

ARTICLE

Rater Agreement Index (RAI)

Surachai Meechan

**Ed.D. (Testing and Measurement), Lecturer,
Department of Educational Evaluation and Research, Faculty of Education,
Prince of Songkla University
E-mail : msuracha@eduadm.edu.psu.ac.th**

Abstract

We can use Rater Agreement Index (RAI) as an index of agreement level of scores gained from two or more raters. This index has a value from 0 to 1. If its value is nearly to 1, it means the raters have a strong agreement in scoring. On the other hand, if its value is nearly to 0, it means that that agreement is not strong. Thus, if the raters are trained and have a good knowledge of scoring, this index can indicate the standard of those scoring rubrics.

Keywords : performance assessment, rater agreement index, scoring rubrics

บทความ

ดัชนีความสอดคล้องระหว่างผู้ประเมิน

สุรชัย มีชาญ

กศ.ด. (การทดสอบและวัดผลการศึกษา), อาจารย์

ภาควิชาประเมินผลและวิจัยทางการศึกษา คณะศึกษาศาสตร์ มหาวิทยาลัยสงขลานครินทร์

E-mail : msuracha@eduadm.edu.psu.ac.th

บทคัดย่อ

ดัชนีความสอดคล้องระหว่างผู้ประเมิน (Rater Agreement Index : RAI) เป็นตัวบ่งชี้ถึงระดับความสอดคล้องกันของคะแนนที่ได้จากผู้ประเมิน 2 คน หรือมากกว่า โดยดัชนีจะมีค่าตั้งแต่ 0-1 เมื่อได้ที่มีค่าเข้าใกล้ 1 แสดงว่าผู้ประเมินสามารถให้คะแนนได้อย่างสอดคล้องกันสูงมาก แต่ถ้ามีค่าเข้าใกล้ 0 ก็แสดงว่ามีความสอดคล้องกันไม่มากนัก ดังนั้นหากผู้ประเมินคือผู้ที่ได้รับการฝึกฝน และมีความรู้ความเข้าใจเกี่ยวกับเกณฑ์การให้คะแนนอย่างดีแล้ว ดัชนีนี้จะช่วยบ่งชี้ถึงมาตรฐานของเกณฑ์การให้คะแนนดังกล่าวได้

คำสำคัญ : การวัดภาคปฏิบัติ, เกณฑ์การให้คะแนน, ดัชนีความสอดคล้องระหว่างผู้ประเมิน

บทนำ

ทุกรั้งที่จัดให้มีการวัดผลการเรียนรู้ในห้องเรียน ความมีเป้าหมายหลักเพื่อค้นหาจุดเด่น และข้อบกพร่องในการเรียนรู้ของนักเรียนแต่ละคน เพื่อที่ครูจะได้หาแนวทางส่งเสริมและปรับปรุงแก้ไขได้อย่างถูกต้องและสอดคล้อง เหมาะสมกับสภาพของแต่ละบุคคลมากที่สุด ดังนั้น ถึงสำคัญอย่างมากที่ครูควรดำเนินการก็คือการสร้างเครื่องมือวัดผลการเรียนรู้ที่มีคุณภาพและการนำเครื่องมือวัดนั้นไปใช้อย่างถูกต้อง โดยเฉพาะยุคปัจจุบันที่การวัดผลการเรียนรู้ได้นั้นหนักไปที่การวัดภาคปฏิบัติ (performance assessment) ซึ่งมุ่งเน้นไปที่การกระทำหรือการปฏิบัติได้ของนักเรียนแต่ละคนมากยิ่งขึ้น ด้วยเหตุนี้เองประสิทธิภาพของการวัดผลการเรียนรู้จึงขึ้นอยู่กับคุณภาพของแบบสังเกตหรือเครื่องมือวัดอื่น ๆ ที่ต้องใช้ดุลยพินิจของผู้ประเมิน (rater) มากยิ่งขึ้นด้วย เพราะ

เมื่อจะวัดความสามารถในการปฏิบัติก็จำเป็นต้องเกี่ยวข้องกับทักษะในกระบวนการ (process) และคุณภาพของผลงาน (product) ที่นักเรียนได้จัดกระทำขึ้น ซึ่งจำเป็นต้องอาศัยดุลยพินิจของผู้ประเมินทั้งสิ้น

แต่ปัญหาที่ครูและสถานศึกษาต่าง ๆ ประสบอยู่ เสมอ ก็คือการขาดเครื่องมือวัดภาคปฏิบัติที่มีคุณภาพโดยเฉพาะเครื่องมือที่มีเกณฑ์การให้คะแนน (scoring rubrics) ที่เหมาะสมและเป็นที่ยอมรับจากทุกฝ่ายที่เกี่ยวข้อง และถึงแม้จะมี ก็พบว่าส่วนใหญ่ไม่ได้ตรวจสอบคุณภาพอย่างเต็มกระบวนการมากนัก โดยเฉพาะการตรวจสอบว่าเครื่องมือนั้นจะสามารถนำไปใช้ได้อย่างเที่ยงตรงและยุติธรรมกับนักเรียนทุกคนหรือไม่ ทั้งนี้ ส่วนหนึ่งคงเป็นเพราะไม่ทราบวิธีการ ขณะที่บางส่วนอาจไม่เห็นความจำเป็น แต่หากเราเ猛ุ่งหวังให้การวัดและ

ประเมินผลการเรียนรู้ในทุกครั้งมีมาตรฐานเป็นที่ยอมรับจากทุกฝ่าย ก็มีความจำเป็นอย่างยิ่งที่เครื่องมือวัดต่าง ๆ ควรจะได้รับการตรวจสอบคุณภาพอย่างดี ที่สุดเท่าที่จะทำได้ก่อนนำไปใช้จริง ทั้งนี้ก็เพื่อให้ได้ผลการวัดที่ถูกต้องและน่าเชื่อถือมากที่สุด

คุณภาพประการหนึ่งที่สำคัญยิ่งของเครื่องมือวัดภาคปฏิบัติ คือ ความชัดเจนและลีดความได้ตรงกันซึ่งเรียกว่า ความเป็น-prนัย (objectivity) โดยเฉพาะในส่วนของเกณฑ์การให้คะแนน ซึ่งจำเป็นต้องมีมาตรฐานอย่างมาก นั่นคือ ไม่ว่าจะนำไปใช้เมื่อใดหรือครุคนใดจะเป็นผู้ใช้ก็ตาม คะแนนเหล่านั้นควรจะคงที่ หรือใกล้เคียงกันมากที่สุดเท่าที่จะเป็นไปได้ ซึ่งคุณภาพดังกล่าวเน้นว่าเป็นลิ่งที่อ่อนด้อยอย่างมากในเครื่องมือวัดทุกประเภทที่ต้องใช้ดุลยพินิจในการตัดสินใจของครุหรือผู้ประเมิน แม้แต่ข้อสอบชนิดบรรยายหรือความเรียง (essay item) ก็ไม่พ้นที่จะประสบปัญหานี้ เช่นเดียวกันโดยเฉพาะในส่วนของการวัดภาคปฏิบัตินั้นไม่ว่าจะมั่งเน้นไปที่กระบวนการหรือผลงานก็ล้วนมีจุดอ่อนนี้ทั้งสิ้น ซึ่งไม่ว่าจะเกิดขึ้นจากอคติหรือความไม่รู้จริงของผู้ประเมินหรือเกิดจากความไม่ชัดเจนของเกณฑ์การให้คะแนนที่กำหนดไว้ก็ตาม จุดอ่อนนี้ควรจะได้รับการแก้ไขให้หมดไปหรือเหลือน้อยที่สุดเท่าที่ครุจะพึงกระทำได้

