

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

เอกสารและงานวิจัยที่เกี่ยวข้องกับการทำหน้าที่ต่างกันของข้อสอบ วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบโดยวิธีชิปเทสต์ ผลสัมฤทธิ์ทางการเรียน และค่าความเที่ยงของแบบทดสอบ ผู้วิจัยได้เสนอเป็น 5 ตอน ดังนี้

ตอนที่ 1 การทำหน้าที่ต่างกันของข้อสอบ

ตอนที่ 2 วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบโดยวิธีชิปเทสต์

ตอนที่ 3 งานวิจัยที่เกี่ยวข้องกับการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบโดยวิธีชิปเทสต์

ตอนที่ 4 ผลสัมฤทธิ์ทางการเรียน

ตอนที่ 5 ค่าความเที่ยงของแบบทดสอบ

ตอนที่ 1 การทำหน้าที่ต่างกันของข้อสอบ

ความเป็นมาของการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ

การศึกษาความลำเอียงหรือการทำหน้าที่ต่างกันของข้อสอบหรือแบบทดสอบนั้น เริ่มมาจากการสังเกตปรากฏการณ์ของผลการสอบคัดเลือก เช่น การสอบคัดเลือกเพื่อเข้าศึกษาต่อ เพื่อบรรจุเข้าทำงาน หรือการสอบเพื่อเลื่อนตำแหน่ง หรือในการสอบอื่น ๆ ซึ่งพบว่าไม่เป็นไปตามสัดส่วนระดับสติปัญญาของผู้เข้าสอบหรือโครงสร้างของประชากร จึงเป็นเหตุให้เกิดความลำเอียงหรือความไม่ยุติธรรมในการสอบและส่งผลให้เกิดการศึกษาความลำเอียงของแบบทดสอบ

(Test Bias) และข้อสอบ (Item Bias) ในระยะต่อ ๆ มาแนวคิดในการวิเคราะห์ความลำเอียงและการตรวจสอบความยุติธรรมของการใช้ข้อสอบ ได้เริ่มปรากฏและได้รับความสนใจตั้งแต่ปี ค.ศ. 1910 โดยอัลเฟรด บีเนตต์และไซมอน ได้ทดสอบเด็กที่มีฐานะทางเศรษฐกิจและสังคมที่แตกต่าง พบว่า มีข้อสอบบางข้อที่น่าจะวัดในสิ่งที่เป็นการกระทบกับการฝึกฝนทางด้านวัฒนธรรม (เช่นที่บ้านหรือที่โรงเรียน) มากกว่าที่จะวัดความสามารถทางสมอง หลังจากศึกษาครั้งนี้ บีเนตต์และไซมอน ได้มีการพิจารณาอย่างละเอียดและได้เอาข้อสอบเหล่านี้ออกจากแบบทดสอบ เช่น ถ้าเป็นเด็กอายุ 7 ปี ข้อคำถามเกี่ยวกับนิ้วมือ การคัดลอกประโยคและการเรียกชื่อเหรียญ จะถูกคัดออกจากแบบทดสอบทั่วไป โดยในการทดสอบจะพิจารณาเฉพาะข้อคำถามที่ไม่ขึ้นกับการฝึกฝนของที่บ้าน (Home Training) ความตั้งใจ (Attention) ภาษา (Language) นิสัยในการพูด (Habit of

Looking at Picture) และแบบฝึกหัดเชิงวิชาการ (Scholastic Exercise) ในปี ค.ศ. 1912

วิลเลียม สเตอร์น (William Stern) ผู้ที่ได้ริเริ่มในนิยาม I.Q. ในรูปของอัตราส่วน ระหว่างอายุ สมองกับอายุปฏิทิน ได้ศึกษาความแตกต่างระหว่างชนชั้นต่าง ๆ (Class Difference) ในประเทศ เยอรมัน ผลที่ได้มีความคล้ายคลึงกับที่บีเนตพบ คือ ความแตกต่างระหว่างชนชั้นมีนัยสำคัญ สเตอร์นพยายามที่จะค้นหาและทำความเข้าใจเกี่ยวกับแหล่งที่ทำให้เกิดความแตกต่างอย่างจริงจัง เพื่อที่จะเสนอแนะว่า แบบทดสอบต่าง ๆ ที่ได้พิสูจน์มาแล้วนั้นเข้าข้างชนชั้นหนึ่งมากกว่าชนชั้นอื่น ๆ อย่างชัดเจน

ต่อมาในปี ค.ศ. 1951 ได้มีการเริ่มต้นศึกษาเกี่ยวกับความลำเอียงของข้อสอบแนวใหม่ โดยเอลส์ (Eells) และคณะสนใจความแตกต่างของการวัดบางอย่าง ซึ่งไม่มีความแม่นยำพอที่จะ สะท้อนให้เห็นความสามารถได้ เช่น ความแตกต่างทางด้านสติปัญญาของนักเรียน อาจขึ้นอยู่กับ เนื้อหาเฉพาะของข้อสอบแต่ละข้อ ในแบบทดสอบ และไม่ได้สะท้อนความสามารถที่แท้จริงของ นักเรียน จุดมุ่งหมายหลักเพื่อที่จะอธิบายความแตกต่างระหว่างกลุ่มนักเรียนโดยใช้สติปัญญา โดย มุ่งไปที่ข้อคำถามแต่ละข้อเช่นเดียวกับบีเนตและสเตอร์น คือดูว่าข้อคำถามใดมีความลำเอียง หรือไม่ แล้ววิเคราะห์ด้วยวิธีหาค่าความยากของข้อสอบระหว่างกลุ่มที่แตกต่างกัน ผลการศึกษา พบว่ายังมีความแตกต่างระหว่างกลุ่มนักเรียนที่มีระดับชั้นทางสังคม และภูมิหลังของเชื้อชาติและ วัฒนธรรมต่างกันในการตอบแบบทดสอบ เอลส์และคณะได้พยายามพัฒนาวิธีการปฏิบัติและ แก้ไขอิทธิพลของระดับชั้นทางสังคมและภูมิหลังของเชื้อชาติ ที่มีผลต่อการตอบข้อสอบ เพื่อใช้ ขจัดข้อสอบที่มีความลำเอียงในแบบทดสอบต่าง ๆ โดยเปรียบเทียบกลุ่มของเชื้อชาติที่อยู่ในชั้นทาง สังคม

ผลจากการศึกษาของเอลส์ได้นำไปสู่การศึกษาอย่างกว้างขวางในช่วง 30 กว่าปีที่ผ่านมา เมื่อรัฐมีความมุ่งหวังที่จะทำให้เกิดความยุติธรรมในการสอบเข้าศึกษาและโอกาสในการมีงานทำ ดังนั้นในช่วงปลายปี ค.ศ. 1960 และ ค.ศ. 1970 ได้มีความตื่นตัวเกี่ยวกับความลำเอียงของข้อสอบ โดยมุ่งไปที่แบบทดสอบวัดสติปัญญา เพราะเป็นแบบทดสอบที่ถูกนำไปใช้ในทางด้านการศึกษา การคัดเลือก (Selection) และจัดบุคคลเข้าสู่ตำแหน่ง (Placement) อย่างแพร่หลายจนกระทั่ง ปี ค.ศ. 1971 บริษัทกริกส์ วี ดุ๊ก เพาเวอร์ จำกัด (Griggs V. Duke Power) ได้วินิจฉัยแบบสอบต่าง ๆ แล้วชี้ให้เห็นว่าผลการทดสอบเหล่านั้นใช้ในการคัดเลือกอาจไม่เหมาะสม อาจพิจารณาตามเชื้อชาติ ของผู้สมัครงาน ยกเว้นกรณีที่ผลของการปฏิบัติงานมีความสอดคล้องกับการทดสอบ

ในช่วงเวลาเดียวกันมีการโต้แย้งในเรื่องความลำเอียงของข้อสอบมากขึ้น เมื่อเจนเซน (Jensen, 1969) ได้เสนอบทความลงในสารทางการศึกษาของฮาร์วาร์ด ฉบับที่ 39 ปี ค.ศ. 1969 โดย กล่าวว่าไอคิวเป็นผลมาจากการถ่ายทอดทางพันธุกรรมมากกว่าสิ่งแวดล้อม ความแตกต่างของไอคิว

ระหว่างคนผิวขาวกับคนผิวดำนั้นไม่ได้มาจากสิ่งแวดล้อมเพียงอย่างเดียว และพันธุกรรมอธิบายความแปรปรวนผลการปฏิบัติงานของแต่ละคนได้ประมาณร้อยละ 80 จากบทความของเจนเซนนี้เองทำให้สมาคมนักจิตวิทยาคนผิวดำเสนอว่า การทดสอบคนผิวดำทุกคนควรทำให้เท่าเทียมกันมากที่สุดเท่าที่จะเป็นไปได้ ยังมีบทความและวิธีการทางสถิติในการวิเคราะห์ความลำเอียงของข้อสอบเกิดขึ้นมากมาย ซึ่งแสดงให้เห็นว่าปัญหาเรื่องความลำเอียงของข้อสอบมีความสำคัญ เพื่อจะสร้างแบบทดสอบที่มีความยุติธรรมทางวัฒนธรรม และให้ผลการวิเคราะห์มีความถูกต้องมากที่สุด (Camilli & Shepard, 1994, pp. 4-7) นอกจากนี้ยังมีเหตุการณ์ที่ทำให้มีการตื่นตัวเป็นอันมากในเรื่องความลำเอียงของข้อสอบ คือ กรณีที่มาร์โก เดอฟูนิส (Marco Defunis) และคณะซึ่งถูกปฏิเสธจากโรงเรียนกฎหมายของมหาวิทยาลัยแห่งวอชิงตัน ได้ฟ้องร้องว่าเขาได้คะแนนการสอบสูงกว่าผู้ได้รับการคัดเลือกบางคนที่มาเข้าศึกษา และได้ยื่นฎีกาฟ้อง ชาร์ล โอเดการ์ด (Charles Odegard) อธิการบดีมหาวิทยาลัยดังกล่าวและคณะ เพื่อให้พิจารณาทบทวนการคัดเลือกนักศึกษาใหม่ หลังจากนั้นการพิจารณาตรวจสอบความลำเอียงของข้อสอบระหว่างผู้สอบกลุ่มย่อยที่มีลักษณะแตกต่างกันในเรื่องเพศ เชื้อชาติ ศาสนาหรือวัฒนธรรม และได้ปฏิบัติกันมาจนปัจจุบัน ซึ่งเป็นเสมือนส่วนหนึ่งของขั้นตอนการพัฒนาแบบทดสอบโดยทั่วไป โดยเฉพาะการพัฒนาแบบทดสอบมาตรฐาน เช่น ศูนย์บริการการทดสอบทางการศึกษา (Education Testing Service) ของประเทศสหรัฐอเมริกา ได้มีการตรวจสอบความลำเอียงทั้งก่อนนำไปทดลองใช้ จะใช้การตรวจสอบโดยผู้เชี่ยวชาญ ซึ่งประกอบด้วยบุคคลหลายฝ่ายตรวจสอบความไว (Sensitivity) ของแบบทดสอบโดยพิจารณาถึงรูปแบบของข้อสอบ เนื้อหา ภาพประกอบ คำที่ใช้ และอื่น ๆ เพื่อไม่ให้มีความลำเอียงหรือเกิดการได้เปรียบเสียเปรียบระหว่างผู้สอบกลุ่มย่อยที่มีลักษณะแตกต่างกัน ส่วนการตรวจสอบความลำเอียงของข้อสอบหลังจากการทดลองใช้นั้นจะใช้วิธีการทางสถิติ

“ความตรง” เป็นหัวใจสำคัญของคุณภาพแบบสอบ ในการสร้างและการตรวจสอบคุณภาพของแบบสอบจะต้องคำนึงถึงคุณภาพด้านความตรงเป็นสำคัญ ทั้งนี้เพราะว่าความตรงเป็นคุณสมบัติของแบบสอบที่แสดงถึงความสามารถในการวัดได้ถูกต้องแม่นยำ ถ้าผลการวัดได้ค่าที่ใกล้เคียงกันของข้อสอบและแบบสอบ ก็เป็นอีกลักษณะหนึ่งของการตรวจสอบคุณภาพด้านความตรง โดยเป็นการตรวจสอบในประเด็นของความยุติธรรมของข้อสอบและแบบสอบ (Item and Test Unfairness)

ความยุติธรรมของข้อสอบ หรือแบบสอบเกิดขึ้นในกรณีที่ผู้สอบกลุ่มย่อยต่างกลุ่มกันและมีลักษณะเฉพาะบางอย่างแตกต่างกัน มีความได้เปรียบหรือเสียเปรียบกันทั้งที่มีความสามารถจริงเท่าเทียมกัน การศึกษาคุณภาพด้านความยุติธรรมของข้อสอบหรือแบบสอบระหว่างผู้สอบกลุ่ม

ต่าง ๆ เริ่มศึกษากันอย่างจริงจังในช่วงปลายทศวรรษของปี ค.ศ. 1960 มีการเสนอวิธีการต่าง ๆ เพื่อตรวจสอบความลำเอียงของข้อสอบ (Item Bias) ความลำเอียงของแบบสอบ (Test Bias) และความลำเอียงในการคัดเลือก (Selection Bias) โดยนิยามความลำเอียงว่าเป็น ความคลาดเคลื่อนอย่างเป็นระบบ (Systematic Error) ที่เกิดขึ้นจากการวัด ความพยายามในการตรวจสอบความลำเอียงดังกล่าวดำเนินไปเพื่อจำแนกข้อสอบที่ทำหน้าที่ไม่เหมาะสมหรือไม่ยุติธรรมสำหรับปรับปรุงหรือตัดข้อสอบข้อนั้นออกจากแบบสอบตาม เป็นการขจัดข้อสอบที่ทำให้เกิดปัญหาความยุติธรรมระหว่างกลุ่มข้อสอบกลุ่มต่าง ๆ ที่มีลักษณะบางอย่างแตกต่างกัน เช่น เชื้อชาติ ศาสนา วัฒนธรรม ภูมิฐานะ สังคม เพศ ภาษา อายุ ประสบการณ์ เป็นต้น เพื่อพัฒนาแบบสอบให้มีคุณภาพเหมาะสมสำหรับนำไปใช้ทดสอบต่อไป

ในเวลาต่อมา นักวัดผลการศึกษา ได้ทำการศึกษาความลำเอียงของข้อสอบกันอย่างกว้างขวาง ทำให้เกิดความสับสนของการใช้คำและความหมาย มีประเด็นโต้แย้งกันว่าความลำเอียงของข้อสอบ เป็นผลการตัดสินว่าข้อสอบมีความยุติธรรมหรือไม่ อันส่งผลต่อการบรรลุจุดมุ่งหมายของการใช้แบบสอบ หรือความลำเอียงของข้อสอบเป็นสารสนเทศทางสถิติที่ได้จากข้อสอบ เกี่ยวกับความสัมพันธ์ระหว่างคุณลักษณะที่ข้อสอบมุ่งวัดกับประสบการณ์ของผู้สอบกลุ่มต่าง ๆ ที่ทำการสอบ เมื่อกลุ่มผู้สอบต่างกลุ่มกันตอบข้อสอบข้อเดียวกัน ความแตกต่างที่เกิดขึ้นอาจมาจากความไม่เหมาะสมของข้อคำถาม ซึ่งสามารถเกิดขึ้นได้หลายลักษณะ หรือประสบการณ์ของผู้สอบซึ่งอาจมีลักษณะพื้นฐานเดิมแตกต่างกัน ในหลายสถานการณ์จึงไม่เหมาะสมที่จะใช้คำว่า ข้อสอบลำเอียง (Biased Item) เนื่องจากเป็นภาษาที่มีความหมายในเชิงลบ ประกอบกับเกณฑ์ที่ใช้สำหรับตัดสินความลำเอียงยังมีความคลุมเครือและค่อนข้างสับสน ดังนั้นจึงควรเปลี่ยนมาใช้คำว่า การทำหน้าที่ต่างกันของข้อสอบ ซึ่งเป็นคำที่มีความเป็นกลางและเหมาะสมกว่า

การทำหน้าที่ต่างกันของข้อสอบกับความลำเอียงของข้อสอบมีแนวคิดที่แตกต่างกัน สำหรับการทำหน้าที่ต่างกันของข้อสอบ เป็นกระบวนการที่เน้นการใช้วิธีการทางสถิติสำหรับตรวจสอบ เพื่อให้ได้สารสนเทศเกี่ยวกับการทำหน้าที่ของข้อสอบสำหรับกลุ่มผู้สอบกลุ่มย่อยที่มีลักษณะเฉพาะบางอย่างแตกต่างกัน ส่วนความลำเอียงของข้อสอบเป็นกระบวนการตัดสินความยุติธรรมของข้อสอบ โดยนำสารสนเทศการทำหน้าที่ต่างกันของข้อสอบมาวิเคราะห์เชิงตรรกะ (Logical Analysis) โดยผู้เชี่ยวชาญพิจารณาถึงการเขียนข้อสอบ เนื้อหาสาระของข้อสอบและจุดมุ่งหมายของการวัด เพื่อระบุว่าข้อสอบข้อนั้นลำเอียงเข้าข้างกลุ่มใดหรือไม่ เพราะเหตุใดจึงเป็นการตัดสินความลำเอียงของข้อสอบ (Camilli & Shapard, 1994)

ความหมายของความลำเอียงและการทำหน้าที่ต่างกันของข้อสอบ

นักวิจัยทางการวัดผลหลายท่านได้ให้ความหมายของความลำเอียงของข้อสอบและการทำหน้าที่ต่างกันของข้อสอบไว้ดังนี้

ความลำเอียงของข้อสอบ หมายถึง สัดส่วนของผู้สอบที่ตอบข้อสอบได้ถูกต้องไม่เท่ากันในแต่ละกลุ่มประชากรที่ใช้ในการศึกษา เมื่อกลุ่มผู้สอบมีคะแนนเท่ากันและข้อสอบมีความเป็นเอกพันธ์ (Scheuneman, 1979)

ความลำเอียงของข้อสอบ หมายถึง ข้อสอบที่มีความยากสัมพัทธ์สำหรับสมาชิกของผู้สอบกลุ่มหนึ่งมากกว่าสมาชิกของผู้สอบอีกกลุ่มหนึ่ง (Rudner, Getson, & Knight, 1980)

ข้อสอบที่มีความลำเอียงด้านวัฒนธรรม หมายถึง ข้อสอบที่ทำให้ผู้สอบซึ่งคุ้นเคยกับวิชาเฉพาะหรือกระบวนการเฉพาะมีโอกาสตอบถูกมากกว่าผู้สอบคนอื่น ๆ ที่มีลักษณะของกลุ่มที่แตกต่างกัน (Eells, 1951 citing Jensen, 1980)

ความลำเอียงของข้อสอบ หมายถึง ความโน้มเอียงของข้อสอบที่เมื่อใช้คะแนนจากข้อสอบนั้นแล้วทำให้การตัดสินใจผลเป็นไปอย่างไม่ยุติธรรม (Popham, 1981)

