})
2. เปอร์เซนต์ของข้อสอบที่น้อยที่สุดที่ผู้สอบควรตอบได้ถูก (K_{min})
3. เปอร์เซนต์ของผู้สอบตกที่มากที่สุดที่ยอมรับได้ (f_{max})
4. เปอร์เซนต์ของผู้สอบตกที่น้อยที่สุดที่ยอมรับได้ (f_{min})

ใช้โครงการแจกแจงสะสมของคะแนนสอบ และความสัมพันธ์ระหว่าง k และ f เพื่อกำหนดจุดสมดุล

คะแนนเกณฑ์ คือ จุดที่ตัดกันระหว่างค่าที่กำหนดข้างต้น กับโครงการแจกแจงสะสมของคะแนนสอบ

วิธี Angoff - contrasting groups plus composite

(Shepard, cited by Berk 1986 : 159) วิธีนี้ใช้การพิจารณา 4 อย่าง คือ

1. ใช้วิธีหาคะแนนจุดตัดโดยการตัดสินของผู้เชี่ยวชาญ เช่นวิธีของแองกอฟ
2. ใช้วิธีหาคะแนนจุดตัดโดยการทดสอบ เช่นวิธีการเปรียบเทียบระหว่างกลุ่มผู้สอบ
3. ทำการตัดสินประมาณอัตราการสอบผ่านที่ยอมรับได้
4. ปรับแก้ความไม่เที่ยงของคะแนนจุดตัด

คะแนนเกณฑ์ จะได้จากการปรับความแตกต่างที่เกิดขึ้นจากทั้ง 4 ข้อ เข้าหากัน

วิธีการใช้ดุลพินิจตัดสินโดยอาศัยสารสนเทศประกอบ

(Informed judgment) (Popham & Yalow, cited by Berk 1986 : 156) วิธีนี้ผู้ตัดสินกำหนดเกณฑ์โดยอาศัยสารสนเทศ 2 อย่าง คือ

1. ผลการทดสอบของนักเรียน เช่น ค่าความยาก ค่าอำนาจจำแนกของข้อสอบและค่าเฉลี่ยของคะแนนสอบ
2. ให้ผู้ที่เกี่ยวข้อง เช่น ครู ผู้บริหารโรงเรียน ศาสตราจารย์ในวิทยาลัย และคณะกรรมการของโรงเรียน เป็นข้อเสนอเกณฑ์ของแบบสอบ

ผู้ตัดสินจะอาศัยสารสนเทศข้างต้น แล้วตัดสินเกณฑ์ของแบบสอบคะแนนเกณฑ์ของแบบสอบได้มาจาก การตัดสินที่สอดคล้องกันของกลุ่มผู้ตัดสินนี้

วิธี Iterative Angoff (Saunders & Mappus, cited by berk 1986 : 157) ในรอบแรกจะให้ผู้ตัดสินประมาณความน่าจะเป็นในการตอบข้อสอบถูกต้องแล้วอนุญาตให้ผู้ตัดสินเปลี่ยนแปลงการตัดสินได้ 3 ครั้ง คือ

1. ภายหลังจากได้ทราบผลการตัดสินของผู้ตัดสินคนอื่น ๆ
2. ภายหลังจากได้ทราบการแจกแจงของคะแนนสอบของผู้สอบทั้งหมด
3. ภายหลังจากได้ทราบผลการตัดสินในขั้นที่ 2 ของผู้ตัดสินทั้งหมดในรูปของสถิติ

ภาคบรรยาย

เกณฑ์ จะถูกกำหนดโดยความสอดคล้องของการตัดสินของผู้ตัดสินทุกคน

วิธี Iterative two - choice Angoff (Gross, Impara, Frary, and Jaeger 1984 : 113-129) ขอร้องให้ผู้ตัดสินตอบคำถามว่า "ผู้สำเร็จการศึกษาชั้นเตรียมอุดมทุกคนสามารถตอบข้อสอบข้อนี้ได้อย่างถูกต้องใช่หรือไม่" ผู้ตัดสินจะต้องตอบคำถามนี้ใน 3 สถานการณ์ คือ

1. ไม่มีสารสนเทศใด ๆ ประกอบการตัดสิน
2. มีสารสนเทศเกี่ยวกับการแจกแจงความถี่สะสมของเกณฑ์ที่ได้จากการตัดสินในสถานการณ์ที่ 1
3. มีสารสนเทศเกี่ยวกับค่าความยากของข้อสอบที่ได้จากการทดลองสอบ

เกณฑ์หาได้จากค่ามัธยฐานของเกณฑ์ของผู้ตัดสินทุกคนที่ตัดสินเกณฑ์ใน 3 สถานการณ์

วิธี Modified Angoff - empirical (McLean & Halpin, cited by berk 1986 : 156) เป็นวิธีที่ให้ผู้ตัดสินประมาณ "ความน่าจะเป็น" สำหรับแต่ละความสามารถโดยรอบแรกจะให้ผู้ตัดสินประมาณความน่าจะเป็น และรอบที่สองจะให้ค่าเฉลี่ยของความยากของข้อสอบทั้งฉบับ เกณฑ์ของแบบสอบหาได้จากค่าเฉลี่ยของผลบวกของความน่าจะเป็นที่ได้จากการตัดสินในรอบที่สอง

เกณฑ์ในการประเมินวิธีกำหนดคะแนนจุดตัด

เบอร์ค (Berk 1986 : 140-145) ได้เสนอเกณฑ์ในการประเมินวิธีกำหนดจุดตัดที่มีมากมายหลายวิธี โดยใช้เกณฑ์ 2 อย่าง คือ

1. เกณฑ์เกี่ยวกับวิธีดำเนินการ ประกอบด้วย 6 ข้อ คือ

1.1 เป็นวิธีที่ให้จุดตัดที่เหมาะสม โดยปกติจะใช้จุดตัดในการแบ่งประเภทผู้สอบออกเป็น ผ่าน-ไม่ผ่าน มีความสามารถ-ไม่มีความสามารถ แต่บางครั้งอาจจำเป็นต้องใช้จุดตัด 2 จุด เช่นในการสอบแบบรายบุคคล (Adaptive testing) ซึ่งพิสัยระหว่างคะแนนจุดตัด 2 จุด นี้จะไม่สามารถตัดสินได้ว่า ผู้สอบ ครอบรู้ หรือไม่ครอบรู้

1.2 เป็นวิธีที่คำนึงถึงความสามารถของผู้สอบ และคุณภาพของข้อสอบ เช่น ค่าความยาก และค่าอำนาจจำแนกของข้อสอบ ถ้าแบบสอบประกอบด้วยข้อสอบที่มีค่าความยากเท่ากับ .3 ถึง .5 เป็นจำนวนมาก วิธีกำหนดจุดตัดที่ให้คะแนนจุดตัดมีค่าสูง จะเป็นจุดตัดที่ไม่เหมาะสมกับผู้สอบ

1.3 เป็นวิธีที่สอดคล้องกับการเรียนการสอน ถ้าแบบสอบวัดไม่ตรงกับวัตถุประสงค์การเรียนการสอนแล้ว คะแนนจุดตัดที่ได้ก็จะไม่มีความตรง หรือไม่เหมาะสม

1.4 เป็นวิธีที่ใช้สถิติซึ่งเหมาะสมและถูกต้อง เช่นในการคำนวณคะแนนจุดตัดที่ได้จากการตัดสินของผู้เชี่ยวชาญ โดยการคิดเป็นเปอร์เซ็นต์ การวัดแนวโน้มเข้าสู่ส่วนกลาง เป็นต้น

1.5 เป็นวิธีที่ให้คะแนนจุดตัดบนสเกลของคะแนนจริง แต่วิธีกำหนดจุดตัดส่วนใหญ่ จะหาคะแนนจุดตัดจากการแจกแจงของคะแนนสอบ และตรวจสอบความคลาดเคลื่อนของการวัด

1.6 ควรเป็นวิธีที่สามารถแสดงความตรงของการจำแนกผู้สอบออกเป็น ผู้ครอบรู้ และผู้ไม่ครอบรู้ ด้วยคะแนนจุดตัด

2. เกณฑ์เกี่ยวกับการนำมาปฏิบัติได้จริง ประกอบด้วย 4 ข้อ คือ

2.1 เป็นวิธีที่เข้าใจง่าย ปฏิบัติได้ง่าย มีขั้นตอนการปฏิบัติที่ไม่ยุ่งยากซับซ้อน ไม่เสียเวลา และเป็นระบบ

2.2 เป็นวิธีที่มีการคำนวณไม่ยุ่งยาก หรือสามารถใช้โปรแกรมสำเร็จรูปได้

2.3 เป็นวิธีที่สามารถอธิบายให้คนอื่น ๆ ที่เกี่ยวข้อง เช่น นักเรียน ผู้ปกครอง ครู ผู้บริหารโรงเรียน สามารถเข้าใจได้โดยง่าย

2.4 เป็นวิธีที่น่าเชื่อถือ วิธีที่ใช้สถิติที่ยุ่งยากซับซ้อน ไม่จำเป็นต้องเป็นวิธีที่น่าเชื่อถือเสมอไป บางครั้งอาจทำให้สับสนได้มากกว่าวิธีที่ใช้การคำนวณง่าย ๆ

และเบอร์ก (Berk 1986 : 154-155) ได้ใช้เกณฑ์การประเมินวิธีกำหนดจุดตัดดังกล่าวข้างต้น 10 ข้อ ซึ่งแบ่งออกเป็นเกณฑ์การประเมินวิธีดำเนินการ 6 ข้อ และเกณฑ์การประเมินการนำมาปฏิบัติได้จริง 4 ข้อ ทำการประเมินวิธีกำหนดจุดตัดวิธีต่าง ๆ 23 วิธี ยกเว้นเฉพาะวิธีกำหนดจุดตัดที่ใช้ข้อมูลการทดสอบประมาณความคลาดเคลื่อน ในการจำแนกผู้สอบออกเป็นผู้รอบรู้ไม่จริง และผู้ไม่รอบรู้ไม่จริง ซึ่งเป็นวิธีที่ยุ่งยากซับซ้อนและนำมาปฏิบัติได้ยากแล้วสรุปผลการประเมินได้ดังแสดงในตารางที่ 1