การกำหนดเกณฑ์การให้คะแนน

โดยทั่วไป เครื่องมือวัดภาคปฏิบัติจะประกอบด้วย 2 ส่วนใหญ่ ๆ คือ ส่วนที่เป็นแบบบันทึกคะแนน ซึ่งครุจะต้องใช้ในการจดบันทึกคะแนนและข้อลักษณะต่าง ๆ กับส่วนที่เป็นเกณฑ์การให้คะแนน เพื่ออธิบายให้ครุทราบว่าจะต้องพิจารณาประเด็นใดบ้างและให้คะแนนในแต่ละประเด็นอย่างไร ซึ่งสองส่วนนี้อาจพิมพ์ไว้คนละด้านหรืออาจจัดพิมพ์แยกไว้ต่างหากก็แล้วแต่ความเหมาะสม ในที่นี้จะขอกล่าวถึงเฉพาะลักษณะและตัวอย่างของเกณฑ์การให้คะแนนที่มีผู้นำเสนอนี้แล้วอย่างคร่าว ๆ เพื่อเป็นการเกรินนำเข้าสู่ขั้นตอนการตรวจสอบคุณภาพของเกณฑ์ดังกล่าวถูกต้องหรือไม่เท่านั้น โดยจะไม่กล่าวถึงลักษณะและตัวอย่างของแบบบันทึกคะแนนแต่ประการใด ทั้งนี้เพราะสามารถศึกษาค้นคว้าในประเด็นเหล่านี้ได้จากเอกสารต่างๆ ทางด้านการวัด

และประเมินผลการศึกษาที่พิมพ์เผยแพร่ต่อผู้ที่นำไป และตามแนวทางที่ปฏิบัติกันโดยทั่วไปนั้น ผู้สร้างเครื่องมือวัดก็มีอิสระที่จะกำหนดรูปลักษณ์ของแบบบันทึกคะแนน ได้อย่างหลากหลาย ขึ้นอยู่กับความพึงพอใจและความสะดวกในการนำไปใช้เป็นสำคัญ

รุ่งศิรินทร์ จันทร์หอม (2545, 26) ได้นำเสนอตัวอย่างเกณฑ์การให้คะแนน สำหรับใช้ในการวัดภาคปฏิบัติ ทั้งในส่วนของการกำหนดเกณฑ์การให้คะแนนแบบภาพรวม (holistic scoring rubrics) อันหมายถึง การให้คะแนนโดยพิจารณาคุณภาพของผลงานหรือการกระทำในภาพรวมทั้งหมด และการกำหนดเกณฑ์การให้คะแนนแบบแยกองค์ประกอบ (analytic scoring rubrics) ซึ่งเป็นการให้คะแนนโดยการแบ่งย่อยกระบวนการหรือผลงานนั้นออกเป็นส่วน ๆ แล้วจึงพิจารณาให้คะแนนในแต่ละส่วนนั้น ดังปรากฏในตัวอย่างที่ 1 และ 2 ดังนี้

ตัวอย่างที่ 1

เกณฑ์การให้คะแนนแบบภาพรวม สำหรับงานประดิษฐ์ใบตองกลีบบัวหลวง

4 (ดีมาก) หมายถึง เตรียมวัสดุอุปกรณ์ครบถ้วน เหมาะสม ฉีกใบตองเท่ากันทุกชิ้น ไม่ช้ำ พับกลีบปลายแหลมสมบูรณ์ทุกกลีบ การส่งกลีบเสมอ กันทุกกลีบ รอยเย็บเรียบ แข็งแรงและสามารถนำไปใช้ได้ตามวัตถุประสงค์

3 (ดี) หมายถึง เตรียมวัสดุอุปกรณ์ครบถ้วน เหมาะสม ฉีกใบตองเท่ากันทุกชิ้น ไม่ช้ำ พับกลีบปลายแหลมสมบูรณ์บางกลีบ การส่งกลีบเสมอ กันทุกกลีบ รอยเย็บเรียบ แข็งแรงพอใช้ สามารถนำไปใช้ได้ตามวัตถุประสงค์

2 (พอใช้) หมายถึง เตรียมวัสดุอุปกรณ์มาบางส่วน ฉีกใบตองไม่ช้ำแต่ยังไม่เท่ากันทุกชิ้น พับกลีบปลายไม่แหลม การส่งกลีบไม่เสมอ กัน รอยเย็บไม่เรียบ นำไปใช้งานยังไม่เป็นที่น่าพอใจนัก

1 (ควรปรับปรุง) หมายถึง ยังไม่วัสดุอุปกรณ์จากเพื่อน ปฏิบัติงานไม่ตลอดเวลา ผลงานไม่สำเร็จ

ตัวอย่างที่ 2

เกณฑ์การให้คะแนนแบบแยกองค์ประกอบ สำหรับงานประดิษฐ์ลีบของจ่าวสุดทุ่เหลือใช้

รายการ	ระดับคุณภาพ		
	3 (ดี)	2 (พอใช้)	1 (ควรปรับปรุง)
การเตรียมงาน	สะสมวัสดุเหลือใช้ได้พอเพียงและเหมาะสม	สะสมวัสดุเหลือใช้ได้พอเพียงและเหมาะสมบางส่วน	สะสมวัสดุเหลือใช้ได้ไม่พอเพียง
ลำดับขั้นในการทำงาน	ปฏิบัติงานได้ตามลำดับขั้นตอน	ปฏิบัติงานเป็นไปตามขั้นตอนบางส่วน	ปฏิบัติงานไม่เป็นไปตามขั้นตอน
ความคิดริเริ่มสร้างสรรค์	ความคิด ผลงาน ผู้เรียนคิดขึ้นเอง	ความคิด ผลงาน ผู้เรียนค้นคว้า ลอกเลียนแบบจากหนังสือ	ความคิด ผลงาน ลอกเลียนแบบจากเพื่อน
ใช้งานได้ตามวัตถุประสงค์	ผลงานนำไปใช้ได้ตามวัตถุประสงค์	ผลงานนำไปใช้ยังไม่เป็นที่น่าพอใจ	ผลงานไม่เสร็จสมบูรณ์
ความรับผิดชอบ	ทำงานที่ได้รับมอบหมาย ครบถ้วน และส่งงานตามกำหนดเวลา	ทำงานที่ได้รับมอบหมาย ครบถ้วน แต่ส่งงานช้า กว่ากำหนดเวลา	ทำงานที่ได้รับมอบหมาย บางครั้ง และส่งงานที่ไม่เสร็จสมบูรณ์
ความประณีต เรียนร้อย	ผลงานมีความประณีต เรียบร้อยดี	ผลงานเรียบร้อยพอใช้	ผลงานขาดความประณีต เรียบร้อย
ความมีน้ำใจ	ช่วยเหลือผู้อื่นสม่ำเสมอ	ช่วยเหลือผู้อื่นบ้างในบางครั้ง	หลีกเลี่ยงการช่วยเหลือผู้อื่น