ความลำเอียงของข้อสอบ หมายถึง โอกาสในการตอบข้อสอบได้ถูกต้องแตกต่างกันสำหรับการวัดความสามารถ หรือโอกาสในการตอบข้อสอบในทางบวกแตกต่างกันสำหรับการวัดเจตคติ เมื่อผู้สอบที่มีคุณลักษณะของการวัดในปริมาณเท่ากัน แต่มาจากกลุ่มประชากรย่อยที่แตกต่างกัน (Hulin, Drasgow, & Parson, 1983)

ความลำเอียงของข้อสอบ หมายถึง โอกาสในการตอบข้อสอบได้ถูกต้องของผู้สอบกลุ่มหนึ่ง มีค่าต่ำกว่าหรือสูงกว่าผู้สอบอีกกลุ่มหนึ่งที่มีระดับความสามารถเดียวกัน (Dorans & Kulick, 1986)

ความลำเอียงของข้อสอบ หมายถึง คะแนนข้อสอบของกลุ่มผู้สอบที่มีความสามารถเท่ากันแต่มาจากต่างกลุ่มกัน มีความแตกต่างกันอย่างเป็นระบบ (Kederman, 1990)

การทำหน้าที่ต่างกันของข้อสอบ หมายถึง สารสนเทศทางสถิติของข้อสอบที่ได้จากผลการตอบของผู้สอบต่างกลุ่มกันและมีความสามารถเท่ากัน แต่มีโอกาสนในการตอบข้อสอบได้ถูกต้องแตกต่างกัน (Holland & Wainer, 1993)

การทำหน้าที่ต่างกันของข้อสอบ หมายถึง ความเป็นพหุมิติในการวัดของข้อสอบ ซึ่งแสดงได้จากการแจกแจงความสามารถหลัก (Primary Ability) ของผู้สอบตั้งแต่ 2 กลุ่มขึ้นไปมีความเท่ากัน แต่มีการแจกแจงความสามารถรอง (Secondary Ability) แตกต่างกัน (Camilli & Shepard, 1994)

การทำหน้าที่ต่างกันของข้อสอบ หมายถึง ฟังก์ชันการตอบสนองข้อสอบซึ่งคำนวณจากกลุ่มผู้สอบย่อยที่ต่างกัน มีค่าไม่เท่ากัน (Naryanan & Swaminathan, 1996)

ข้อสอบทำหน้าที่ต่างกัน เป็นข้อสอบที่วัดความสามารถหรือคุณลักษณะทางจิตวิทยาของแต่ละกลุ่มไม่ตรงกัน (Allen & Yen, 1979 อ้างถึงใน อารี วัชรโสคติกุล, 2543, หน้า 8)

การทำหน้าที่ต่างกันของข้อสอบ หมายถึง ความแตกต่างในการทำหน้าที่ของข้อสอบหลังจากกลุ่มของผู้สอบได้ถูกจับคู่ตามความสามารถหรือคุณลักษณะที่ข้อสอบนั้นวัด (Millsap & Everson, 1993 อ้างถึงใน อารี วัชรโสคติกุล, 2543, หน้า 8)


ดังนั้นจึงสรุปได้ว่า การทำหน้าที่ต่างกันของข้อสอบ หมายถึง การที่ข้อสอบทำให้ผู้สอบจากต่างกลุ่มกันที่มีความสามารถหรือคุณลักษณะที่มุ่งวัดเท่ากัน มีโอกาสในการตอบข้อสอบได้ถูกต้องแตกต่างกัน หรือมีฟังก์ชันการตอบสนองข้อสอบแตกต่างกัน การทำหน้าที่ต่างกันของข้อสอบเกิดขึ้นเมื่อนำข้อสอบไปทดสอบกับผู้สอบกลุ่มย่อยต่างกัน ที่มีความสามารถหลัก (Primary Ability) ระดับเดียวกันหรือมีคุณลักษณะแฝง (Latent Trait) ที่ต้องการวัดเท่ากัน แต่มีความสามารถรอง (Secondary Ability) แตกต่างกัน ทำให้ผู้สอบต่างกลุ่มที่นำมาจับคู่เปรียบเทียบมีโอกาสตอบข้อสอบถูกแตกต่างกัน

ประเภทของการทำหน้าที่ต่างกันของข้อสอบ

การทำหน้าที่ต่างกันของข้อสอบ เป็นการเปรียบเทียบผลการตอบข้อสอบระหว่างกลุ่มผู้สอบอย่างน้อย 2 กลุ่มขึ้นไป ปกตินิยมทำการเปรียบเทียบ 2 กลุ่ม ประกอบด้วยกลุ่มแรก เรียกว่า กลุ่มเปรียบเทียบ (Focal Group หรือกลุ่ม F) เป็นกลุ่มที่สนใจศึกษาและคาดว่าจะจะเป็นกลุ่มที่เสียเปรียบในการตอบข้อสอบ และกลุ่มที่สอง เรียกว่า กลุ่มอ้างอิง (Reference Group หรือกลุ่ม R) เป็นกลุ่มที่คาดว่าจะได้เปรียบในการตอบข้อสอบได้ถูกต้อง

ในการวิเคราะห์การทำหน้าที่ต่างกันของข้อสอบ พบว่า ข้อสอบสามารถทำหน้าที่แตกต่างกันได้ 2 ประเภท (Mellenbergh, 1982) ได้แก่ การทำหน้าที่ต่างกันของข้อสอบแบบเอกรูป (Uniform) และแบบอนเอกรูป (Nonuniform)

1. ข้อสอบทำหน้าที่ต่างกันแบบเอกรูป (Uniform DIF) หมายถึง ข้อสอบที่ทำให้ผู้สอบกลุ่มหนึ่ง มีโอกาสในการตอบข้อสอบถูกมากกว่าผู้สอบอีกกลุ่มหนึ่งสม่ำเสมอ ในทุกระดับความสามารถ เมื่อพิจารณาไค้งคุณลักษณะข้อสอบของผู้สอบ 2 กลุ่ม จะพบว่าไม่มีปฏิสัมพันธ์ระหว่างระดับความสามารถของผู้สอบกับการเป็นสมาชิกกลุ่ม (Group Membership) ดังภาพที่ 1



ภาพที่ 1 ข้อสอบทำหน้าที่ต่างกันแบบเอกรูป (Uniform DIF)

2. ข้อสอบทำหน้าที่ต่างกันแบบอนเอกรูป (Nonuniform DIF) หมายถึง ข้อสอบที่ทำให้

โอกาสในการตอบข้อสอบถูกของผู้สอบระหว่างกลุ่มแตกต่างกันอย่างไม่สม่ำเสมอในทุกระดับความสามารถ เมื่อพิจารณาโค้งลักษณะข้อสอบของผู้สอบ 2 กลุ่ม พบว่ามีปฏิสัมพันธ์ร่วมกันระหว่างระดับความสามารถของผู้สอบกับการเป็นสมาชิกกลุ่ม เช่น ที่ระดับความสามารถอีกระดับหนึ่ง กลุ่มผู้สอบกลุ่ม R มีโอกาสในการตอบข้อสอบถูกมากกว่ากลุ่มผู้สอบกลุ่ม F แต่ที่ระดับความสามารถอีกระดับหนึ่งกลุ่มผู้สอบกลุ่ม F มีโอกาสในการตอบข้อสอบถูกมากกว่ากลุ่มผู้สอบกลุ่ม R

ตามทฤษฎีการตอบสนองข้อสอบ (Item Response Theory: IRT) สามารถพิจารณา


“ปฏิสัมพันธ์” ดังกล่าวได้จากความแตกต่างของค่าพารามิเตอร์อำนาจจำแนกของข้อสอบ ระหว่างผู้สอบกลุ่มย่อยสองกลุ่ม กล่าวคือ ถ้าข้อสอบทำหน้าที่ต่างกันแบบเอกรูปแล้ว โค้งลักษณะข้อสอบ (Item Characteristic Curves: ICCs) ระหว่างผู้สอบกลุ่มย่อยสองกลุ่มจะขนานกัน หรือมีฟังก์ชันการตอบสนองข้อสอบ (Item Response Theory: IRT) เหมือนกัน แต่ถ้าข้อสอบทำหน้าที่ต่างกันแบบอนเอกรูปแล้ว โค้งลักษณะข้อสอบระหว่างผู้สอบกลุ่มย่อยสองกลุ่มจะไม่ขนานกัน หรือมีฟังก์ชันการตอบสนองข้อสอบต่างกัน ดังนั้นความแตกต่างระหว่างโค้งลักษณะข้อสอบทั้งสอง

แบบจะบ่งบอกถึงขนาดและทิศทางของข้อสอบทำหน้าที่ต่างกัน ซึ่งสามารถคำนวณได้โดยใช้สูตรการคำนวณพื้นที่ของ Raju (1990)


ข้อสอบทำหน้าที่ต่างกันแบบอนกรุปสามารถจำแนกได้เป็น 2 ลักษณะ (Swaminathan & Rogers, 1990) ดังนี้

1. ข้อสอบทำหน้าที่ต่างกันแบบอนกรุปโดยมีปฏิสัมพันธ์ไม่เป็นลำดับ (Disordinal Interaction) เป็นการทำหน้าที่ต่างกันสำหรับกลุ่มผู้สอบซึ่งเกิดขึ้น เมื่อโค้งลักษณะข้อสอบตัดกันระหว่างช่วงความสามารถของผู้สอบหรือเรียกว่าข้อสอบทำหน้าที่ต่างกันแบบไม่มีทิศทาง (Non - Directional DIF) ดังภาพที่ 2

2. ข้อสอบทำหน้าที่ต่างกันแบบอนกรุปโดยมีปฏิสัมพันธ์เป็นลำดับ (Ordinal Interaction) เป็นการทำหน้าที่ต่างกันสำหรับกลุ่มผู้สอบซึ่งเกิดขึ้น เมื่อโค้งลักษณะข้อสอบต่างกันอย่างไม่สม่ำเสมอแต่ไม่ตัดกัน หรืออาจตัดกันนอกช่วงความสามารถของผู้สอบตรงปลายสุดของช่วงความสามารถต่ำหรือสูง อาจเรียกข้อสอบลักษณะนี้ว่า ข้อสอบทำหน้าที่ต่างกันแบบมีทิศทางเดียว (Unidirectional DIF) ดังภาพที่ 3



ภาพที่ 2 ข้อสอบทำหน้าที่ต่างกันแบบไม่มีทิศทาง (Non - Directional DIF)



ภาพที่ 3 ข้อสอบทำหน้าที่ต่างกันแบบมีทิศทางเดียวกัน (Unidirectional DIF)

หลักการและวิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ

1. หลักการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ

การตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ เป็นการเปรียบเทียบผลการตอบข้อสอบ เป็นรายข้อระหว่างกลุ่มผู้สอบอย่างน้อย 2 กลุ่ม ที่มีความสามารถหลัก (Primary Ability) หรือความสามารถเป้าหมายที่ต้องการวัดเท่ากัน แต่คาดว่าจะมีความได้เปรียบหรือเสียเปรียบกัน โดยกลุ่มหนึ่งถือเป็นกลุ่มอ้างอิงซึ่งตอบข้อสอบได้ถูกต้องมากกว่า ส่วนอีกกลุ่มคือกลุ่มเปรียบเทียบ ซึ่งเป็นกลุ่มที่สนใจศึกษาและคาดว่าจะน่าจะเป็นกลุ่มที่เสียเปรียบ


ในการเปรียบเทียบผลการตอบข้อสอบระหว่างกลุ่มอ้างอิงและกลุ่มเปรียบเทียบ จำเป็นต้องจับคู่ (Matching) ผู้สอบตามความสามารถ ซึ่งเป็นเงื่อนไขสำคัญของการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ เกณฑ์การจับคู่ (Matching Criteria) ที่นิยมใช้กันมี 2 วิธี ดังนี้

1.1 เกณฑ์ภายนอก (External Criterion)

การวิเคราะห์การทำหน้าที่ต่างกันโดยใช้เกณฑ์ภายนอกนี้ สามารถนำไปใช้ได้ทั้งข้อสอบรายข้อและแบบสอบทั้งฉบับ โดยการใช้คะแนนจากแบบสอบสอบอื่นเป็นเกณฑ์ภายนอก แล้วใช้เทคนิคการวิเคราะห์การถดถอย (Regression Analysis) เพื่อทำการเปรียบเทียบเส้นกราฟความสัมพันธ์ระหว่างตัวแปรเกณฑ์กับตัวแปรทำนาย ระหว่างกลุ่มอ้างอิงและกลุ่มเปรียบเทียบ

หลักการนี้มีจุดมุ่งหมายเพื่อสร้างสมการทำนายตัวแปรเกณฑ์ ซึ่งเป็นคะแนนของแบบสอบอื่นจากตัวแปรทำนายซึ่งเป็นคะแนนรายข้อ หรือคะแนนสอบระหว่างกลุ่มอ้างอิงและกลุ่มเปรียบเทียบ ในการวิเคราะห์การทำหน้าที่ต่างกันของข้อสอบจะใช้คะแนนรายข้อเป็นตัวแปรทำนาย แต่ถ้าวเคราะห์การทำหน้าที่ต่างกันของแบบสอบ จะใช้คะแนนรวมของแบบสอบทั้งฉบับเป็นตัวแปรทำนาย สำหรับตัวแปรเกณฑ์ที่ใช้เป็นเกณฑ์ภายนอก อาจใช้คะแนนรวมทั้งฉบับหรือเกรดเฉลี่ย หรือผลสัมฤทธิ์ในงานที่เกี่ยวข้องของผู้สอบ (Cronbach & Furby, 1970) สมการทำนายสำหรับกลุ่มอ้างอิงและกลุ่มเปรียบเทียบแสดงได้ดังนี้

กลุ่มอ้างอิง (R)	$R_i = A_R + B_R X_i$
กลุ่มเปรียบเทียบ (F)	$Y_i = A_F + B_F X_i$
เมื่อ	$Y_i =$ คะแนนของตัวแปรเกณฑ์ภายนอก
	$X_i =$ คะแนนของตัวแปรทำนาย
	$A =$ ค่าคงที่หรือค่าตัดแกน (Intercept)
	$B =$ ค่าความชัน (Slope)



ภาพที่ 4 การตรวจสอบการทำหน้าที่ต่างกันของข้อสอบและแบบสอบโดยใช้วิธีการวิเคราะห์สมการถดถอย

จากฟังก์ชันการทำนายทั้ง 2 สมการ สามารถเปรียบเทียบค่าตัดแกน (A) และค่าความชัน (B) ของเส้นกราฟระหว่างกลุ่มอ้างอิงและกลุ่มเปรียบเทียบได้ ถ้าเส้นกราฟดังกล่าวมีค่าความชันหรือค่าตัดแกนแตกต่างกันสำหรับข้อสอบใดหรือแบบสอบใด แสดงว่าข้อสอบหรือแบบสอบนั้นมีการทำหน้าที่ต่างกัน โดยเข้าข้างกลุ่มผู้สอบที่มีค่าตัดแกนหรือค่าความชันที่สูงกว่า

การใช้เกณฑ์ภายนอกมีข้อดี คือ เกณฑ์ที่ใช้มีความเป็นอิสระจากข้อสอบและแบบสอบที่ต้องการตรวจสอบ แต่มีจุดอ่อนตรงที่ความเหมาะสมของเกณฑ์ที่จะนำมาใช้ ในทางปฏิบัติเป็นการยากที่จะหาตัวแปรเกณฑ์ภายนอกจากแบบสอบฉบับอื่นที่มีความตรงเชิงทำนาย ซึ่งจะทำให้ผลการวิเคราะห์การทำหน้าที่ต่างกันของข้อสอบหรือแบบสอบ ขาดความแม่นยำและความสมบูรณ์

1.2 เกณฑ์ภายใน (Internal Criterion)

การวิเคราะห์การทำหน้าที่ต่างกันโดยใช้เกณฑ์ภายใน เป็นการนำวิธีการทางสถิติมาตรวจสอบการทำหน้าที่ต่างกันของข้อสอบหรือแบบสอบ โดยเน้นการพิจารณาจากโครงสร้างภายในของแบบสอบเป็นหลัก ด้วยการวิเคราะห์ผลจากการตอบข้อสอบ และความสามารถหรือคะแนนจริงของผู้สอบที่ได้จากแบบสอบฉบับนั้น เพื่อนำมาเปรียบเทียบระหว่างผู้สอบจากกลุ่มอ้างอิงและกลุ่มเปรียบเทียบที่มีความสามารถหรือคะแนนจริงเท่ากันว่าจะมีผลการตอบหรือโอกาสในการตอบข้อสอบได้ถูกต้องแตกต่างกันหรือไม่ เพื่อบ่งชี้ถึงการทำหน้าที่ต่างกันของข้อสอบ การวิเคราะห์ในลักษณะนี้นิยมใช้ค่าสถิติต่าง ๆ เป็นตัวบ่งชี้ถึงการทำหน้าที่ต่างกันของข้อสอบ ค่าสถิติทดสอบที่นิยมนำมาใช้พอสรุปได้ดังนี้

1.2.1 การทดสอบปฏิสัมพันธ์ (Interaction)

ในระยะเริ่มแรกของการศึกษาความลำเอียงของข้อสอบ มีการใช้สถิติทดสอบเอฟ (F-Test) ในการวิเคราะห์ความแปรปรวน เพื่อทดสอบปฏิสัมพันธ์ระหว่างกลุ่มผู้สอบกับข้อสอบ ถ้าการทดสอบมีนัยสำคัญ เป็นสัญญาณของการทำหน้าที่ต่างกันของข้อสอบ (Cleary & Hilton, 1968, Jensen, 1974) จากนั้นจึงทำการวิเคราะห์ต่อด้วยวิธีการ Post Hoc เพื่อระบุข้อสอบที่มีผลต่อการเกิดปฏิสัมพันธ์ซึ่งเป็นข้อที่ทำหน้าที่ต่างกัน

วิธีการนี้มีข้อดีที่สามารถศึกษาผู้สอบหลาย ๆ กลุ่มได้สะดวก แต่มีจุดอ่อนในเรื่องการควบคุมกลุ่มต่าง ๆ ให้มีความสามารถที่ทัดเทียมกัน ขนาดกลุ่มตัวอย่างของกลุ่มต่าง ๆ และอัตราความคลาดเคลื่อนประเภทที่ 1 จะสูงขึ้น ถ้าจำนวนข้อสอบเพิ่มมากขึ้น

1.2.2 การวัดความเบี่ยงเบนสัมพัทธ์ (Relative Deviation)

การคำนวณค่าความยากของข้อสอบ เช่น p, b เป็นต้น เมื่อคำนวณแยกระหว่างกลุ่ม และแปลงให้เป็นค่าความยากมาตรฐาน (Δ) สามารถนำมาพล็อตเปรียบเทียบเป็นรายข้อ ถ้าข้อใดเบี่ยงเบนไปจากเกณฑ์ที่คาดหมาย หรือเบี่ยงเบนเกินความคลาดเคลื่อนมาตรฐานของค่าความยากที่กำหนด ย่อมแสดงถึงการกระทำหน้าที่ต่างกันของข้อสอบ (Cleary & Hilton, 1968; Angoff & Ford, 1973) รวมทั้งสามารถคำนวณค่าสหสัมพันธ์ระหว่างค่าความยากรายข้อระหว่างกลุ่ม เพื่อแสดงถึงการทำหน้าที่ต่างกันของข้อสอบ ถ้าสหสัมพันธ์เข้าใกล้ 1.00 แสดงว่าค่าความ