ตารางที่ 1 ผลการประเมินวิธีกำหนดจุดตัด 23 วิธี

วิธีกำหนดจุดตัด	การประเมิน										ค่าเฉลี่ย การประเมิน	
	วิธีดำเนินการ											
	1	2	3	4	5	6	7	8	9	10		
1. วิธีที่ใช้ดุลพินิจของผู้เชี่ยวชาญตัดสิน												
1.1 วิธี Adjusted/modified M-C Angoff	++	--	-	+	+	--	++	-	++	++		+
1.2 วิธีแองกอฟ (Angoff)	++	--	-	++	++	--	+	++	++	++		+
1.3 วิธี Angoff - Nedelsky combination	++	--	-	+	+	--	--	-	-	+		-
1.4 วิธี Difficulty - importance estimate	++	--	-	++	--	--	-	+	+	+		-
1.5 วิธีอีเบล (Ebel)	++	--	-	-	++	--	-	+	-	-		-
1.6 วิธี Difficulty - taxonomy Ebel	++	+	-	-	-	--	-	+	-	-		-

ตารางที่ 1 (ต่อ)

วิธีกำหนดจุดตัด	การประเมิน										ค่าเฉลี่ย การประเมิน
	วิธีดำเนินการ					การนำมาปฏิบัติ					
	1	2	3	4	5	6	7	8	9	10	
1.7 วิธี Item specifications	++	--	-	-	--	--	+	+	+	+	-
1.8 วิธี Modified M-C Angoff	++	--	-	-	-	--	++	++	++	++	+
1.9 วิธีเนเดลสกี (Nedelsky)	++	--	-	-	++	--	-	-	-	+	-
1.10 วิธี Relevance - taxonomy Ebel	++	--	--	-	-	--	-	+	-	-	-
1.11 วิธี Two - Choice Angoff	++	--	-	-	-	--	++	+	+	+	--
2. วิธีที่อาศัยการทดลองสอบ											
2.1 วิธีสอบกับเด็กคาบเส้น (Borderline group)	++	++	+	+	-	--	+	+	+	-	+
2.2 วิธีการเปรียบเทียบระหว่าง กลุ่มผู้สอบ (Contrasting groups)	++	++	++	+	+	++	-	+	+	-	+
2.3 วิธีใช้เกณฑ์ภายนอก (Criterion groups)	++	++	++	+	-	++	-	+	+	-	+
2.4 วิธีพิจารณาผลทางการศึกษาที่ ตามมา (Educational consequences)	++	++	++	--	--	--	+	+	-	-	--
2.5 วิธีใช้ผลการสอบของคนอื่น ๆ เป็นเกณฑ์ (Norm - referenced criterion)	++	++	-	-	--	-	+	+	-	-	--

ตารางที่ 1 (ต่อ)

วิธีกำหนดจุดตัด	การประเมิน										ค่าเฉลี่ย การประเมิน	
	วิธีดำเนินการ					การนำมาปฏิบัติ						
	1	2	3	4	5	6	7	8	9	10		
3. วิธีที่ใช้ดุลพินิจของผู้เชี่ยวชาญ โดยมีข้อมูลการทดสอบ												
3.1 วิธีทางจุดสมดุลระหว่างเกณฑ์ สัมบูรณ์และเกณฑ์สัมพัทธ์แบบที่ 1 (Absolute - relative compromise I)	++	+	+	++	+	--	-	--	-	-	-	-+
3.2 วิธีทางจุดสมดุลระหว่างเกณฑ์ สัมบูรณ์และเกณฑ์สัมพัทธ์แบบที่ 2 (Absolute - relative compromise II)	++	+	+	++	+	--	--	--	-	-	-	-+
3.3 วิธี Angoff-contrasting groups plus composite	++	++	+	+	+	++	--	--	+	+	+	+
3.4 วิธีการใช้ดุลพินิจตัดสินโดย อาศัยสารสนเทศประกอบ (Informed judgment)	++	+	+	++	++	--	+	++	++	++	++	+ / ++
3.5 วิธี Iterative Angoff	++	+	+	+	++	--	--	++	+	++	++	+
3.6 วิธี Iterative two - choice Angoff	++	+	+	+	+	--	--	-	+	++	++	+
3.7 วิธี Modified Angoff - empirical	++	+	-	-	--	--	+	+	++	++	++	+

หมายเหตุ : -- คือ ไม่ต่ออย่างย้ง
- คือ ไม่ดี
+ คือ ดี
++ คือ ดีอย่างย้ง

ผลการประเมินวิธีกำหนดจุดตัดทั้งหมด 23 วิธี ของเบอร์ก ปรากฏว่า

1. วิธีกำหนดจุดตัดที่ใช้คุณลักษณะของผู้เชี่ยวชาญตัดสินทั้ง 11 วิธี เป็นวิธีที่ไม่มีหลักการที่ชัดเจน มักเป็นไปตามอำเภอใจมากกว่า แต่ก็พบว่าวิธีของแองกอฟเป็นวิธีที่เหมาะสมที่สุด มีความสมคัลย์ทั้งวิธีการและการนำไปปฏิบัติ
2. วิธีกำหนดจุดตัดที่อาศัยการทดลองสอบ ภายใน 5 วิธีนี้ พบว่าวิธีใช้การเปรียบเทียบระหว่างกลุ่มผู้สอบ เป็นวิธีที่น่าเชื่อถือที่สุด นอกจากนี้ยังมีวิธีการที่น่าเชื่อถือที่สุดในวิธีกำหนดจุดตัดทั้งหมด 23 วิธีนี้ด้วย
3. วิธีกำหนดจุดตัดที่อาศัยการใช้คุณลักษณะของผู้เชี่ยวชาญตัดสินกับการทดลองสอบร่วมกัน ภายใน 7 วิธีนี้ พบว่าวิธีการใช้คุณลักษณะตัดสิน โดยอาศัยสารสนเทศประกอบเป็นวิธีที่น่าเชื่อถือที่สุด และยังเป็นวิธีที่น่าเชื่อถือที่สุดในวิธีกำหนดจุดตัดทั้งหมด 23 วิธีนี้ด้วย

ตอนที่ 2 ทฤษฎีการตอบสนองข้อสอบ (Item Response Theory)

หลักการของทฤษฎีการตอบสนองข้อสอบ คือ

- 1 สามารถทำนายผลการสอบของนักเรียนได้โดยคุณลักษณะแฝงที่อยู่ภายในตัวบุคคล หรือที่เรียกว่าความสามารถ
- 2 ความสัมพันธ์ระหว่างการตอบข้อสอบกับความสามารถที่อยู่ภายในตัวผู้สอบมีอิทธิพลกับผลการตอบข้อสอบได้ถูก อธิบายได้ด้วยฟังก์ชันลักษณะข้อสอบ (Item Characteristic function) ซึ่งแสดงให้เห็นว่าผู้สอบที่มีความสามารถสูงกว่าจะมีโอกาสตอบข้อสอบได้ถูกสูงกว่าผู้ที่มีความสามารถต่ำกว่า (Hambleton 1985 : 13-14)

ข้อตกลงเบื้องต้นของทฤษฎีการตอบข้อสอบ

1. มิติของคุณลักษณะแฝงที่อยู่ภายในหรือความสามารถของผู้สอบที่ใช้ในการตอบข้อสอบในแบบสอบฉบับหนึ่งต้องมีมิติเดียว คือ ข้อสอบแต่ละข้อในแบบสอบจะวัดความสามารถเดียวกัน (Unidimensional)
2. ข้อสอบแต่ละข้อเป็นอิสระกัน (Local Independence) คือ การตอบข้อสอบแต่ละข้อของผู้สอบเป็นอิสระกัน
3. โค้งลักษณะข้อสอบ (Item Characteristic Curve) เป็นฟังก์ชันทางคณิตศาสตร์ ที่แสดงถึงความสัมพันธ์ระหว่างโอกาสในการตอบข้อสอบข้อนั้น ได้ถูกต้องกับระดับความสามารถที่วัดได้โดยชุดของข้อสอบหรือแบบสอบนั้น ถ้าแบบสอบนั้นวัดความสามารถเดียวแล้วโค้งลักษณะข้อสอบจะไม่แปรเปลี่ยนไปตามกลุ่มประชากรผู้สอบ นั่นคือโอกาสในการตอบข้อสอบได้ถูก

ของผู้สอบคนหนึ่งขึ้นอยู่กับโด่งลักษณะข้อสอบนั้น และไม่ขึ้นกับประชากรผู้สอบ โด่งลักษณะข้อสอบมีอยู่ 4 รูปแบบ ตามรูปแบบการตอบสนองข้อสอบ (Item Response Model) โดยที่จำนวนของพารามิเตอร์ที่ใช้อธิบายโด่งลักษณะข้อสอบ จะขึ้นกับรูปแบบการตอบสนองข้อสอบ (Hambleton 1985 : 15-31)

รูปแบบการตอบสนองข้อสอบ (Item Response Model)

รูปแบบทางคณิตศาสตร์ที่ใช้ในการวิเคราะห์ข้อสอบ อาศัยฟังก์ชันการกระจายรูปแบบโลจิสติก (logistic distribution function) ซึ่งแบ่งออกเป็น 4 รูปแบบ ตามจำนวนพารามิเตอร์ของโด่งลักษณะข้อสอบ