ตัวอย่างที่ 3

แบบวัดฉบับหนึ่งถูกสร้างขึ้นเพื่อวัดทักษะของนักเรียนในการพูดถือสารที่หน้าชั้นเรียน โดยทักษะดังกล่าวประกอบด้วยพฤติกรรมบ่งชี้หรือองค์ประกอบที่สำคัญรวม 4 ประการ และกำหนดเกณฑ์การให้คะแนนไว้ดังต่อไปนี้ (ดัดแปลงจาก สุวิมล ว่องวานิช, 2535, 516)

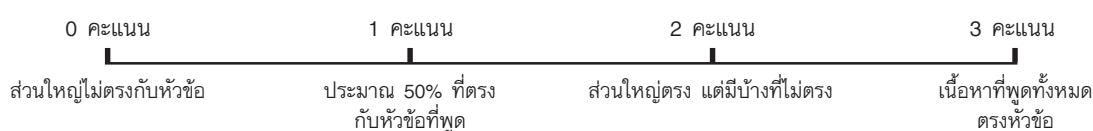
จากตัวอย่างที่ 3 แสดงให้เห็นว่าเกณฑ์การให้คะแนนและปัญหาด้านคุณภาพตามที่ได้กล่าวมาแล้วนั้น แนวทางหนึ่งที่ควรคำนึงถึงคือการก็อปปี้การตรวจสอบว่าเครื่องมือวัด

ฉบับนั้นจะสามารถนำไปใช้ได้อย่างมีมาตรฐานมากน้อยเพียงใด ทั้งนี้โดยการมอบหมายให้ผู้ประเมินอย่างน้อย 2 คนได้ทดลองประเมินการทำงานหรือผลงานของนักเรียนหนึ่งคนหรือมากกว่า แล้วจึงใช้กระบวนการทางสถิติมาช่วยตรวจสอบความสอดคล้องของคะแนนที่ได้จากการช่วยเหล่านั้นว่ามีมากน้อยเพียงใด ถ้าพบว่ามีความสอดคล้องกันอย่างมาก ย่อมบ่งชี้ว่าเครื่องมือวัดฉบับนั้นมีมาตรฐานเพียงพอที่จะนำไปใช้ต่อไป และหนึ่งในวิธีการทางสถิติก็คือดัชนีความสอดคล้องระหว่าง

เกณฑ์การให้คะแนน

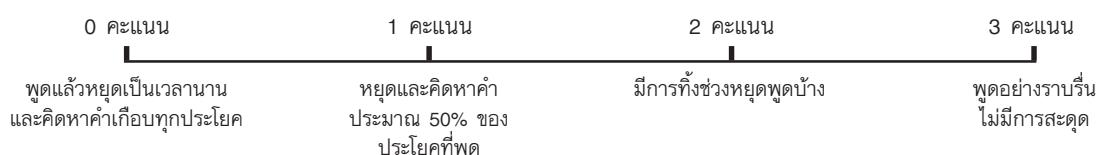
1. ความตรงของเนื้อหา

เนื้อหาที่พูดตรงกับหัวข้อหรือไม่ ?



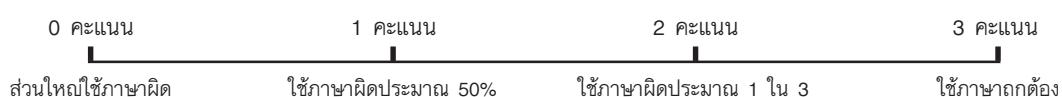
2. ความต่อเนื่องของการพูด

การพูดดำเนินไปอย่างราบรื่นหรือไม่ ?



3. ความถูกต้องในการใช้ภาษา

ใช้ภาษาได้ถูกต้องหรือไม่ ?



4. ความเหมาะสมของน้ำเสียง

ใช้น้ำเสียงเหมาะสมหรือไม่ ?



ผู้ประเมินซึ่งนำเสนอไว้โดย Judith A. Burry-Stock และคณะ (Burry-Stock & other, 1996)

ดัชนีความสอดคล้องระหว่างผู้ประเมิน

เราสามารถใช้ดัชนีความสอดคล้องระหว่างผู้ประเมิน เพื่อตรวจสอบคุณภาพของเครื่องมือวัดที่กำหนด คะแนนไว้เป็นช่วง ๆ ได้อย่างหลักหลาຍ ทั้งที่ให้คะแนนแบบ 0-1 หรือแบบหลักค่าต่าง ๆ เช่น ให้

0-1-2-3, 1-2-3-4 หรืออื่น ๆ ซึ่งในการคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมินที่จะกล่าวถึงต่อไปนี้ ผู้เขียนจะได้นำเสนอแยกเป็นประเด็นย่อย ๆ ตามจำนวนของพฤติกรรมบางช่วงที่เรื่องค์ประกอบที่มุ่งวัด จำนวนของนักเรียนหรือผลงาน(ในกรณีที่ต้องการประเมินผลงาน) และจำนวนของผู้ประเมินห่างหมัด โดยมีการเพิ่มเติมตัวแปรและลัญลักษณ์ในสูตรคำนวณเดิมบ้างเล็กน้อย ทั้งนี้ด้วยความคาดหวังว่าจะช่วยให้ลือความเข้าใจได้ดี

ยิ่งขึ้น และทุกครั้งที่มีการกล่าวถึงดัชนีความสอดคล้องระหว่างผู้ประเมินที่คำนวณมาได้จะหมายถึงเฉพาะกรณีที่ผู้ประเมินทุกคนได้รับคำชี้แจงและฝึกฝนการใช้เครื่องมือวัดอย่างดีที่สุดแล้ว ทั้งนี้เพื่อให้ดัชนีดังกล่าวสามารถบ่งชี้ถึงคุณภาพของเครื่องมือวัดอย่างแท้จริง เพราะถ้าไม่ใช่ ดัชนีนี้อาจจะบ่งชี้กลับไปยังมาตรฐานของผู้ประเมินแทน (แต่ก็คงไม่ใช่เรื่องยากนัก หากจะลองเชื่อมโยงความคิดจากประดิษฐ์แบบไปสู่ประเด็นที่สองหรือประเด็นอื่น ๆ ต่อไปอีก) ดังรายละเอียดต่อไปนี้