ยากสัมพันธ์ของข้อสอบมีค่าใกล้เคียงกันระหว่างกลุ่ม ดังนั้นแบบสอบวัดคุณลักษณะคล้ายกันระหว่างกลุ่ม

วิธีการนี้มีข้อดีและข้อเสียคล้ายการทดสอบปฏิบัติสัมพันธ์ นอกจากนี้ค่าความยากของข้อสอบ มีใช้ตัวแทนของค่าความยากจริงของข้อสอบ และได้รับอิทธิพลจากค่าแทรกซ้อนอื่นได้แก่ ค่าอำนาจจำแนกและความสามารถของผู้สอบ

1.2.3 การเปรียบเทียบน้ำหนักตัวประกอบ (Factor Loading)

การวิเคราะห์ตัวประกอบ (Factor Analysis) เป็นเทคนิคทางสถิติที่นิยมใช้ในการตรวจสอบความตรงเชิงทฤษฎีหรือโครงสร้าง (Construct Validity) เมื่อนำการวิเคราะห์ตัวประกอบมาใช้ในการวิเคราะห์โครงสร้างของแบบสอบแยกตามกลุ่มผู้สอบ ความไม่สอดคล้องกันระหว่างน้ำหนักตัวประกอบบนคุณลักษณะสำคัญที่มุ่งวัด หรือความแตกต่างของค่าเฉลี่ยคะแนนตัวประกอบ (Factor Scores) ระหว่างกลุ่มผู้สอบ ย่อมสะท้อนการทำหน้าที่ต่างกันของข้อสอบและแบบสอบ

การใช้เทคนิคการวิเคราะห์ตัวประกอบเชิงสำรวจ (Exploratory Factor Analysis: EFA) สำหรับศึกษาการทำหน้าที่ต่างกันของข้อสอบ จะมีจุดอ่อนในเรื่องความไม่สอดคล้องระหว่างน้ำหนักตัวประกอบ อาจเกิดจากความต้องการของความสามารถระหว่างกลุ่มก็ได้ แนวทางที่เหมาะสมจึงควรใช้เทคนิคการวิเคราะห์ตัวประกอบเชิงยืนยัน (Confirmatory Factor Analysis: CFA) นอกจากนี้ยังสามารถใช้ CFA สำหรับตรวจสอบความแตกต่างระหว่างกลุ่ม ในด้านคุณลักษณะหรือความสามารถหลักและความสามารถรองได้อีกด้วย (Camilli & Shepard, 1994)

1.2.4 การเปรียบเทียบโอกาสตอบข้อสอบถูก

การวิเคราะห์โอกาสตอบข้อสอบถูกของผู้สอบจากกลุ่มอ้างอิงและกลุ่มเปรียบเทียบที่มีความสามารถเท่ากัน เป็นแนวทางสำคัญที่นิยมใช้กันและเป็นที่ยอมรับในปัจจุบัน สำหรับบ่งชี้การทำหน้าที่ต่างกันของข้อสอบ มีการคำนวณค่าสถิติ 2 แนวทางดังนี้

เปรียบเทียบค่าสัดส่วนหรือความน่าจะเป็นในการตอบข้อสอบถูกของผู้สอบต่างกลุ่มที่มีความสามารถเท่ากัน เช่น วิธีแมนเทิล - เฮนส์เชล เป็นต้น

เปรียบเทียบค่าฟังก์ชันการตอบสนองข้อสอบ หรือโค้งลักษณะข้อสอบระหว่างกลุ่มที่มีระดับความสามารถเท่ากัน เป็นวิธีที่อยู่บนพื้นฐานของทฤษฎี IRT เช่น วิธีวัดความแตกต่างของพื้นที่ วิธีวัดความแตกต่างของค่าพารามิเตอร์ความยาก วิธีการทดสอบไค-สแควร์ของลอว์ด์ เป็นต้น

วิธีการนี้มีข้อดีที่สำคัญ ได้แก่ การคำนวณค่าสถิติของข้อสอบมีความน่าเชื่อถือ มีกลไกควบคุมความสามารถของผู้สอบโดยการจับคู่กลุ่มความสามารถ เพื่อทำการเปรียบเทียบ

ณ ตำแหน่งต่าง ๆ ที่มีความสามารถเท่ากัน จึงเป็นวิธีการที่ยอมรับกันทั่วไปแต่มีข้อจำกัดในด้านความสลับซับซ้อนของแนวคิดพื้นฐาน และการวิเคราะห์มีความจำเป็นต้องใช้โปรแกรมคอมพิวเตอร์โดยเฉพาะ

2. วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ

วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ จำแนกตามลักษณะการตรวจให้คะแนนได้เป็น 2 ประเภท คือ ข้อสอบที่มีการตรวจให้คะแนนแบบทวิภาคหรือ 2 ค่า และข้อสอบที่มีการให้คะแนนแบบพหุภาคหรือหลายค่า วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบแต่ละประเภทยังสามารถจำแนกได้อีก 2 มิติ ได้แก่ มิติลักษณะของตัวแปรเกณฑ์ ซึ่งแบ่งเป็นกลุ่มวิธีที่ใช้คะแนนสังเกตได้ และกลุ่มวิธีที่ใช้คะแนนสังเกตไม่ได้หรือคะแนนของตัวแปรแฝง และมีมิติลักษณะของสถิติวิเคราะห์ ซึ่งแบ่งเป็นกลุ่มวิธีที่ใช้สถิติพารามตริก และกลุ่มวิธีที่ใช้สถิตินั้นพารามตริก

2.1 วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบที่ใช้คะแนนแบบทวิภาค

2.1.1 กลุ่มวิธีที่ใช้คะแนนสังเกตได้

วิธีในกลุ่มนี้มักวิเคราะห์ตามทฤษฎีการทดสอบแบบดั้งเดิม หรือกลุ่มที่ไม่ใช้ทฤษฎีการตอบสนองข้อสอบ โดยใช้คะแนนรวมของผู้สอบเป็นเกณฑ์การจับคู่ของกลุ่มข้อสอบ วิธีการตรวจสอบที่สำคัญในกลุ่มนี้ ได้แก่

2.1.1.1 วิธีวิเคราะห์ความแปรปรวน (Cleary & Hilton, 1968)

2.1.1.2 วิธีวิเคราะห์การถดถอยโลจิสติก (Swaminathan & Rogers, 1990)

2.1.1.3 วิธีการแปลงค่าความยากของข้อสอบ (Clear & Hilton, 1968; Angoff & Ford, 1973)

2.1.1.4 วิธีแมนเทล – แฮนส์เซล (Holland & Thayer, 1989)

2.1.1.5 วิธีดัชนีมาตรฐาน การปรับให้เป็นมาตรฐานด้วยน้ำหนักตัวประกอบ (Dorans & Kulick, 1986)

2.1.2 กลุ่มที่ใช้คุณลักษณะแฝง

วิธีในกลุ่มนี้ใช้คุณลักษณะหรือตัวแปรแฝง ซึ่งวิเคราะห์บนพื้นฐานของทฤษฎีการตอบสนองข้อสอบ สำหรับใช้เป็นเกณฑ์การจัดกลุ่มผู้สอบ วิธีการตรวจสอบที่สำคัญในกลุ่มนี้ ได้แก่

2.1.2.1 วิธีวัดพื้นที่ความแตกต่างระหว่างโค้งการตอบสนองข้อสอบ

(Linn et al., 1981; Shepard et al., 1984; Raju, 1990; Kim & Cohen, 1991)

2.1.2.2 วิธีไค – สแควร์ของลอร์ด (Lord, 1980)

2.1.2.3 วิธีอัตราส่วนโลกลีสุดทั่วไป (Thissen, Steinberg, & Wainer, 1993)

2.1.2.4 วิธีอัตราส่วนโลกลีสุด ลอกลีเนียร์ (Loglinear IRT Likelihood Ratio)

(Thissen, Steinberg, & wainer, 1993)

2.1.2.6 วิธีชิปเทสต์ (Shealy & Stout, 1993)

2.2 วิธีการตรวจสอบการทำหน้าที่แตกต่างกันของข้อสอบที่ให้คะแนนแบบพหุวิภาค

2.2.1 กลุ่มวิธีที่ใช้คะแนนสังเกตได้

2.2.1.1 วิธีการวิเคราะห์ความแปรปรวน (Clear & Hilton, 1968)

2.2.1.2 วิธีการวิเคราะห์การถดถอยโลจิสติกพหุวิภาค (Swaminathan &

Rogers, 1990)

2.2.1.3 วิธีคันทิมาตรฐานพหุวิภาค (Dorans & Kulick, 1968)

2.2.1.4 วิธีแมนเทิล-แฮนส์เซิลทั่วไป (Holland & Thayer, 1988, 1989)

2.2.2 กลุ่มที่ใช้คะแนนลักษณะแฝง

2.2.2.1 วิธีอัตราส่วนโลกลีสุดในรูปทั่วไป (Thissen, Steinberg, & Wainer, 1993)

2.2.2.2 วิธีการให้คะแนนบางส่วน (Master, 1982)

2.2.2.3 วิธีชิปเทสต์พหุวิภาค (Shealy & Stout, 1993)

2.2.2.4 วิธีการใช้คะแนนบางส่วนทั่วไป (Muraki, 1992, 1993)

การตรวจสอบการทำหน้าที่ต่างกันของข้อสอบตามแนวคิดของทฤษฎีการตอบสนอง

ข้อสอบ (Item Response Theory)

วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบวิธีนี้ จะพิจารณาเปรียบเทียบฟังก์ชันการตอบข้อสอบ (Item Response Function) หรือเส้นคุณลักษณะข้อสอบ (Item Characteristic Curves) ระหว่างกลุ่มตั้งแต่ 2 กลุ่มขึ้นไปว่ามีความแตกต่างกันหรือไม่

การตรวจสอบการทำหน้าที่ต่างกันของข้อสอบตามแนวคิดทฤษฎีการตอบข้อสอบ มีจุดเด่นกว่าวิธีตามแนวคิดทฤษฎีการทดสอบแบบดั้งเดิม ดังนี้

1. ทฤษฎีการตอบข้อสอบสามารถประมาณค่าพารามิเตอร์ของข้อสอบ เช่น ค่าความยาก (b) ค่าอำนาจจำแนก (a) และค่าการเดา (c) ทำให้ลดความปนกันของพารามิเตอร์ข้อสอบลงได้
2. คุณสมบัติทางสถิติของข้อสอบ (Statistical Properties of Item) สามารถอธิบายได้ละเอียดและชัดเจนกว่า เมื่อข้อสอบทำหน้าที่ต่างกันระหว่าง 2 กลุ่ม
3. คุณสมบัติทางสถิติของข้อสอบ สามารถแสดงด้วยแผนภาพที่เป็นกราฟ ทำให้เข้าใจง่ายและนำไปใช้ได้อย่างกว้างขวาง

การวิเคราะห์การทำหน้าที่ต่างกันของแบบสอบและข้อสอบ

1. แนวคิดพื้นฐานของการวิเคราะห์การทำหน้าที่ต่างกันของแบบสอบ

ถ้าให้ $P_i(\theta_s)$ เป็นความน่าจะเป็นในการตอบข้อสอบข้อที่ i ได้ถูกต้องของผู้สอบคนที่ S ซึ่งมีความสามารถ θ ในกรณีที่เรามีผู้สอบร่วมกัน 2 กลุ่ม ได้แก่ กลุ่มอ้างอิง (R) และกลุ่มเปรียบเทียบ (F) แต่ละกลุ่มทำแบบสอบฉบับเดียวกันซึ่งมีจำนวน k ข้อ เมื่อทำการแยกวิเคราะห์ตามกลุ่ม แต่ละกลุ่มต่างก็มีชุดของค่าพารามิเตอร์ของข้อสอบ (a , b และ c) ซึ่งสามารถคำนวณหาความน่าจะเป็นในการตอบถูกได้ ดังนี้

$P_{iR}(\theta_s)$ = ความน่าจะเป็นในการตอบข้อสอบข้อที่ i ได้ถูกต้อง ของผู้สอบคนที่ S ซึ่งเป็นสมาชิกของกลุ่มอ้างอิงและมีความสามารถ θ

$P_{iF}(\theta_s)$ = ความน่าจะเป็นในการตอบข้อสอบข้อที่ i ได้ถูกต้อง ของผู้สอบคนที่ S ซึ่งเป็นสมาชิกของกลุ่มเปรียบเทียบและมีความสามารถ θ

ตามทฤษฎี IRT เราสามารถคำนวณค่าคะแนนจริง (True Scores) ของผู้สอบคนที่ S ซึ่งมีความสามารถ θ ได้ดังนี้

$$T_S = \sum_{i=1}^K P_i(\theta_s)$$

ผู้สอบแต่ละคนไม่ว่าจะเป็นสมาชิกของกลุ่มใด มี T_S ได้ 2 ค่า ในฐานะสมาชิกของกลุ่ม R และ F จึงคำนวณค่าได้ทั้ง T_{SR} และ T_{SF}

ถ้า $T_{SR} = T_{SF}$ แสดงว่า ผู้สอบ S เป็นอิสระจากกลุ่มสมาชิก ดังนั้นแบบสอบจึงทำหน้าที่ไม่แตกต่างกัน

$T_{SR} \neq T_{SF}$ แสดงว่า การเป็นสมาชิกกลุ่มของผู้สอบคนที่ S มีผลทำให้ T_S แตกต่างกันจึงเป็นสัญญาณของการทำหน้าที่ต่างกันของแบบสอบ

2. การวิเคราะห์การทำหน้าที่ต่างกันของแบบสอบและการทำหน้าที่ต่างกันของข้อสอบ

ราจูและคณะ (Raju et al., 1995) ได้เสนอกระบวนการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบและแบบสอบ (DIF and DTF Procedures) บนพื้นฐานของทฤษฎี IRT มีการคำนวณที่ซับซ้อนแต่ให้ผลที่น่าเชื่อถือ โดยนำวิธีทางสถิติมาใช้ในการตรวจสอบโครงสร้างแบบสอบตามด้วยเกณฑ์ภายใน กระบวนการตรวจสอบประกอบด้วยการคำนวณดัชนีการทำหน้าที่ต่างกัน 2 ระดับ

ได้แก่ ดัชนีการทำหน้าที่ต่างกันระดับแบบสอบ (DTF Index) และดัชนีการทำหน้าที่ต่างกันระดับข้อสอบ (DIF Index)

2.1 ดัชนีการทำหน้าที่ต่างกันระดับข้อสอบ (DIF Index)

$$\text{ถ้าให้ } d_{is} = P_{iR}(\theta_s) - P_{iF}(\theta_s)$$

$$\text{และ } D_s = T_{SR} - T_{SF}$$

ดังนั้นดัชนีการทำหน้าที่ต่างกันของข้อสอบแบบชดเชย (Compensatory DIF Index: CDIF) เป็นดังนี้

$$\begin{aligned} \text{CDIF}_i &= E(d_i, D) \\ &= \text{Cov}(d_i, D) + \mu_{d_i} \mu_D \end{aligned}$$

เมื่อ E = ค่าความคาดหวัง (Expectation)

$\text{Cov}(d_i, D)$ = ความแปรปรวนระหว่างความแตกต่างของคะแนนจะเป็นในการตอบข้อสอบข้อที่ i ได้ถูก กับความแตกต่างของคะแนนจริงระหว่างกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบที่มีค่า θ เท่ากัน

μ_{d_i} = ค่าเฉลี่ยของความแตกต่างของคะแนนจะเป็นในการตอบข้อสอบข้อที่ i ได้ถูกต้อง ระหว่างกลุ่มอ้างอิงและกลุ่มเปรียบเทียบที่มีค่า θ เท่ากัน

μ_D = ค่าเฉลี่ยความแตกต่างของคะแนนจริงระหว่างกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบที่มี θ เท่ากัน

2.2 ดัชนีการทำหน้าที่ต่างกันระดับแบบสอบ (DTF Index)

$$\begin{aligned} \text{DTF} &= E(T_{SR} - T_{SF})^2 \\ &= E(D_s)^2 \\ &= E(D_s)^2 - \mu_D^2 + \mu_D^2 \\ &= \sigma_D^2 + (\mu_{TR} - \mu_{TF})^2 \\ &= \sigma_D^2 + \mu_D^2 \end{aligned}$$

$$\begin{aligned} \text{เมื่อ } D &= T_{SF} - T_{SR} = \sum_{i=1}^K P_{iR}(\theta_s) - \sum_{i=1}^K P_{iF}(\theta_s) \\ &= \sum_{i=1}^K P_{iR}(\theta_s) - \sum_{i=1}^K P_{iF}(\theta_s) \end{aligned}$$

$$\begin{aligned}
 &= \sum_{i=1}^K d_i \\
 \therefore \text{DTF} &= E_f \cdot D^2 \\
 &= E_f \cdot \left(\sum_{i=1}^K d_i \right)^2 \\
 &= \sum_{i=1}^K [\text{cov}(d_i, D) + \mu_{d_i} \mu_D]
 \end{aligned}$$

สาเหตุของการทำหน้าที่ต่างกันของข้อสอบ

สาเหตุที่น่าจะก่อให้เกิดการทำหน้าที่ต่างกันของข้อสอบมีหลายสาเหตุด้วยกัน ซึ่งสามารถสรุปสาเหตุที่ก่อให้เกิดการทำหน้าที่ต่างกันของข้อสอบมากที่สุด ได้ดังนี้

1. การเดา (Guessing) อาจเกิดจากข้อสอบนั้นยากเกินไปหรือเวลาไม่เพียงพอ จะก่อให้เกิดความไม่เท่าเทียมกัน ในโอกาสการตอบข้อสอบถูกของผู้สอบแต่ละคน
 2. ความเร็ว (Speed) หรือเวลาในการตอบ จะทำให้เกิดการเดาหรือในกรณีเวลาน้อย อาจจะทำให้ข้อสอบไม่ทัน ซึ่งจะมีผลกับข้อสอบข้อหลัง ๆ โดยเฉพาะในการศึกษาความลำเอียงของข้อสอบวัดความถนัด
 3. ความกำกวมหรือความไม่ชัดเจน (Unclear) ของข้อคำถาม นั่นคือ ข้อคำถามขาดความเป็นปรนัย การใช้ภาษาที่กำกวมหรือใช้คำที่ไม่เป็นภาษากลางในการสื่อสารความหมาย ซึ่งจะทำให้เกิดความลำเอียงกับกลุ่มภาษาใดภาษาหนึ่งขึ้นได้
 4. ลำดับขึ้นของคำถาม (Series) อาจจะเป็นสิ่งที่ก่อให้เกิดความสับสน หรือชี้แนะคำตอบของข้อสอบบางข้อได้
 5. สถานภาพทางสังคมหรือความเกี่ยวข้องทางสังคม (Social Implication) ก็เป็นสิ่งที่ก่อให้เกิดความแตกต่างระหว่างกลุ่มผู้สอบแต่ละกลุ่มได้
 6. ประสบการณ์หรือการฝึกฝนของแต่ละกลุ่มย่อย เป็นสิ่งที่ก่อให้เกิดการได้เปรียบเสียเปรียบของแต่ละกลุ่มค่อนข้างชัดเจน
 7. องค์ประกอบทางวัฒนธรรม ความเป็นอยู่ ขนบธรรมเนียมประเพณี เชื้อชาติ ศาสนา ก็จะเอื้อให้กับบางกลุ่มย่อย จึงทำให้เกิดการได้เปรียบเสียเปรียบในบางเนื้อหาวิชาได้
- นอกจากนี้การทำหน้าที่ต่างกันของข้อสอบอาจเกิดจากสาเหตุหรือแหล่งที่สำคัญ 2 แหล่งคือ