1. รูปแบบโลจิสติกที่มี 1 พารามิเตอร์ (One-Parameter Logistic Model)
รูปแบบนี้ถือว่าข้อสอบทุกข้อมีค่าอำนาจจำแนกเท่ากัน ($a_i = 1.00$) และไม่มีค่าการเดา ($c_i = 0$) ค่าหนึ่งถึงเฉพาะค่าความยากของข้อสอบ (b_i) ดังสมการ

$$P_i(\theta) = \frac{e^{D(\theta - b_i)}}{1 + e^{D(\theta - b_i)}} \quad (i = 1, 2, \dots, n)$$

เมื่อ $P_i(\theta)$ คือ ความน่าจะเป็นที่ผู้สอบซึ่งมีระดับความสามารถ θ จะตอบข้อสอบข้อ i ได้ถูก

b_i คือ ค่าความยากของข้อสอบข้อ i ที่แสดงถึงระดับความสามารถที่จุดโด่งลักษณะข้อสอบมีความชันที่สุด ในทางปฏิบัติจะมีค่าอยู่ระหว่าง -2 ถึง $+2$

D คือ ค่า Scaling factor = 1.7

2. รูปแบบโลจิสติกที่มี 2 พารามิเตอร์ (Two-Parameter Logistic Model)
รูปแบบนี้ถือว่าข้อสอบทุกข้อไม่มีค่าการเดา ค่าหนึ่งถึงค่าความยากและค่าอำนาจจำแนกของข้อสอบเท่านั้น ดังสมการ

$$P_i(\theta) = \frac{e^{Da_i(\theta - b_i)}}{1 + e^{Da_i(\theta - b_i)}} \quad (i = 1, 2, \dots, n)$$

เมื่อ a_i คือ ค่าอำนาจจำแนกของข้อสอบข้อ i ที่เป็นสัดส่วนโดยตรงกับความชันของโค้งลักษณะข้อสอบ ซึ่งมีค่าได้ตั้งแต่ $-\infty$ ถึง $+\infty$ แต่ในทางปฏิบัติจะใช้ค่าอยู่ระหว่าง 0 ถึง 2

3. รูปแบบโลจิสติกที่มี 3 พารามิเตอร์ (Three-Parameter Logistic Model) รูปแบบนี้คำนึงถึงค่าความยาก ค่าอำนาจจำแนกและค่าการเดาของข้อสอบ ดังสมการ

$$P_i(\theta) = c_i + (1 - c_i) \frac{e^{Da_i(\theta - b_i)}}{1 + e^{Da_i(\theta - b_i)}} \quad (i = 1, 2, \dots, n)$$

เมื่อ c_i คือ ความน่าจะเป็นที่ผู้สอบซึ่งมีความสามารถต่ำมากจะตอบข้อสอบข้อ i ได้ถูก ในทางปฏิบัติจะเลือกข้อสอบที่มีค่าการเดา ≤ 0.3

4. รูปแบบโลจิสติกที่มี 4 พารามิเตอร์ (Four-Parameter Logistic Model) รูปแบบนี้คำนึงถึงความสะเพร่าในการตอบข้อสอบด้วย นอกเหนือจาก 3 พารามิเตอร์ที่กล่าวมาแล้ว ดังสมการ

$$P_i(\theta) = c_i(r_i - c_i) \frac{e^{Da_i(\theta - b_i)}}{1 + c_i^{Da_i(\theta - b_i)}} \quad (i = 1, 2, \dots, n)$$

เมื่อ r_i คือ ค่าความรอบคอบของข้อสอบข้อ i ซึ่งมีค่าน้อยกว่า 1

แต่รูปแบบนี้ยังไม่สามารถนำมาใช้ในทางปฏิบัติได้

คุณสมบัติของคะแนนความสามารถ

การประมาณคะแนนความสามารถ (θ) ด้วยค่า $\hat{\theta}$ เมื่อรู้ค่าพารามิเตอร์ของข้อสอบ โดยการใช้วิธีการประมาณค่าความเป็นไปได้สูงสุด (Maximum likelihood estimation) ซึ่งค่าที่ประมาณได้จะมีคุณสมบัติ ดังนี้

1. มีความคงเส้นคงวา (Consistent) คือ เมื่อขนาดของกลุ่มตัวอย่างและจำนวนข้อสอบเพิ่มขึ้น การประมาณค่าจะเข้าใกล้ค่าที่แท้จริง

2. เป็นค่าสถิติที่เพียงพอ (Sufficient) คือ มีข้อมูลทั้งหมดที่เกี่ยวกับค่าพารามิเตอร์ โดยไม่จำเป็นต้องอาศัยข้อมูลอื่น ๆ อีก
3. มีประสิทธิภาพ (Efficient) คือ การประมาณค่าด้วยวิธีนี้จะมีความแปรปรวนน้อยที่สุด
4. การกระจายของค่าสถิติเข้าใกล้การกระจายแบบปกติ (Normally distributed) โดยมีค่าเฉลี่ยเท่ากับ 0 และความแปรปรวนเท่ากับ $[I(\theta)]^{-1}$ เมื่อ $I(\theta)$ คือ ฟังก์ชันสารสนเทศแบบสอบ (test information function) ซึ่งมีสมการ ดังนี้

$$I(\theta) = -E[\partial^2 \ln L / \partial \theta^2] = \sum_{i=1}^n P_i^2 / P_i Q_i$$

เมื่อ E คือ ค่าคาดหวัง
 P_i คือ อนุพันธ์ของฟังก์ชันการตอบข้อสอบ ข้อ i ณ ระดับความสามารถ
 Q_i คือ $1 - P_i$
 และ ความแปรปรวนของ $\hat{\theta}$ เขียนเป็นสมการได้ดังนี้

$$\text{Var}(\hat{\theta} / \theta) = [I(\theta)]^{-1}$$

โดยที่ $\hat{\theta}$ เป็นค่าสถิติที่เชื่อถือได้ เราจึงแทน θ ด้วย $\hat{\theta}$ ได้

เบอร์นบอม (Birnbbaum 1968 : 457) ได้แสดงขอบเขตความเชื่อมั่นของการประมาณค่า θ (maximum likelihood confidence limit estimator) โดยมีช่วงความเชื่อมั่น $(1 - \alpha)$ ดังนี้

$$\hat{\theta} - z_{\frac{\alpha}{2}} [I(\hat{\theta})]^{-\frac{1}{2}} \leq \theta \leq \hat{\theta} + z_{\frac{\alpha}{2}} [I(\hat{\theta})]^{-\frac{1}{2}}$$

ทำให้ได้ว่า $[I(\hat{\theta})]^{-\frac{1}{2}}$ คือ ความคลาดเคลื่อนมาตรฐานของการประมาณค่า θ ด้วยวิธีความเป็นไปได้สูงสุดที่เขียนเป็นสมการได้ ดังนี้ (Hambleton 1985 : 88-90)

$$\text{SE}(\theta) = \frac{1}{\sqrt{I(\theta)}}$$

ฟังก์ชันสารสนเทศแบบสอบหาได้จากผลรวมของฟังก์ชันสารสนเทศข้อสอบ ($I(\theta, u_i)$) แต่ละข้อในแบบสอบซึ่งเขียนเป็นสมการได้ดังนี้

$$I(\theta, u_i) = (P_i)^2 / P_i Q_i$$

ฟังก์ชันสารสนเทศข้อสอบจะขึ้นอยู่กับความชันของฟังก์ชันการตอบข้อสอบ และความแปรปรวนที่แต่ละระดับความสามารถ (θ) ค่าสารสนเทศจะสูงขึ้นเมื่อความชันสูงขึ้น และความแปรปรวนน้อยลง และจะทำให้ความคลาดเคลื่อนมาตรฐานของการวัดมีค่าน้อยลง

ความสัมพันธ์ของคะแนนความสามารถ (θ) กับคะแนนโดเมน (π)

ถ้านำแบบสอบ 2 ชุด ที่วัดความสามารถเดียวกันไปดำเนินการสอบกับผู้สอบกลุ่มหนึ่ง และแบบสอบทั้ง 2 ชุด นั้นไม่ได้ขนานกันอย่างแท้จริง จะได้ผลการแจกแจงของคะแนนสอบที่ต่างกัน 2 ชุด ความแตกต่างของการแจกแจงคะแนน 2 ชุด นี้ขึ้นอยู่กับความแตกต่างของความยากของแบบสอบ 2 ฉบับ นั้นจึงไม่อาจบอกได้ว่าการแจกแจงหนึ่งดีกว่าอีกการแจกแจงหนึ่ง การแจกแจงของคะแนนสอบไม่ได้ให้ข้อมูลเกี่ยวกับการแจกแจงของคะแนนความสามารถเพราะคะแนนดิบจากแบบสอบแต่ละฉบับไม่เท่ากันและต่างกัน โดยที่สเกลความสามารถ คือ สเกลอันหนึ่ง ซึ่งผู้สอบคนหนึ่งจะมีคะแนนความสามารถเท่ากัน บนแบบสอบที่ไม่ขนานกันเหล่านั้น ดังนั้น ถึงแม้ว่าคะแนนของผู้สอบคนหนึ่งจะเปลี่ยนแปลงไปตามแบบสอบที่ไม่ขนานกัน แต่คะแนนความสามารถสำหรับผู้สอบคนหนึ่งจะเป็นอย่างเดียวกันบนแบบสอบแต่ละฉบับนั้น

มโนทัศน์ของคะแนนจริง หรือคะแนนโดเมน เป็นสิ่งสำคัญพื้นฐานในทฤษฎีคลาสสิกอล (Classical test theory) โดยถูกกำหนดให้เป็นคะแนนคาดหวังบนเซตของข้อสอบ ของผู้สอบคนหนึ่ง