1. กรณีที่มีพฤติกรรมบ่งชี้เพียงหนึ่งตัว นักเรียนคนเดียว และมีผู้ประเมิน 2 คน

ในกรณีที่ทดลองใช้เครื่องมือวัดนั้นกับนักเรียนเพียงคนเดียวโดยมีพฤติกรรมบ่งชี้เพียงหนึ่งตัวและมีผู้ประเมิน 2 คน คะแนนที่ได้จากผู้ประเมินแต่ละคนจึงมีเพียง 1 ค่า เช่นเดียวกัน ดังนั้นในการคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมิน 2 คนใด ๆ จึงสามารถใช้แนวคิดพื้นฐานอย่างง่ายได้ว่า หากผู้ประเมินทั้งสองให้คะแนนเท่ากันแล้ว "ผลต่างของคะแนนที่ได้จากผู้ประเมินทั้งสอง" จะมีค่าเท่ากับ 0 ซึ่งจะส่งผลให้ลดต่ำลง (proportion) ของ "ผลต่างของคะแนนที่ได้จากผู้ประเมินทั้งสอง" กับ "ผลต่างสูงสุดของคะแนนที่เป็นไปได้" มีค่าเท่ากับ 0 ด้วย (มีความสอดคล้องกันอย่างสมบูรณ์) แต่เมื่อใดที่ผู้ประเมินทั้งสองให้คะแนนต่างกันมากขึ้น ลักษณะดังกล่าวก็จะมีค่าสูงขึ้นตามไปด้วย โดยจะมีค่าเท่ากับ 1 เมื่อคะแนนทั้งสองต่างกันสุดขั้ว ดังนั้นหากกำหนดให้ | ค่าคะแนนที่ได้ - ค่าคะแนนที่เป็นไปได้ | = 1 แสดงจำนวนของคะแนนที่เป็นไปได้ทั้งหมด เช่น เมื่อกำหนดคะแนนไว้เป็น "0-1-2-3 คะแนน" กรณีนี้จะมีจำนวนของคะแนนที่เป็นไปได้ เท่ากับ 4 ค่า (I = 4) ดังนั้นผลต่างสูงสุดของคะแนนที่เป็นไปได้จากผู้ประเมิน 2 คนใด ๆ จึงมีค่าเท่ากับ | I - 1 | หรือ 4 - 1 หรือ 3 คะแนนดังนั้นหากผู้ประเมินทั้งสองให้คะแนนต่างกันสุดขั้ว คือ "0 กับ 3" ยอมสะท้อนให้เห็นว่าไม่มีความสอดคล้องระหว่างผู้ประเมินทั้งสองคนนั้น ในทำนองกลับกันหากผู้ประเมินทั้งสองให้คะแนนเท่ากันก็แสดงว่ามีความสอดคล้องระหว่างผู้ประเมินอย่างสมบูรณ์จากหลักการพื้นฐานนี้จึงอาจกล่าวอย่างรวบรัดถึงสูตรที่ใช้ในการคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมิน (2 คน) ได้ดังนี้

$$RAI = 1 - \frac{| R_1 - R_2 |}{I - 1} \quad 1$$

โดยที่

R_1 แทน ดัชนีความสอดคล้องระหว่างผู้ประเมิน

R_2 แทน คะแนนที่ได้จากผู้ประเมินคนที่ 1

I แทน คะแนนที่ได้จากผู้ประเมินคนที่ 2

| แทน จำนวนของคะแนนทั้งหมดที่เป็นไปได้

(ตามเกณฑ์การให้คะแนน)

ทั้งนี้ดัชนีความสอดคล้องระหว่างผู้ประเมินจะมีค่าสูงสุดเท่ากับ 1 เมื่อผู้ประเมินทั้งสองคนให้คะแนนเท่ากัน และมีค่าต่ำสุดเท่ากับ 0 เมื่อผู้ประเมิน 2 คนนั้นให้คะแนนต่างกันสุดต่ำหรือสวนทางกันอย่างสิ้นเชิง กล่าวคือหากคนหนึ่งให้คะแนนสูงสุดเท่าที่จะเป็นไปได้ อีกคนหนึ่งจะให้คะแนนต่ำสุดเท่าที่จะเป็นไปได้ ซึ่งจะทำให้ผลต่างของคะแนนที่ได้จากผู้ประเมินทั้งสอง (ค่าสัมบูรณ์ของ $R_1 - R_2 : | R_1 - R_2 |$) มีค่าเท่ากับ $I - 1$ อันจะส่งผลให้ RAI มีค่าเท่ากับ 0 ดังกล่าวแล้ว

อย่างไรก็ตามในการนำไปประยุกต์ใช้ก็ไม่ได้มีการกำหนดเกณฑ์ไว้อย่างเด่นชัดว่าดัชนีความสอดคล้องระหว่างผู้ประเมินที่คำนวณได้ควรมีค่าเท่าใดจึงจะถือว่ามีความสอดคล้องระหว่างผู้ประเมินมากพอที่จะยอมรับเพราะภัยได้เงื่อนไขของ การปฏิบัติจริง เราจำเป็นต้องพิจารณาตัดสินใจด้วยว่าจากจุดประสงค์ของการใช้เครื่องมือวัดในครั้งนั้น ๆ จำเป็นต้องใช้เครื่องมือที่มีคุณภาพมากน้อยเพียงใด ดังนั้นการแปลความหมายของค่าดัชนีความสอดคล้องระหว่างผู้ประเมินที่ปรากฏในบทความนี้จึงเป็นการใช้คำตามความหมายอย่างกว้าง ๆ เพียงเพื่อให้สื่อความกันโดยทั่วไปได้เท่านั้น

ตัวอย่าง

จากการประเมินงานประดิษฐ์ใบตองกลีบบัวหลวงของนักเรียนคนหนึ่งโดยผู้ประเมิน 2 คน ด้วยเครื่องมือวัดที่มีเกณฑ์การให้คะแนน รวม 4 ค่า คือ 1-2-3-4 คะแนน (จากตัวอย่างที่ 1)

สมมติว่า ผู้ประเมินคนแรกให้ 4 คะแนน และผู้ประเมินคนที่สองให้เพียง 2 คะแนน ผลต่างของคะแนนที่ได้จากผู้ประเมินทั้งสอง หรือ $| R_1 - R_2 |$ จะมี

ค่าเท่ากับ 2 คะแนน ขณะที่ผลต่างสุดสุดที่เป็นไปได้เท่ากับ 1 - 1 หรือ 4 - 1 หรือ 3 คะแนน ดังนั้น RAI จะมีค่าเท่ากับ $0.33 \times$ ซึ่งค่าดังกล่าวนี้แสดงให้เห็นว่าการตัดสินครั้งนี้ไม่มีมาตรฐานพอที่จะยอมรับได้ เพราะแม้จะมีเกณฑ์การให้คะแนนที่กำหนดไว้ร่วมกันแล้ว แต่ผู้ประเมินทั้งสองคนยังไม่สามารถให้คะแนนอย่างสอดคล้องกันได้ ทั้งนี้จึงมีความจำเป็นต้องพิจารณาแก้ไขเกณฑ์การให้คะแนนให้มีคุณภาพดีอีก