1. การเลือกเนื้อหา (Bias in Selection) คือผู้สร้างข้อสอบเลือกเนื้อหาเฉพาะส่วนใดส่วนหนึ่งมาสร้างข้อสอบ ทำให้ได้ข้อสอบที่มีเนื้อหาไม่ครอบคลุมและไม่ได้สัดส่วนที่สมดุลกัน

2. การสร้างข้อสอบ (Bias in Construction) คือการใช้ภาษาหรือข้อความบางอย่างที่เอื้อให้เกิดประโยชน์กับผู้สอบกลุ่มใดกลุ่มหนึ่ง

ตอนที่ 2 วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบโดยวิธีชิปเทสท์

วิธีชิปเทสท์ พัฒนาโดยเชยลีและสเตท์ (Shealy & Stout, 1993) เพื่อใช้ตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ การทำหน้าที่ต่างกันของแบบสอบ และการทำหน้าที่ต่างกันของกลุ่มข้อสอบ (Differential Bundle Functioning: DBF) วิธีนี้สามารถวิเคราะห์ได้ทั้งในแบบสอบเอกมิติ และแบบสอบพหุมิติ (Stout, Li, & Nandakumar, 1997) วิธีชิปเทสท์ใช้สถิติ ทดสอบแบบนันทพาราเมตริก ซึ่งพัฒนามาบนพื้นฐานของทฤษฎี IRT ชนิดพหุมิติ แต่ไม่ต้องใช้ฟังก์ชันการตอบสนองข้อสอบหรือการประมาณค่าความสามารถแฝง วิธีชิปเทสท์ถูกออกแบบมาสำหรับการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบแบบมีทิศทางเดียว ดังนั้นจึงไม่มีความไวในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบแบบไม่มีทิศทาง (Li & Stout, 1996) จุดเด่นของวิธีชิปเทสท์ คือ สามารถคำนวณได้ง่ายไม่ซับซ้อน ประหยัดค่าใช้จ่าย และไม่จำเป็นต้องใช้กลุ่มตัวอย่างที่มีขนาดใหญ่ ทั้งยังใช้สถิติทดสอบนัยสำคัญ (Narayanan & Swaminathan, 1996) นอกจากนี้ยังสามารถนำไปประยุกต์ใช้กับการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ ที่มีการให้คะแนนแบบพหุวิภาค (Polytomous DIF) (Chang, Mazzeo, & Roussos, 1995)

ในการศึกษาการทำหน้าที่ต่างกันของข้อสอบด้วยวิธีชิปเทสท์ของแบบสอบเอกมิติถือว่าข้อสอบในแบบสอบจะต้องมุ่งวัดคุณลักษณะ หรือความสามารถแฝงเพียงลักษณะเดียว ความสามารถแฝงสามารถจำแนกเป็นความสามารถเป้าหมายที่ต้องการวัด (θ) กับความสามารถแทรกซ้อนที่ไม่ใช่เป้าหมายของการวัด (η) ตัวอย่าง เช่น แบบสอบคำศัพท์ในวิชาภาษาอังกฤษ ข้อสอบบางข้ออาจถามความรู้สำหรับผู้ชายเป็นพิเศษ เช่น ความรู้เกี่ยวกับกีฬา ในขณะที่ข้อสอบบางข้ออาจถามความรู้เกี่ยวกับผู้หญิงโดยเฉพาะ เช่น ความรู้เกี่ยวกับงานในบ้าน จากสถานการณ์ดังกล่าวทักษะความรู้เกี่ยวกับคำศัพท์ในวิชาภาษาอังกฤษ เป็นความสามารถเป้าหมายที่ต้องการวัด (θ) ส่วนความรู้ทางด้านกีฬาและงานในบ้านเป็นความสามารถแทรกซ้อน ที่ไม่ใช่เป้าหมายของการวัด (η_1 และ η_2) ข้อสอบทุกข้อในแบบสอบจะวัดความสามารถเป้าหมาย ส่วนข้อสอบบางข้อทำหน้าที่ต่างกันจะวัดทั้งความสามารถเป้าหมาย และความสามารถแทรกซ้อน (Nandakumar, 1993)

ถ้าให้ฟังก์ชันการตอบสนองข้อสอบ (IRF) ข้อที่ i ซึ่งขึ้นอยู่กับความสามารถ θ เพียงอย่างเดียวแทนด้วย $P_i(\theta)$ ส่วน IRF ข้อที่ i ที่ขึ้นอยู่กับความสามารถทั้ง θ และ η แทนด้วย

$P_i(\theta, \eta)$ ฟังก์ชันการตอบสนองข้อสอบของข้อสอบดังกล่าวแบบ 3 พารามิเตอร์จะเป็นดังนี้ (Shealy & Stout, 1993)

$$P_i(\theta) = c_i + \frac{(1 - c_i)}{1 + \exp[-1.7a_{i\theta}(\theta - b_{i\theta})]}, \quad i = 1, \dots, N$$

$$P_i(\theta, \eta) = c_i + \frac{(1 - c_i)}{1 + \exp\{-1.7[a_{i\theta}(\theta - b_{i\theta}) + a_{i\eta}(\eta - b_{i\eta})]\}}, \quad i = 1, \dots, N$$

ดังนั้นฟังก์ชันความน่าจะเป็นอย่างมีเงื่อนไขของแบบแผนการตอบข้อสอบทั้งฉบับเป็นดังนี้

$$P[U/(\Theta = \theta, \eta = \eta)] = \prod_{i=1}^N P_i(\theta, \eta)^{u_i} [1 - P_i(\theta, \eta)]^{1-u_i}$$

เชียลและสตาท์ (Shealy & Stout, 1993) ได้ใช้ Marginal IRFs อธิบายการทำหน้าที่ต่างกันของข้อสอบ ดังนี้

$$M_{ig}(\theta) = \int_{\eta} P_i(\theta, \eta) f_g(\eta | \theta) d\eta$$

เมื่อ $M_{ig}(\theta)$ = Marginal IRF สำหรับความสามารถเป้าหมาย θ ที่ต้องการวัดของผู้สอบกลุ่มอ้างอิงหรือกลุ่มเปรียบเทียบ

$P_i(\theta, \eta)$ = IRF ของข้อสอบข้อที่ i

$f_g(\eta | \theta)$ = การแจกแจงแบบมีเงื่อนไขของกลุ่มผู้สอบ

การเปรียบเทียบ Marginal IRF ระหว่างกลุ่มอ้างอิง (R) กับกลุ่มเปรียบเทียบ (F) จะทำให้ทราบถึงทิศทางของการได้เปรียบหรือเสียเปรียบ กล่าวคือ ถ้า $M_{iF}(\theta) < M_{iR}(\theta)$ ทุกค่าของ θ แสดงว่า ข้อสอบทำหน้าที่ต่างกันแบบมีทิศทางเดียว โดยข้อสอบจะเข้าข้างผู้สอบกลุ่มอ้างอิงและถ้า $M_{iF}(\theta) > M_{iR}(\theta)$ ทุกค่าของ θ แสดงว่าข้อสอบทำหน้าที่ต่างกันแบบมีทิศทางเดียว โดยข้อสอบจะเข้าข้างผู้สอบกลุ่มเปรียบเทียบ การทำหน้าที่ต่างกันของข้อสอบแบบมีทิศทางเดียวอาจเรียกอีกอย่างหนึ่งว่า “การทำหน้าที่ต่างกันแบบไม่ตัดกัน” (Noncrossing DIF)

ในการเปรียบเทียบผลการตอบข้อสอบระหว่างกลุ่มอ้างอิงและกลุ่มเปรียบเทียบตามวิธีชิปเทสท์ จะแบ่งข้อสอบออกเป็น 2 ชุดย่อย (Subtests) คือ (1) ชุดแบบสอบที่มีความตรง (Valid Subtests) หรือชุดแบบสอบที่ใช้ในการจับคู่เปรียบเทียบ (Matching Subtests) แบบสอบชุดนี้ประกอบด้วยข้อสอบที่ไม่ทำหน้าที่ต่างกัน และ (2) ชุดแบบสอบที่ต้องการศึกษา (Studied Subtests)

ประกอบด้วยข้อสอบที่สงสัยว่าทำหน้าที่ต่างกัน ถ้าแบบสอบชุดแรกมีจำนวน n ข้อ (ข้อที่ 1 ถึง n) แล้วแบบสอบชุดที่ 2 จะมีจำนวน $N-n$ ข้อ (ข้อที่ $n+1$ ถึง N) เมื่อ N เป็นจำนวนข้อสอบทั้งหมด

ฟังก์ชันการตอบสนองข้อสอบของแบบสอบที่ต้องการศึกษา จากผู้สอบกลุ่มอ้างอิงและกลุ่มเปรียบเทียบ กำหนดในรูปฟังก์ชัน Marginal ดังนี้

$$M_{SR}(\theta) = \sum_{i=n+1}^N M_{iR}(\theta)$$

$$M_{SE}(\theta) = \sum_{i=n+1}^N M_{iE}(\theta)$$

เมื่อ $M_{SR}(\theta)$ = ผลรวมของ Marginal IRFs ของข้อสอบที่ต้องการศึกษาจากผู้สอบกลุ่มอ้างอิง ณ ระดับความสามารถ θ

$M_{SE}(\theta)$ = ผลรวมของ Marginal IRFs ของข้อสอบที่ต้องการศึกษาจากผู้สอบกลุ่มเปรียบเทียบ ณ ระดับความสามารถ θ

ขนาดของความแตกต่างระหว่าง $M_{SR}(\theta)$ และ $M_{SE}(\theta)$ แสดงถึงปริมาณความเข้มของการทดสอบการทำหน้าที่ต่างกันของข้อทดสอบแบบมีทิศทางเดียว หรือการทำหน้าที่แบบไม่คัดค้านจากชุดแบบสอบถามที่ต้องการศึกษา ณ ระดับความสามารถ θ ซึ่งสามารถคำนวณตลอดช่วงความสามารถ θ ของผู้สอบ ด้วยการอินทิเกรต ดังนี้

$$\beta_{uni} = \int_{\theta} [M_{SR}(\theta) - M_{SE}(\theta)] f_p(\theta) d\theta$$

เมื่อ β_{uni} = ดัชนีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบแบบมีทิศทางเดียว

$f_p(\theta)$ = ฟังก์ชันความหนาแน่นของโอกาสการแจกแจงความสามารถ θ ของผู้สอบทั้ง 2 กลุ่ม

ดัชนี β_{uni} ที่คำนวณได้จากสูตรดังกล่าว นำมาทดสอบสมมติฐานของการทำหน้าที่ต่างกันของข้อสอบแบบมีทิศทางเดียว ดังนี้

$$H_0 : \beta_{uni} = 0$$

$$H_1 : \beta_{uni} > 0$$

สมมติฐานอื่น (H_1) มีลักษณะทิศทางเดียว ซึ่งใช้ทดสอบการทำหน้าที่ต่างกันของข้อสอบที่เข้าข้างผู้สอบกลุ่มอ้างอิง สำหรับค่าประมาณของ β_{uni} คำนวณได้จากคะแนนรวมของชุดแบบสอบที่มีความตรงและชุดแบบสอบที่ต้องการศึกษา ซึ่งกำหนดด้วยสัญลักษณ์ ดังนี้

$$X = \sum_{i=1}^n U_i$$

$$Y = \sum_{i=n+1}^N U_i$$

เมื่อ $X =$ คะแนนรวมของชุดแบบสอบที่มีความตรง
 $Y =$ คะแนนรวมของชุดแบบสอบที่ต้องการศึกษา
 $U_i =$ ผลการตอบข้อสอบข้อที่ i (ตอบถูกได้ 1 คะแนน และตอบผิดได้ 0 คะแนน)

นำคะแนนรวมของชุดแบบสอบที่มีความตรง (X) เป็นเกณฑ์ในการจับคู่ผู้ที่มีความสามารถระดับเดียวกัน แล้วคำนวณคะแนนเฉลี่ยรายข้อจากผลการตอบข้อสอบชุดแบบสอบที่ต้องการศึกษา ระหว่างผู้สอบกลุ่มอ้างอิงและกลุ่มเปรียบเทียบที่มีความสามารถระดับเดียวกันมาจับคู่เปรียบเทียบกัน ณ $X = k$ โดยเขียนในรูปสัญลักษณ์ได้ ดังนี้

$$\bar{Y}_{Rk} - \bar{Y}_{Tk} \quad ; \quad k = 0, 1, 2, \dots, n$$

เมื่อ $\bar{Y}_{Rk} =$ ค่าเฉลี่ยของคะแนนรายข้อจากชุดแบบสอบที่ต้องการศึกษาของผู้สอบกลุ่มอ้างอิง ซึ่งได้คะแนน $X = k$
 $\bar{Y}_{Tk} =$ ค่าเฉลี่ยของคะแนนรายข้อจากชุดแบบสอบที่ต้องการศึกษาของผู้สอบกลุ่มเปรียบเทียบ ซึ่งได้คะแนน $X = k$
 $k =$ คะแนนรวมจากชุดแบบสอบถามที่มีความตรง

ค่า $\bar{Y}_{Rk} - \bar{Y}_{Tk}$ ดังกล่าวเป็นความแตกต่างของผลการตอบข้อสอบในชุดแบบสอบที่ต้องการศึกษาระหว่างผู้สอบกลุ่มอ้างอิง และกลุ่มเปรียบเทียบที่มีความสามารถระดับเดียวกัน ถ้า $\bar{Y}_{Rk} - \bar{Y}_{Tk} = 0$ ทุกคะแนน k แสดงว่า ข้อสอบที่ต้องการศึกษาทำหน้าที่ไม่ต่างกัน แต่ถ้า $\bar{Y}_{Rk} - \bar{Y}_{Tk} > 0$ ทุกคะแนน k แสดงว่า ข้อสอบทำหน้าที่ต่างกันแบบมีทิศทางเดียว โดยจะเข้าข้างผู้สอบกลุ่มอ้างอิง ค่าความแตกต่างของผลการตอบข้อสอบสามารถประมาณค่าในรูป β_{uni} ได้ดังนี้

$$\hat{\beta}_{uni} = \sum_{k=0}^n \hat{P}_k (\bar{Y}_{Rk} - \bar{Y}_{Tk})$$

โดยที่
$$\hat{P}_k = \frac{(J_{Rk} + J_{Fk})}{\sum_{k=0}^n (J_{Rk} + J_{Fk})}$$

เมื่อ P_k = สัดส่วนของจำนวนผู้สอบกลุ่มเปรียบเทียบและกลุ่มอ้างอิงที่ได้คะแนนรวม $X = k$ จากจำนวนผู้สอบทั้งหมด

J_{Fk} = จำนวนผู้สอบกลุ่มเปรียบเทียบที่ได้คะแนนรวม $X = k$

J_{Rk} = แทนจำนวนผู้สอบกลุ่มอ้างอิงที่ได้คะแนนรวม $X = k$

สำหรับการทดสอบสมมติฐานศูนย์ของ no DIF ใช้สถิติ β_{uni} ดังนี้

$$\beta_{uni} = \frac{\hat{\beta}_{uni}}{\sigma(\hat{\beta}_{uni})}$$

โดยที่
$$\hat{\sigma}(\hat{\beta}_{uni}) = \sqrt{\sum_{k=0}^n \hat{P}_k^2 \left[\frac{1}{J_{Rk}} \hat{\sigma}^2(Y|k, R) + \frac{1}{J_{Fk}} \hat{\sigma}^2(Y|k, F) \right]}$$

เมื่อ $\sigma(\beta_{uni})$ = ค่าประมาณความคลาดเคลื่อนมาตรฐานของ β_{uni}

$\sigma^2(Y|k, g)$ = ค่าประมาณความแปรปรวนของคะแนนจากชุดแบบสอบที่ต้องการศึกษา สำหรับผู้สอบกลุ่ม g (R หรือ F) ซึ่งมีคะแนนรวมเท่ากับ k

J_{gk} = จำนวนผู้สอบกลุ่ม g (R หรือ F) ซึ่งตอบชุดแบบสอบที่มีความตรงแล้วได้คะแนนรวม $X = k$

β_{uni} มีการแจกแจงในลักษณะปกติมาตรฐาน $[N(0,1)]$ จึงสามารถทดสอบนัยสำคัญด้วยสถิติทดสอบ Z ถ้าผลการทดสอบปรากฏว่า $\beta_{uni} > Z_\alpha$ แสดงว่าการทดสอบมีนัยสำคัญจึงปฏิเสธ H_0 นั่นคือ ข้อสอบที่นำมาตรวจสอบทำหน้าที่ต่างกัน โดยจะเข้าข้างผู้สอบกลุ่มอ้างอิง เมื่อ β_{uni} มีค่าเป็นบวก และจะเข้าข้างผู้สอบกลุ่มเปรียบเทียบเมื่อ β_{uni} มีค่าเป็นลบ

สถิติที่ใช้ในการทดสอบสำหรับสรุปอ้างอิงการทำหน้าที่ต่างกันของข้อสอบดังกล่าว มักจะมีปัญหาในกรณีที่มีความแตกต่างของการแจกแจงความสามารถเป้าหมาย ระหว่างกลุ่มผู้สอบ กล่าวคือ ถ้าผู้สอบกลุ่มอ้างอิงมีความสามารถเป้าหมายสูงกว่าผู้สอบกลุ่มเปรียบเทียบ จะเกิดผลกระทบทำให้สถิติ β_{uni} มีค่าเพ้อ (Inflate) หรือมีค่าสูงผิดปกติ ถึงแม้ว่าในความเป็นจริงข้อสอบทำหน้าที่ไม่ต่างกัน จึงควรแก้ไขความแตกต่างของการแจกแจงความสามารถเป้าหมาย ด้วยการ

ปรับแก้ค่าความถดถอย เพื่อจัดผลกระทบดังกล่าวโดยปรับแก้ค่า $\bar{Y}_{Rk}$ และ $\bar{Y}_{I,k}$ เป็นรายฤดู ก่อนการคำนวณ β_{uni}

ตอนที่ 3 งานวิจัยที่เกี่ยวข้องกับการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ โดยวิธีชิปเทสต์

วิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบมีวิวัฒนาการมาเป็นเวลานาน โดยพยายามแก้ไขข้อบกพร่องของวิธีการที่มีมาก่อน ประกอบกับความก้าวหน้าของเทคโนโลยีคอมพิวเตอร์ ทำให้มีการพัฒนาวิธีการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบหลายวิธี และได้มีผลการศึกษาค้นคว้าวิจัยโดยใช้ข้อมูลจำลองจำนวนมาก เพื่อหลีกเลี่ยงข้อจำกัดบางประการของข้อมูลเชิงประจักษ์ งานวิจัยที่เกี่ยวข้องกับการทำหน้าที่ต่างกันของข้อสอบมีดังนี้

กาญจนา วัฒนสุนทร (2538) ได้พัฒนาเกณฑ์ในการตัดสินข้อสอบลำเอียงทางเพศ โดยใช้ข้อมูลเชิงประจักษ์ จากการสุ่มคัดเลือกเข้าระดับอุดมศึกษาปีการศึกษา 2535 ใช้วิธีการตรวจสอบ 3 วิธี คือ วิธีตามแนวคิดทฤษฎีการตอบข้อสอบ วิธีแมนเทิลและแฮนส์เซล และวิธีชิปเทสต์ ดัชนีที่พัฒนาเพื่อเป็นเกณฑ์ในการตัดสินข้อสอบลำเอียงคือ SA , UA , α_{MH} , β_{SIB} ตามลำดับซึ่งในการวิจัยครั้งนี้ได้จากการวิเคราะห์ค่าเฉลี่ยของดัชนีแต่ละตัว ตัวแปรที่ใช้ในการศึกษา ได้แก่ ความยาวของแบบทดสอบขนาด 20, 30, 40 ข้อ สำหรับวิชาคณิตศาสตร์ และ 50, 60, 70 และ 80 ข้อ สำหรับวิชาภาษาอังกฤษ ขนาดกลุ่มตัวอย่างผู้ตอบข้อสอบ 100, 200, 400, 600, 800 และ 1,000 คน ผลการวิจัย พบว่า ขนาดผู้ตอบข้อสอบมีอิทธิพลต่อค่าเฉลี่ยของดัชนีทุกตัว ความยาวของแบบทดสอบมีผลต่อค่าเฉลี่ยของดัชนี SA และ UA แต่ไม่มีอิทธิพลต่อค่าเฉลี่ยของดัชนี α_{MH} และ β_{SIB} เกณฑ์ที่พัฒนาขึ้นเพื่อใช้ตัดสินความลำเอียง ระหว่างผู้ตอบข้อสอบเพศหญิงและเพศชาย มีดังนี้

1. $|SA| > .80$ และ $UA > .50$ เมื่อความยาวแบบทดสอบน้อยกว่า 50 ข้อ
2. $|SA| > .40$ และ $UA > 1.20$ เมื่อความยาวแบบทดสอบ 50 ข้อ ขึ้นไป
3. $\alpha_{MH} > .60$ และ $\alpha_{MH} < 1.40$ สำหรับทุกขนาดของผู้ตอบข้อสอบและความยาวแบบทดสอบ

4. $|\beta_{SIB}| > .06$ สำหรับทุกขนาดผู้ตอบข้อสอบ และความยาวแบบทดสอบ

ทั้งนี้ในการใช้ดัชนี SA หรือ UA ควรใช้ผู้ตอบข้อสอบขนาด 800 คนขึ้นไป ส่วนดัชนี

α_{MH} และ β_{SIB} ควรใช้ผู้ตอบข้อสอบอย่างน้อย 600 คน

จิตติมา วรณศรี (2539) ได้เปรียบเทียบประสิทธิภาพการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบระหว่างวิธีแมนเทิล - แฮนส์เซลและวิธีชิปเทสต์ โดยศึกษาจากข้อมูลจำลอง ตัวแปรที่ศึกษาได้แก่ ความยาวของแบบทดสอบ 3 ขนาด คือ 30, 60 และ 90 ข้อ ขนาดกลุ่มตัวอย่าง 3 ขนาด คือ 200, 600 และ 1,000 คน โดยแต่ละขนาดมีอัตราส่วนระหว่างผู้เข้าสอบกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบต่างกัน คือ 1:1, 1: 0.9, 1:0.75 และ 1:0.5 ผลการศึกษาปรากฏว่า วิธีแมนเทิล - แฮนส์เซลและวิธีชิปเทสต์มีประสิทธิภาพเท่าเทียมกัน ในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบในทุกขนาดกลุ่มตัวอย่างและทุกอัตราส่วนภายใต้ความยาวของแบบทดสอบเดียวกัน และเมื่อใช้แบบทดสอบที่มีความยาวปานกลาง (60 ข้อ) ทั้งสองสามารถตรวจสอบได้อย่างมีประสิทธิภาพที่สุด นอกจากนี้เมื่อใช้ขนาดกลุ่มตัวอย่างมากขึ้นจะสามารถตรวจสอบข้อสอบทำหน้าที่ต่างกันได้ถูกต้องมากขึ้น โดยส่วนมากวิธีชิปเทสต์มีอัตราความคลาดเคลื่อนประเภทที่ 1 มากกว่าวิธีแมนเทิล-แฮนส์เซลเล็กน้อย

พรรณี จินตมาศ (2540) ได้ศึกษาผลการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบกับเพศ จากแบบทดสอบคณิตศาสตร์โจทย์ปัญหาที่ผู้วิจัยสร้างขึ้นเอง โดยใช้วิธีวิเคราะห์การทำหน้าที่ต่างกันของข้อสอบ 3 วิธี คือ วิธีแปลงค่าความยาก วิธีแมนเทิล - แฮนส์เซลและวิธีชิปเทสต์ ในขนาดกลุ่มผู้เข้าสอบ 500 คน และขนาดกลุ่มผู้เข้าสอบ 1,000 คน โดยเปรียบเทียบจำนวนข้อสอบทำหน้าที่ต่างกัน และเปรียบเทียบค่าความเที่ยงแบ่งครึ่งฉบับของแบบทดสอบหลังคัดเลือกข้อสอบทำหน้าที่ต่างกันออกแล้ว กลุ่มตัวอย่างเป็นนักเรียนชั้นมัธยมศึกษาปีที่ 1 ภาคเรียนที่ 2 ปีการศึกษา 2539 ของโรงเรียนสังกัดกรมสามัญศึกษาส่วนกลางจำนวน 2,200 คน ซึ่งได้มาโดยการสุ่มแบบชั้น มีขนาดโรงเรียนเป็นชั้นและโรงเรียนเป็นหน่วยการสุ่ม ผลการศึกษาปรากฏว่าเมื่อวิเคราะห์จากกลุ่มผู้เข้าสอบขนาด 500 คน วิธีชิปเทสต์พบข้อสอบทำหน้าที่ต่างกันมากที่สุด และวิธีแปลงค่าความยากพบข้อสอบทำหน้าที่ต่างกันน้อยที่สุด โดยจำนวนข้อสอบทำหน้าที่ต่างกันแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติทุกวิธีวิเคราะห์ และเมื่อวิเคราะห์จากกลุ่มผู้เข้าสอบ 1,000 คน วิธีแมนเทิล - แฮนส์เซล พบข้อสอบทำหน้าที่ต่างกันมากที่สุด วิธีแปลงค่าความยากไม่พบข้อสอบทำหน้าที่ต่างกัน โดยจำนวนข้อสอบทำหน้าที่ต่างกัน จากการวิเคราะห์ด้วยวิธีแปลงค่าความยากกับวิธีแมนเทิล - แฮนส์เซล และวิธีแปลงค่าความยากกับวิธีชิปเทสต์แตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ .05 นอกนั้นแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ สำหรับจำนวนข้อสอบทำหน้าที่ต่างกัน จากการวิเคราะห์ด้วยวิธีแปลงค่าความยาก ระหว่างกลุ่มผู้เข้าสอบ 500 คนและขนาดกลุ่มผู้เข้าสอบ 1,000 คน จะมีจำนวนข้อสอบทำหน้าที่ต่างกันแตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ .05 นอกนั้นมีความแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ

วลีมาศ แซ่อึ้ง (2543) เปรียบเทียบอำนาจการทดสอบและอัตราความคลาดเคลื่อน

ประเภทที่ 1 ในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบอนุกรม ระหว่างวิธีซิปปเทสท์ปรับปรุงใหม่ และวิธีการถดถอยโลจิสติก โดยการศึกษาจำลองด้วยโมเดลโลจิสติกชนิด 3 พารามิเตอร์ ในเงื่อนไขต่าง ๆ 324 เงื่อนไข ผลการศึกษาพบว่าอำนาจการทดสอบของวิธีซิปปเทสท์ปรับปรุงใหม่และวิธีการถดถอยโลจิสติกมีค่าเท่าเทียมกันทุกเงื่อนไข และทั้งสองวิธีดังกล่าวมีอำนาจการทดสอบสูงกว่าวิธีซิปปเทสท์และแมนเทล - แฮนส์เซลเกือบทุกเงื่อนไข อัตราความคลาดเคลื่อนประเภทที่ 1 ที่ตรวจสอบด้วยวิธีการทั้ง 4 ข้างต้น มีค่าอยู่ภายในเกณฑ์ของอัตราความคลาดเคลื่อน ที่ระดับ 10 % เกือบทุกเงื่อนไข

นารายานาน และสวามิธาน (Narayanan & Swaminathan, 1994, pp. 315- 328 อ้างถึงใน อารี วัชร โสคติกุล, 2543, หน้า 28) ได้เปรียบเทียบผลการวิเคราะห์การทำหน้าที่ต่างกันของข้อสอบแบบอนุกรม ด้วยวิธีแมนเทล - แฮนส์เซลและวิธีซิปปเทสท์ โดยใช้ข้อมูลที่ทำลองภายใต้เงื่อนไข 1,296 เงื่อนไข ($9 \times 3 \times 2 \times 4 \times 6$) แล้วคำนวณซ้ำ 100 ครั้ง แต่ละเงื่อนไขประกอบด้วย

1. ขนาดกลุ่มตัวอย่างที่แตกต่างกัน 3 ขนาด คือกลุ่มเปรียบเทียบใช้ขนาด 100, 200 และ 300 คน กลุ่มอ้างอิงใช้ขนาด 300, 500 และ 1,000 คน วางไว้กันได้กลุ่มตัวอย่างทั้งหมด 9 กลุ่ม
2. ความแตกต่างในการแจกแจงความสามารถ 3 ระดับ ระดับที่ 1 ให้ทั้ง 2 กลุ่ม มีค่าเฉลี่ยการแจกแจงความสามารถที่ 0.0 ระดับที่ 2 ให้ค่าเฉลี่ยของความสามารถในกลุ่มอ้างอิงและกลุ่มเปรียบเทียบเป็น 0.0 และ 0.5 ตามลำดับ และระดับที่ 3 ค่าเฉลี่ยของความสามารถในกลุ่มอ้างอิงและเปรียบเทียบเป็น 0.0 และ -1.0 ตามลำดับ ส่วนเบี่ยงเบนมาตรฐานของทั้ง 3 ระดับเป็น 1.0
3. ร้อยละของข้อสอบทำหน้าที่ต่างกันมี 2 ขนาด คือ ร้อยละ 10 และ ร้อยละ 20 จากแบบทดสอบจำนวน 40 ข้อ
4. ขนาดอิทธิพลของข้อสอบทำหน้าที่ต่างกัน 4 ระดับ คือ 0.4, 0.6, 0.8 และ 1.0
5. ลักษณะของข้อสอบ 6 ระดับ (ลักษณะ b ต่ำกับ a ปานกลาง, b ต่ำกับ a สูง, b ปานกลางกับ a ต่ำ, b ปานกลางกับ a สูง, b สูงกับ a ต่ำ, b สูงกับ a ปานกลาง)

ผลการศึกษาปรากฏว่า วิธีแมนเทล-แฮนส์เซล และวิธีซิปปเทสท์สามารถตรวจพบข้อสอบทำหน้าที่ต่างกันได้ใกล้เคียงกัน โดยตรวจพบได้ดีในขนาดกลุ่มตัวอย่าง 600 คน (กลุ่มอ้างอิงและกลุ่มเปรียบเทียบกลุ่มละ 300 คน) ขนาดของข้อสอบทำหน้าที่ต่างกันทั้ง 4 ขนาดมีผลต่อการตรวจพบการทำหน้าที่ต่างกันของข้อสอบทั้งสองวิธี อย่างมีนัยสำคัญทางสถิติ ความแตกต่างในการแจกแจงความสามารถไม่มีผลต่อวิธีการวิเคราะห์การทำหน้าที่ต่างกันโดยวิธีซิปปเทสท์ แต่มีผลต่อวิธีแมนเทล-แฮนส์เซล ที่เป็นเช่นนี้อาจเป็นเพราะวิธีซิปปเทสท์ได้มีการปรับแก้การถดถอยขนาดของแบบทดสอบและร้อยละของข้อสอบทำหน้าที่ต่างกันไม่มีผลต่อวิธีทั้งสอง สำหรับการ

เกิดความคลาดเคลื่อนแบบที่ 1 วิธีแมนเทิล-แฮนส์เซล จะมีอัตราการเกิดอยู่ในระดับปกติ แต่วิธีชิปเทสต์จะเพิ่มเล็กน้อยในกลุ่มที่มีความสามารถเท่ากัน แต่ในกลุ่มที่มีความสามารถไม่เท่ากันการเกิดความคลาดเคลื่อนแบบที่ 1 จะมีอัตราเกิดสูงขึ้นทั้งสองวิธี ซึ่งการเพิ่มความยาวของแบบทดสอบจะทำให้เกิดความเที่ยงสูงขึ้น มีผลให้ความคลาดเคลื่อนประเภทที่ 1 น่าจะมีอัตราการเกิดลดลง

นารายานันและสวามินาธาน (Narayanan & Swaminathan, 1996, หน้า 257-274 อ้างถึงใน นุชริน ใบโพธิ์, 2544, หน้า 46) ได้เปรียบเทียบการทำหน้าที่ต่างกันของข้อสอบแบบอนเกรุปด้วยวิธีแมนเทิล - แฮนส์เซล วิธีถดถอยโลจิสติกและวิธีชิปเทสต์ โดยศึกษาอำนาจการตรวจสอบและการจำแนกผิดพลาดโดยการจำลองข้อมูล ตัวแปรที่ศึกษา ได้แก่ ขนาดกลุ่มตัวอย่าง ความแตกต่างของการกระจายความสามารถระหว่างกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบ สัดส่วนของข้อสอบทำหน้าที่ต่างกันที่มีภายในแบบทดสอบ ขนาดพื้นที่ระหว่างโค้งลักษณะข้อสอบของผู้เข้าสอบสองกลุ่ม ค่าความยากและค่าอำนาจจำแนกของแบบทดสอบ ผลการศึกษาปรากฏว่าวิธีชิปเทสต์และวิธีถดถอยโลจิสติก มีประสิทธิภาพในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบแบบอนเกรุปได้เท่าเทียมกันในทุกเงื่อนไขที่ศึกษา ส่วนวิธีแมนเทิล - แฮนส์เซลไม่สามารถตรวจพบข้อสอบทำหน้าที่ต่างกันแบบอนเกรุป และการจำแนกผิดพลาดวิธีแมนเทิล - แฮนส์เซลจะสูงกว่าวิธีถดถอยโลจิสติกและวิธีชิปเทสต์

นุชริน ใบโพธิ์ (2544) เปรียบเทียบความสอดคล้องของผลการตรวจสอบข้อสอบทำหน้าที่ต่างกันระหว่างวิธี ไค - สแควร์ของลอร์ด วิธีแมนเทิล - แฮนส์เซล และวิธีชิปเทสต์ โดยใช้กลุ่มตัวอย่างเป็นนักเรียนชั้นมัธยมศึกษาปีที่ 1 ปีการศึกษา 2543 ในเขตกรุงเทพมหานคร จำนวน 790 คน เครื่องมือที่ใช้วัดเป็นแบบทดสอบวัดความถนัดทางคณิตศาสตร์ จำนวน 60 ข้อ ผลการวิจัยพบว่า

1. ข้อสอบทำหน้าที่ต่างกันจากการตรวจสอบด้วย วิธี ไค - สแควร์ของลอร์ด, วิธีแมนเทิล - แฮนส์เซล และวิธีชิปเทสต์ มีจำนวนข้อสอบที่ตรวจพบแตกต่างกัน เมื่อขนาดกลุ่มตัวอย่างและจำนวนข้อสอบต่างกัน ได้แก่ กรณีแบบทดสอบ 30 ข้อ ที่ใช้กลุ่มตัวอย่างที่มีขนาด 300 คน และ 500 คน แบบทดสอบ 40 ข้อ ใช้กลุ่มตัวอย่าง 500 คน และ 700 คน

2. ความสอดคล้องของผลการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ เมื่อพิจารณาจากข้อสอบจำนวน 20 ข้อ และ 30 ข้อ ที่ตรวจสอบโดยวิธีไค - สแควร์ของลอร์ด วิธีแมนเทิล - แฮนส์เซลและวิธีชิปเทสต์ พบว่ากลุ่มตัวอย่างขนาด 500 คน และ 700 คน มีจำนวนข้อสอบที่ตรวจพบสอดคล้องกันสูงสุด ส่วนข้อสอบจำนวน 40 ข้อ ซึ่งตรวจด้วยวิธีไค - สแควร์ของลอร์ด พบว่ากลุ่มตัวอย่างขนาด 300 คน และ 500 คน มีจำนวนข้อสอบที่ตรวจพบสอดคล้องกันสูงสุด

แต่เมื่อตรวจสอบด้วยวิธีแมนเทิล - แฮนส์เซลและวิธีชิปเทสต์ พบว่ากลุ่มตัวอย่างขนาด 500 และ 700 คน มีจำนวนข้อสอบที่ตรวจพบสอดคล้องกันสูงสุด

สิริรัตน์ วิภาสศิลป์ (2545) ได้เปรียบเทียบการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ หมวดข้อสอบและแบบทดสอบ จากข้อมูลการตอบข้อสอบที่ใช้ความสามารถหลายมิติ ระหว่างวิธีชิปเทสต์กับวิธีดีเอฟไอที ภายใต้เงื่อนไขความยาวของแบบทดสอบ 30, 40 และ 50 ข้อ กลุ่มตัวอย่างขนาด 50, 100, 200, 500, และ 1,000 คน กลุ่มตัวอย่างการศึกษาได้มาจากการสุ่มแบบใส่คืนจากประชาชนเต็ม ซึ่งกำหนดจากนักเรียนชายและนักเรียนหญิงชั้นมัธยมศึกษาปีที่ 1 จังหวัดนนทบุรี แต่ละขนาดสุ่มกลุ่มตัวอย่าง 50 ครั้ง เครื่องมือที่ใช้ในการวิจัยเป็นแบบทดสอบวิชาคณิตศาสตร์ที่ผู้วิจัยสร้างขึ้น ซึ่งเป็นข้อสอบแบบหลายตัวเลือก 5 ตัวเลือก จำนวน 50 ข้อ มีข้อสอบที่ผู้เชี่ยวชาญพิจารณาว่าเป็นข้อสอบทำหน้าที่ต่างกันต่อเพศชายจำนวน 16 ข้อ หลังจากเก็บรวบรวมข้อมูลแล้วคัดเลือกข้อสอบตามสัดส่วนในตารางสัดส่วนกำหนด จัดเป็นแบบทดสอบที่มีความยาว 30 และ 40 ข้อ แล้วตรวจสอบการทำหน้าที่ต่างกันของข้อสอบ หมวดข้อสอบ และแบบทดสอบในเงื่อนไขต่าง ๆ โดยโปรแกรมชิปเทสต์และดีเอฟไอที จากนั้นนำผลที่ได้ไปเปรียบเทียบความถูกต้อง และการระบุผิดพลาดในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบด้วยวิธีเดียวกันและต่างกัน โดยการวิเคราะห์ความแปรปรวนแบบตัวแปรพหุ กำหนดความสอดคล้องในการตรวจสอบการทำหน้าที่ต่างกันของหมวดข้อสอบ และแบบทดสอบด้วยวิธีชิปเทสต์และวิธีดีเอฟไอที โดยใช้สถิติ Z-test ผลการศึกษาปรากฏว่า