ถ้าให้ x = คะแนนที่สังเกตได้
 t = คะแนนจริง

แล้วให้ $t = E(x)$

ความสัมพันธ์ของคะแนนจริง หรือคะแนนโดเมน กับคะแนนความสามารถ θ หาได้ดังนี้

ถ้าให้ r = คะแนนที่สังเกตได้
 n = จำนวนข้อสอบทั้งหมด

แล้วให้ $r = \sum_{i=1}^n U_i$

เมื่อ U_i = ค่าตอบของข้อสอบข้อ i ซึ่งถ้าตอบถูกจะเป็น 1 ถ้าตอบผิดจะเป็น 0

และถ้าให้ π = คะแนนโตนเมน

$\hat{\pi}$ = สัดส่วนของคะแนนถูก

$$\text{แล้วจะได้ } \hat{\pi} = \frac{1}{n} \sum_{i=1}^n U_i$$

จากมโนทัศน์ของคะแนนจริงได้ว่า $E(\hat{\pi}) = \pi$

$$\text{ดังนั้นจึงได้ว่า } E(\hat{\pi}) = \pi = \frac{1}{n} \sum_{i=1}^n E(U_i)$$

และที่ระดับความสามารถ θ ทำให้

$$\hat{\pi}/\theta = \frac{1}{n} \sum_{i=1}^n (U_i/\theta)$$

$$\begin{aligned} E(\hat{\pi}/\theta) &= \pi/\theta \\ &= \frac{1}{n} \sum_{i=1}^n E(U_i/\theta) \end{aligned}$$

ซึ่ง U_i เป็นตัวแปรเชิงสุ่มที่มีค่า 0 หรือ 1

$$\begin{aligned} \text{ดังนั้นทำให้ } E(U_i/\theta) &= (U_i=1) P_i(U_i=1/\theta) + (U_i=0) P_i(U_i=0/\theta) \\ &= 1 \cdot P_i(U_i=1/\theta) + 0 \cdot P_i(U_i=0/\theta) \\ &= P_i(U_i=1/\theta) \\ &= P_i(\theta) \end{aligned}$$

$$\text{ทำให้ได้ว่า } \pi/\theta = \frac{1}{n} \sum_{i=1}^n P_i(\theta)$$

ฟังก์ชันนี้คือค่าเฉลี่ยของฟังก์ชันการตอบข้อสอบ (Item response function) ของข้อสอบ n ข้อ เรียกว่า ฟังก์ชันลักษณะแบบสอบ (Test Characteristic Function) ถ้านำไปพลอตกราฟ จะได้โค้งลักษณะแบบสอบ (Test Characteristic Curve) และความแปรปรวนสามารถแทนได้ด้วย

$$\text{Var}(\hat{\pi}/\theta) = \text{Var} \left\{ \frac{1}{n} \sum_{i=1}^n (U_i/\theta) \right\}$$

จากข้อตกลงเบื้องต้นของความเป็นอิสระของข้อสอบ จะได้ว่า

$$\text{Var} \frac{1}{n} \sum_{i=1}^n (U_i/\theta) = \frac{1}{n^2} \sum_{i=1}^n \text{Var} (U_i/\theta)$$

เนื่องจาก U_i/θ เป็น binomial variable

$$\text{Var}(U_i/\theta) = P_i(\theta) Q_i(\theta)$$

ดังนั้น

$$\text{Var} \frac{1}{n} (U_i/\theta) = \frac{1}{n^2} P_i(\theta) Q_i(\theta)$$

จึงได้ว่า

$$\text{Var}(\hat{\pi}/\theta) = \frac{1}{n^2} \sum_{i=1}^n P_i(\theta) Q_i(\theta)$$

เมื่อแบบสอบยาวขึ้น โดยการเพิ่มจำนวนข้อสอบที่ขนานกันเข้าไปจนกระทั่ง $n \rightarrow \infty$ แล้วจะทำให้ $\hat{\pi}/\theta \rightarrow \pi$ และ $\text{Var}(\hat{\pi}/\theta) \rightarrow 0$ ดังนั้นจึงกล่าวได้ว่า $\hat{\pi}$ เป็นตัวประมาณค่าที่คงเส้นคงวาของ π (คะแนนโดเมน)

สรุปได้ว่า คะแนนโดเมน (π) และคะแนนความสามารถ (θ) มีความสัมพันธ์กันแบบขึ้นทางเดียว (monotonically) ความสัมพันธ์หาได้โดยฟังก์ชันลักษณะแบบสอบ คะแนนโดเมนและคะแนนความสามารถมีมีโนทัศน์เหมือนกัน แต่สเกลการวัดแตกต่างกัน คือ คะแนนโดเมนจะอยู่ในช่วง $(0, 1)$ ขณะที่คะแนนความสามารถจะอยู่ในช่วง $(-\infty, \infty)$ และที่สำคัญที่สุดคือสเกลของความสามารถเป็นอิสระจากข้อสอบ แต่สเกลของคะแนนโดเมนขึ้นกับข้อสอบที่ใช้

ดังนั้นเมื่อรู้ค่าพารามิเตอร์ (ค่าความยาก ค่าอำนาจจำแนก ค่าการเดา) ของข้อสอบทั้งหมดในโดเมน หรือของกลุ่มตัวแทนของข้อสอบชุดหนึ่งในโดเมนนั้น แล้วสามารถหาความสัมพันธ์ระหว่างคะแนนโดเมน กับคะแนนความสามารถได้ โดยที่คะแนนโดเมนจะหมายถึงคะแนนที่คาดหวังที่ได้จากข้อสอบทั้งหมดในโดเมนนั้น แต่เมื่อใช้กลุ่มตัวอย่างของข้อสอบที่มีความเป็นตัวแทนของข้อสอบทั้งหมดในโดเมนนั้น ก็จะสามารถประมาณความสัมพันธ์ระหว่าง π และ θ ได้โดย

$$\pi = \frac{1}{m} \sum_{i=1}^m P_i(\theta)$$

เมื่อ m = จำนวนข้อสอบในแบบสอบ

โดยทั่วไปจะกำหนดคะแนนจุดตัดบนสเกลของคะแนนโดเมน (π_0) และสามารถแปลงให้อยู่ในสเกลของคะแนนความสามารถ (θ_0) ด้วยสมการข้างต้น (Hambleton 1985 : 260)

แบบสอบอิงเกณฑ์กับทฤษฎีการตอบข้อสอบ

แฮมเบิลตัน (Hambleton 198. : 33-34) ได้ศึกษาเปรียบเทียบการใช้รูปแบบโลจิสติกที่มี 1, 2 และ 3 พารามิเตอร์ กับแบบสอบอิงเกณฑ์ในการประมาณคะแนนโดเมนและการตัดสินใจให้ผู้สอบเป็นผู้รอบรู้ หรือผู้ไม่รอบรู้ เพื่อเปรียบเทียบว่ารูปแบบใดจะให้คะแนนโดเมนที่มีความคงเส้นคงวากว่า (consistent) หากการศึกษาโดยสร้างข้อมูล θ ต่าง ๆ ของผู้สอบด้วยเหตุการณ์จำลอง (simulate) จำนวน 2,000 คน ที่มีค่าเฉลี่ยเท่ากับ 0 และค่าเบี่ยงเบนมาตรฐานเท่ากับ 1 จากการตอบข้อสอบจำนวน 40 ข้อ แล้วแปลงระดับความสามารถ (θ) ให้เป็นคะแนนโดเมน (π) โดยอาศัยโค้งลักษณะแบบสอบ ดังสมการ

$$\pi_i = \frac{1}{n} \sum_{g=1}^n P_g(\theta_i) \quad (1)$$

เมื่อ $P_g(\theta_i)$ คือ ความน่าจะเป็นที่ผู้สอบ i ที่มีระดับความสามารถ θ จะตอบข้อสอบ g ได้ถูก

n คือ จำนวนข้อสอบในแบบสอบ

π_i คือ คะแนนโดเมนของผู้สอบคนที่ i บนแบบสอบ

หากการศึกษาแบบสอบที่มีความยาวต่าง ๆ คือ 10, 15, 20 และ 40 ข้อ และที่คะแนนจุดตัด 3 จุด คือ $0_0 = -1.50, 0$ และ 1.50 ส่วนกลุ่มข้อสอบก็ได้จากการสร้างขึ้นเองโดยอาศัยคอมพิวเตอร์ ใช้จำนวนผู้สอบ 2,000 คน เพื่อหาค่าพารามิเตอร์ของข้อสอบจำนวน 40 ข้อ ข้อสอบมีค่าความยากอยู่ในช่วง $(-2.00, +2.00)$ ค่าอำนาจจำแนกอยู่ในช่วง $(.40, 2.00)$ และค่าการเดาอยู่ในช่วง $(.15, .25)$

เกณฑ์ที่ใช้เปรียบเทียบ

1. ความถูกต้องแม่นยำ (precision) ของการประมาณคะแนนโดเมนโดยอาศัยค่าเฉลี่ยของความเบี่ยงเบนสัมบูรณ์ของคะแนนโดเมนของผู้สอบ 200 คน ที่ระดับความสามารถต่าง ๆ $(-2.00, -1.00, -.50, 1.00)$ ดังนี้

$$\sum_{j=1}^N |\pi_i - \pi_{ij}| / N \quad (2)$$

เมื่อ π_i ได้จากสมการที่ 1

$$\hat{\pi}_{ij} = \frac{1}{n} \sum_{g=1}^n \hat{P}_g(\hat{\theta}_{ij}) \quad (3)$$

n คือ จำนวนข้อสอบ

$\hat{\theta}_{ij}$ คือ ความสามารถของผู้สอบคนที่ i บนแบบสอบฉบับที่ j

N คือ จำนวนผู้สอบ ($N = 200$ คน)

จะได้ค่าเฉลี่ยของความเบี่ยงเบนสัมบูรณ์ระหว่าง คะแนนโดเมนที่เป็นคะแนนจริงของผู้สอบกับคะแนนโดเมนที่ได้จากการประมาณด้วยแต่ละรูปแบบโลจิสติกที่ระดับความสามารถต่าง ๆ

2. ความลำเอียงในการประมาณคะแนนโดเมนของแต่ละรูปแบบโลจิสติก
3. ความถูกต้องแม่นยำของการตัดสินใจให้ผู้สอบ เป็นผู้รอบรู้หรือไม่รอบรู้ ของแต่ละรูปแบบโลจิสติก