ในกรณีที่กำหนดคะแนนไว้เพียง 2 ค่า ($I = 2$) เช่น เมื่อให้ 0-1 หรือ 1-2 คะแนน จะทำให้ $1 - 1$ มีค่าเท่ากับ 1 จึงสามารถเขียนสูตรใหม่ให่ง่ายขึ้นกว่าเดิมได้ดังนี้

$$RAI = 1 - |R_1 - R_2| \quad \dots \dots \dots 2$$

แม้ว่าโอกาสที่จะได้ใช้สูตรที่ 1 และ 2 คงไม่บ่อยนัก เพราะเครื่องมือวัดที่เรารังขึ้นมักจะถูกนำไปทดลองใช้กับนักเรียนจำนวนมาก และโดยทั่วไปก็มักจะมีพฤติกรรมบ่งชี้หลาย ๆ ด้าน แต่สำหรับที่นิยมสูตรนี้มา กันกว้างขึ้นได้ด้วยก็เพื่อให้ทราบแนวคิดพื้นฐานของการพัฒนาสูตรต่าง ๆ ที่ซับซ้อนขึ้นดังที่จะได้กล่าวถึงด่อไป

2. กรณีที่มีพฤติกรรมบ่งชี้เพียงหนึ่งตัว นักเรียนคนเดียว และมีผู้ประเมินหลายคน

ในกรณีที่นำเครื่องมือวัดที่มีพฤติกรรมบ่งชี้เพียงหนึ่งตัวไปทดลองใช้กับนักเรียนเพียงคนเดียว แต่กำหนดให้มีผู้ประเมินหลายคน เรายสามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมินได้ด้วยสูตรดังต่อไปนี้

$$RAI = 1 - \frac{\sum_{m=1}^M |R_m - \bar{R}|}{(M-1)(I-1)} \quad \dots \dots \dots 3$$

โดยที่

RAI แทน ดัชนีความสอดคล้องระหว่างผู้ประเมิน

R_m แทน คะแนนที่ได้จากผู้ประเมินคนที่ m ($m = 1, 2, 3, \dots, M$)

\bar{R} แทน คะแนนเฉลี่ย หรือค่าเฉลี่ยเลขคณิต (arithmetic mean) ของคะแนนที่ได้จากผู้ประเมินทุกคน ซึ่งคำนวณได้จากสูตร

$$\bar{R} = \frac{\sum_{m=1}^M R_m}{M}$$

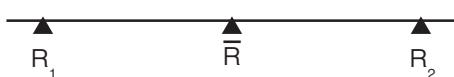
M แทน จำนวนของผู้ประเมินทั้งหมด

I แทน จำนวนของคะแนนทั้งหมดที่เป็นไปได้ (ตามเกณฑ์การให้คะแนน)

ทั้งนี้หากพิจารณาโดยอาศัยหลักสถิติจะเห็นได้ว่าผลลัพธ์ของคะแนนแต่ละตัวลบด้วยค่าเฉลี่ย ($R_m - \bar{R}$) ก็คือ คะแนนเบี่ยงเบน (deviate score) นั่นเอง ซึ่งหากผลรวมของค่าล้มบูรณาของคะแนนเบี่ยงเบนทั้งหมดมีค่ามากย่อมแสดงว่าผู้ประเมินแต่ละคนให้คะแนนที่แตกต่างกันมาก ในทางตรงกันข้ามถ้าผลรวมดังกล่าวมีค่าลดต่ำลงก็แสดงว่าผู้ประเมินให้คะแนนได้อย่างสอดคล้องกันมากขึ้นด้วย โดยเมื่อได้ที่ผู้ประเมินทุกคนสามารถให้คะแนนได้เท่ากัน คะแนนเบี่ยงเบนทุกด้วยก็จะมีค่าเท่ากับ 0 ซึ่งจะทำให้ RAI มีค่าเท่ากับ 1 ดังนั้นหากเราย้อนกลับไปพิจารณาสูตรที่ 1 ยิ่กครั้งจะพบว่าเป็นสูตรเดียวกับสูตรที่ 3 นั่นเอง เพียงแต่มีการปรับเปลี่ยนรูปลักษณะใหม่ เพราะในการนี้มีผู้ประเมิน 2 คน ($M = 2$) ค่าของ $M - 1$ จะเท่ากับ 1 จึงไม่ปรากฏ $M - 1$ อยู่ในสูตรดังกล่าว และ

$$\text{ในทางสถิตินั้น } \sum_{m=1}^2 |R_m - \bar{R}| \text{ ย่อมมีค่าเท่ากับ } |R_1 - R_2|$$

จึงสามารถใช้แทนกันได้เสมอ ซึ่งในกรณีนี้ท่านสามารถพิจารณาถึงความเท่ากันของทั้งคู่ได้ด้วยเส้นกราฟต่อไปนี้



ตัวอย่าง

สมมติว่าคะแนนงานประดิษฐ์คาดใบทองกลีบบัวหลวงของนักเรียนคนหนึ่งที่ได้จากผู้ประเมิน 3 คน มีค่าเท่ากับ 3, 3 และ 2 คะแนน ตามลำดับ เราสามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมินได้ดังนี้

R_1	R_2	R_3	\bar{R}	$ R_1 - \bar{R} $	$ R_2 - \bar{R} $	$ R_3 - \bar{R} $
3	3	2	2.67	0.33	0.33	0.67
$\sum_{m=1}^3 R_m - \bar{R} = 1.33$						

แทนค่าต่าง ๆ ลงในสูตรคำนวณ จะได้

$$\begin{aligned} RAI &= 1 - \frac{\sum_{m=1}^M |R_m - \bar{R}|}{(M-1)(I-1)} \\ &= 1 - \frac{1.33}{(3-1)(4-1)} \\ &= 0.78 \end{aligned}$$

ดัชนีความสอดคล้องระหว่างผู้ประเมินจึงมีค่าเท่ากับ 0.78 ซึ่งแสดงให้เห็นว่าเครื่องมือวัดฉบับนี้มีคุณภาพอยู่ในขั้นใช้ได้ แต่ความสามารถปรับปรุงเกณฑ์การให้คะแนนให้ชัดเจนและถือความได้ตรงกันมากขึ้นกว่านี้ก็จะดีมาก

3. กรณีที่มีพฤติกรรมบ่งชี้หลายตัว นักเรียนคนเดียว และมีผู้ประเมิน 2 คน

ในการนี้ที่นำเครื่องมือวัดที่มีพฤติกรรมบ่งชี้หลายตัวไปทดลองใช้กับนักเรียนเพียงคนเดียว โดยกำหนดให้มีผู้ประเมิน 2 คน คะแนนที่ได้จากผู้ประเมินแต่ละคนก็จะมีหลายค่าตามจำนวนของพฤติกรรมบ่งชี้ทั้งหมด และสามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมินได้ด้วยสูตรดังต่อไปนี้

$$RAI = 1 - \frac{\sum_{k=1}^K |R_{1k} - R_{2k}|}{K(I-1)} \quad \dots \dots \dots \quad 4$$

โดยที่

R_{1k} แทน ดัชนีความสอดคล้องระหว่างผู้ประเมิน R_{2k} แทน คะแนนที่ได้จากผู้ประเมินคนที่ 1 ในพฤติกรรมที่ k ($k = 1, 2, 3, \dots, K$)

R_{2k} แทน คะแนนที่ได้จากผู้ประเมินคนที่ 2 ในพฤติกรรมที่ k ($k = 1, 2, 3, \dots, K$)

K แทน จำนวนของพฤติกรรมบ่งชี้ทั้งหมด

I แทน จำนวนของคะแนนทั้งหมดที่เป็นไปได้ (ตามเกณฑ์การให้คะแนน)