1. เมื่อแบบทดสอบประกอบด้วยข้อสอบ 30, 40 และ 50 ข้อ กลุ่มตัวอย่างขนาด 50, 100 และ 200 คน ส่งผลต่อความถูกต้องในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบด้วยวิธีชิปเทสต์ไม่แตกต่างกัน กลุ่มตัวอย่างขนาด 500 และ 1,000 คน ส่งผลต่อความถูกต้องในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบด้วยวิธีชิปเทสต์สูงกว่ากลุ่มตัวอย่างขนาด 50, 100 และ 200 คน แต่การระบุผิดพลาดในการตรวจสอบสูงกว่าด้วย เมื่อตรวจสอบด้วยวิธีดีเอฟไอที พบว่ากลุ่มตัวอย่างขนาด 50, 100, 200, 500 และ 1,000 คน ส่งผลต่อความถูกต้องในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบไม่แตกต่างกัน

2. ทุกเงื่อนไขความยาวแบบทดสอบและกลุ่มตัวอย่างขนาดแตกต่างกัน วิธีชิปเทสต์มีความถูกต้องในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบน้อยกว่าวิธีดีเอฟไอที และพบว่าความสอดคล้องในการตรวจสอบการทำหน้าที่ต่างกันของข้อสอบด้วยวิธีทั้งสองมีค่าต่ำกว่าร้อยละ 1

3. วิธีชิปเทสต์มีความถูกต้องในการตรวจสอบการทำหน้าที่ต่างกันของหมวดข้อสอบมากกว่าดีเอฟไอที เมื่อแบบทดสอบมีข้อสอบ 30 ข้อ กลุ่มตัวอย่าง 1,000 คน และเมื่อแบบทดสอบแบบมี 40 ข้อ กลุ่มตัวอย่างขนาด 500 คน

4. วิธีชิปเทสที่มีความถูกต้องในการตรวจสอบการทำหน้าที่ต่างกันของแบบทดสอบมากกว่าวิธีดีเอฟไอที เมื่อแบบทดสอบมีข้อสอบ 50 ข้อ กลุ่มตัวอย่างขนาด 100, 200 และ 1,000 คน

ราชู แวนเดอร์ ลินเดน และฟลีร์ (Raju, Vander, Linden, & Fleer, 1995, pp. 353 – 368 อ้างถึงใน สิริรัตน์ วิภาสศิลป์, 2545, หน้า 40) เสนอวิธีการตรวจสอบการทำหน้าที่เบี่ยงเบนของข้อสอบและแบบทดสอบ (Internal Measures of Difficential Functioning of Items and Tests: DFIT) โดยอาศัยกรอบความคิดของทฤษฎีการตอบข้อสอบ ศึกษาโดยใช้ข้อมูลจำลองที่สร้างขึ้นมาใช้แบบจำลองโลจิสติก ชนิด 2 พารามิเตอร์ ด้วยโปรแกรม RANDGEN (Fleer, Kiley, & Raju, 1991) สร้างแบบทดสอบที่มีความยาว 40 ข้อ ประกอบด้วยข้อสอบที่แสดง DIF 0 % , 5 % , 10 % และ 20 % ขนาดของกลุ่มตัวอย่างกลุ่มละ 500 คน สำหรับเงื่อนไขกลุ่มตัวอย่างขนาดเล็ก และกลุ่มละ 1000 คน สำหรับกลุ่มตัวอย่างขนาดใหญ่ ตรวจสอบการทำหน้าที่เบี่ยงเบนในเงื่อนไขต่าง ๆ ด้วยวิธีการของโค – สแควร์ของลอว์ด การวัดพื้นที่แบบคิดเครื่องหมาย การวัดพื้นที่โดยไม่คิดเครื่องหมายและวิธีดีเอฟไอที ผลที่ได้พบว่าวิธีการดีเอฟไอทีสามารถตรวจสอบการทำหน้าที่เบี่ยงเบนของข้อสอบทั้งแบบที่มีการชดเชยและแบบที่ไม่มีการชดเชย (CDIF และ NCDIF) ได้อย่างถูกต้อง

ดักลาส รูสโซ และ สตูต (Douglas, Roussos, & Stout, 1996, pp. 465 – 484 อ้างถึงใน สิริรัตน์ วิภาสศิลป์, 2545, หน้า 40) ได้ตรวจสอบการทำหน้าที่เบี่ยงเบนของข้อสอบ โดยพิจารณาข้อสอบพร้อม ๆ กันครั้งละหลายข้อ โดยเสนอวิธีการตรวจสอบหมวดข้อสอบที่คาดว่าจะแสดงการทำหน้าที่เบี่ยงเบนของข้อสอบเหล่านั้นเข้ามาพิจารณาพร้อมกัน 2 วิธี คือ ใช้เฉพาะความคิดเห็นของผู้เชี่ยวชาญ และใช้วิธีทางสถิติและตรวจสอบซ้ำด้วยความเห็นของผู้เชี่ยวชาญ พร้อมทั้งแสดงตัวอย่างตรวจสอบการทำหน้าที่เบี่ยงเบน 3 ตัวอย่าง ดังนี้ ตัวอย่างที่ 1 เลือกหมวดข้อสอบโดยใช้ความเห็นของผู้เชี่ยวชาญอย่างเดียว ให้ผู้เชี่ยวชาญชาย 3 คน และหญิง 1 คน พิจารณาแบบทดสอบย่อยใช้เหตุผลเชิงตรรกศาสตร์ (Logical Reasoning Subtest) ที่ได้จากการดำเนินการสอบในเดือนธันวาคม ค.ศ. 1991 (December 1991 Administration of the Low School Admission Test: LSAT) จำนวน 49 ข้อ ในการตรวจให้เพศชายเป็นกลุ่มอ้างอิงและเพศหญิงเป็นกลุ่มสนใจ ผู้เชี่ยวชาญจัดหมวดข้อสอบออกเป็น 8 หมวด และพิจารณาว่าหมวดใดน่าจะให้ประโยชน์แก่เพศชายหรือเพศหญิง หลังจากนั้นวิเคราะห์ด้วยโปรแกรมคอมพิวเตอร์สำเร็จรูปชิปเทสท์ ใช้กลุ่มตัวอย่างเพศชาย 3,000 คน พบว่าความคิดเห็นของผู้เชี่ยวชาญและผลวิเคราะห์ด้วยโปรแกรมชิปเทสท์สอดคล้องกัน จึงทำการวิเคราะห์ปริมาณ DIF ของแต่ละข้อ พบว่าแต่ละข้อแสดง DIF ด้วยปริมาณที่น้อยมาก จึงไม่มีการคัดเลือกข้อสอบออกจากแบบทดสอบ ตัวอย่างที่ 2 ใช้วิธีการทางสถิติในการตรวจสอบหมวดข้อสอบ คือ วิธี HCA (Agglomerative Hierarchical Cluster Analysis;

Jian & Dubes, 1988) และ DIMTEST (Nandacumar & Stout, 1993; Stout, 1987) แล้วจึงตรวจสอบด้วยโปรแกรมชิปเทสต์ ในการตรวจสอบใช้ข้อสอบ (National Assessment of Educational Progress (NEAP) จำนวน 36 ข้อ ใช้กลุ่มตัวอย่างจำนวน 500 คน ผลการตรวจสอบพบว่า การตรวจสอบการทำหน้าที่เบี่ยงเบนของหมวดข้อสอบ ประสบความสำเร็จเป็นอย่างดี ตัวอย่างที่ 3 ใช้แบบทดสอบความเข้าใจในการอ่าน ที่สอบในเดือนธันวาคม ค.ศ. 1991 ซึ่งเป็นส่วนหนึ่งของการทดสอบ LSAT แบ่งเป็นบทความที่กำหนดให้อ่านเป็น 4 บทความ แต่ละบทความมีข้อสอบให้อ่าน 5-8 ข้อ แล้วทำการตรวจสอบหมวดข้อสอบซ้ำโดยใช้วิธี เอชซีเอ และ ดิมเทสต์ หลังจากนั้นจึงวิเคราะห์ด้วยโปรแกรมชิปเทสต์ ใช้กลุ่มตัวอย่างกลุ่มละ 1,000 คน พบว่าทั้ง 4 บทความ แสดงการทำหน้าที่เบี่ยงเบนของหมวดข้อสอบ ข้อสอบ 2 หมวดให้ประโยชน์แก่เพศชาย และ 2 หมวด ให้ประโยชน์แก่เพศหญิง

สุมาลี แก้วทองงศ์ (2547) ได้ศึกษาการทำหน้าที่ต่างกันของข้อสอบด้านเพศ ภาษาพูด และเชื้อชาติ ของแบบสอบสาระการเรียนรู้ภาษาไทย และสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม และตรวจสอบสาเหตุของการทำหน้าที่ต่างกันของข้อสอบด้านเพศ ภาษาพูด และเชื้อชาติ ของแบบสอบกลุ่มสาระการเรียนรู้ภาษาไทย และกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม กลุ่มตัวอย่างที่ใช้ในการวิจัย คือ นักเรียนระดับชั้นมัธยมศึกษาปีที่ 1 ปีการศึกษา 2546 สำนักงานเขตพื้นที่การศึกษาสงขลา พัทลุง ตรัง และสตูล จำนวน 1,320 คน เครื่องมือที่ใช้ในการวิจัยประกอบด้วยแบบสอบถามเพื่อสำรวจความสนใจในการอ่านของผู้เรียน แบบสอบในกลุ่มสาระการเรียนรู้ภาษาไทยและกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม และแบบวินิจฉัยสาเหตุการทำหน้าที่ต่างกันของข้อสอบ ในกลุ่มสาระการเรียนรู้ภาษาไทยและสังคมศึกษา ศาสนา และวัฒนธรรม วิเคราะห์การทำหน้าที่ต่างกันของข้อสอบโดยวิธีแมนเทิล - ฮานส์เซล และโปรแกรมชิปเทสต์ และตรวจสอบสาเหตุการทำหน้าที่ต่างกันโดยผู้เชี่ยวชาญ ผลการวิจัยพบว่า

1. แบบสอบกลุ่มสาระการเรียนรู้ภาษาไทยมี 3 ฉบับ ประกอบด้วยข้อสอบจำนวน 120 ข้อ มีข้อสอบที่ทำหน้าที่ต่างกันด้านเพศ 9 ข้อ ภาษาพูด 15 ข้อ และเชื้อชาติ 28 ข้อ และกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรมมีข้อสอบที่ทำหน้าที่ต่างกันด้านเพศ 22 ข้อ ด้านภาษาพูด 52 ข้อ และเชื้อชาติ 20 ข้อ
2. ข้อสอบที่ทำหน้าที่ต่างกันด้านเพศของแบบสอบสาระการเรียนรู้ภาษาไทย ส่วนใหญ่มีสาเหตุมาจากการเนื้อเรื่องที่นำเสนอและภาษาที่ใช้ในแบบสอบ โดยมีลักษณะของข้อสอบที่ออกตามความสนใจและมีการใช้ภาษาในแบบสอบที่เป็นสำนวนและคำศัพท์ และข้อสอบที่ทำหน้าที่ต่างกันด้านเพศ ของแบบสอบสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม มีสาเหตุมาจาก

เนื้อเรื่องที่สนใจและเนื้อเรื่องเกี่ยวกับวัฒนธรรม โดยมีลักษณะของข้อสอบที่มีเนื้อเรื่องที่สนใจ และมีเนื้อเรื่องเกี่ยวกับวัฒนธรรมของผู้สอบ

3. ข้อสอบที่ทำหน้าที่ต่างกันด้านภาษาพูดของแบบสอบสาระการเรียนรู้ภาษาไทย ส่วนใหญ่มีสาเหตุมาจาก เนื้อเรื่องที่สนใจ และภาษาที่ใช้ในแบบสอบ โดยมีลักษณะข้อสอบที่ออกตามความสนใจและมีการใช้ภาษาที่เป็นคำศัพท์เฉพาะ เช่น ราชศัพท์ และข้อสอบที่ทำหน้าที่ต่างกันด้านภาษาพูดของแบบสอบสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม มีสาเหตุมาจากเนื้อเรื่องที่สนใจ และเนื้อเรื่องเกี่ยวกับวัฒนธรรม โดยมีลักษณะของข้อสอบที่ออกตามความสนใจ เช่น ภูมิศาสตร์ และในเรื่องเกี่ยวกับวัฒนธรรมไทย

4. ข้อสอบที่ทำหน้าที่ต่างกันในด้านเนื้อหาของแบบสอบสาระการเรียนรู้ภาษาไทย ส่วนใหญ่มีสาเหตุมาจากเนื้อเรื่องที่สนใจ และภาษาที่ใช้ในแบบสอบถาม โดยมีลักษณะข้อสอบที่ออกตามความสนใจ และมีการใช้คำราชาศัพท์หรือคำศัพท์ยากมาออกข้อสอบ และข้อสอบที่ทำหน้าที่ต่างกันในด้านเนื้อหาของแบบสอบสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม มีสาเหตุจากเนื้อเรื่องที่สนใจและเนื้อเรื่องเกี่ยวกับวัฒนธรรมและประเพณี

ศุภวัฒน์ มะลิเผือก (2548) ได้ศึกษาอิทธิพลของการทำหน้าที่ต่างกันของข้อสอบที่ส่งผลต่อคุณภาพของแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียนระดับชาติดิวิชันภาษาไทย ชั้นประถมศึกษาปีที่ 6 ปีการศึกษา 2546 ด้วยวิธีชิปทดสอบกับวิธีถดถอยโลจิสติก โดยการเปรียบเทียบค่าความเที่ยง ความตรงเชิงโครงสร้าง ความคงที่ของโครงสร้างองค์ประกอบ และค่าสัมประสิทธิ์สหสัมพันธ์อันดับของผู้สอบ ระหว่างแบบทดสอบฉบับก่อนกับฉบับหลังดัดข้อสอบทำหน้าที่ต่างกันออก ผลปรากฏว่า พบข้อสอบที่ต่างกันเมื่อจำแนกกลุ่มผู้สอบตามตัวแปรเพศจำนวน 12 ข้อ คิดเป็นร้อยละ 30 แบบทดสอบฉบับก่อนกับฉบับหลังดัดข้อสอบทำหน้าที่ต่างกันมีค่าความเที่ยงแตกต่างกัน โครงสร้างองค์ประกอบคงที่และค่าสัมประสิทธิ์สหสัมพันธ์อันดับของผู้สอบ มีความสัมพันธ์กันอย่างมีนัยสำคัญทางสถิติที่ระดับ 0.5

รูสโซ และสตาท์ (Roussos & Stout, 1996, pp. 215-230 อ้างถึงใน ปิยะทิพย์ ดินวร, 2549, หน้า 34) ได้ศึกษาสถานการณ์จำลองของผลกระทบของกลุ่มตัวอย่างขนาดเล็ก และค่าพารามิเตอร์ของข้อสอบที่มีต่ออัตราความคลาดเคลื่อนประเภทที่ 1 ด้วยวิธีชิปทดสอบและวิธีแมนเทิล-แฮนส์เชล โดยจำลองข้อมูล 2 ครั้ง ครั้งแรกศึกษากลุ่มตัวอย่างขนาดเล็ก ใช้กลุ่มตัวอย่าง 4 ขนาด (100, 200, 500, และ 1,000) และความแตกต่างของการแจกแจงค่าความสามารถระหว่างผู้เข้าสอบกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบ 3 ขนาด (0, 0.5 และ 1) ใช้แบบทดสอบ 25 ข้อ ครั้งที่ 2 ศึกษาค่าพารามิเตอร์ของข้อสอบ ใช้กลุ่มตัวอย่าง 3 ขนาด (500, 1,000 และ 3,000) และความแตกต่างของการแจกแจงค่าความสามารถระหว่างผู้เข้าสอบกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบ 2 ขนาด

(0 และ 1) เลือกค่าพารามิเตอร์อำนาจจำแนก 3 ค่า (0.4, 1.0 และ 2.5) พารามิเตอร์ความยาก 5 ค่า (-1.5, -0.5, 0, 0.5 และ 1.5) และค่าพารามิเตอร์การเดา 1 ค่า (.20) ผลการศึกษาพบว่า ครั้งที่ 1 เมื่อศึกษากลุ่มตัวอย่างขนาดเล็ก พบว่าอัตราความคลาดเคลื่อนประเภทที่ 1 ระหว่างวิธีซิปเทสท์และวิธีแมนเทล-แฮนส์เซล มีค่าไม่แตกต่างกัน ครั้งที่ 2 เมื่อศึกษาค่าพารามิเตอร์ของข้อสอบ พบว่าเมื่อความแตกต่างของการแจกแจงค่าความสามารถ ระหว่างผู้เข้าสอบกลุ่มอ้างอิงกับกลุ่มเปรียบเทียบ ไม่แตกต่างกัน และอัตราความคลาดเคลื่อนประเภทที่ 1 ของวิธีซิปเทสท์มีค่าต่ำกว่าวิธีแมนเทล - แฮนส์เซลในทุกเงื่อนไข

ตอนที่ 4 ผลสัมฤทธิ์ทางการเรียน

ผลสัมฤทธิ์ทางการเรียน หมายถึงคุณลักษณะรวมถึงความรู้ความสามารถของบุคคลอันเป็นผลมาจากการเรียนการสอน หรือมวลประสบการณ์ทั้งปวงที่บุคคลได้รับจากการเรียนการสอน ทำให้บุคคลเกิดการเปลี่ยนแปลงพฤติกรรมในด้านต่าง ๆ ของสมรรถภาพสมอง แสดงว่าเป็นการตรวจสอบพฤติกรรมของผู้เรียนในด้านพุทธิพิสัยนั่นเอง โดยการวัด 2 องค์ประกอบ คือ