ผลการเปรียบเทียบพบว่า

1. การเปรียบเทียบความถูกต้องแม่นยำ ของการประมาณคะแนนโดเมนที่ความยาวของแบบสอบ 4 ขนาด ด้วยรูปแบบโลจิสติก 1, 2 และ 3 พารามิเตอร์ ที่ระดับความสามารถ 5 ระดับ จาก -2.00 ถึง $+1.00$ ปรากฏว่ารูปแบบ 3 พารามิเตอร์ จะประมาณคะแนนโดเมนได้ดีกว่ารูปแบบ 1 หรือ 2 พารามิเตอร์
2. ความลำเอียงในการประมาณคะแนนโดเมนด้วยโลจิสติกทั้ง 3 รูปแบบ มีค่าน้อยมาก
3. ความถูกต้องแม่นยำของการตัดสินใจให้ผู้สอบ เป็นผู้รอบรู้หรือไม่รอบรู้ พบว่ารูปแบบ 2 พารามิเตอร์ให้ความถูกต้องของการตัดสินใจที่ไม่แน่นอน แต่รูปแบบ 1 พารามิเตอร์ ใช้ได้ดีพอๆ กับรูปแบบ 3 พารามิเตอร์ ยกเว้นที่ระดับความสามารถต่ำ ๆ (-2.0 ถึง -1.5)

การใช้ทฤษฎีการตอบข้อสอบกับวิธีกำหนดคะแนนคะแนนจุดตัดที่ใช้คุณลักษณะของผู้เชี่ยวชาญตัดสิน

เคน (Kane 1987 : 333-345) ได้รวบรวมวิธีการแปลงคะแนนจุดตัดที่ได้จากวิธีการกำหนดคะแนนจุดตัดโดยใช้คุณลักษณะของผู้เชี่ยวชาญตัดสิน ให้เป็นระดับความสามารถขั้นต่ำสุดที่ยอมรับผ่าน (θ^*) โดยมีข้อตกลงว่า จะต้องทราบค่าโค้งลักษณะข้อสอบ ($P_i(\theta)$) ซึ่งเป็นหลัก

ของทฤษฎีการตอบสนองข้อสอบในการประมาณความน่าจะเป็นที่ผู้สอบซึ่งมีระดับความสามารถ θ ต่าง ๆ จะสามารถตอบข้อสอบได้ถูก ซึ่งมีอยู่ 3 วิธี คือ

วิธีที่ 1 ประมาณค่า θ^* ของข้อสอบแต่ละข้อโดยอาศัยโค้งลักษณะข้อสอบรายข้อ แล้วจึงคำนวณหา θ^* เฉลี่ยของข้อสอบทุกข้อในแบบสอบ มี 3 ขั้นตอน ดังนี้

1. คำนวณหาค่าเฉลี่ยของความน่าจะเป็นในการตอบข้อสอบ i ได้ถูกที่ใช้ดุลพินิจของผู้เชี่ยวชาญตัดสิน (M_{iR})
2. ให้ M_{iR} เป็นค่าประมาณของความน่าจะเป็นที่ผู้สอบซึ่งมีระดับความสามารถขั้นต่ำสุดที่ยอมให้ผ่าน สามารถตอบข้อสอบได้ถูกในรูปแบบโลจิสติก ซึ่งแทนได้ด้วยโค้งลักษณะข้อสอบที่ระดับความสามารถ $\hat{\theta}_{iR}^*$ ดังสมการ

$$M_{iR} = P_i(\hat{\theta}_{iR}^*)$$

3. ประมาณค่าความแปรปรวนของ ($\hat{\theta}_{iR}^*$) ในข้อ i

กำหนดให้
$$P_i(\hat{\theta}_{iR}^*) = \frac{\Delta M_{iR}}{\Delta \hat{\theta}_{iR}^*} \quad (6)$$

เป็นความชันของโค้งลักษณะข้อสอบข้อ i ที่ความสามารถ (θ_{iR}) แทน ด้วยความเบี่ยงเบนมาตรฐาน

$$\frac{P_i'(\hat{\theta}_{iR}^*)}{\sigma_i(M_{iR})} = \frac{1}{\sigma_i(\hat{\theta}_{iR}^*)} \quad (7)$$

$$\frac{[P_i'(\hat{\theta}_{iR}^*)]^2}{\sigma^2(M_{iR})} = \frac{1}{\sigma_i^2(\hat{\theta}_{iR}^*)} \quad (8)$$

4. ประมาณค่า θ^* จากค่าเฉลี่ยของ $\hat{\theta}_{iR}^*$

$$\hat{\theta}^* = \frac{1}{n} \sum_i (\hat{\theta}_{iR}^*) \quad (9)$$

ซึ่งมีความแปรปรวน
$$\sigma^2(\hat{\theta}^*) = \frac{1}{n^2} \sum_i \sigma_i^2(\hat{\theta}_{iR}^*) \quad (10)$$

โดยมีข้อตกลงเบื้องต้นว่าการตัดสินความน่าจะเป็นในการตอบถูกของข้อสอบแต่ละข้อ เป็นอิสระกัน

แต่การที่ผู้ตัดสินคนหนึ่งต้องตัดสินข้อสอบทุกข้อในแบบสอบอาจทำให้ผลการตัดสินข้อสอบ รายข้อไม่เป็นอิสระกัน จึงแทนสมการที่ (9) ด้วยการประมาณแบบถ่วงน้ำหนัก ดังนี้

$$\hat{\theta}_w^* = \sum_i w_i \hat{\theta}_{iR}^* \quad (11)$$

เมื่อ $\sum_i w_i = 1$ และมีความแปรปรวนเป็น

$$\sigma^2(\theta_w) = \sum_i w_i^2 \sigma_i^2 (\hat{\theta}_{iR}^*) \quad (12)$$

$$\sigma^2(\theta_w) = \sum_i w_i^2 \sigma_i^2 (\hat{\theta}_{iR}^*) \quad (13)$$

ค่าของ w_i ที่จะทำให้ความแปรปรวนในสมการที่ (13) มีค่าน้อยที่สุดและมีคุณสมบัติตั้งในสมการที่ (12) ทำได้โดยการใช้ Lagrange multipliers

$$w_i = \frac{1/\sigma_i^2 (\theta_{iR})}{\sum_i (1/\sigma_i^2) (\theta_{iR})} \quad (14)$$

การประมาณแบบถ่วงน้ำหนักนี้จะช่วยลดความคลาดเคลื่อนมาตรฐานของ $\hat{\theta}_i^*$ โดยข้อสอบที่ผู้ตัดสิน ตัดสินคล้าย ๆ กัน จะถูกถ่วงน้ำหนักมาก ส่วนข้อที่ผู้ตัดสิน ตัดสินต่างกันออกไป ก็จะถูกถ่วงน้ำหนักน้อย

วิธีที่ 2 เป็นวิธีที่ใช้กันมากที่สุด เป็นการประมาณ θ^* โดยอาศัยโด่งลักษณะแบบสอบ มี 3 ขั้นตอน คือ

1. คำนวณหาค่าเฉลี่ยของความน่าจะเป็นในการตอบข้อ i ถูก ที่ตัดสินโดยผู้ตัดสินทั้งหมด (M_{iR})
2. คำนวณหาคะแนนจุดตัดของแบบสอบ ซึ่งอยู่บนเส้นของคะแนนจริงจากผลรวมของ M_{iR} ในแต่ละข้อของแบบสอบ
3. ใช้โด่งลักษณะแบบสอบ (test characteristics curve) ทหาระดับความสามารถ θ ซึ่งสัมพันธ์กับคะแนนจริงในขั้นที่ 2 จากสมการ

$$\sum_i M_{iR} = \sum_i P_i(\hat{\theta}^*) \quad (15)$$

$$\sum_i [M_{iR} - P_i(\hat{\theta}^*)] = 0 \quad (16)$$

จากสมการที่ (5)
$$\sum_i [P_i(\hat{\theta}_{iR}^*) - P_i(\theta^*)] = 0 \quad (17)$$

แต่

$\hat{\theta}_{iR}^* \rightarrow \theta^*$ ความสัมพันธ์สามารถประมาณได้ด้วย linear function (lord 1980 : 69)

$$\sum_i P_i'(\hat{\theta}_{iR}^*)(\hat{\theta}_{iR}^* - \theta^*) \approx 0 \quad (18)$$

$$\theta^* \approx \frac{1}{\sum_i P_i'(\hat{\theta}_{iR}^*)} \sum_i P_i'(\hat{\theta}_{iR}^*) \hat{\theta}_{iR}^* \quad (19)$$

จากสมการที่ (7) และ (19)

$$\theta^* \approx \frac{1}{\sum_i \sigma_i(M_{iR})/\sigma_i(\hat{\theta}_{iR}^*)} \sum_i \frac{\sigma_i(M_{iR})}{\sigma_i(\hat{\theta}_{iR}^*)} \hat{\theta}_{iR}^* \quad (20)$$

การประมาณ θ^* จากสมการที่ 20 ยังไม่ใช่ค่าที่ดีที่สุด สามารถปรับปรุงได้โดยการถ่วงน้ำหนักด้วย $1/\sigma_i(M_{iR})$ ในสมการที่ (17) จะได้

$$\hat{\theta}_w^* \approx \frac{1}{\sum_i P_i'(\hat{\theta}_{iR}^*)/\sigma_i(M_{iR})} \sum_i \frac{P_i'(\hat{\theta}_{iR}^*)}{\sigma_i(M_{iR})} \hat{\theta}_{iR}^* \quad (21)$$

จากสมการที่ (7) จะได้ว่า

$$\hat{\theta}_w^* \approx \frac{1}{\sum_i (1/\sigma_i(\hat{\theta}_{iR}^*))} \sum_i \frac{1}{\sigma_i(\hat{\theta}_{iR}^*)} \hat{\theta}_{iR}^* \quad (22)$$