กรณีนี้ RAI จะมีค่าสูงสุดเท่ากับ 1 เมื่อผู้ประเมินทั้งสองสามารถให้คะแนนได้ตรงกันในทุกพฤติกรรม และจะมีค่าต่ำสุดเท่ากับ 0 เมื่อผู้ประเมินทั้งสองคนนั้นให้คะแนนต่างกันสุดโต่งหรือสวนทางกันอย่างสิ้นเชิงในทุกพฤติกรรม

ตัวอย่าง

คะแนนทักษะในการพูดหน้าชั้น (ตามที่ได้กล่าวถึงมาแล้วในตัวอย่างที่ 3) ของนักเรียนคนหนึ่งที่ได้จากผู้ประเมิน 2 คน ปรากฏผลดังนี้

รายการประเมิน	คะแนนที่ได้จากผู้ประเมิน คนที่ 1	คะแนนที่ได้จากผู้ประเมิน คนที่ 2
1. ความตรงของเนื้อหา	2	3
2. ความต่อเนื่องของ การพูด	1	1
3. ความถูกต้องในการใช้ภาษา	3	2
4. ความเหมาะสมของน้ำเสียง	2	2

จากคะแนนที่ปรากฏ สามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมิน ได้ดังนี้

k	R_{1k}	R_{2k}	$ R_{1k} - R_{2k} $
1	2	3	1
2	1	1	0
3	3	2	1
4	2	2	0

	$\sum_{k=1}^4 R_{1k} - R_{2k} = 2$
--	--------------------------------------

แทนค่าต่างๆ ลงในสูตรคำนวณ จะได้

$$\begin{aligned} RAI &= 1 - \frac{\sum_{k=1}^K |R_{1k} - R_{2k}|}{K(I-1)} \\ &= 1 - \frac{2}{4(4-1)} \\ &= 0.83 \end{aligned}$$

ดัชนีความสอดคล้องระหว่างผู้ประเมินจึงมีค่าเท่ากับ 0.83 ซึ่งแสดงให้เห็นว่าแบบวัดทักษะการพูดหน้าชั้นฉบับนี้มีคุณภาพอยู่ในขั้นใช้ได้ แต่หากปรับปรุงเกณฑ์การให้คะแนนในพฤติกรรมที่ 1 และ 3 ให้ชัดเจนจะสามารถอีกความได้ตรงกันมากกว่านี้ก็จะดีมาก

4. กรณีที่มีพฤติกรรมบ่งชี้หลายตัว นักเรียนคนเดียว และผู้ประเมินหลายคน

ในการนี้ที่นำเครื่องมือวัดที่มีพฤติกรรมบ่งชี้หลายตัวไปทดลองใช้กับนักเรียนเพียงคนเดียว แต่กำหนดให้มีผู้ประเมินหลายคน จะสามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมินได้ด้วยสูตรดังต่อไปนี้

$$RAI = 1 - \frac{\sum_{k=1}^K \sum_{m=1}^M |R_{mk} - \bar{R}_k|}{K(M-1)(I-1)} \quad \dots\dots\dots 5$$

โดยที่

RAI แทน ดัชนีความสอดคล้องระหว่างผู้ประเมิน
 R_{mk} แทน คะแนนที่ได้จากผู้ประเมินคนที่ m ในพฤติกรรมที่ k ($m = 1, 2, 3, \dots, M$ และ $k = 1, 2, 3, \dots, K$)

\bar{R}_k แทน คะแนนเฉลี่ยในพฤติกรรมที่ k
ซึ่งคำนวณได้จากสูตร

$$\bar{R}_k = \frac{\sum_{m=1}^M R_{mk}}{M}$$

K แทน จำนวนของพฤติกรรมบ่งชี้ทั้งหมด

M แทน จำนวนของผู้ประเมินทั้งหมด

I แทน จำนวนของคะแนนทั้งหมดที่เป็นไปได้
(ตามเกณฑ์การให้คะแนน)

ตัวอย่าง

คะแนนทักษะการพูดหน้าชั้นของนักเรียนคนหนึ่งที่ได้จากผู้ประเมิน 3 คน ปรากฏผลดังนี้

รายการประเมิน	คะแนนที่ได้จากผู้ประเมินคนที่ 1	คะแนนที่ได้จากผู้ประเมินคนที่ 2	คะแนนที่ได้จากผู้ประเมินคนที่ 3
1. ความตรงของเนื้อหา	2	3	2
2. ความต่อเนื่องของสารพูด	1	1	1
3. ความถูกต้องในการใช้ภาษา	3	2	3
4. ความเหมาะสมสมของน้ำเสียง	2	2	2

จากคะแนนที่ปรากฏ สามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมิน ได้ดังนี้

k	R _{1k}	R _{2k}	R _{3k}	\bar{R}_k	R _{1k} - \bar{R}_k	R _{2k} - \bar{R}_k	R _{3k} - \bar{R}_k	$\sum_{m=1}^3 R_{mk} - \bar{R}_k $
1	2	3	2	2.33	0.33	0.67	0.33	1.33
2	1	1	1	1	0	0	0	0
3	3	2	3	2.67	0.33	0.67	0.33	1.33
4	2	2	2	2	0	0	0	0

$\sum_{k=1}^4 \sum_{m=1}^3 R_{mk} - \bar{R}_k = 2.66$

แทนค่าต่าง ๆ ลงในสูตรคำนวณ จะได้

$$\begin{aligned} RAI &= 1 - \frac{\sum_{k=1}^K \sum_{m=1}^M |R_{mk} - \bar{R}_k|}{K(M-1)(I-1)} \\ &= 1 - \frac{2.66}{4(3-1)(4-1)} \\ &= 0.89 \end{aligned}$$

ดัชนีความสอดคล้องระหว่างผู้ประเมินจึงมีค่าเท่ากับ 0.89 ซึ่งแสดงให้เห็นว่าแบบวัดทักษะการพูดหน้ากลุ่มนักเรียนทุกคนได้มาตรฐานปัจจุบัน แต่หากปรับปรุงเกณฑ์การให้คะแนนในพฤติกรรมที่ 1 และ 3 ให้ชัดเจนจะสามารถลือความได้ตรงกันมากกว่านี้ก็จะดีมาก

5. กรณีที่มีพฤติกรรมบ่งชี้หลายตัว นักเรียนหลายคน และผู้ประเมิน 2 คน

ในกรณีที่เรานำเครื่องมือวัดที่มีพฤติกรรมบ่งชี้หลายตัวไปทดลองใช้กับนักเรียนกลุ่มนี้ (แทนที่จะทดลองใช้กับนักเรียนเพียงคนเดียว) โดยกำหนดให้มีผู้ประเมิน 2 คน จะสามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมิน ได้ด้วยสูตรดังต่อไปนี้

$$RAI = 1 - \frac{\sum_{k=1}^K \sum_{n=1}^N |R_{1nk} - R_{2nk}|}{KN(I-1)} \quad \dots\dots 6$$

โดยที่

R_{1nk} แทน ดัชนีความสอดคล้องระหว่างผู้ประเมิน R_{2nk} แทน คะแนนที่ได้จากผู้ประเมินคนที่ 1 ของนักเรียนคนที่ n ในพฤติกรรมที่ k (n = 1, 2, 3,..., N และ k = 1, 2, 3,..., K)