1. การวัดด้านปฏิบัติ โดยให้ผู้เรียนได้ลงมือปฏิบัติจริงให้เป็นผลงานปรากฏออกมา ทำให้สังเกตและวัดได้ เช่น ศิลปศึกษา พลศึกษา เป็นต้น การวัดแบบนี้จึงต้องใช้ข้อสอบภาคปฏิบัติ ซึ่งเป็นการประเมินผลและพิจารณาที่วิธีปฏิบัติและผลงานที่ปฏิบัติ
2. การวัดด้านเนื้อหาเป็นการตรวจสอบความรู้ความสามารถเกี่ยวกับเนื้อหาวิชา รวมถึงพฤติกรรมความสามารถในด้านต่าง ๆ อันเป็นผลมาจากการทำกิจกรรมการเรียนการสอน มีวิธีสอบวัดได้ 2 ลักษณะ คือ การสอบปากเปล่า และการสอบแบบให้เขียนตอบ ในการสอบแบบเขียนตอบนี้จะใช้กันแพร่หลาย เครื่องมือที่ใช้ในการสอบวัด เรียกว่า “ข้อสอบวัดผลสัมฤทธิ์” หรือ “แบบทดสอบวัดผลสัมฤทธิ์” เพื่อให้การวัดผลสัมฤทธิ์ทางการเรียนเกิดประสิทธิภาพสามารถแยกพฤติกรรมด้านต่าง ๆ ได้ชัดเจน จึงต้องมีการสร้างแบบทดสอบที่เหมาะสมกับจุดมุ่งหมายของเนื้อหาขึ้น

จะเห็นว่าผลสัมฤทธิ์ทางการเรียน เป็นผลที่เกิดขึ้นจากการเรียนการสอนหรือมวลประสบการณ์ที่ได้รับจากสิ่งแวดล้อม ซึ่งทำให้บุคคลเกิดการเปลี่ยนแปลงพฤติกรรมในด้านต่าง ๆ ของสมรรถภาพทางสมอง ซึ่งในการศึกษารังนี้ผู้รายงานใช้แบบทดสอบในลักษณะเขียนตอบ โดยเรียกว่าแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน เพราะสามารถทราบสมรรถภาพทางสมองและสามารถวัดพฤติกรรมต่าง ๆ ได้ชัดเจนครบถ้วนตามจุดมุ่งหมายที่ต้องการวัด

จุดมุ่งหมายของการวัดผลสัมฤทธิ์ทางการเรียน

การวัดผลสัมฤทธิ์ทางการเรียนมีจุดมุ่งหมายเพื่อ

1. ตรวจสอบความสามารถด้านพุทธิพิสัย เพื่อเปรียบเทียบการเปลี่ยนแปลงในการเรียนรู้ โดยวัดทางด้านเนื้อหา

2. ปรับปรุงแก้ไขกระบวนการเรียนการสอน โดยใช้การวัดผลเป็นองค์ประกอบหนึ่งของการเรียนการสอน

3. ประเมินผลผู้เรียนว่าบรรลุเป้าหมายในสิ่งที่สอนไปหรือไม่ โดยการประเมินผลผู้เรียน มีประโยชน์ต่อการจัดการศึกษาคือ

3.1 ช่วยสำรวจความต้องการด้านการศึกษาของแต่ละบุคคล

3.2 ช่วยตรวจสอบประสิทธิผลของวิธีการจัดการเรียนการสอน

3.3 ช่วยให้สารสนเทศแก่ผู้เรียน อาจารย์ที่ปรึกษาและนักแนะแนว

3.4 ช่วยให้สารสนเทศแก่ผู้บริหารการศึกษา เพื่อนำไปใช้ในการจัดทรัพยากรของโรงเรียน

3.5 ช่วยให้สารสนเทศแก่ผู้บริหารการศึกษา เพื่อนำไปใช้จัดการบริหารงานบุคคล

3.6 เพื่อเลือกวิธีหรือกระบวนการสอบที่เหมาะสม ที่จะเป็นแรงกระตุ้นให้ผู้เรียนมีความสนใจในการเรียนยิ่งขึ้น

วิธีการทดสอบวัดผลสัมฤทธิ์ทางการเรียน

วิธีการทดสอบวัดผลสัมฤทธิ์ทางการเรียนมี 2 วิธี

1. การทดสอบแบบอิงกลุ่ม เป็นการทดสอบที่แปลความหมายของคะแนนโดยการนำเอาผลการปฏิบัติงาน ไปเปรียบเทียบกับผลการปฏิบัติงานของคนอื่น ๆ ภายในกลุ่ม การรายงานผลการทดสอบใช้คะแนนมาตรฐานในการบ่งบอก เช่น เปอร์เซนต์ไทล์ เกรดเทียบเท่า (Grade Equivalent)

2. การทดสอบแบบอิงเกณฑ์ เป็นการทดสอบที่แปลความหมายของคะแนนโดยการนำเอาผลการปฏิบัติงานไปเปรียบเทียบกับมาตรฐานที่แท้จริง (Absolute Standard) ซึ่งเป็นเกณฑ์ภายนอกกลุ่มที่กำหนดไว้อย่างรอบคอบโดยไม่เปรียบเทียบกับผลงานคนอื่นภายในกลุ่ม ดังนั้น ผลงานของนักเรียนจะอยู่ในระดับมาตรฐานหรือไม่ ต้องพิจารณาและเปรียบเทียบกับมาตรฐานที่แท้จริงเท่านั้น การรายงานผลการทดสอบเสนอในพจน์ของจำนวน หรือเปอร์เซ็นต์การตอบถูกของแต่ละบุคคล แบบทดสอบแบบอิงเกณฑ์จำแนกเป็น 2 ประเภท ดังนี้

2.1 แบบทดสอบอิงจุดประสงค์ เป็นแบบทดสอบอิงเกณฑ์ที่สร้างขึ้นโดยใช้จุดประสงค์รายวิชา ส่วนมากจะมีการกำหนดเกณฑ์เพื่อบ่งชี้ระดับความรู้ของผู้สอบ ซึ่งมักจะใช้คะแนนจุดตัดของแบบทดสอบ

2.2 แบบทดสอบอิงความรู้ เป็นแบบทดสอบอิงเกณฑ์ที่สร้างขึ้นโดยยึดหลัก

เฉพาะของมวลความรู้ ใช้การประมวลความสามารถของผู้สอบที่สามารถตอบข้อสอบถูกใน
ประชากรข้อสอบ

แบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน (Achievement Test)

แนวคิดของแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน (เยาเวดี วิบูลย์ศรี, 2545,
หน้า 14-27)

1. แบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน (Achievement Test) เป็นเครื่องมือสำหรับ
ช่วยให้ครูสามารถตัดสินผลสัมฤทธิ์ทางการเรียนได้อย่างมีประสิทธิภาพ เพราะเป็นวิธีการประเมิน
พฤติกรรมของนักเรียนที่มีความเป็นอิสระได้มากกว่าวิธีอื่นๆ แบบทดสอบวัดผลสัมฤทธิ์ทางการ
เรียนที่ใช้ในโรงเรียนมุ่งวัดความรู้ในแต่ละวิชา และทักษะต่างๆ โดยมีวัตถุประสงค์พื้นฐานที่
สำคัญ 2 ประการ คือ ประการแรก เพื่อเป็นเครื่องมือในการวัดผลสัมฤทธิ์ทางการเรียน อันเป็น
ข้อมูลที่ได้รับการประเมินผลการเรียนการสอนเป็นรายบุคคล ประการที่สอง เพื่อเป็นการ
ตรวจสอบความสามารถของนักเรียนแต่ละคนซึ่งแตกต่างกันโดยธรรมชาติ เมื่อความสามารถของ
แต่ละคนมีความแตกต่างกันทั้งเด็กและผู้ใหญ่ ดังนั้นการที่จะให้บุคคลต่างๆ ได้รับการพัฒนา
ความสามารถเฉพาะตนที่มีอยู่อย่างเหมาะสม จึงก่อให้เกิดการพัฒนาแบบทดสอบวัดผลสัมฤทธิ์ที่มี
ประสิทธิภาพขึ้น เพื่อใช้เป็นเครื่องมือในการวัดระดับความสามารถของบุคคล หรือเพื่อจำแนก
ความสามารถของบุคคลที่แตกต่างกัน ทำให้เราสามารถศึกษาให้สอดคล้องกับระดับความสามารถ
ของบุคคลต่างๆ ได้

2. ประเภทของแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน เราสามารถจำแนกตามมิติ
ต่างๆ ได้หลายมิติ ดังนี้

2.1 จำแนกตามขอบข่ายเนื้อหาวิชาของแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน อาจ
กำหนดให้กว้างได้หรือจำกัดให้แคบลง ตามปกติแล้วยังไม่มีมาตรฐานอ้างอิงสากลที่จะนำไปใช้ในการ
การกำหนดเนื้อหาวิชาสำหรับแบบทดสอบวัดผลสัมฤทธิ์ ผู้ใช้แบบทดสอบเท่านั้นจะต้องกำหนด
เนื้อหาวิชาขึ้นเอง โดยให้สอดคล้องกับวัตถุประสงค์ของการสอบ ผู้สร้างแบบทดสอบสามารถที่
จะพัฒนาแบบทดสอบให้มีเนื้อหาได้ตามขอบข่ายที่ต้องการ สำหรับแบบทดสอบมาตรฐานวัด
ผลสัมฤทธิ์ ซึ่งจัดพิมพ์ในต่างประเทศจำนวนมากมักจะรวมแบบทดสอบต่างๆ ไว้เป็นชุด
(Batteries) แต่ละชุดจะครอบคลุมเนื้อหาวิชาสำหรับระดับชั้นเรียนที่ต่าง ๆ กัน ทั้งนี้เพื่อให้
โรงเรียนทั้งหลายสามารถวัดผลสัมฤทธิ์ของนักเรียนได้อย่างต่อเนื่อง ตามความเจริญของงานทาง
วิชาการในแต่ละยุคแต่ละสมัย ตัวอย่างเช่น แบบทดสอบวัดผลสัมฤทธิ์ทั่วไป (General
Achievement Test Batteries) หรือเรียกย่อ ๆ ว่า GATB ซึ่งเป็นแบบทดสอบวัดผลสัมฤทธิ์
มาตรฐานที่นิยมใช้กันในระดับประถมศึกษาและมัธยมศึกษาเป็นส่วนใหญ่ ทั้งนี้เพราะเนื้อหาที่

เหมาะสมกับช่วงชั้นดังกล่าวเป็นอย่างดี เช่น ในระดับประถมศึกษาเน้นลักษณะของแบบทดสอบจะประกอบด้วยเนื้อหาซึ่งสัมพันธ์กับทักษะสามประการ (3R) คือ การอ่าน (Reading) การเขียน (Writing) และการคำนวณ (Arithmetic) ส่วนในระดับมัธยมศึกษาแบบทดสอบ GATB มีความมุ่งหมายเพื่อวัดผลสัมฤทธิ์ทั่วไป รวมทั้งเพื่อวัดพื้นฐานความรู้ของแต่ละวิชา เช่น พื้นฐานความรู้ทางสังคมศาสตร์ พื้นฐานความรู้ของวิชาวิทยาศาสตร์ธรรมชาติ เป็นต้น นอกจากนั้นก็จะเน้นการวัดความสามารถด้านการอ่าน ความเข้าใจในสาขาวิชา รวมทั้งความคิดเกี่ยวกับจำนวนและคำศัพท์ทั่วไป ซึ่งเป็นการวัดในด้านการพัฒนาความสามารถเชิงวิชาการ ดังนั้นแบบทดสอบ GATB ในระดับนี้ จึงมักจะใช้ในการสอบคัดเลือกบุคคลเข้าศึกษาต่อในสถาบันอุดมศึกษา หรือในการสอบคัดเลือกเข้าแข่งขันชิงทุนประเภทต่าง ๆ เป็นต้น

2.2 จำแนกตามลักษณะหน้าที่ทั่วไปของแบบทดสอบ ซึ่งแบ่งออกเป็น 3 ลักษณะ ดังนี้

2.2.1 แบบทดสอบเพื่อการสำรวจผลสัมฤทธิ์ (Survey Tests) เป็นแบบทดสอบวัดผลสัมฤทธิ์ที่ทำหน้าที่ในการสำรวจความสามารถทั่ว ๆ ไปของนักเรียน โดยประเมินความรู้ในเนื้อหาวิชาหรือทักษะต่าง ๆ เพื่อแสดงระดับความสามารถของนักเรียน ดังนั้นแบบทดสอบวัดผลสัมฤทธิ์จึงมักจะครอบคลุมเนื้อหาทั้งในระดับกว้างและระดับทั่วไป โดยถือคะแนนรวมที่ได้จากแบบทดสอบเป็นตัวบ่งชี้ถึงระดับความสามารถที่วัดได้

2.2.2 แบบทดสอบเพื่อวินิจฉัยผลสัมฤทธิ์ (Diagnostic Test) เป็นแบบทดสอบวัดผลสัมฤทธิ์ที่ทำหน้าที่วินิจฉัยเกี่ยวกับจุดเด่นและจุดด้อยขององค์ประกอบสำคัญทางด้านทักษะต่าง ๆ ของนักเรียน ตัวอย่างเช่น แบบทดสอบเพื่อวินิจฉัยผลสัมฤทธิ์ทางด้านภาษา อาจจะรวมแบบทดสอบย่อยหลายชุด ซึ่งครอบคลุมเนื้อหาเกี่ยวกับการรู้จักใช้คำ ความเข้าใจเกี่ยวกับถ้อยคำต่าง ๆ รวมทั้งคำศัพท์ ตลอดจนอัตราการอ่าน ความเข้าใจในเรื่องที่อ่าน การจำแนกเสียงและการจำแนกพยางค์ ฯลฯ คะแนนที่ได้จากแต่ละองค์ประกอบของแบบทดสอบวินิจฉัยดังกล่าว จะช่วยให้นักจิตวิทยาหรือครูสามารถตัดสินใจได้ว่า อะไรคือจุดบกพร่องของผู้สอบ ซึ่งจะช่วยให้สามารถสอนเสริมในส่วนของเนื้อหาวิชาหรือทักษะที่ยังขาดอยู่ได้อย่างมีประสิทธิภาพ

2.2.3 แบบทดสอบเพื่อวัดความพร้อม (Readiness Test) เป็นแบบทดสอบวัดผลสัมฤทธิ์ ซึ่งทำหน้าที่ในการวัดทักษะที่จำเป็นสำหรับการเรียนในชั้นที่สูงขึ้น แบบทดสอบที่วัดความพร้อม ใช้สำหรับทำนายการกระทำในอนาคต จึงทำหน้าที่เป็นเครื่องมือในการวัดความถนัด ไปในตัวด้วย

2.3 จำแนกตามคำตอบที่ใช้ โดยทั่วไปแล้วแบบทดสอบวัดผลสัมฤทธิ์ส่วนใหญ่ที่ใช้กันมักจะเป็นประเภทข้อเขียน และที่ใช้กันค่อนข้างมาก คือแบบทดสอบภาคปฏิบัติ (Performance

Test) เป็นแบบทดสอบที่ต้องการให้นักเรียนหรือผู้เข้าสอบได้สาริตทักษะของตนเอง เช่น ให้แสดงทักษะในการแก้ไขเครื่องยนต์กลไกที่ไม่ทำงาน หรือแสดงทักษะในการเล่นดนตรี เป็นต้น

สำหรับแบบทดสอบประเภทข้อเขียนนั้น ยังแยกออกได้อย่างกว้าง ๆ อีก 2 ระดับ คือ (1) ระดับการเลือกคำตอบจากที่กำหนดไว้แล้ว (Recognition) และ (2) ระดับของการเขียนคำตอบ จากความรู้หรือความทรงจำที่มีอยู่เดิม (Recall) ในแบบทดสอบระดับที่ 1 แต่ละข้อจะมีคำตอบที่ตายตัว และจะประกอบด้วยตัวเลือกหลาย ๆ ตัวที่เป็นไปได้รวมอยู่ในคำตอบที่เกี่ยวข้อง ผู้เข้าสอบจะต้องตัดสินใจเลือกคำตอบอย่างรอบคอบและถูกต้องให้สอดคล้องกับชนิดของคำถามที่ระบุไว้ ตัวอย่างของข้อสอบระดับนี้ เช่น แบบทดสอบหลายตัวเลือก (Multiple Choice) แบบทดสอบประเภทถูก – ผิด (True - False) และแบบทดสอบประเภทจับคู่ (Matching)

ส่วนแบบทดสอบระดับที่ 2 ซึ่งต้องใช้ความรู้และความทรงจำที่มีอยู่เดิมมาเขียนตอบ นั้นลักษณะของคำตอบอาจจะไม่ตายตัว ขึ้นอยู่กับเหตุผลและความถูกต้องในเชิงวิชาการ ผสมผสานกับความคิดริเริ่มสร้างสรรค์ของผู้เข้าสอบเป็นสำคัญ แบบทดสอบระดับนี้ ได้แก่ แบบทดสอบประเภทเติมคำหรือข้อความในช่องว่าง (Completion) แบบทดสอบประเภทตอบสั้น (Short Answer) และแบบทดสอบประเภทความเรียง

3. แบบทดสอบวัดผลสัมฤทธิ์มาตรฐาน

เป็นแบบทดสอบที่สร้างขึ้น โดยกลุ่มผู้เชี่ยวชาญมากกว่าที่จะสร้างขึ้น โดยบุคคลใดบุคคลหนึ่งเพียงบุคคลเดียวเท่านั้น ตามปกติแล้วผู้สร้างแบบทดสอบวัดผลสัมฤทธิ์มาตรฐานมักจะประกอบด้วยผู้เชี่ยวชาญทางด้าน การวัดและประเมินผล รวมทั้งผู้เชี่ยวชาญในสาขาวิชานั้น ๆ ตลอดจนครูในโรงเรียนต่าง ๆ ซึ่งมีบทบาทในการกำหนดขอบข่ายเนื้อหาวิชาที่ต้องการทดสอบให้เหมาะสม แบบทดสอบวัดผลสัมฤทธิ์มาตรฐาน ไม่จำเป็นต้องครอบคลุมเนื้อหาและทักษะที่มีในหลักสูตร เนื้อหาและทักษะของแบบทดสอบวัดผลสัมฤทธิ์มาตรฐานส่วนมากมักจะได้จากตำราเรียนและความคิดเห็นของผู้เชี่ยวชาญทางด้านหลักสูตร เนื้อหาโดยทั่วไปจะเป็นความรู้และทักษะในระดับที่กว้าง ๆ เพื่อให้สามารถนำไปใช้กับนักเรียนโรงเรียนต่าง ๆ ได้ สำหรับขั้นตอนในการสร้างแบบทดสอบวัดผลสัมฤทธิ์มาตรฐาน จะต้องมีการวางแผนสร้างอย่างเป็นระบบ คือ มีการระบุหลักเกณฑ์และเหตุผลของการสร้างแบบทดสอบ มีการกำหนดวัตถุประสงค์ของการสร้างที่ชัดเจน มีการทดลองใช้แบบทดสอบที่สร้างขึ้น เพื่อตรวจสอบความเป็นมาตรฐาน โดยการวิเคราะห์ระดับความยากง่าย และอำนาจจำแนกของข้อสอบ มีการหาค่าความตรง และความเที่ยงของแบบทดสอบ พร้อมทั้งพัฒนาตารางปกติวิสัย (Norm Table) เพื่อใช้ในการเปรียบเทียบ มีการกำหนดเวลาของการทดสอบและวิธีดำเนินการสอบ ตลอดจนมีคู่มือประกอบการใช้แบบทดสอบ