วิธีที่ 3 เป็นการประมาณ θ^* ที่เหมาะสมที่สุดระหว่างการใช้คลัทช์ในการตัดสินความน่าจะเป็นในการตอบข้อสอบได้ถูก (M_{iR}) กับโด่งลักษณะข้อสอบ มี 3 ขั้นตอน คือ

1. คำนวณหาค่าเฉลี่ยของความน่าจะเป็นในการตอบข้อ i ถูก ที่ตัดสินโดยผู้ตัดสินทั้งหมด (M_{iR})
2. คำนวณหาความแปรปรวนของค่าเฉลี่ยความน่าจะเป็นในการตอบข้อ i ถูก ที่ตัดสินโดยผู้ตัดสินทั้งหมด $\sigma_i^2(M_{iR})$
3. คำนวณหา $\hat{\theta}^*$ ซึ่งมีผลบวกของความเบี่ยงเบนกำลังสองระหว่าง M_{iR} และ $P_i(\hat{\theta}^*)$ มีค่าน้อยที่สุด จากสมการ

(23)

แต่ $\theta_{iR} \rightarrow \theta^*$ และสมการที่ 18

$$\begin{aligned} \sum_i \frac{(M_{iR} - P_i(\hat{\theta}^*))^2}{\sigma_i^2(M_{iR})} &\approx \sum_i \frac{1}{\sigma_i^2(M_{iR})} [P_i'(\hat{\theta}_{iR}^*) (\hat{\theta}_{iR}^* - \hat{\theta}^*)]^2 \\ &\approx \sum_i \frac{P_i'^2(\hat{\theta}_{iR}^*)}{\sigma_i^2(M_{iR})} (\hat{\theta}_{iR}^* - \hat{\theta}^*)^2 \end{aligned} \quad (24)$$

กำหนดให้สมการที่ (24) เท่ากับ 0

$$\sum_i \frac{P_i'^2(\hat{\theta}_{iR}^*)}{\sigma_i^2(M_{iR})} (\hat{\theta}_{iR}^* - \hat{\theta}^*)^2 = 0 \quad (25)$$

$$\hat{\theta}^* \approx \frac{1}{\sum_i P_i'^2(\hat{\theta}_{iR}^*)/\sigma_i^2(M_{iR})} \sum_i \frac{P_i'^2(\hat{\theta}_{iR}^*)}{\sigma_i^2(M_{iR})} \hat{\theta}_{iR}^* \quad (26)$$

จากสมการที่ (8)

$$\hat{\theta}^* \approx \frac{1}{\sum_i [1/\sigma_i^2(\hat{\theta}_{iR}^*)]} \sum_i \frac{1}{\sigma_i^2(\hat{\theta}_{iR}^*)} \hat{\theta}_{iR}^* \quad (27)$$

สรุปวิธีการประมาณ θ^* ของทั้ง 3 วิธี จะเห็นว่าวิธีที่ 1 และ 3 จะอาศัยผลการสอบของข้อสอบแต่ละข้อประกอบกับการใช้คัลพินิจของผู้เชี่ยวชาญ แต่สำหรับวิธีที่ 2 จะหาคะแนนจุดตัดจากคัลพินิจของผู้เชี่ยวชาญก่อน แล้วจึงอาศัยโค้งลักษณะแบบสอบ แปลงคะแนนจุดตัดในสเกลของคะแนนโดเมนให้อยู่บนสเกลของความสามารถ ซึ่งเป็นวิธีที่นิยมกัน สำหรับในการวิจัยครั้งนี้ ผู้วิจัยใช้วิธีที่ 2 เพราะต้องการคะแนนจุดตัดจากการตัดสินของผู้เชี่ยวชาญแล้วจึงแปลงให้เป็นระดับความสามารถ θ^*

ตอนที่ 3 งานวิจัยที่เกี่ยวข้อง

ปัญหาของวิธีกำหนดจุดตัดที่อาศัยการตัดสินใจของผู้เชี่ยวชาญสามารถแบ่งออกได้เป็น 3 ข้อ คือ

1. มโนทัศน์เกี่ยวกับความสามารถขั้นต่ำสุด
2. ความคงที่ของการตัดสินใจ

นักการศึกษาได้แสดงมโนทัศน์เกี่ยวกับความสามารถขั้นต่ำสุดว่าหมายถึง ระดับของความชำนาญ หรือความรู้ที่ต่ำที่สุดที่บุคคลยังสามารถทำสิ่งหนึ่งสิ่งใดได้ ซึ่งอัลเฟรด การ์วิน (Alfred garvin, cited by Glass 1978 : 251) การกำหนดเกณฑ์ของความสามารถในทางการศึกษานั้นทำได้ยาก หรืออาจทำไม่ได้เลย

ความคงที่ของการตัดสินใจ

ปัญหาเกี่ยวกับความคงที่ของการตัดสินใจในงานวิจัยที่ศึกษาเกี่ยวกับปัญหาเรื่องนี้ คือ เมสคาคัส และเวสเตอร์ (Meskauskas and Webster, cited by Glass 1978 : 248) ได้ทำการศึกษาโดยให้ผู้ตัดสินใจ 6 คน ใช้วิธีนี้เดลสกีกำหนดจุดตัดในรูปของเปอร์เซ็นต์ของข้อสอบที่ตอบถูก ผลการศึกษาพบว่า คะแนนจุดตัดกระจายอยู่ในช่วง 36% ถึง 80% แล้วสรุปว่าการตัดสินใจคะแนนจุดตัดไม่มีความคงที่ นอกจากนี้ยังมีงานวิจัยที่เปรียบเทียบคะแนนจุดตัดระหว่าง วิธีนี้เดลสกี วิธีอีเบล และวิธีแองกอฟ ดังต่อไปนี้

แอนดรู และเฮก (Andrew & Hecht, cited by Glass 1978 : 249) เปรียบเทียบวิธีนี้เดลสกี และวิธีอีเบล โดยให้ผู้เชี่ยวชาญ 8 คน ตัดสินคะแนนจุดตัดของแบบสอบที่ขนานกัน 2 ฉบับ ฉบับแรกใช้วิธีนี้เดลสกี ฉบับที่สองใช้วิธีอีเบล ผลการวิจัยพบว่าจุดตัดที่ได้จากการตัดสินใจด้วยวิธีอีเบลเท่ากับ 68% จะมีผู้สอบผ่านประมาณ 50% ส่วนจุดตัดที่ได้จากการตัดสินใจด้วยวิธีนี้เดลสกีเท่ากับ 49% จะมีผู้สอบผ่านประมาณ 95% จุดตัดที่ได้จากทั้ง 2 วิธีนี้แตกต่างกันอย่างมีนัยสำคัญ ทั้งที่ใช้แนวคิดเกี่ยวกับความสามารถขั้นต่ำสุดอย่างเดียวกัน และไม่มีเหตุผลสนับสนุนอย่างเพียงพอที่จะบอกได้ว่าวิธีใดดีกว่า

สกาเกิน และคลิง (Kkakun & Kling 1980 : 229-235) เปรียบเทียบวิธีนี้เดลสกี กับวิธีที่ประยุกต์จากวิธีอีเบล 2 วิธี ในการกำหนดคะแนนจุดตัดของแบบสอบวิชาการผ่านตัดทั่วไป ซึ่งมีข้อสอบจำนวน 194 ข้อ ผลการวิจัยพบว่าคะแนนจุดตัดที่ได้จากการตัดสินใจด้วยวิธีนี้เดลสกี และวิธีที่ประยุกต์จากวิธีอีเบล 2 วิธี มีความแตกต่างกัน 3% และ 5% ตามลำดับ และจะมีผู้สอบตก ถ้าใช้วิธีอีเบล มากกว่าวิธีนี้เดลสกี ประมาณ 23%

เบรนแนน และล็อกวูด (Brennan and Lockwood 1980 : 219-240) ได้ศึกษาเปรียบเทียบการกำหนดจุดตัดด้วยวิธีแองกอฟกับวิธีนี้เดสส์กี โดยใช้ทฤษฎีการสรุปอ้างอิง (Generalizability Theory) การดำเนินการวิจัยใช้กลุ่มตัวอย่างเป็นผู้ตัดสิน 5 คน ตัดสินข้อสอบ 126 ข้อ ด้วยวิธีแองกอฟ และวิธีนี้เดสส์กี ผลการวิจัยพบว่า

1. วิธีแองกอฟ และวิธีนี้เดสส์กี จะให้คะแนนจุดตัดที่แตกต่างกันอย่างมีนัยสำคัญ และความเบี่ยงเบนมาตรฐานของคะแนนจุดตัดของวิธีนี้เดสส์กี จะเป็น 2 เท่า ของวิธีแองกอฟ

2. เมื่อทำการวิเคราะห์ความแปรปรวน (ANOVA) แบบ 3 ทาง คือ วิธีกำหนดคะแนนจุดตัด 2 วิธี X ผู้ตัดสิน 5 คน X -hvlv[126 ข้อ พบว่า ส่วนเบี่ยงเบนมาตรฐานของคะแนนจุดตัดจะใกล้เคียงกับส่วนเบี่ยงเบนมาตรฐานของการตัดสิน โดยวิธีแองกอฟ

3. การใช้ผู้ตัดสินกลุ่มเดียวกันทำการตัดสินข้อสอบทั้งวิธีแองกอฟ และวิธีนี้เดสส์กี พบว่า

3.1 วิธีแองกอฟ กับวิธีนี้เดสส์กี ไม่สัมพันธ์กัน ($r = -.052$)