R_{2nk} แทน คะแนนที่ได้จากผู้ประเมินคนที่ 2 ของนักเรียนคนที่ n ในพฤติกรรมที่ k (n = 1, 2, 3,..., N และ k = 1, 2, 3,..., K)

- K แทน จำนวนของพฤติกรรมบ่งชี้ทั้งหมด
 N แทน จำนวนของนักเรียนทั้งหมด
 I แทน จำนวนของคะแนนทั้งหมดที่เป็นไปได้ ที่ได้จากผู้ประเมิน 2 คน ปรากฏผลดังนี้
 (ตามเกณฑ์การให้คะแนน)

นักเรียน คนที่	คะแนนที่ได้จากผู้ประเมินคนที่ 1				คะแนนที่ได้จากผู้ประเมินคนที่ 2			
	ความตรง ของเนื้อหา	ความต่อเนื่อง ของการพูด	ความถูกต้อง ในการใช้ภาษา	ความเหมาะสม ของน้ำเสียง	ความตรง ของเนื้อหา	ความต่อเนื่อง ของการพูด	ความถูกต้อง ในการใช้ภาษา	ความเหมาะสม ของน้ำเสียง
1	2	1	3	2	3	1	2	2
2	1	2	3	1	3	2	1	2
3	1	2	2	3	1	2	2	3
4	2	1	3	1	3	2	1	2
5	0	2	3	2	1	2	3	2

จากคะแนนที่ปรากฏ สามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมิน ได้ดังนี้

	R_{1nk}				R_{2nk}				$ R_{1nk} - R_{2nk} $			
$n \backslash k$	1	2	3	4	1	2	3	4	1	2	3	4
1	2	1	3	2	3	1	2	2	1	0	1	0
2	1	2	3	1	3	2	1	2	2	0	2	1
3	1	2	2	3	1	2	2	3	0	0	0	0
4	2	1	3	1	3	2	1	2	1	1	2	1
5	0	2	3	2	1	2	3	2	1	0	0	0

$R_{1nk} - R_{2nk}$	$\sum_{k=1}^4 \sum_{n=1}^5 R_{1nk} - R_{2nk} = 13$
---------------------	--

แทนค่าต่าง ๆ ลงในสูตรคำนวณ จะได้

$$\begin{aligned}
 RAI &= 1 - \frac{\sum_{k=1}^K \sum_{n=1}^N |R_{1nk} - R_{2nk}|}{KN(I-1)} \\
 &= 1 - \frac{13}{(4)(5)(4-1)} \\
 &= 0.78
 \end{aligned}$$

ดัชนีความสอดคล้องระหว่างผู้ประเมินจึงมีค่าเท่ากับ 0.78 ซึ่งแสดงให้เห็นว่าแบบวัดทักษะการพูดหน้าชั้นบันบีมีคุณภาพอยู่ในขั้นใช้ได้ แต่หากปรับปรุงเกณฑ์การให้คะแนนในบางพฤติกรรมให้ชัดเจนจะสามารถสื่อความได้ตรงกันมากกว่านี้ก็จะดีมาก (จากตัวอย่างนี้พฤติกรรมที่ประเมินได้ตรงกันมากที่สุดคือพฤติกรรมที่ 2)

6. กรณีที่ว่าไป : เมื่อมีพฤติกรรมบ่งชี้หลายตัว นักเรียนหลายคน และมีผู้ประเมินหลายคน

ในกรณีที่นำไป หากเราต้องการตรวจสอบคุณภาพของเครื่องมือวัดที่มีพฤติกรรมบ่งชี้หลายตัวโดยการนำไปทดลองใช้กับนักเรียนกลุ่มนี้และกำหนดให้มีผู้ประเมินหลายคนนั้น เราสามารถคำนวณหาดัชนีความสอดคล้องระหว่างผู้ประเมินได้โดยอาศัยแนวคิดพื้นฐานตามที่ได้กล่าวมาแล้วห้างหมด ซึ่งเขียนเป็นสูตรการคำนวณได้ดังนี้

$$RAI = 1 - \frac{\sum_{k=1}^K \sum_{n=1}^N \sum_{m=1}^M |R_{mnk} - \bar{R}_{nk}|}{KN(M-1)(I-1)} \quad \dots \dots 7$$

โดยที่

\bar{R}_{nk} แทน ดัชนีความสอดคล้องระหว่างผู้ประเมิน R_{mnk} แทน คะแนนที่ได้จากผู้ประเมินคนที่ m ของนักเรียนคนที่ n ในพฤติกรรมที่ k ($m = 1, 2, 3, \dots, M$; $n = 1, 2, 3, \dots, N$ และ $k = 1, 2, 3, \dots, K$)

\bar{R}_{nk} แทน คะแนนเฉลี่ยของนักเรียนคนที่ n ในพฤติกรรมที่ k

ซึ่งคำนวณได้จากสูตร

$$\bar{R}_{nk} = \frac{\sum_{m=1}^M R_{mnk}}{M}$$

K แทน จำนวนของพฤติกรรมบ่งชี้ห้ามดี

N แทน จำนวนของนักเรียนห้ามดี

M แทน จำนวนของผู้ประเมินห้ามดี

I แทน จำนวนของคะแนนห้ามดีที่เป็นไปได้

(ตามเกณฑ์การให้คะแนน)

ตัวอย่าง

คะแนนทักษะการพูดหน้าชั้นของนักเรียน 5 คน ที่ได้จากผู้ประเมิน 3 คน ปรากฏผลดังนี้

คน ที่	คะแนนที่ได้จากผู้ประเมินคนที่ 1 (R_{1nk})				คะแนนที่ได้จากผู้ประเมินคนที่ 2 (R_{2nk})				คะแนนที่ได้จากผู้ประเมินคนที่ 3 (R_{3nk})			
	พฤติกรรม ที่ 1	พฤติกรรม ที่ 2	พฤติกรรม ที่ 3	พฤติกรรม ที่ 4	พฤติกรรม ที่ 1	พฤติกรรม ที่ 2	พฤติกรรม ที่ 3	พฤติกรรม ที่ 4	พฤติกรรม ที่ 1	พฤติกรรม ที่ 2	พฤติกรรม ที่ 3	พฤติกรรม ที่ 4
1	2	1	3	2	3	1	2	2	2	1	3	2
2	1	2	3	1	3	2	1	2	2	2	2	2
3	1	2	2	3	1	2	2	3	2	3	2	3
4	2	1	3	1	3	2	1	2	3	2	2	2
5	0	2	3	2	1	2	3	2	0	2	2	3

จากข้อมูลห้ามดี สามารถคำนวณหาคะแนนเฉลี่ยของนักเรียนคนที่ n ในพฤติกรรมที่ k (\bar{R}_{nk}) ได้ดังนี้

นักเรียน คนที่	คะแนนเฉลี่ย (\bar{R}_{nk})			
	พฤติกรรม ที่ 1	พฤติกรรม ที่ 2	พฤติกรรม ที่ 3	พฤติกรรม ที่ 4
1	2.33	1	2.67	2
2	2	2	2	1.67
3	1.33	2.33	2	3
4	2.67	1.67	2	1.67
5	0.33	2	2.67	2.33

จากข้อมูลที่ปรากฏแสดงว่า ค่าเฉลี่ยของคะแนนที่ได้มาจากการประเมินทุกคน ในพฤติกรรมที่ 1 ถึง 4 ของนักเรียนคนแรก มีค่าเท่ากับ 2.33, 1, 2.67 และ 2 ตามลำดับ สำหรับกรณีอื่น ๆ ก็มีความหมายในทำนองเดียวกัน ซึ่งโดยหลักการพื้นฐานตามที่เคยกล่าวแล้วนั้น หากผู้ประเมินห้ามคนสามารถให้คะแนนได้อย่างสอดคล้องกันมาก คะแนนเบี่ยงเบนจะต้องมีค่าเข้าใกล้ 0 เป็นส่วนใหญ่ ซึ่งจากข้อมูลที่ปรากฏกลับไม่มีความสอดคล้องกันมากนัก เช่น ในการประเมินพฤติกรรมที่ 1 ของนักเรียนคนแรก ซึ่งได้คะแนนเฉลี่ยเท่ากับ 2.33 นั้น ผู้ประเมิน 3 คน ให้ 2, 3, และ 2 คะแนน คะแนนเบี่ยงเบนจึงเท่ากับ $-0.33, 0.67$ และ -0.33 ตามลำดับ

ในส่วนของพฤติกรรมอื่นและนักเรียนคนอื่น ๆ ก็สามารถคำนวณได้ในทำงเดียวกัน ซึ่งเมื่อหาค่าสัมบูรณ์ของคะแนนเปี่ยงเบนและรวมค่าสัมบูรณ์ทั้งหมดจากทุกค่าหรือทุกช่อง (cell) แล้ว เรายังจะทราบได้ถึงขนาดของ

ความเปี่ยงเบนทั้งหมดที่ปรากฏจริง ซึ่งหากมีค่าสูงย่อมแสดงให้เห็นว่ามีความแตกต่างหรือมีความไม่สอดคล้องระหว่างกลุ่มผู้ประเมินนั้นเอง หากกรณีตัวอย่างจึงสามารถคำนวณหาค่าสัมบูรณ์ของคะแนนเปี่ยงเบนได้ดังนี้

	$ R_{1nk} - \bar{R}_{nk} $				$ R_{2nk} - \bar{R}_{nk} $				$ R_{3nk} - \bar{R}_{nk} $			
$n \backslash k$	1	2	3	4	1	2	3	4	1	2	3	4
1	0.33	0	0.33	0	0.67	0	0.67	0	0.33	0	0.33	0
2	1	0	1	0.67	1	0	1	0.33	0	0	0	0.33
3	0.33	0.33	0	0	0.33	0.33	0	0	0.67	0.67	0	0
4	0.67	0.67	1	0.67	0.33	0.33	1	0.33	0.33	0.33	0	0.33
5	0.33	0	0.33	0.33	0.67	0	0.33	0.33	0.33	0	0.67	0.67
	$\sum_{k=1}^K \sum_{n=1}^N \sum_{m=1}^M R_{mnk} - \bar{R}_{nk} = 20.63$											

แทนค่าต่าง ๆ ลงในสูตรคำนวณ จะได้

$$\begin{aligned}
 RAI &= 1 - \frac{\sum_{k=1}^K \sum_{n=1}^N \sum_{m=1}^M |R_{mnk} - \bar{R}_{nk}|}{KN(M-1)(I-1)} \\
 &= 1 - \frac{20.63}{(4)(5)(3-1)(4-1)} \\
 &= 0.83
 \end{aligned}$$

ดัชนีความสอดคล้องระหว่างผู้ประเมินจึงมีค่าเท่ากับ 0.83 ซึ่งแสดงให้เห็นว่าแบบวัดทักษะการพูดหน้าชั้นฉบับนี้มีคุณภาพอยู่ในชั้นใช้ได้ แต่หากปรับปรุงเกณฑ์การให้คะแนนในบางพฤติกรรมให้ชัดเจนจนสามารถถือความได้ตรงกันมากกว่าที่มีอยู่มาก โดยเฉพาะพฤติกรรมที่ 1 ซึ่งมีผลรวมของค่าสัมบูรณ์ของคะแนนเปี่ยงเบนสูงที่สุด

จากสูตรคำนวณทั้งหมดที่กล่าวมาจึงเห็นได้ว่า ดัชนีความสอดคล้องระหว่างผู้ประเมินไม่ได้อาศัยหลักการและขั้นตอนการคำนวณที่ยังยกแต่ประการใด ผู้

เขียนจึงมีความเชื่อว่าแม้แต่ผู้ที่ไม่ค่อยชื่นชอบหรือสนใจด้านคณิตศาสตร์มากนัก หากได้ลองทำความเข้าใจขั้นตอนการคำนวณดังกล่าวอย่างละเอียดลึกหนึ่ง หรือสองครั้งก็จะช่วยให้เกิดความเข้าใจในแต่ละประเด็นได้โดยไม่ยากนัก และเนื่องจากในโลกยุคปัจจุบันเรามีเครื่องช่วยคำนวณต่าง ๆ อยู่เป็นจำนวนมากจึงเชื่อว่าถ้าสามารถทำความเข้าใจหลักการพื้นฐานจนทราบถึงที่มาที่ไปของสูตรเหล่านี้ได้แล้ว การคำนวณค่าต่าง ๆ ที่จะเกิดขึ้นถัดจากนี้คงไม่ใช่เรื่องยุ่งยากแต่ประการใด ดังนั้นจึงเป็นสิ่งสมควรอย่างยิ่งที่ครูจะได้ใช้ความอุตสาหะของตนในการสร้างและพัฒนาเครื่องมือด้วยมีคุณภาพสูงสุดเท่าที่เพียงจะทำได้ ทั้งนี้เพื่อช่วยกันเพิ่มความน่าเชื่อถือให้กับกระบวนการวัดผลการเรียนรู้ ซึ่งจะส่งผลลัพธ์เนื่องไปถึงมาตรฐานของการจัดการศึกษาโดยรวมได้ในอนาคต

เอกสารอ้างอิง

รุ่งศิรินทร์ จันทร์หอม. (2545). การสร้างเกณฑ์การประเมินผลงานทางคหกรรมศาสตร์ด้วยรูบerrick (Rubrics Assessment). สารสารศึกษาศาสตร์, 14(1), 23-29.

สุวิมล ว่องวนิช. (2535). หน่วยที่ 12 การสร้างเครื่องมือวัดผลด้านทักษะพิลัย. เอกสารประกอบการสอน ชุดวิชาการพัฒนาแบบทดสอบวัดผลสมบูรณ์ที่ทางการเรียน (หน้า 481–558). กรุงเทพฯ : มหาวิทยาลัยสุโขทัยธรรมาธิราช.

Burry-Stock, Judith A. and other. (1996). Rater Agreement Indexes for Performance Assessment. *Educational and Psychological Measurement*, 56(2), 251–262.