ซึ่งจะระบุจุดมุ่งหมายของแบบทดสอบ ประสิทธิภาพของแบบทดสอบรวมทั้งวิธีการใช้แบบทดสอบ และวิธีการตรวจหรือวิธีการให้คะแนน พร้อมทั้งตารางปกติวิสัยของกลุ่ม

4. ความแตกต่างระหว่างแบบทดสอบวัดผลสัมฤทธิ์มาตรฐานกับแบบทดสอบวัดผลสัมฤทธิ์ที่ครูสร้างขึ้น สามารถจำแนกความแตกต่างที่ชัดเจนได้ 5 ประการ ดังนี้

4.1 การจำกัดเนื้อหาวิชาที่สอบ แบบทดสอบวัดผลสัมฤทธิ์มาตรฐานจะสุ่มเนื้อหาสำหรับนำมาสอบในระดับที่กว้างและทั่วไป เพื่อใช้กับโรงเรียนต่าง ๆ คลอดจนมีการกลั่นกรองเนื้อหาในการสร้างข้อกระทงโดยผู้เชี่ยวชาญทางเนื้อหาและหลักสูตร สำหรับแบบทดสอบวัดผลสัมฤทธิ์ที่ครูสร้างขึ้น จะเน้นเนื้อหาเฉพาะที่เกี่ยวกับการเรียนการสอนในชั้นเรียน ครูจะทำหน้าที่เป็นผู้เชี่ยวชาญ ซึ่งอาจประกอบด้วยครูคนเดียวหรือคณะครูเป็นผู้กำหนดเนื้อหาที่เหมาะสมในการสอบ

4.2 การทดลองใช้แบบทดสอบ แบบทดสอบวัดผลสัมฤทธิ์มาตรฐานเมื่อสร้างขึ้นแล้วจะต้องมีการทดลองใช้ เพื่อทำการวิเคราะห์ประสิทธิภาพของแบบทดสอบด้วยค่าสถิติต่าง ๆ ต่อจากนั้นก็จะรายงานในคู่มือการใช้แบบทดสอบ เช่น ค่าความตรง ความเที่ยง ระดับความยากง่ายและค่าอำนาจจำแนก ในทำนองตรงกันข้าม สำหรับแบบทดสอบวัดผลสัมฤทธิ์ที่ครูสร้างขึ้นโดยทั่วไปจะไม่มีการทดลองใช้เพื่อวิเคราะห์ค่าสถิติในการตรวจสอบประสิทธิภาพของแบบทดสอบมาก่อน

4.3 วิธีดำเนินการสอบ แบบทดสอบวัดผลสัมฤทธิ์มาตรฐานโดยปกติจะต้องมีคู่มืออธิบายวิธีดำเนินการสอบอย่างเป็นมาตรฐาน เช่น วิธีการตอบ เวลาในการสอบ ฯลฯ ผู้ใช้แบบทดสอบต้องปฏิบัติตามอย่างเคร่งครัด สำหรับแบบทดสอบวัดผลสัมฤทธิ์ที่ครูสร้างขึ้นโดยทั่วไปไม่มีคู่มือประกอบการใช้ เพราะตัวครูเองเป็นผู้กำหนดมาตรฐานในการปฏิบัติเกี่ยวกับวิธีการสอบ

4.4 วิธีการให้คะแนน แบบทดสอบวัดผลสัมฤทธิ์มาตรฐานจะต้องมีค่าเฉลี่ยสำหรับการตรวจสอบให้คะแนนตามที่ระบุอยู่ในคู่มือการใช้แบบทดสอบ ส่วนแบบทดสอบวัดผลสัมฤทธิ์ที่ครูสร้างขึ้น ครูจะเป็นผู้ให้คะแนนตามมาตรฐานที่กำหนดขึ้นเอง

4.5 ตารางปกติวิสัยเพื่อการเปรียบเทียบ โดยปกติแล้วการสร้างแบบทดสอบวัดผลสัมฤทธิ์มาตรฐาน จะมีการนำไปใช้กับกลุ่มอ้างอิงหรือที่เรียกว่า (Norm Group) เพื่อทำตารางปกติวิสัย (Norm Table) ไว้ในคู่มือของการใช้แบบทดสอบมาตรฐาน โดยมีจุดมุ่งหมายให้ผู้ที่ใช้แบบทดสอบสามารถนำไปใช้ตีความสำหรับคะแนนสอบที่ได้รับ รวมทั้งใช้เป็นตารางเพื่อเปรียบเทียบของคะแนนดังกล่าวด้วย ส่วนแบบทดสอบวัดผลสัมฤทธิ์ที่ครูสร้างขึ้นจะมีเพียงคะแนนของกลุ่มผู้เข้าสอบด้วยกัน ซึ่งอาจใช้เปรียบเทียบได้เฉพาะภายในกลุ่มเท่านั้น

แบบทดสอบวัดผลสัมฤทธิ์ทางการเรียนระดับชาติ ชั้นประถมศึกษาปีที่ 6
ปีการศึกษา 2546 (สำนักทดสอบทางการศึกษา, 2546 อ้างถึงใน สุภวัฒน์ มะลิเผือก, 2548, หน้า 53-55)

กระทรวงศึกษาธิการเห็นความสำคัญและความจำเป็นในการรักษาและยกระดับคุณภาพการศึกษาของสถานศึกษาต่าง ๆ ให้มีมาตรฐานทัดเทียมกัน จึงกำหนดให้มีการประเมินคุณภาพการศึกษาระดับชาติในทุก ๆ ปี โดยจะประเมินในปลายปีการศึกษา โดยมอบหมายให้สำนักทดสอบทางการศึกษา สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน กระทรวงศึกษาธิการ ดำเนินการจัดสอบวัดผลสัมฤทธิ์ทางการเรียนของนักเรียนชั้นประถมศึกษาปีที่ 6 ให้ได้ผลการประเมินที่น่าเชื่อถือและสามารถบ่งชี้คุณภาพการศึกษาระดับชาติ ระดับเขตพื้นที่การศึกษา ระดับสถานศึกษา และระดับผู้เรียนเป็นรายบุคคล ได้อย่างสมเหตุสมผล

วัตถุประสงค์ของการวัดผลสัมฤทธิ์ทางการเรียน

1. เพื่อนำผลไปใช้กำกับ ดูแล ติดตามและประเมินการจัดการศึกษาในระดับประเทศ สำหรับพัฒนาคุณภาพทางการศึกษา
2. เพื่อนักเรียนได้นำผลจากการสอบวัดไปพัฒนาความรู้ ความสามารถและการศึกษาต่อของนักเรียนในระดับที่สูงขึ้น

ขอบข่ายของการประเมิน

ดำเนินการประเมินนักเรียนทุกคนในสังกัดคณะกรรมการการศึกษาขั้นพื้นฐาน และสังกัดอื่นที่จัดการศึกษาระดับประถมศึกษา ตามหลักสูตรประถมศึกษา พุทธศักราช 2521 (ฉบับปรับปรุง 2533) ทุกจังหวัดทั่วประเทศ ได้แก่ สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน สำนักงานคณะกรรมการการศึกษาเอกชน สำนักงานคณะกรรมการการอุดมศึกษา สำนักงานการศึกษากรุงเทพมหานคร สำนักบริหารการศึกษาท้องถิ่น กองบังคับการตำรวจตระเวนชายแดน สำนักงานตำรวจแห่งชาติ และสำนักงานพัฒนาการศึกษาและนันทนาการ

ลักษณะทั่วไปของแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียน

เป็นแบบทดสอบที่สร้างและพัฒนาขึ้นจนเป็นแบบทดสอบมาตรฐาน เพื่อใช้ประเมินผลการเรียนรู้ของนักเรียนที่ได้สะสมมาตลอดการเรียน ตามหลักสูตรประถมศึกษา พุทธศักราช 2521 (ฉบับปรับปรุง 2533) ของกระทรวงศึกษาธิการ

โครงสร้างของแบบทดสอบ

1. เนื้อหาสาระของแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียนชั้นประถมศึกษาปีที่ 6 ประกอบด้วย เนื้อหาตามหลักสูตรประถมศึกษา พุทธศักราช 2521 (ฉบับปรับปรุง 2533) วิชาที่สอบในครั้งนี้ ได้แก่ วิชาภาษาไทย คณิตศาสตร์ วิทยาศาสตร์ และภาษาอังกฤษ

2. แบบทดสอบแต่ละวิชานับวัดความรู้ความเข้าใจ ความคิดวิเคราะห์ และทักษะเชิงกระบวนการเฉพาะวิชา

การเตรียมการสอบ

1. แต่งตั้งคณะกรรมการคุมสอบ

ให้สำนักงานเขตพื้นที่การศึกษาแต่งตั้งคณะกรรมการคุมสอบสลับโรงเรียนภายในเขตพื้นที่การศึกษานั้น ๆ โดยในการคุมสอบแต่ละห้องต้องมีคณะกรรมการคุมสอบ 2 คน

2. การเตรียมตัวนักเรียน

ก่อนดำเนินการสอบให้ผู้บริหารโรงเรียน และครู – อาจารย์ ชี้แจงทำความเข้าใจกับนักเรียนให้ตระหนักถึงประโยชน์และความสำคัญของการสอบ ตั้งใจตอบแบบทดสอบให้เต็มความสามารถที่แท้จริง ทั้งนี้ข้อมูลที่ได้จากการประเมินจะเกิดประโยชน์ต่อนักเรียนและส่วนรวม ดังนี้

2.1 ประโยชน์ต่อนักเรียน นักเรียนจะได้ประโยชน์จากการสอบวัดผลสัมฤทธิ์ทางการเรียนของนักเรียนในระดับชาติ ทำให้เกิดความชำนาญในการคิด ได้เห็นรูปแบบของแบบทดสอบมาตรฐาน เป็นการเพิ่มพูนประสบการณ์ในการสอบ และคะแนนที่ได้จะเป็นข้อมูลประกอบในการพิจารณาเข้าศึกษาต่อของนักเรียน รวมทั้งได้รับทราบความสามารถของตนเองมีจุดเด่นด้านใด ควรปรับปรุงและพัฒนาด้านใด เพราะในการสอบครั้งนี้เป็นการวัดความสามารถหลายด้าน คือ ภาษาไทย คณิตศาสตร์ วิทยาศาสตร์ และภาษาอังกฤษ ผลจากการสอบต้องมาบันทึกลงในเอกสารหลักฐานการศึกษา

2.2 ประโยชน์ต่อสถานศึกษา คณะครู – อาจารย์ นำผลการประเมินไปใช้เป็นข้อมูลในการแนะแนวทางการศึกษาให้กับผู้เรียน และพัฒนาการจัดการเรียนการสอนให้ได้คุณภาพมาตรฐานยิ่งขึ้น

2.3 ประโยชน์ต่อประเทศ รัฐบาลและหน่วยงานที่เกี่ยวข้องกับการจัดการศึกษานำผลการประเมินไปใช้เป็นข้อมูลในการกำหนดนโยบายทางการศึกษา และส่งเสริมสนับสนุนให้สถานศึกษาและหน่วยงานที่เกี่ยวข้อง พัฒนาคุณภาพการศึกษาให้ได้มาตรฐานทัดเทียมนานาชาติ

แนวปฏิบัติกรณีจำเป็นในการดำเนินการสอบ

กระทรวงศึกษาธิการต้องการให้นักเรียนชั้นที่ประเมิน ได้รับการประเมินทุกคนพร้อมกันทั่วประเทศ เพื่อควบคุมความเป็นมาตรฐานในการดำเนินงาน และผลการประเมินมีความตรงเป็นที่น่าเชื่อถือ แต่ในกรณีที่โรงเรียนไม่สามารถดำเนินการสอบในวันที่กำหนด อาจเนื่องมาจาก

เหตุจำเป็นต้องปฏิบัติ ถ้าไม่ดำเนินการจะทำให้ราชการเสียหาย หรือเหตุสุดวิสัยอื่น โรงเรียนอาจเลื่อนการสอบไปได้ โดยเสนอประธานคณะกรรมการดำเนินงานระดับเขตพื้นที่การศึกษาพิจารณาแล้วแจ้งสำนักงานคณะกรรมการการศึกษาขั้นพื้นฐานทราบ

การดำเนินการสอบให้เป็นไปตามระเบียบการสอบของกระทรวงศึกษาธิการอย่างเคร่งครัด กรณีที่นักเรียนขาดสอบให้โรงเรียนพิจารณาถึงสาเหตุและความจำเป็น แล้วจึงพิจารณาให้นักเรียนเข้าสอบชดเชย โดยเก็บรักษาข้อสอบเป็นความลับ และดำเนินการสอบตามระเบียบของกระทรวงศึกษาธิการ

การดำเนินการหลังการสอบ

การดำเนินการหลังการสอบ แบ่งเป็น 3 ส่วน ดังนี้

1. เมื่อกรรมการดำเนินการสอบเก็บและตรวจความเรียบร้อยของกระดาษคำตอบแล้วให้นำส่งคณะกรรมการดำเนินการสอบระดับโรงเรียน จากนั้นโรงเรียนรวบรวมกระดาษคำตอบทั้งหมดส่งคณะกรรมการที่สำนักงานเขตพื้นที่การศึกษากำหนดไว้ สำหรับส่วนกลางให้รวบรวมกระดาษคำตอบส่งที่สำนักทดสอบทางการศึกษา สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน กรุงเทพมหานคร
2. โรงเรียนรวบรวมแบบทดสอบทั้งหมดส่งคืนคณะกรรมการที่สำนักงานเขตพื้นที่การศึกษาแต่งตั้ง เพื่อดำเนินการย่อย/เผาทำลายต่อไป สำหรับส่วนกลาง นำส่งที่โรงพิมพ์คุรุสภาลาดพร้าว
3. คณะกรรมการดำเนินงานระดับเขตพื้นที่การศึกษา รวบรวมกระดาษคำตอบทั้งหมดส่งสำนักทดสอบทางการศึกษา สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน กระทรวงศึกษาธิการทันที เนื่องจากสำนักทดสอบทางการศึกษาจะต้องตรวจกระดาษคำตอบให้ทั้งหมด ซึ่งมีปริมาณมากให้เสร็จสิ้นโดยเร็ว เพื่อให้โรงเรียนได้ทำบันทึกลงในเอกสารหลักฐานการศึกษาได้ทันก่อนปิดภาคเรียน

ตอนที่ 5 ค่าความเที่ยงของแบบทดสอบ

ความเที่ยงของแบบทดสอบ หมายถึง ความคงที่ของคะแนนที่ได้จากการสอบนักเรียนคนเดียวกันหลายครั้งในแบบทดสอบชุดเดิม ถ้าคะแนนเปลี่ยนไปจากเดิม แสดงว่าแบบทดสอบขาดความเที่ยง ทำให้ผลการสอบมีความคลาดเคลื่อนไปจากความรู้จริงของนักเรียน ความคลาดเคลื่อนชนิดนี้ เรียกว่า ความคลาดเคลื่อนในการวัด (Error of Measurement) ในการวัดผลนั้นจะต้องสร้างเครื่องมือที่ต้องการนำไปวัดผลให้มีคุณภาพที่เชื่อมั่นได้ เพื่อผลการวัดที่ออกมาจะได้เป็นคะแนนความรู้จริงของนักเรียนที่ปราศจากความคลาดเคลื่อนในการวัด และค่าเที่ยงจะมีค่าอยู่

ระหว่าง -1 ถึง $+1$ และจะพิจารณาเฉพาะค่าที่เป็นบวกเท่านั้น ซึ่งควรมีค่ามากกว่า 0.70 จึงจะเป็นแบบทดสอบที่มีความเชื่อถือได้

การคำนวณหาค่าความเที่ยงนั้นจะคำนวณในรูปของการประมาณค่า ในรูปของค่าสัมประสิทธิ์ของความเที่ยง มักใช้สัญลักษณ์ว่า r_{tt} , r_{xx} หรือ r_{cc} โดยทั่วไปแล้วความเที่ยงแบ่งออกเป็น 2 ประเภท คือ ความเที่ยงของแบบทดสอบอิงกลุ่ม (Reliability of Norm-Referenced Test) กับความเที่ยงของแบบทดสอบอิงเกณฑ์ (Reliability of Criterion-Referenced Test) และในแต่ละประเภทของการคำนวณหาค่าความเที่ยงนั้น จะมีสูตรที่ใช้ประมาณค่าความเที่ยงอยู่หลายสูตร ซึ่งวิธีคำนวณจำแนกตามลักษณะของแบบทดสอบอิงกลุ่มและอิงเกณฑ์ สำหรับค่าความเที่ยงที่เกี่ยวข้องกับงานวิจัยนี้ เป็นค่าความเที่ยงที่คำนวณโดยใช้ความสอดคล้องภายใน (Internal Consistency Reliability) เป็นการหาความเที่ยงที่ใช้แบบทดสอบฉบับเดียวทำการทดสอบเพียงครั้งเดียว วิธีหาค่าความเที่ยงที่เกี่ยวข้องกับงานวิจัยนี้ได้แก่ วิธีของครอนบาค (Cronbach Alpha Procedure)

ครอนบาคได้พัฒนาสูตรหาความเที่ยงในรูปสัมประสิทธิ์แอลฟา (α -Coefficient) ในปี ค.ศ. 1951 โดยพัฒนามาจากสูตร KR-20 ทั้งนี้เป็นเพราะจะได้ใช้หาความเที่ยงกับเครื่องมือที่ไม่ได้ตรวจให้คะแนนเป็น 1 กับ 0 จะตรวจให้คะแนนลักษณะใดก็ได้ เช่น ถ้าทำถูกได้คะแนนเป็น 10, 8 หรือในลักษณะแบบสอบถามที่ให้คะแนนแต่ละข้อเป็น 3, 2, 1 หรือ 5, 4, 3, 2, 1 ก็ได้ สูตรที่ใช้คือ

$$\alpha = \frac{k}{k-1} \left\{ 1 - \frac{\sum \sigma_i^2}{\sigma^2} \right\}$$

เมื่อ	α	คือ	สัมประสิทธิ์ความเที่ยง
	k	คือ	จำนวนข้อสอบ
	σ_i^2	คือ	คะแนนความแปรปรวนเป็นรายข้อ
	σ^2	คือ	คะแนนความแปรปรวนของทั้งฉบับ

โดยที่

$$\sigma_i^2 = \frac{N \sum X_i^2 - (\sum X_i)^2}{N^2}$$

เมื่อ	$\sum X_i^2$	คือ	ผลรวมกำลังสองของคะแนนในข้อที่ i
	$(\sum X_i)^2$	คือ	ผลรวมทั้งหมดของคะแนนในข้อที่ i ยกกำลังสอง

N คือ จำนวนคนเข้าสอบ

และ

$$\sigma^2 = \frac{N \sum X^2 - (\sum X)^2}{N^2}$$

เมื่อ $\sum X^2$ คือ ผลรวมกำลังสองของคะแนนของข้อสอบทั้งฉบับ
 $(\sum X)^2$ คือ ผลรวมทั้งหมดของคะแนนของข้อสอบทั้งฉบับยกกำลังสอง