3.2 คะแนนจุดตัดของวิธีแองกอฟสูงกว่าของวิธีนี้เดสส์กี

3.3 ส่วนเบี่ยงเบนมาตรฐานของคะแนนจุดตัดของวิธีแองกอฟต่ำกว่าของวิธีนี้เดสส์กี

ในการกำหนดจุดตัดโดยอาศัยการตัดสินของผู้เชี่ยวชาญนี้ เชปาร์ด (Shepard 1980) แนะนำว่าควรจะให้สารสนเทศประกอบการตัดสินของผู้เชี่ยวชาญ เพื่อลดความคลาดเคลื่อนของการตัดสิน ซึ่งมีงานวิจัยที่ศึกษาเกี่ยวกับเรื่องนี้ ดังนี้

ครอส และคณะ (Cross, et al 1984 : 113-129) ได้ศึกษาหาวิธีกำหนดคะแนนจุดตัด ที่เหมาะสมให้กับแบบสอบของ 'The National Teacher Examinations' (NTE) วิชาคณิตศาสตร์ และการศึกษาเบื้องต้นโดยให้ผู้เชี่ยวชาญ 2 กลุ่ม ๆ ละ 15 คน ตัดสินเกณฑ์มาตรฐาน กลุ่มละวิชา ในแต่ละวิชาจะใช้วิธีกำหนดคะแนนจุดตัด ทั้ง 3 วิธี คือ วิธีแองกอฟ วิธีนี้เดสส์กี และวิธีเจอร์ โดยแบ่งผู้เชี่ยวชาญออกเป็น 3 กลุ่ม ให้ตัดสินคะแนนจุดตัดกลุ่มละวิธี ซึ่งมีขั้นตอนในการดำเนินงาน แบ่งออกเป็น 3 รอบ คือ

1. ในรอบแรก ผู้ตัดสินจะได้รับข้อสอบเฉพาะข้อคำถามพิจารณา โดยไม่มีสารสนเทศใด ๆ ประกอบ

2. ในรอบที่สอง ผู้ตัดสินจะได้รับข้อสอบเฉพาะข้อคำถามพิจารณา แต่จะมีสารสนเทศประกอบ คือ ค่าความยากของข้อสอบแต่ละข้อ

3. ในรอบสุดท้าย ผู้ตัดสินจะได้รับการขอร้องให้พิจารณาซ้ำอีกครั้งหนึ่ง โดยพิจารณาเฉพาะข้อดี และมีสารสนเทศประกอบ คือ ผลการตัดสินเกณฑ์มาตรฐานของผู้ตัดสินคน

อื่น ๆ ในรอบแรก และการแจกแจงความถี่ของคะแนนที่ผู้สอบทำได้จากการนำแบบสอบไปใช้

ผลการศึกษาพบว่า วิธีกำหนดคะแนนจุดตัด ที่แตกต่างกัน และการให้สารสนเทศแก่ผู้ตัดสิน มีผลกระทบต่อคะแนนจุดตัด แต่เนื้อหาวิชาไม่มีผลกระทบต่อคะแนนจุดตัด สำหรับค่าความเที่ยงของการตัดสิน ผู้วิจัยคำนวณหาจากสูตรที่เสนอโดยอีเบล (Ebel formula d) และประมาณความแปรปรวนของการตัดสินจากสูตรที่เสนอโดยเบรนนัน และล็อกวูด (Brennan and Lockwood) จากการวิเคราะห์หาค่าความเที่ยงและความแปรปรวนของการตัดสินนี้ ทำให้สรุปได้ว่า การใช้วิธีแองกอฟโดยให้สารสนเทศประกอบแก่ผู้ตัดสินจะสามารถกำหนดคะแนนจุดตัด ที่มีความเที่ยงสูงกว่าวิธีอื่น

นอร์ซินี และคณะ (Norcini, et al. 1988 : 57-65) ได้ศึกษาถึงผลของการให้สารสนเทศเกี่ยวกับค่าความยากของข้อสอบ ต่อการกำหนดคะแนนจุดตัดด้วยวิธีแองกอฟ ดำเนินการวิจัยโดยใช้ผู้ตัดสิน 6 คน ตัดสินข้อสอบ 48 ข้อ แบ่งออกเป็น 2 รอบ ในรอบแรกผู้ตัดสินจะตัดสินคะแนนจุดตัดโดยไม่ทราบค่าความยากของข้อสอบ ในรอบที่สองผู้ตัดสินจะได้รับการขอร้องให้ตัดสินคะแนนจุดตัดซ้ำอีกครั้งหนึ่ง โดยมีสารสนเทศเกี่ยวกับค่าความยากของข้อสอบประกอบ ผลการศึกษาพบว่า การให้สารสนเทศเกี่ยวกับค่าความยากของข้อสอบไม่มีผลกระทบต่อคะแนนจุดตัด แต่ช่วยลดความคลาดเคลื่อนในการตัดสินได้

ครอส และคณะ (Cross, et al. 1985 : 137-146) ได้ทำการศึกษานำร่องหาคะแนนจุดตัดของแบบสอบอัตรานักวิชาทักษะการติดต่อสื่อสาร (the communication skills test) ของ the National Teacher Examinations (NTE) จำนวน 12 ข้อ ทำการศึกษาโดยการเปรียบเทียบคะแนนจุดตัดของผู้ตัดสิน 2 กลุ่ม กลุ่มหนึ่งจะได้รับสารสนเทศเกี่ยวกับคะแนนของข้อสอบอัตรานักทั้ง 12 ข้อ นั้น ซึ่งให้คะแนนโดย the Educational Testing Service (ETS) แล้วให้ตัดสินคะแนนที่น้อยที่สุดที่ยอมรับได้ของข้อสอบแต่ละข้อ ซึ่งเป็นไปได้ตั้งแต่ 1-6 คะแนน ส่วนกลุ่มที่ 2 จะทำการตัดสินคะแนนจุดตัดของแบบสอบฉบับนี้ 2 รอบ คือ รอบแรก ให้ตัดสินคะแนนที่น้อยที่สุดที่ยอมรับได้ของข้อสอบแต่ละข้อ โดยไม่ทราบคะแนนของข้อสอบที่ตรวจโดย ETS รอบที่สอง ดำเนินการตัดสินคะแนนจุดตัดเช่นเดียวกับกลุ่มหนึ่ง ในการศึกษาครั้งนี้ใช้ผู้ตัดสินกลุ่มละ 20 คน ผลการศึกษานำร่องพบว่า

1. คะแนนจุดตัดที่ได้จากการตัดสินของผู้ตัดสินกลุ่มที่ 2 ที่ตัดสินโดยไม่มี และโดยมีสารสนเทศเกี่ยวกับคะแนนของข้อสอบซึ่งตรวจโดย ETS นั้น เท่ากับ 2.99 และ 3.10 ตามลำดับ ส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.79 เท่ากัน และเมื่อทดสอบความแตกต่าง ปรากฏว่าแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติที่ระดับ .05

2. คะแนนจุดตัดของผู้ตัดสินกลุ่มที่ 1 และกลุ่มที่ 2 ในรอบแรก เท่ากับ 3.30 และ 2.99 ส่วนเบี่ยงเบนมาตรฐานเท่ากับ .66 และ .79 และเมื่อทดสอบความแตกต่าง ปรากฏว่า แตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติที่ระดับ .05

ในขั้นการวิจัยได้ทำการศึกษาหาคะแนนจุดตัดของแบบสอบอัตนัยชุดใหม่ จำนวน 11 ข้อ ดำเนินการวิจัยเช่นเดียวกับการศึกษานำร่อง ทำการศึกษากับผู้ตัดสิน 2 กลุ่ม จำนวน 72 และ 49 คน ในมลรัฐเวอร์จิเนีย (Virginia) และมลรัฐเคนทักกี (Kentucky) ผู้ตัดสินแต่ละกลุ่มประกอบด้วยครูที่มาจากโรงเรียนรัฐบาล และอาจารย์มหาวิทยาลัย ผลการวิจัยพบว่า

1. คะแนนจุดตัดที่ได้จากการตัดสินของผู้ตัดสินที่ไม่มีสารสนเทศ และที่มีสารสนเทศ เท่ากับ 3.44 และ 4.0 ตามลำดับ ส่วนเบี่ยงเบนมาตรฐานเท่ากับ .80 และ .90 ตามลำดับ และเมื่อทดสอบความแตกต่าง ปรากฏว่าแตกต่างกันอย่างไม่มีนัยสำคัญ

2. คะแนนจุดตัดที่ได้จากการตัดสินของครูในโรงเรียนรัฐบาล และอาจารย์มหาวิทยาลัย แตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ .05

นอร์ซินี และคณะ (Norcini, et al. 1987:56-64) ได้ทำการศึกษาเปรียบเทียบคะแนนจุดตัดของวิธีเองกอพใน 3 ช่วงเวลา คือก่อนการประชุม ระหว่างประชุม และหลังการประชุมผู้เชี่ยวชาญ ใช้ผู้เชี่ยวชาญซึ่งเป็นสมาชิกของ Test development Committee จำนวน 6 คน แบ่งแบบสอบออกเป็น 2 ฉบับ ที่มีความเท่าเทียมกันในเรื่องค่าความยาก ค่าอำนาจจำแนก และส่วนเบี่ยงเบนมาตรฐาน วิธีดำเนินการในระยะเวลาก่อนการประชุม 1 เดือน ให้ผู้เชี่ยวชาญประมาณความน่าจะเป็นในการตอบข้อสอบทุกของแบบสอบชุดแรก ในระหว่างการประชุมนำแบบสอบชุดแรกมาประเมินอีกครั้งหนึ่งที่ละข้อ ผู้เชี่ยวชาญที่ประมาณความน่าจะเป็นแต่ละข้อมีค่าสูงสุด หรือต่ำสุด ต้องให้เหตุผลแก่ที่ประชุม หลังจากนั้นทุกคนมีสิทธิปรับความน่าจะเป็นใหม่ หากจนครบทุกข้อ และแก้ไขจนพอใจ หลังจากนั้นผู้เชี่ยวชาญแต่ละคนจะได้ดูผลการประมาณความน่าจะเป็นซึ่งทำก่อนการประชุม แล้วหลังจากการประชุม 1 เดือน ก็จะส่งแบบสอบชุดที่สองไปให้ผู้เชี่ยวชาญชุดเดิมประมาณความน่าจะเป็นที่จะตอบข้อสอบทุก แล้วส่งกลับไปยัง The American Board of Internal Medicine (ABIM) ทำการวิเคราะห์ความคงเส้นคงวาของการตัดสินใจของผู้เชี่ยวชาญด้วยทฤษฎีสรูปอ้างอิง (General liability Theory) ผลการวิจัยพบว่า คะแนนจุดตัดที่ได้จากก่อนการประชุม ระหว่างการประชุม และหลังการประชุมไม่แตกต่างกันอย่างมีนัยสำคัญ ทางสถิติที่ระดับ .05 แต่การประมาณความน่าจะเป็นของการตอบข้อสอบทุกของผู้เชี่ยวชาญที่ได้จากก่อนการประชุม มีความคงเส้นคงวา (consistent) น้อยกว่าระหว่างการประชุมและหลังการประชุม แสดงว่าการให้ผู้เชี่ยวชาญได้ประชุมปรึกษากัน จะทำให้การกำหนดคะแนนจุดตัดด้วยวิธีเองกอพมีประสิทธิภาพขึ้น

แวน เดอร์ ลินเดน (Van der Linden 1982:295-308) ได้ศึกษาความไม่สอดคล้องของการตัดสินใจโดยผู้เชี่ยวชาญในการกำหนดคะแนนจุดตัดตามวิธีแองกอฟ และวิธีนี้เดลส์กี โดยอาศัยทฤษฎีการตอบข้อสอบ ที่แสดงความสัมพันธ์ระหว่างการตอบข้อสอบ กับความสามารถที่อยู่ภายในตัวผู้สอบ ในรูปของโค้งลักษณะข้อสอบ ($P_i(\theta)$) ซึ่งความน่าจะเป็นในการตอบข้อสอบได้ถูกของผู้สอบที่มีระดับความสามารถ จะขึ้นอยู่กับ โค้งลักษณะข้อสอบนั้น วิธีการศึกษาคือ หากระดับความสามารถ θ_c ที่เป็นตัวกำหนดความน่าจะเป็นในการตอบข้อสอบได้ถูกของข้อสอบทุกข้อในแบบสอบ ($P_i(\theta_c)$) และนำไปเปรียบเทียบกับความน่าจะเป็นในการตอบข้อสอบได้ถูกที่ตัดสินโดยผู้เชี่ยวชาญ สำหรับข้อสอบทุกข้อในแบบสอบ ความแตกต่างที่ได้จะแสดงถึงความไม่คงเส้นคงวาของการตัดสินใจ ความแตกต่างนี้อาจเนื่องมาจากว่า ผู้เชี่ยวชาญไม่ทราบคุณสมบัติของข้อสอบ และทำให้ประมาณความน่าจะเป็นในการตอบข้อสอบได้ถูกไม่ตรงกับฟังก์ชันลักษณะข้อสอบ แสดงว่าผู้เชี่ยวชาญมีข้อมูลไม่เพียงพอในการเดา มีขั้นตอนการศึกษาดังนี้

1. หาค่าพารามิเตอร์ของข้อสอบ โดยใช้ทฤษฎีการตอบข้อสอบวิเคราะห์ข้อสอบ
2. นำข้อสอบในข้อ 1. ไปให้ผู้เชี่ยวชาญประมาณความน่าจะเป็นในการตอบข้อสอบได้ถูก แทนด้วย $P_i(s)$ ตามวิธีกำหนดจุดตัดของแองกอฟ หรือ นี้เดลส์กี
3. คำนวณหาคะแนนจุดตัด (θ_c) ของวิธีแองกอฟ หรือวิธีนี้เดลส์กี ซึ่งอยู่บนสเกลของคะแนนจริง
4. แปลงคะแนนจุดตัดที่อยู่บนสเกลของคะแนนจริง ให้อยู่บนสเกลของระดับความสามารถ (θ -scale) โดยอาศัยโค้งลักษณะแบบสอบ จะได้ θ_c
5. คำนวณหาความน่าจะเป็นในการตอบข้อสอบได้ถูกจากโค้งลักษณะข้อสอบ (P_i) ที่ระดับความสามารถ θ_c ของข้อสอบทุกข้อ
6. คำนวณหาดัชนีความคงที่ (index of consistency : C) ของการตัดสินใจโดยผู้เชี่ยวชาญ ดังนี้

6.1 หาความแตกต่างระหว่าง $P_i(s)$ และ P_i สำหรับข้อสอบทุกข้อ

$$e_i = P_i(s) - P_i$$

6.2 หาค่าเฉลี่ยความคลาดเคลื่อนสัมบูรณ์ของการตัดสินใจโดยผู้เชี่ยวชาญของข้อสอบทั้งหมด

$$E = \frac{P_i(s) - P_i}{n}$$

เมื่อ n คือ จำนวนข้อสอบ

6.3 หาดัชนีความคงที่ (C) ของการตัดสินใจโดยผู้เชี่ยวชาญ

$$C = \frac{M-E}{M}$$

$$\text{เมื่อ } M = \sum_{i=1}^n e_i(u)/n$$

$$e_i(u) = \max\{p_i, 1-p_i\}$$

ถ้า C เข้าใกล้ 0 แสดงว่าการตัดสินใจคะแนนจุดตัดโดยผู้เชี่ยวชาญไม่มีความคงที่ ผลการวิจัยพบว่า การให้ผู้เชี่ยวชาญกำหนดจุดตัดโดยวิธีของแองกอฟ จะทำให้การตัดสินใจมีดัชนีความคงที่ (0.77) สูงกว่าวิธีของนีเคลสกี (0.68)

อาราสมิธ (Arrasmith 1987:3405-A) ทำการศึกษาเกี่ยวกับความคลาดเคลื่อนในการกำหนดคะแนนจุดตัดของวิธีแองกอฟ และวิธีการเปรียบเทียบระหว่างกลุ่ม (Contrasting-groups) โดยอาศัยทฤษฎีสູรູ່อຳงູ່อຳง (generalizability theory), ทฤษฎีการตอบสนองข้อสอบ (item response theory) และ (bootstrap estimation) เพื่อเป็นแนวทางในการเลือกวิธีกำหนดจุดตัดที่เหมาะสม ผลการวิจัยพบว่า สำหรับวิธีแองกอฟ การหาค่าดัชนีความคงที่โดยทฤษฎีการตอบสนองข้อสอบ (IRT index of consistency) และการวิเคราะห์ความแตกต่างของความน่าจะเป็นในการตอบข้อสอบได้ถูกระหว่างการประมาณ โดยใช้คลุพินิจของผู้เชี่ยวชาญ กับการประมาณ $P_i(\theta)$ สามารถแสดงถึงความไม่สอดคล้องของการตัดสินใจโดยผู้เชี่ยวชาญ นอกจากนี้ทฤษฎีสູรູ່อຳงູ່อຳง และ bootstrap estimate ก็สามารถประมาณความคลาดเคลื่อนรวม ๆ ในการตัดสินใจของผู้เชี่ยวชาญได้ สำหรับวิธีการเปรียบเทียบระหว่างกลุ่มสามารถใช้วิธี bootstrap ประมาณความคลาดเคลื่อนของคะแนนจุดตัดได้

สำหรับงานวิจัยเกี่ยวกับแบบสอบอิงเกณฑ์ในประเทศไทยที่ศึกษาเกี่ยวกับวิธีการกำหนดคะแนนจุดตัดที่ใช้คลุพินิจของผู้เชี่ยวชาญตัดสินใจ คือ งานวิจัยของ ประภา แก่นเพิ่ม (2523) ที่ศึกษาความถูกต้องในการกำหนดคะแนนจุดตัดของวิธีกิลเบอ์ท (Guilbert) และวิธีของมหาวิทยาลัยอิลลินอยส์ ซึ่งดัดแปลงมาจากวิธีของนีเคลสกี โดยการเปรียบเทียบจุดตัดที่ได้จากการตัดสินใจของครู กับจุดตัดที่ได้จากผลการสอบแบบสอบวิชาคณิตศาสตร์ จำนวน 40 ข้อ ของนักเรียนที่อยู่ระดับคาบเส้นจำนวน 82 คน ผลการวิจัยพบว่า จุดตัดที่ได้จากวิธีกิลเบอ์ทเท่ากับ 38% และจุดตัดที่ได้จากวิธีของมหาวิทยาลัยอิลลินอยส์ เท่ากับ 32% นำจุดตัดจากทั้งสองวิธีเปรียบเทียบกับจุดตัดที่ได้จากการทดสอบนักเรียนคาบเส้น ปรากฏว่ามีความแตกต่างกันน้อยมากไม่เกิน 10%

จากการศึกษาเอกสารและงานวิจัยทั้งหมดดังกล่าวแสดงให้เห็นว่าการกำหนดคะแนนจุดตัดยังเป็นปัญหาที่สำคัญของการทดสอบแบบอิงเกณฑ์ แต่วิธีที่นิยมใช้กันมากคือวิธีกำหนดจุดตัดโดยอาศัยการตัดสินของผู้เชี่ยวชาญ ซึ่งก็มีปัญหาเกี่ยวกับกับความคงที่ของการตัดสิน ความคลาดเคลื่อนที่เกิดขึ้นนี้อาจเนื่องมาจากผู้ผู้เชี่ยวชาญไม่มีสารสนเทศประกอบการพิจารณา กำหนดคะแนนจุดตัด ดังนั้นผู้วิจัยจึงสนใจเปรียบเทียบคะแนนจุดตัด และดัชนีความคงที่ของการตัดสินคะแนนจุดตัดซึ่งตัดสินโดยผู้ผู้เชี่ยวชาญที่ไม่มีสารสนเทศและผู้เชี่ยวชาญที่มีสารสนเทศประกอบการตัดสิน

ศูนย์วิจัยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย