

เชเปิร์ค และคนอื่น ๆ (Shepard and Others, 1985 : 81) กล่าวว่า เมื่อพบร่องรอยจะข้อสอบของกลุ่มล่างอิง และกลุ่มเปรียบเทียบแตกต่างกันมากพอที่จะเป็นหลักฐานได้ว่าข้อสอบที่ศึกษาอยู่ไม่ได้รับผลลัพธ์ที่ถูกต้อง จึงใช้ค่านี้ที่บ่งชี้ถึงระดับล่างอิง ดังนี้

1. พื้นที่ชนิดไม่มีเครื่องหมาย (Unsigned Area) เป็นค่าสัมบูรณ์ของพื้นที่ระหว่างโถงลักษณะข้อสอบทั้งสอง

2. ผลบวกกำลังสองแบบที่ 1 (SOS 1) เป็นค่าผลรวมของความแตกต่างระหว่างกำลังสองทุกค่าของความสามารถที่เป็นไปได้

3. ผลบวกกำลังสองแบบที่ 2 (SOS 2) คล้าย SOS 1 แต่ให้นักหนักความแตกต่างกำลังสอง ด้วยหัวนักลับของความคาดเดือนของความแปรปรวนในการประมาณค่าความเป็นไปได้ ดังนั้น ถ้ามีการประมาณโถงอย่างไม่ดีในส่วนใดส่วนหนึ่งแล้ว จะทำให้ลดประโยชน์ต่อความแตกต่างระหว่างสองกลุ่ม

4. ไคสแควร์ ($IRT - \chi^2$) เป็นการทดสอบนัยสำคัญทางสถิติ โดยการเปรียบเทียบความแตกต่างของค่าความยาก และค่าอำนาจจำแนก ระหว่างกลุ่มพร้อม ๆ กัน โดย ลอร์ด (Lord, 1980)

5. พื้นที่ชนิดมีเครื่องหมาย เหมือนพื้นที่ชนิดไม่มีเครื่องหมายแต่มีการให้เครื่องหมายไว้เพื่อแสดงให้เห็นว่ากลุ่มใดเสียประโยชน์ และกลุ่มใดได้ประโยชน์ ถ้าโถงลักษณะการตอบข้อสอบตัดกัน แสดงว่า มีความล่างอิงต่างกันสำหรับผู้มีความสามารถต่างกัน และค่าสัมบูรณ์ของพื้นที่ชนิดมีเครื่องหมายจะน้อยกว่าชนิดไม่มีเครื่องหมาย

6. ผลบวกกำลังสองแบบที่ 3 (SOS 3) เป็นผลบวกกำลังสองของความแตกต่างชนิดมีเครื่องหมายของ SOS 1 โดยการใช้เครื่องหมายของความแตกต่างแต่ละตัวที่ยังไม่ยกกำลังสอง

7. ผลบวกกำลังสองแบบที่ 4 (SOS 4) เป็นค่านี้คู่บนกับ SOS 2 แต่เป็นผลบวกที่มีการให้น้ำหนักและให้เครื่องหมาย

การวัดพื้นที่ของความแตกต่างระหว่างโถงลักษณะข้อสอบของกลุ่มเดียวบ้างเมื่อพิจารณาถึงขนาดของความล่างอิงของข้อสอบนั้นน้อย 2 ลักษณะ คือ การวัดแบบช่วงเปิดและแบบช่วงปิด (Open and Closed Intervals) กรณีของการวัดแบบช่วงปิดจะกำหนดขอบเขตของการวัดให้อยู่ในช่วงความสามารถที่กำหนด ในขณะที่การวัดแบบช่วงเปิดจะวัดภายในช่วงความสามารถทั้งหมด เพื่อให้ได้พื้นที่ที่แน่นอน (Exact Area) ระหว่างโถงลักษณะข้อสอบ 2 โถง ภายใต้การวัดแบบช่วงปิดนั้นสามารถวัดพื้นที่ได้ 2 ลักษณะ คือ พื้นที่ชนิดมีเครื่องหมายและไม่มีเครื่องหมาย (Signed and Unsigned Areas) โดยมีสูตรการคำนวณทั่ว ๆ ไป ดังนี้

จากพังก์ชันการตอบข้อสอบแบบ 3 พารามิเตอร์

$$P(\theta) = c + (1 - c)P^*(\theta)$$

$$\text{โดยที่ } P^*(\theta) = (1 + e[Da(\theta - b)])^{-1}$$

เมื่อ a, b และ c เป็นพารามิเตอร์ที่แสดงลักษณะของข้อสอบ และ D เป็นค่าคงที่กำหนดให้ มีค่าเท่ากับ 1.7

พื้นที่ระหว่างความสามารถที่กำหนดช่วงไว้ 2 จุดนั้นสเกลความสามารถคำนวณได้จาก

$$S(\theta_1, \theta_2) = \int_{\theta_1}^{\theta_2} P(\theta) d\theta = c(\theta_2 - \theta_1) + (1 - c)(Da)^{-1} \ln \frac{(1 + e[Da(\theta_2 - b)])}{(1 + e[Da(\theta_1 - b)])}$$

ในการศึกษาความถ้วนความถี่ของข้อสอบนั้น จะมีพารามิเตอร์ของ 2 กลุ่ม คือ กลุ่มซึ่งอยู่ได้แก่ a_R, b_R และ c_R และกลุ่มเปลี่ยนเทียบ คือ a_F, b_F และ c_F พื้นที่ชนิดที่ไม่เครื่องหมาย (Closed – Interval Signed Area – CSA) สามารถคำนวณได้จาก

$$CSA = \int_{\theta_1}^{\theta_2} [P_R(\theta) - P_F(\theta)] d\theta = s_R(\theta_1, \theta_2) - s_F(\theta_1, \theta_2)$$

และพื้นที่ชนิดไม่มีเครื่องหมาย (Closed – Interval Unsigned Area – CUA) หรือ ϕ สามารถคำนวณได้จาก

$$CUA = \int_{\theta_1}^{\theta_2} [P_R(\theta) - P_F(\theta)] d\theta$$

สูง ลักษณะ และคอฟแม่น (สูรศักดิ์ อัมรรัตนศักดิ์, 2531 : 54 ; อ้างจาก สูง ลักษณะ และคอฟแม่น, 1980 : 11) เสนอให้ใช้ค่า $CUA > .20$ เป็นเกณฑ์ที่ความถ้วนความถี่ของข้อสอบ

สำหรับการวิจัยครั้นนี้ผู้วิจัยได้เลือกการเปรียบเทียบໄก์ลักษณะข้อสอบแต่ละข้อสำหรับกลุ่มผู้สอบ 2 กลุ่ม ว่าข้อสอบข้อใดมีความถ้วนความถี่ของข้อสอบที่มีความถ้วนความถี่ของข้อสอบแต่ละข้อสำหรับ 2 กลุ่ม ใช้ค่า $CUA > .40$ เป็นค่าในการกำหนดว่าข้อสอบมีความถ้วนความถี่ของข้อสอบ (ทัศนิย์ พิรัมนตรี, 2530 : 9 ; อ้างจาก Rudner, 1977)

งานวิจัยที่เกี่ยวข้องกับการวิเคราะห์ความล้าเอียงของข้อสอบ

1. งานวิจัยภายในประเทศ

งานวิจัยที่เกี่ยวข้องกับการวิเคราะห์ความล้าเอียงของข้อสอบเป็นการเบริ่งเทียนผลการวิเคราะห์ความล้าเอียง ที่ใช้วิธีวิเคราะห์ต่างกัน โดยพิจารณาความล้าเอียงที่เกิดขึ้นระหว่างประชากรกลุ่มย่อยที่มีเพศต่างกัน สภาพภูมิศาสตร์ต่างกัน และการพัฒนาเกณฑ์การตัดสินความล้าเอียงทางเพศ ผู้วิจัยรวมรวมและสรุปได้ดังนี้

ชัชชัย เพ่าพงศ์ (2527 : 73 – 73) ได้ศึกษาความล้าเอียงของข้อสอบวัดความถนัดทางการเรียนด้านคณิตศาสตร์และภาษา ระหว่างกลุ่มเพศชายและเพศหญิง ด้วยวิธีโครงสร้างข้อสอบแบบจำลองໂโลจิก 3 พารามิเตอร์ โดยใช้แบบทดสอบวัดความถนัดทางการเรียนด้านคณิตศาสตร์และภาษา ในระดับมัธยมต้น ซึ่งพัฒนาโดยสำนักทดสอบทางการศึกษาและจิตวิทยา มหาวิทยาลัยครินธรวิโรฒ ประสานมิตร กลุ่มตัวอย่างที่ใช้ในการศึกษาเป็นนักเรียนชั้นมัธยมศึกษาปีที่ 3 ปีการศึกษา 2524 ซึ่งประกอบด้วยทุกภาคภูมิศาสตร์ทั่วประเทศไทย ภาค คือ ภาคเหนือ ภาคกลาง ภาคใต้ ภาคตะวันออก ภาคตะวันออกเฉียงเหนือ จำนวน 5,248 คน แบ่งเป็นกลุ่มที่ใช้วิเคราะห์ความล้าเอียงของแบบทดสอบความล้าเอียงด้านภาษา จำนวน 2,974 คน เป็นนักเรียนชาย 1,610 คน และนักเรียนหญิง 1,337 คน อีกกลุ่มหนึ่งใช้วิเคราะห์ความล้าเอียงของแบบทดสอบความล้าเอียงด้านภาษา จำนวน 2,301 คน เป็นนักเรียนชาย 1,316 คน นักเรียนหญิง 985 คน

ผลการศึกษาพบว่า แบบทดสอบวัดความถนัดทางการเรียนด้านคณิตศาสตร์ จำนวน 20 ข้อ มีข้อสอบที่มีความล้าเอียงต่อกลุ่มให้กลุ่มหนึ่งโดยเฉพาะ 9 ข้อ คือ ล้าเอียงต่อกลุ่มนักเรียนชาย 7 ข้อ และล้าเอียงต่อกลุ่มนักเรียนหญิง 2 ข้อ เมื่อพิจารณาแยกตามระดับความสามารถสามารถปานกลางขึ้นไปมี จำนวน 5 ข้อ ซึ่งวัดในเรื่องร้อยละ การหาปริมาตร และการหาความยาวของเส้นในด้านของรูปสามเหลี่ยม จำนวนเรื่องละ 1 ข้อ อีกจำนวน 2 ข้อ เป็นเรื่องเกี่ยวกับโจทย์ปัญหา จากข้อสอบจำนวน 5 ข้อ ดังกล่าวนี้ เป็นข้อสอบที่มีความล้าเอียงต่อกลุ่มนักเรียนหญิงในระดับความสามารถต่ำ และล้าเอียงต่อกลุ่มนักเรียนชายในระดับความสามารถปานกลาง จำนวน 1 ข้อ ส่วนแบบทดสอบวัดความถนัดทางการเรียนด้านภาษา จำนวน 40 ข้อ มีข้อสอบที่ล้าเอียงต่อกลุ่มให้กลุ่มหนึ่ง โดยเฉพาะ 11 ข้อ เป็นข้อสอบที่ล้าเอียงต่อนักเรียนชาย 3 ข้อ และล้าเอียงต่อนักเรียน 8 ข้อ เมื่อพิจารณาแยกตามระดับความสามารถนี้ข้อสอบที่มีความล้าเอียงในระดับความสามารถปานกลางขึ้นไปมี

จำนวน 9 ข้อ ซึ่งวัดความเข้าใจเกี่ยวกับการอ่านคำประพันธ์ บทร้อยก颂 อย่างละ 1 ข้อและวัดความเข้าใจเกี่ยวกับการอ่านข้อความ จำนวน 7 ข้อจากข้อสอบจำนวน 9 ข้อนี้เป็นข้อที่มีความถูกต้องต่อกรุ่นนักเรียนชาย จำนวน 1 ข้อ และเป็นข้อสอบที่มีความถูกต้องต่อกรุ่นนักเรียนหญิง จำนวน 6 ข้อ และมีข้อสอบที่มีความถูกต้องมากกว่าหนึ่งช่วงความสามารถ จำนวน 2 ข้อ จากผลการวิจัยครั้งนี้ เบาสรุปว่ามีแบบทดสอบวัดความดันด้านทางการเรียนด้านคณิตศาสตร์และด้านภาษา ฉบับนี้มีความถูกต้องเพียง ดังนั้นเราเสนอว่าในการที่จะนำแบบทดสอบฉบับนี้ไปทดสอบกับกลุ่มเพศชายและเพศหญิง ควรจะพิจารณาข้อที่มีค่าอำนาจจำแนกของทั้ง 2 กลุ่ม ที่แตกต่างกันไม่นัก ไม่ว่าข้อสอบข้อนี้ๆ จะมีค่าอำนาจจำแนกสูงหรือต่ำกี่ตาม

ทัศนีย์ พิรนนทร์ (2530 :76-78) ได้ศึกษาเปรียบเทียบวิธีวิเคราะห์ความถูกต้องของแบบทดสอบวิชาคณิตศาสตร์ โครงการตรวจสอบคุณภาพทางการศึกษาของสำนักงานทดสอบทางการศึกษาระดับชาติ การตรวจศึกษาธิการ โดยเปรียบเทียบจำนวนข้อสอบที่มีความถูกต้องระหว่างกลุ่มนักเรียน ในกรุงเทพมหานครกับกลุ่มนักเรียนในภาคภูมิศาสตร์ทั้ง 5 ภาค คือภาคกลาง ภาคใต้ ภาคเหนือ ภาคตะวันออกเฉียงเหนือ และภาคตะวันออก ด้วยวิธีวิเคราะห์ 3 วิธี คือวิธีกำหนดจุดค่าเดคลา วิธีทดสอบความแตกต่างระหว่างกลุ่มด้วยสถิติไคสแควร์ในไมเคเลลลีก ลินีบ 2 ไมเคเลล คือ ไมเคเลที่ไม่มีพารามิเตอร์ ผู้รวมระหว่างระดับคะแนนกับกลุ่ม ไมเคเลที่ไม่มีพารามิเตอร์ของผลทดสอบที่เกิดจากกลุ่ม และวิธีให้ลักษณะข้อสอบ 3 พารามิเตอร์ กลุ่มตัวอย่างที่ใช้ศึกษาเป็นนักเรียนชั้นมัธยมศึกษาปีที่ 6 ปีการศึกษา 2526 จำนวน 7,036 คน

ผลการศึกษาพบว่า เมื่อแยกข้อสอบออกตามค่าความยากที่วิเคราะห์ด้วยวิธีดังเดิมนี้ ข้อสอบที่มีความถูกต้อง จำนวน 43 ข้อ และไม่ถูกต้อง 17 ข้อ เหมือนกันทุกภาค เมื่อเปรียบเทียบจำนวนข้อสอบที่มีความถูกต้องระหว่างกลุ่มนักเรียนในกรุงเทพมหานคร และกลุ่มนักเรียนภาคอื่นๆ พบร่วมกันวิเคราะห์ความถูกต้องด้วยวิธีให้ลักษณะข้อสอบ 3 พารามิเตอร์ พบรหัสข้อสอบที่มีความถูกต้องมากที่สุด และมีข้อสอบที่มีความถูกต้องมากที่สุด จำนวน 17 ข้อ ภาค กับนักเรียนในกรุงเทพมหานคร ในแต่ละวิชามีจำนวนไม่เท่ากัน โดยที่วิธีกำหนดจุดค่าเดคลาและวิธีทดสอบความแตกต่างระหว่างกลุ่มด้วยสถิติไคสแควร์ในไมเคเลลลีก ลินีบ 2 ไมเคเลล มีจำนวน ข้อสอบที่มีความถูกต้องมากที่สุดระหว่างกรุงเทพมหานคร และภาคตะวันออกเฉียงเหนือ ส่วนวิธีให้ลักษณะข้อสอบ 3 พารามิเตอร์ มีจำนวนข้อสอบที่มีความถูกต้องมากที่สุด ระหว่างกรุงเทพมหานคร และภาคตะวันออก

การเบริ่งเที่ยบผลการวิเคราะห์ความสำเร็จ ทั้ง 3 วิธี กับความสำเร็จที่เกิดขึ้นในภาคเดียวกัน พนข้อสอบที่มีความสำเร็จช้ากัน ข้อสอบที่มีความสำเร็จส่วนมากเป็นข้อสอบที่จ่ายสำหรับนักเรียนในกรุงเทพมหานครมากกว่ากู้นักเรียนภาคอื่นๆ จากการวิเคราะห์ด้วยวิธีกำหนดคุณเดลตา แต่เป็นข้อที่มีความสำเร็จในเกณฑ์ต่ำ สำหรับวิธีโถงถักจะข้อสอบ 3 พารามิเตอร์ และเป็นข้อที่สำเร็จรูปแบบเดียวกันในการวิเคราะห์ด้วยวิธีทดสอบความแตกต่างระหว่างกู้นักเรียน สถิติไกสแควร์ในไมเดลล์อกลีเนย ทั้ง 2 ในเดือน

พัชรี ปีบัญชา (2531 ; 65-67) ได้ศึกษาเบริ่งเที่ยบวิเคราะห์ความสำเร็จของข้อสอบจากแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียนวิชาคณิตศาสตร์ ด้วยวิธีแปลงค่าความยากวิธีไกสแควร์ และวิธีโถงถักจะข้อสอบ 1 พารามิเตอร์ ตัวแปรที่ศึกษาคือ เพศ และภาควิชานิคัลสตร์ กู้นี้ตัวชี้บ่งที่ใช้ในการศึกษาเป็นนักเรียนชายและนักเรียนหญิง ชั้นประถมศึกษานี้ปีที่ 6 ปีการศึกษา 2530 ของโรงเรียนสังกัดสำนักงานคณะกรรมการการประถมศึกษาแห่งชาติในกรุงเทพมหานครและจังหวัดสมุทรสาคร จำนวน 1,948 คน เพื่อวิเคราะห์หาดัชนีความสำเร็จของข้อสอบแล้วหาสัมประสิทธิ์สหสัมพันธ์ของดัชนีความสำเร็จระหว่างวิธีวิเคราะห์ความสำเร็จของข้อทั้ง 3 วิธีและศึกษาเบริ่งเที่ยบค่าความเชื่อมั่นของแบบทดสอบก่อนและหลังการคัดเลือกข้อสอบที่สำเร็จออกແล้า

ผลการศึกษาพบว่า การวิเคราะห์ความสำเร็จของข้อสอบด้วยวิธีโถงถักจะข้อสอบพนจำนวนข้อสอบที่มีความสำเร็จมากที่สุด รองลงมาคือ วิธีไกสแควร์ และวิธีแปลงค่าความยากพนจำนวนข้อสอบที่สำเร็จน้อยที่สุดและมีค่าสัมประสิทธิ์สหสัมพันธ์ของดัชนีความสำเร็จต่อเพศระหว่างวิธีวิเคราะห์ความสำเร็จของข้อทั้ง 3 วิธี มีค่าอยู่ระหว่าง .1713 ถึง .5618 ค่าสัมประสิทธิ์สหสัมพันธ์ของดัชนีความสำเร็จต่อเพศระหว่าง .1868 ถึง .6009 ส่วนค่าความเชื่อมั่นของแบบทดสอบก่อนและหลังคัดเลือกข้อสอบที่สำเร็จแล้วแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ

สุรศักดิ์ ออมรัตนศักดิ์ (2531 : 200-207) ได้ศึกษาเบริ่งเที่ยบผลของวิธีวิเคราะห์ความสำเร็จของข้อสอบที่แตกต่างกัน 4 วิธี คือ วิธีวิเคราะห์ความแปรปรวน วิธีแบ่งค่าความยากของข้อสอบ วิธีโถงถักจะข้อสอบที่มี 1 พารามิเตอร์ และวิธีโถงถักจะข้อสอบที่มี 3 พารามิเตอร์ จากแบบทดสอบที่ใช้สอบแบ่งขั้นเพื่อบรรจุเข้ารับราชการเป็นข้าราชการครูในปี พ.ศ. 2529 ซึ่งมี 4 ฉบับ คือ ฉบับที่ 1 แบบทดสอบวิชาเอก (ความรู้เกี่ยวกับการประถมศึกษา) ฉบับที่ 2 แบบทดสอบวิชาการศึกษาและกฎหมาย ฉบับที่ 3 แบบทดสอบวิชาภาษาไทย ฉบับที่ 4 แบบทดสอบวิชาความสามารถทั่วไป เพื่อหาสัมประสิทธิ์สหสัมพันธ์ของดัชนีความสำเร็จระหว่างวิธีวิเคราะห์

ความสำเร็จ 4 วิธีและเปรียบเทียบความแตกต่างของผลการคัดเลือกก่อนและหลังการศึกษาความสำเร็จของข้อสอบตามวิธีการคิดคะแนนรวมที่แตกต่างกัน 6 วิธี ในด้านจำนวนผู้ได้รับการคัดเลือก สัดส่วนของชายต่อหญิงที่ได้รับการคัดเลือกและความเชื่อมั่นของแบบทดสอบ กลุ่มตัวอย่างที่ศึกษา คือ ผู้เข้าสอบแข่งขันเพื่อบรรจุเข้ารับราชการเป็นข้าราชการครู ในปี พ.ศ.2528 จำนวน 2,340 คน เป็นชาย 1,170 คน หญิง 1,170 คน

ผลการศึกษาพบว่า วิธีวิเคราะห์ความสำเร็จแต่ละวิธี พบร้านจำนวนข้อสอบที่มีความสำเร็จ ต่างกัน โดยวิธี ให้ลักษณะข้อสอบที่มี 3 พารามิเตอร์ พบร้านจำนวนข้อสอบที่มีความสำเร็จมากที่สุด รองลงมา ได้แก่ วิธีวิเคราะห์ความแปรปรวน และวิธีแปลงค่าความยากของข้อสอบ พบร้านจำนวนข้อสอบที่มีความสำเร็จน้อยที่สุด ส่วนค่าสัมประสิทธิ์สัมพันธ์ของดัชนีความสำเร็จระหว่าง วิธีวิเคราะห์ความสำเร็จ 4 วิธี พบร้า นิค่าอยู่ระหว่าง .7535 ถึง .9921 สำหรับจำนวนผู้ได้รับการคัดเลือกเมื่อเปรียบเทียบความแตกต่างของผลการคัดเลือกก่อนและหลังศึกษาความสำเร็จของข้อสอบตามวิธีคิดคะแนนคืนกับวิธีรวมคะแนนแบบอินชา อีก 5 วิธี มีจำนวนผู้ได้รับการคัดเลือก แตกต่างกันประมาณ 4 เปอร์เซ็นต์ถึง 24 เปอร์เซ็นต์ ส่วนวิธีแปลงคะแนนคืนเป็นคะแนนมาตรฐานที่ปกติกับวิธีรวมคะแนนแบบอินชา อีก 4 วิธี มีจำนวนผู้ได้รับการคัดเลือกต่างกันประมาณ 6 เปอร์เซ็นต์ ถึง 23 เปอร์เซ็นต์ ส่วนความเชื่อมั่นของแบบทดสอบหลังจากคัดข้อสอบที่มีความสำเร็จพบว่าค่าความเชื่อมั่นของแบบทดสอบลดลงกว่าแบบทดสอบเดิมเล็กน้อย

สุพัฒน์ ศุภมงคลสันต์ (2534) "ได้วิเคราะห์ความสำเร็จของข้อสอบภาษาอังกฤษเพื่อคัดเลือกเข้าศึกษาต่อในมหาวิทยาลัย ด้วยวิธีวิเคราะห์ความสำเร็จ 3 วิธี ได้แก่ วิธีกำหนดค่าเดลต้า (Delta-Plot Method) วิธีไอกสแควร์ชนิดที่แบ่งความสามารถของผู้สอบเป็น 3 ระดับ ได้แก่ กลุ่มที่มีระดับความสามารถต่ำ (ผู้ได้คะแนนรวม 0-40 คะแนน) กลุ่มนี้ระดับความสามารถปานกลาง (ผู้ได้คะแนนรวม 41-70 คะแนน) และกลุ่มที่มีระดับความสามารถสูง (ผู้ได้คะแนนรวม 71-100 คะแนน) วิธีการวัดพื้นที่ความแตกต่างระหว่าง ให้ลักษณะข้อสอบที่วิเคราะห์ตามทฤษฎีการตอบข้อคำ答 แบบ 3 พารามิเตอร์ จากแบบทดสอบภาษาอังกฤษเข้ามหาวิทยาลัย ชุด กข และชุด กข ก ปี 2531-2533 ซึ่งมีข้อสอบชุดละ 100 ข้อ ตัวแปรที่ศึกษาความสำเร็จ คือ เพศ และภาคภูมิศาสตร์ ของผู้สอบ ซึ่งแยกออกเป็น 5 ภาค ตามภูมิลักษณะของผู้สอบ ได้แก่ ภาคกลาง ภาคตะวันออก ภาคใต้ ภาคตะวันออกเฉียงเหนือ และภาคเหนือ"

เกณฑ์การตัดสินความถูกต้องของข้อสอบ สำหรับวิธีต่างๆ ที่ สุพัฒน์ ศุภมงคลสันต์ กำหนดขึ้น คือ

1. วิธีกำหนดค่าเฉลี่า ข้อสอบที่ถูกต้อง คือข้อที่มีระดับตั้งจากจุดย่อขั้นคับค่าเฉลี่าไปยังเส้นแกนหลัก (d) มากกว่า 1.964 Sd. หรือน้อยกว่า -1.964 Sd.

2. วิธีไกสแควร์ ข้อสอบที่ถูกต้อง คือ ข้อสอบที่ผู้สอบต่างกลุ่มกันมีอยู่ในระดับคะแนนเดียวกันมีสัดส่วนการตอบถูกหรือผิดแตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ $\alpha = 0.017$

3. วิธีการวัดพื้นที่ความแตกต่างระหว่างโถงลักษณะข้อสอบ ข้อสอบที่ถูกต้อง คือ ข้อที่มีพื้นที่ความแตกต่างมากกว่า 0.40 โดยแบ่งเป็น 3 ระดับ

3.1 พื้นที่ ที่มากกว่า 0.70 แสดงว่ามีความถูกต้องมาก

3.2 พื้นที่ ที่มีค่าอยู่ระหว่าง 0.40 – 0.70 แสดงว่ามีความถูกต้องปานกลาง

3.3 พื้นที่ ที่มีค่ามากกว่า 0.00 แต่น้อยกว่า 0.40 แสดงว่ามีความถูกต้องน้อย

ผลการศึกษาพบว่า แบบทดสอบภาษาอังกฤษ ฉบับ กษ และ กบค ปี 2531-2533 มีความถูกต้องต่อเพศในช่วง 7-28 ข้อ และช่วง 4-41 ข้อ โดยมีแนวโน้มที่ถูกต้องต่อเพศชายมากกว่าเพศหญิง และถูกต้องต่อภาคภูมิศาสตร์ในช่วง 6-45 ข้อ และ 5-43 ข้อ โดยมีความถูกต้องต่อผู้สอบจากภาคอื่นมากกว่าภาคกลางประมาณ 2-3 เท่า

การเปรียบเทียบผลของการวิเคราะห์โดยใช้วิธีวิเคราะห์ต่างกัน พบว่า จำนวนข้อสอบที่ระบุว่าถูกต้องแตกต่างกันอย่างมีนัยสำคัญทางสถิติ และแต่ละวิธีให้ผลที่มีความสัมพันธ์กันอย่างไม่มีนัยสำคัญทางสถิติ การวิเคราะห์ด้วยวิธีของทฤษฎีการตอบข้อคำถามเมื่อใช้เกณฑ์พื้นที่แสดงความถูกต้องของข้อสอบ มากกว่า 0.40 พบว่า มีจำนวนข้อสอบที่มีความถูกต้องน้อยกว่า 2 วิธีแรกประมาณ 3-4 เท่า

นิรนด ชัยชาติ (2537 : 57-58) ได้ศึกษาเปรียบเทียบผลการวิเคราะห์ความถูกต้องของแบบทดสอบวัดความเข้าใจในการอ่านภาษาไทยตามมาตรฐานคุณลักษณะด้านภาษา ที่ใช้วิธีวิเคราะห์ต่างกัน 3 วิธี คือ วิธีแบ่งค่าความยาก วิธีไกสแควร์ และวิธีวิเคราะห์ความแปรปรวน จากแบบทดสอบวัดความเข้าใจในการอ่านภาษาไทย จำนวน 5 ข้อ กลุ่มตัวอย่างที่ใช้ศึกษาเป็นนักเรียนชายหญิง ชั้นมัธยมศึกษาปีที่ 1 ปีการศึกษา 2536 ของโรงเรียนในสังกัดกรมสามัญศึกษา เขตพระโขนง กรุงเทพมหานคร จำนวน 1,006 คน โดยศึกษาเปรียบเทียบจำนวนข้อที่มีความถูกต้อง ค่าความเชื่อมั่นที่ใช้สูตรคำนวณแบบ KR-20 และแบบแบ่งครึ่งฉบับ ของแบบทดสอบหลังทัศนคติเลือกข้อสอบที่มีความถูกต้องมากถึง 95%

ผลการศึกษาพบว่าการวิเคราะห์ความสำเร็จด้วยวิธีแปลงค่าความยากกับวิธีไอกสแควร์ และวิธีแปลงค่าความยาก กับวิธีวิเคราะห์ความแปรปรวน มีจำนวนข้อสอบที่มีความสำเร็จแตกต่าง กันอย่างมีนัยสำคัญทางสถิติที่ระดับ .05 ส่วนวิธีไอกสแควร์กับวิธีวิเคราะห์ความแปรปรวนพบ จำนวนข้อสอบที่มีความสำเร็จแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

สำหรับค่าความเชื่อมั่นของแบบทดสอบที่ใช้สูตรคำนวณทั้งแบบ KR-20 และแบบแบ่ง ครึ่งฉบับหลังคัดเลือกข้อสอบที่มีความสำเร็จออกแล้ว จากการวิเคราะห์ด้วยวิธีแปลงค่าความยาก วิธีไอกสแควร์และวิธีวิเคราะห์ความแปรปรวนแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ

กาญจนा วัชนาสุนทร (2538) ได้ศึกษาเกี่ยวกับการพัฒนาเกณฑ์ตัดสินข้อสอบสำเร็จ ทางเพศ โดยใช้ดัชนีการวิเคราะห์ 4 ตัว คือ พื้นที่ระหว่าง ให้การตอบข้อสอบชนิดที่มีเกรดอง茫 (SA) และไม่มีเกรดอง茫 (UA) จากวิธีใช้ทฤษฎีการตอบข้อคำถามตามแบบจำลอง 2 พารามิเตอร์ α_{MH} จากวิธีของเมนเดล-ແยนส์ชล และ B_{SIB} จากวิธี SIBTEST จากข้อมูลเชิงประจักษ์เพื่อ พัฒนาเกณฑ์ตัดสินข้อสอบสำเร็จทางเพศ

ข้อมูลที่ใช้ศึกษาเป็นข้อมูลการตอบข้อสอบคัดเลือกนูกกกลเข้าศึกษาในสถาบันอุดมศึกษา ของทบทวนมหาวิทยาลัย ปีการศึกษา 2535 โดยใช้ความยาวของแบบทดสอบ 20, 30 และ 40 ข้อ สำหรับวิชาคณิตศาสตร์ และ 50, 60, 70 และ 80 ข้อ สำหรับวิชาภาษาอังกฤษ โดยใช้กตุน ผู้สอน 6 ขนาด คือ 100, 200, 400, 600, 800 และ 1,000 คน

การพัฒนาเกณฑ์กระทำโดยคำนวณค่าดัชนี ทั้ง 4 ตัว จากข้อมูลการตอบข้อสอบของ ผู้สอนเพศเดียวกัน เพศละ 50 ค่า สำหรับแต่ละความยาวของแบบทดสอบ และขนาดของกตุนผู้สอน จากนั้นนำค่าดัชนีที่ได้ทั้งหมดมาวิเคราะห์หาค่าเฉลี่ย และกำหนดเกณฑ์จากค่าเฉลี่ย 2 ลักษณะคือ เกณฑ์ที่กำหนด โดยพิจารณาจากค่าเฉลี่ยรวม จากค่าดัชนีทุกชิ้น โดยไม่พิจารณาความแตกต่างใน ด้านความยาวของแบบทดสอบและขนาดของกตุนผู้สอน และเกณฑ์ที่พิจารณาจากค่าเฉลี่ย ซึ่ง พิจารณาถึงความยาวของแบบทดสอบและขนาดของกตุนผู้สอน

ผลจากการศึกษาพบว่า เมื่อนำเกณฑ์ที่กำหนดไว้ไปตัดสินค่าดัชนีที่ได้จากการวิเคราะห์ ความสำเร็จระหว่างผู้สอนเพศหญิงและชาย ไม่ว่าจะใช้เกณฑ์ลักษณะใดผลค่าน้ำหนักของข้อสอบใน รูปของร้อยละของข้อสอบที่มีความสำเร็จ และความสอดคล้องของ การตัดสินมีความไม่คงที่ทุก ๆ ความยาวของแบบทดสอบและทุกๆ ขนาดของกตุนผู้สอน โดยที่เกณฑ์ในลักษณะหลังจะลดความไม่ คงที่ลงได้ระดับหนึ่ง ทั้งนี้เนื่องจากค่าดัชนีแต่ละตัวที่ได้จากการกตุนผู้สอนต่างเพศกันมีความไม่คงที่ จะเปลี่ยนไปเมื่อความยาวของแบบทดสอบที่ใช้ และขนาดของกตุนผู้สอนเปลี่ยนไป

นักจากนั้นพบว่าที่ความขาวของแบบทดสอบ 40 ข้อ สำหรับวิชาคณิตศาสตร์ และ 80 ข้อ สำหรับวิชาภาษาอังกฤษมีจำนวนข้อสอบที่ได้รับการตัดสินว่ามีความถูกต้องมากกว่าในความขาวอีก 7 ข้อ มาก อีกทั้งยังพบว่าเกณฑ์ที่กำหนดได้จากการศึกษาครั้งนี้มีค่าสูงกว่าเกณฑ์ที่ขึ้นต่อที่ควรใช้ : ในกรณีของค่า UA ในขณะที่ α_{MH} มีค่าใกล้เคียงกับเกณฑ์ขึ้นต่อที่ควรใช้ในเกณฑ์ตัดสินความถูกต้องของข้อสอบจากเกณฑ์ที่พัฒนาได้ครั้งนี้ คือ : SA : > .40 , UA > .50 เมื่อใช้ความขาวของแบบทดสอบ 50 ข้อ ขึ้นไป และ : SA : > .80 , UA > 1.20 กรณีความขาวของแบบทดสอบสั้นกว่า 50 ข้อ ค่า .60 > α_{MH} > 1.40 และ : SA : > .06

จิตสุค้า ธรรมพร (2539) ได้ศึกษาการเปรียบเทียบผลการวิเคราะห์ความถูกต้องของข้อสอบจากแบบทดสอบโดยที่ปัญหาทางคณิตศาสตร์และแบบทดสอบความเข้าใจทางภาษาที่ใช้ร่วมกัน 3 วิชี คือ วิธีแปลงค่าความยากของข้อสอบ วิธีให้เกล็ดและวิธีของแบบทดสอบ-ແ xenstzczl เพื่อเปรียบเทียบค่าความเชื่อมั่นที่คำนวณโดยใช้สูตร KR-20 และใช้สูตรแบบแบ่งครึ่งฉบับ ของแบบทดสอบหลังคัดเลือกข้อสอบที่มีความถูกต้องของ กดุ่นตัวอย่างที่ศึกษาเป็นนักเรียนชั้นมัธยมศึกษาปีที่ 2 ปีการศึกษา 2538 ของโรงเรียนสังกัดกรมสามัญศึกษาในจังหวัดกระปี้ จำนวน 2,689 คน ซึ่งเลือกมาโดยการสุ่มอย่างง่าย

ผลการวิจัย พบว่า แต่ละวิธีที่พับจำนวนข้อสอบที่มีความถูกต้องแตกต่างกัน ซึ่งวิธีของแบบทดสอบ-ແ xenstzczl พับจำนวนข้อสอบที่มีความถูกต้องมากที่สุด และวิธีแปลงค่าความยากของข้อสอบพับจำนวนข้อสอบที่มีความถูกต้องน้อยที่สุด โดยที่การวิเคราะห์ความถูกต้องด้วยวิธีแปลงค่าความยากของข้อสอบกับวิธีให้เกล็ดและวิธีของแบบทดสอบ แสดงว่าความถูกต้องของข้อสอบกับวิธีแปลงค่าความยากของข้อสอบกับวิธีของแบบทดสอบ-ແ xenstzczl มีจำนวนข้อสอบที่มีความถูกต้องแตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ .001 ส่วนวิธีให้เกล็ดและวิธีของแบบทดสอบ-ແ xenstzczl มีจำนวนข้อสอบที่มีความถูกต้องแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ

สำหรับค่าความเชื่อมั่นของแบบทดสอบโดยที่ปัญหาทางคณิตศาสตร์ที่คำนวณโดยใช้สูตร KR-20 หลังจากคัดเลือกข้อสอบที่มีความถูกต้องของจากการวิเคราะห์ความถูกต้องด้วยวิธีแปลงค่าความยากของข้อสอบกับวิธีให้เกล็ดและวิธีของแบบทดสอบ แสดงว่าความถูกต้องของข้อสอบกับวิธีของแบบทดสอบ-ແ xenstzczl มีค่าแตกต่างกันอย่างมีนัยสำคัญทางสถิติที่ระดับ .05 และวิธีให้เกล็ดและวิธีของแบบทดสอบ-ແ xenstzczl มีค่าแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ ส่วนค่าความเชื่อมั่นของแบบทดสอบที่คำนวณโดยใช้สูตรแบบแบ่งครึ่งฉบับ หลังจากคัดเลือกข้อสอบที่มีความถูกต้องของจากการวิเคราะห์ความถูกต้อง 3 วิธี มีค่าความแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ ส่วนแบบทดสอบความเข้าใจทางภาษา ค่าความเชื่อมั่นโดยใช้สูตร KR-20 และ

แบบแบ่งครึ่งฉบับ หลังคัดเลือกข้อสอบที่มีความลำเอียงออกจากวิเคราะห์ความล้าเอียง มีค่าแตกต่างกันอย่างไม่มีนัยสำคัญทางสถิติ

เรวี อินทรสาระ (2539:277) ได้ศึกษาความเที่ยงตรงเชิงพยากรณ์ของแบบทดสอบคัดเลือกที่วิเคราะห์ความล้าเอียงต่อเพศด้วยวิธีใช้ทฤษฎีการตอบข้อคำถาม (IRT) วิธีแม่นเทตนัยส์เซล (MH) และวิธี SIBTEST การตัดสินผลการสอนที่คิดคะแนนมาตรฐานที่ปักติดและคะแนนน้ำหนักความสามารถและสาเหตุความล้าเอียงของข้อสอบ โดยศึกษาความล้าเอียงของข้อสอบคัดเลือกเข้าศึกษาในชั้นปีที่ 1 ประเภทรับตรง ปีการศึกษา 2538 ของมหาวิทยาลัยสงขลานครินทร์ ในวิชาภาษาไทย ก วิชาสังคมศึกษา ก วิชาภาษาอังกฤษ กบ วิชาละ 8,127 คน (ชาย 2,722 คน หญิง 5,405 คน) วิชาภาษาไทย กบ วิชาสังคม กบ และวิชาภาษาอังกฤษ กบ วิชาละ 5,415 คน (ชาย 1,454 คน หญิง 3,961 คน) ความเที่ยงตรงเชิงพยากรณ์ศึกษาจากคะแนนสอนคัดเลือกนับเกรดภาคเรียนที่ 1 ปีการศึกษา 2538 ของนักเรียนที่ได้รับการคัดเลือกจากประเภทรับตรง สาขาวิชาศาสตร์ 763 คน และสาขาวิชาศิลปศาสตร์ 281 คน และสาเหตุความล้าเอียงของข้อสอบจากการระบุสาเหตุของนักวัดผลการศึกษาหรืออาจารย์ผู้สอน จำนวน 50 คน และนิสิตนักศึกษาที่เรียนในสาขาวิชานั้นๆ วิชาละ 50 คน

ผลการศึกษาพบว่า วิธีการตรวจสอบความล้าเอียงทั้ง 3 วิธี ตัดสินจำนวนข้อสอบที่ล้าเอียงแตกต่างกันในวิชาภาษาไทย ก ฉบับที่ 2 และวิชาสังคมศึกษา ก ฉบับที่ 1 ที่ระดับนัยสำคัญทางสถิติที่ .05 นอกนั้นต่างกันที่ระดับนัยสำคัญทางสถิติที่ .01 โดยที่วิธีใช้ทฤษฎีตอบข้อคำถาม ตัดสินจำนวนข้อสอบที่ล้าเอียงมากที่สุด ความสำคัญของค่าดับที่ของการสอนไม่ว่าจะคิดคะแนนมาตรฐานที่ปักติด หรือคิดคะแนนน้ำหนักความสามารถและใช้ข้อสอบจำนวนทั้งหมดหรือใช้เฉพาะข้อสอบที่ปราศจากความล้าเอียงต่างมีความสัมพันธ์กันอย่างมีนัยสำคัญทางสถิติที่ระดับ .01

ประสิทธิภาพในการทำนายผลสัมฤทธิ์ทางการเรียนในสาขาวิชาศาสตร์ การคิดคะแนนน้ำหนักความสามารถที่ใช้ข้อสอบจำนวนทั้งหมดและใช้เฉพาะข้อสอบที่ปราศจากความล้าเอียงนี้ ประสิทธิภาพในการทำนายสูงกว่าการคิดคะแนนมาตรฐานที่ปักติด ส่วนสาขาวิชาศิลปศาสตร์การคิดคะแนนมาตรฐานที่ - ปักติดทั้งที่ใช้ข้อสอบจำนวนทั้งหมดและใช้เฉพาะข้อสอบที่ปราศจากความล้าเอียง มีประสิทธิภาพในการทำนายสูงกว่าการคิดคะแนนน้ำหนักความสามารถและสาเหตุของความล้าเอียงของข้อสอบต่อเพศทั้งชายและหญิง เกิดจากข้อสอบเป็นข้อคำถามที่ผู้สอนได้รับการฝึกฝนเฉพาะ จะมีโอกาสตอบถูกมากกว่า เป็นเรื่องราวที่ก่อรุ่นเรือนๆ สนใจและเป็นข้อสอบที่ถูกความจำ

2. งานวิจัยต่างประเทศ

สำนักงานวิจัยที่เกี่ยวข้องกับการวิเคราะห์ความล้าเอียงของข้อสอบในต่างประเทศนั้น มีผู้วิจัยทำวิจัยไว้หลายท่าน ซึ่งผู้วิจัยอนามัย 2 ประเด็น คือ

1. การวิเคราะห์ความล้าเอียงของข้อสอบจากข้อมูลจำลอง และ
2. การวิเคราะห์ความล้าเอียงของข้อสอบจากข้อมูลจริง

2.1 การวิเคราะห์ความล้าเอียงของข้อสอบจากข้อมูลจำลอง

เบอร์ก (Berk, 1982 : 164; quoting Merz and Grossen, 1979) ได้ศึกษาเปรียบเทียบ วิธีวิเคราะห์ความล้าเอียงของข้อสอบ โดยวิเคราะห์ความล้าเอียงด้วยวิธีแปลงค่าความยาก วิธีพอยท์ ใบซีเรียล วิธีไคลสแควร์ การวิเคราะห์องค์ประกอบ วิธีໄດ້ລັກນະข้อสอบ 3 พารามิเตอร์ และวิธีໄດ້ລັກນະข้อสอบ 1 พารามิเตอร์ โดยใช้ข้อมูลสมมติ

ผลการศึกษาพบว่า การวิเคราะห์ความล้าเอียงด้วยวิธีวิเคราะห์ด้วยพอยท์ใบซีเรียล เป็นวิธีที่ให้ผลการวิเคราะห์สอดคล้องกับวิธีอื่นน้อย ส่วนวิธีแปลงค่าความยากให้ผลการวิเคราะห์สอดคล้องกับวิธีอื่นมาก รวมทั้งวิธีໄດ້ລັກນະข้อสอบ 3 พารามิเตอร์ และ 1 พารามิเตอร์ ให้ผลการวิเคราะห์สอดคล้องกับวิธีอื่นมาก เช่นกัน วิธีไคลสแควร์และวิธีวิเคราะห์องค์ประกอบให้ผลการวิเคราะห์สอดคล้องกับวิธีอื่นปานกลาง แต่วิธีแปลงค่าความยากเป็นวิธีที่เหมาะสม เพราะไม่มีข้อจำกัดในเรื่องจำนวนกูุ้่นตัวอย่าง และการคำนวณ

ชูเนอร์ (Schoener, 1984) ได้ศึกษาเปรียบเทียบวิธีการวิเคราะห์ความล้าเอียงของข้อสอบ ด้วยวิธีการทางสถิติที่ใช้ทุนถือการตอบข้อคำถามที่มี 3 พารามิเตอร์ และการตัดสินด้วยผู้ตัดสินจำนวน 24 คน เป็นผู้ตัดสินผู้ค้า 8 คน ผิวขาว 8 คน และเชื้อสายสเปน 8 คน เป็นชายและหญิงจำนวนท่าๆ กัน โดยใช้แบบทดสอบอิงเกณฑ์ กูุ้่นตัวอย่างที่นักเรียนชายและหญิงที่ระดับชั้นมัธยมศึกษาที่มีภูมิหลังทางวัฒนธรรมต่างๆ กันจำนวน 1,064 คน การตัดสินใช้ผู้ตัดสินที่มีความรู้ทางด้านคณิตศาสตร์เป็นอย่างดี และใช้แบบฟอร์มการใช้คะแนนเป็นช่วง (Rating Form) สำหรับการวิเคราะห์ ได้พิจารณาถึงความสอดคล้องจากการตัดสินของกูุ้่นผู้ตัดสินทั้ง 3 กูุ้่น และความสอดคล้องระหว่างวิธีการทางสถิติทางการตัดสินของผู้ตัดสิน โดยใช้ค่าสถิติของ แคปป้า (Kappa)

ผลการศึกษาพบว่า ความสอดคล้องระหว่างการตัดสินໄດ້ผู้เขียนข่ายต่างกัน ไม่มีนัยสำคัญทางสถิติสำหรับทั้งความล้าเอียงทางด้านวัฒนธรรมและทางเพศ แต่พบความสอดคล้อง กันอย่างมีนัยสำคัญทางสถิติในตัวบ่งชี้บางตัวที่คำนวณขึ้นเพื่อรวมการให้คะแนนของผู้ตัดสิน แต่

ไม่พบรความสอดคล้องระหว่างการวิเคราะห์ความล้าเอียงทั้ง 2 วิธี การตัดข้อสอบที่พบทางสถิติ ว่ามีความล้าเอียงออกไป ไม่ทำให้คำค้นของคนในกลุ่มย่ออย่างรวมทั้งหมดเปลี่ยนไป นอกจากนี้ ทั้งแบบทดสอบฉบับเดิม และแบบทดสอบที่มีความล้าเอียงออกแล้ว มีความสำพันธ์อย่างมีนัย สำคัญทางสถิติกับแบบทดสอบวิชาคณิตศาสตร์อิงกุ่มที่เป็นแบบทดสอบมาตรฐาน

รัดเนอร์ และคนอื่นๆ (Rudner and other, 1980) ได้เปรียบเทียบวิธีวิเคราะห์หาความล้าเอียงของข้อสอบ โดยใช้วิธีวิเคราะห์ที่ต่างกัน 7 วิธี ได้แก่ วิธีแปลงค่าความยากของข้อสอบ 2 วิธี คือวิธีใช้เส้นแกนหลัก (TID-MA) และวิธีใช้เส้นแกน 45 องศา (TID-45) วิธีไคสแคร์ 2 วิธี คือ วิธีไคสแคร์ที่แบ่งแบบ 5 ช่วง (CHI - 5) และวิธีไคสแคร์ที่แบ่งแบบ habitats ช่วง (CHI-N) และวิธี โถงลักษณะข้อสอบ 3 วิธี คือ วิธีโถงลักษณะข้อสอบ 3 พารามิเตอร์ (ICC-3) วิธีโถงลักษณะข้อสอบ 1 พารามิเตอร์ ชนิดค่าสถิติเหมาะสม (ICC-1F) และชนิดความแตกต่างในความจ่ายของข้อสอบ (ICC-1E) โดยใช้ข้อมูลสมมติ (Simulate Data) ที่ผู้วิจัยสร้างขึ้นเอง

ผลการศึกษาพบว่า วิธีโถงลักษณะข้อสอบที่มี 3 พารามิเตอร์ เป็นวิธีกันพนข้อสอบที่มีความล้าเอียงจากข้อมูลสมมติที่ดีที่สุด รองลงมาได้แก่วิธีวิเคราะห์แบบไคสแคร์แบบ 5 ช่วง ส่วน วิธีแปลงค่าความยากของข้อสอบทั้ง 2 วิธี ผู้วิจัยแนะนำให้ใช้ได้ในทางปฏิบัติ เมื่อพิจารณาค่าสหสัมพันธ์ของจำนวนข้อสอบที่มีความล้าเอียงระหว่างวิธีวิเคราะห์ความล้าเอียงต่างกัน วิธีโถงลักษณะข้อสอบ 3 พารามิเตอร์ วิธีไคสแคร์ ที่แบ่งแบบ 5 ช่วง และวิธีแปลงค่าความยากที่ใช้เส้นแกน 45 องศา เป็นวิธีที่ถูกต้องมากที่สุด คือ มีค่าสหสัมพันธ์เท่ากับ .80, .73 และ .63 ส่วน วิธีโถงลักษณะข้อสอบ 1 พารามิเตอร์ ชนิดค่าสถิติเหมาะสม มีความถูกต้องน้อยที่สุด มีค่าสหสัมพันธ์เท่ากับ .55 วิธีวิเคราะห์ความล้าเอียงทุกวิธี ยกเว้นวิธีโถงลักษณะข้อสอบ 1 พารามิเตอร์ ชนิดค่าสถิติเหมาะสมสามารถกันพนข้อสอบที่มีความล้าเอียงในกรณีที่มีความยากแตกต่างกันเท่านั้น แต่วิธีโถงลักษณะข้อสอบ 1 พารามิเตอร์ ชนิดค่าสถิติเหมาะสม มีความไวต่อความล้าเอียงของข้อสอบที่มีทั้งความยากและค่าอำนาจจำแนกแตกต่างกัน นอกจากนี้ยังพบว่าวิธีไคสแคร์ที่แบ่งแบบ 5 ช่วง มีประสิทธิภาพเท่า ๆ กับวิธีโถงลักษณะข้อสอบที่มี 3 พารามิเตอร์ และถ้าได้คำนึงถึงความขาวของแบบทดสอบหรือขนาดของความล้าเอียงของข้อสอบแล้ว ทั้งสองวิธีก็สามารถนำมาใช้แทนกันได้

ธิสเซ่น สไทร์เบอร์ก และ瓦因เบอร์ (Thissen, Steinberg and Wainer, 1988) ได้ศึกษาความแตกต่างของโถงการตอบข้อสอบระหว่างกลุ่มด้วยทฤษฎีการตอบข้อคำถาม เพื่อศึกษาถึงสภาพการณ์ในการทดสอบสมมติฐานความเท่ากันของค่าพารามิเตอร์ ด้วยค่าไคสแคร์แบบอัตราส่วน Likelihood (IRT-LR) โดยใช้ข้อมูลสมมติ (Simulated Data) แล้วจึงทำการเปรียบเทียบการทดสอบสมมติฐานความเท่ากันของค่าพารามิเตอร์ด้วยวิธี IRT-LR กับวิธีของแมนเกล-แยนส์เซล

ผลการศึกษาพบว่า วิธีไสแก้วร์แบบอัตราส่วน Likelihood (IRT-LR) สามารถใช้ วิเคราะห์ความถูกต้องของข้อสอบได้เมื่อมีจำนวนกลุ่มตัวอย่างน้อยๆ คือประมาณ 500 คน ความแตกต่างของค่าความยากของข้อสอบระหว่างกลุ่ม มีค่าเท่ากับ 0.3 และความแตกต่างในด้านค่า สัมประสิทธิ์การเดาไม่ถูกเท่ากับ 0.1 โดยจำนวนร่วมจะมากหรือน้อยก็ไม่มีผลกระทบ ถ้าความ แตกต่างมีค่าน้อยกว่านี้ไม่สามารถที่จะใช้วิธีไสแก้วร์แบบอัตราส่วน Likelihood (IRT-LR) วิเคราะห์ได้ว่าข้อสอบถูกต้องหรือไม่ แต่ถ้าใช้กลุ่มตัวอย่างจำนวนมากก็อาจทำการวิเคราะห์ได้

การระบุความถูกต้องของข้อสอบ ใช้วิธีเบร็บน์เพื่อบรรยายความแตกต่างระหว่างกลุ่มใน ข้อสอบที่ต้องการวิเคราะห์ความถูกต้องกับข้อสอบร่วม ซึ่งมีข้อตกลงว่าข้อสอบร่วมนั้นไม่มี ความถูกต้องของข้อสอบที่ต้องการวิเคราะห์ความถูกต้องกับข้อสอบร่วม และการทดสอบความถูกต้องของข้อสอบทั้งฉบับ สำหรับผลการวิเคราะห์ความถูกต้องของข้อสอบ ด้วยวิธีไสแก้วร์แบบ อัตราส่วน Likelihood (IRL-LR) กับวิธีของแมนเกล-แ昏ส์เซลล์ ทั้งสองวิธีให้ผลการวิเคราะห์ คล้ายกันมาก ข้อเสนอแนะจากการวิจัยครั้งนี้ คือ วิธีของแมนเกล-แ昏ส์เซลล์ อาจใช้ในการ วิเคราะห์ความถูกต้องของแบบทดสอบขายๆ หรืออาจใช้เครื่องมือในการกั้นกรองข้อสอบ ก่อนที่จะใช้วิธีไสแก้วร์แบบอัตราส่วน Likelihood (IRT-LR) ต่อไป

สวามินาธาน และ โรเจอร์ส (Swaminathan and Rogers, 1990) ได้ตรวจสอบความ ถูกต้องของข้อสอบ ด้วยวิธีการทดลองแบบโลจิสติกกับวิธีของแมนเกล-แ昏ส์เซลล์ (MH) จากการ จำลองข้อมูลการตอบข้อสอบคัวขับโปรแกรม DATAGEN แบบ 3 พารามิเตอร์ และข้อมูลการ จำลองความถูกต้องแบบ 2 พารามิเตอร์ จำลองข้อมูลที่มีความถูกต้อง 2 แบบ คือ ความถูกต้อง แบบสม่ำเสมอ (Uniform) และการถูกต้องแบบไม่สม่ำเสมอ (Nonuniform) โดยใช้ค่าอ่านใจ จำแนกของ 2 กลุ่ม เท่ากันส่วนค่าความยากของข้อสอบแบ่งเป็นปั๊ลย์บัน ไปตามกลุ่มเพื่อให้เกิดระดับ ความถูกต้องต่างๆ กัน ตามต้องการ แต่ในลักษณะการถูกต้องไม่สม่ำเสมอ (Nonuniform) นั้น ให้ค่าความยากของข้อสอบของ 2 กลุ่มเท่ากัน แต่ค่าอ่านใจจำแนกแบ่งเป็นปั๊ลย์บัน ไปตามกลุ่ม โดย ศึกษากับขนาดกลุ่มตัวอย่าง 2 ขนาด คือ 250 และ 500 คน และความขาวของแบบทดสอบ 3 ขนาด คือ 40,60 และ 80 ข้อ

ผลการศึกษาพบว่า การตรวจสอบความถูกต้องของข้อสอบ ทั้ง 2 วิธี ให้ผลใกล้เคียงกัน ในกรณีความถูกต้องแบบสม่ำเสมอ (Uniform) วิธีของแมนเกล-แ昏ส์เซลล์ ตรวจสอบความถูกต้อง ของข้อสอบได้ดีกว่าวิธีการทดลองแบบโลจิสติกน้อย โดยมีการตรวจสอบความถูกต้องได้ถูกต้อง ร้อยละ 75 กรณีใช้กลุ่มตัวอย่าง 250 คน และตรวจสอบได้ถูกต้องร้อยละ 100 ในกรณีใช้กลุ่มตัว อย่าง 500 คน ในทุกความขาวของแบบทดสอบ แต่ในกรณีของความถูกต้องแบบไม่สม่ำเสมอ

(Nonuniform) นั้น วิธีของแมนเทล-แ昏ส์เซล ไม่สามารถตรวจสอบความถูกต้องได้ ด้วยวิธีการคัดอยแบบโลจิสต ตรวจสอบความถูกต้องประมาณร้อยละ 50 ในกรณีกู้มตัวอย่างน้อย และข้อสอบสั้น และตรวจสอบความถูกต้องประมาณร้อยละ 75 ในกรณีกู้มตัวอย่างขนาดใหญ่และแบบทดสอบบัว แต่กรณีมีความถูกต้องแบบไม่สม่ำเสมอ โดยที่โครงสร้างจะข้อสอบตัดกันที่ปลายทางของโครงสร้างค้านหนึ่งไม่ว่าจะเป็นค้านความสามารถสูงหรือต่ำก็ตาม วิธีของแมนเทล-แ昏ส์เซล จะตรวจสอบความถูกต้องได้ดีกว่า

ในการตรวจสอบผิดพลาด ก็คือ ระบุว่าข้อสอบมีความถูกต้อง ทั้งๆ ที่ไม่ถูกต้องนั้น วิธีของแมนเทล-แ昏ส์เซล ดีกว่า โดยตรวจสอบผิดประมาณร้อยละ 1 ส่วนวิธีคัดอยแบบโลจิสต ตรวจสอบผิดพลาดประมาณร้อยละ 1-6 และเสียค่าใช้จ่ายมากกว่าประมาณ 3-4 เท่า เมื่อว่าจะมีความถูกต้องและเป็นแบบทั่วไปมากกว่าวิธีของแมนเทล-แ昏ส์เซล

ประโยชน์ของวิธีการคัดอยแบบโลจิสต อยู่ตรงที่เป็นวิธีการที่มีพื้นฐานเป็นแบบจำลอง ที่สามารถเพิ่มตัวแปรความสามารถเข้าไปในแบบจำลองได้ ซึ่งทำให้เข้าใจในธรรมชาติของความถูกต้องได้ดีกว่า

คลอเชอร์ และคนอื่นๆ (Clauser and Others, 1991) ได้ศึกษาถึงอิทธิพลต่างๆ ที่มีผลต่อวิธีการตรวจสอบความถูกต้องของข้อสอบ ด้วยวิธีของแมนเทล-แ昏ส์เซล ข้อมูลที่ใช้เป็นข้อมูลที่จำลองขึ้นเพื่อใช้ในการศึกษาตรวจสอบความถูกต้องแบบสม่ำเสมอ ข้อมูลที่จำลองขึ้นเป็นแบบทดสอบจำนวน 75 ข้อ ให้มีความถูกต้องอยู่ 16 ข้อ และมีระดับความแตกต่างของค่าความยากทารายระดับ ระหว่างกู้มตัวอย่างและกู้มเป้าหมาย กู้มตัวอย่างที่ใช้ศึกษามีจำนวน 3,000 คน เป็นกู้มตัวอย่าง 1,500 คน กู้มเป้าหมาย 1,500 คน มีการวิเคราะห์ระดับความยากของแบบทดสอบที่ต่างกันหลายระดับ กับระดับความยากของแบบทดสอบ 5 ระดับ อ่านจากมาก 4 ระดับ และการกระจายของความสามารถ 2 ลักษณะ

ผลการศึกษาพบว่า สิ่งที่มีอิทธิพลต่อการตรวจสอบความถูกต้องของข้อสอบคือ วิธีของแมนเทล-แ昏ส์เซล คือ ความแตกต่างในระดับความยากระหว่างผู้สอบทั้ง 2 กลุ่ม รวมทั้งค่าอ่านจากมาก และค่าความยากของข้อสอบคัวชี้ จากการวิจัยนี้ทำให้ได้ข้อเสนอแนะว่า วิธีของแมนเทล-แ昏ส์เซล นี้ใช้ได้ดี สำหรับข้อสอบที่มีค่าอ่านจากมากสูง และมีแนวโน้มจะไม่สามารถตรวจสอบความถูกต้องของข้อสอบ ในข้อสอบที่มีค่าความยากสูงได้

เมเชอร์ และคนอื่นๆ (Mazor and Other, 1991) ได้ศึกษาวิธีการตรวจสอบความถูกต้องของข้อสอบคัวชี้ของแมนเทล-แ昏ส์เซล การตรวจสอบความถูกต้องของข้อสอบจะใช้การทดสอบค่า $MH - \chi^2$ นี้ $df = 1$ จากข้อมูลที่จำลองขึ้นเป็นข้อสอบ จำนวน 5 ชุด และ 75 ชุด โดยศึกษา

กับกลุ่มตัวอย่างที่มีขนาดต่างกัน 5 ขนาด คือ 2,000, 1,000, 500, 200 และ 100 คน เพื่อเปรียบเทียบการตรวจสอบความถูกต้องของข้อสอบ

ผลการศึกษา พบว่า เมื่อใช้กลุ่มตัวอย่างขนาด 2,000 คน วิธีนี้วิเคราะห์ความถูกต้องของข้อสอบผิดพลาดร้อยละ 30 และเมื่อใช้จำนวนกลุ่มตัวอย่างตั้งแต่ 500 คนลงไป วิธีนี้จะวิเคราะห์ความถูกต้องของข้อสอบได้ผิดพลาดร้อยละ 50 ทั่วไปของข้อสอบที่ไม่สามารถตรวจทั้งหมดความถูกต้องได้ ได้แก่ ข้อสอบที่ยากมากๆ ข้อสอบที่มีค่าความยากต่างกันเล็กน้อยสำหรับกลุ่มตัวอย่าง 2 กลุ่ม และเป็นกลุ่มที่มีค่าอำนาจจำแนกต่ำ

สำหรับการวิเคราะห์ความถูกต้องของข้อสอบโดยใช้ข้อมูลจริง มีผู้ศึกษาดังนี้

พงษ์จิต อินทสุวรรณ (Intaswan, 1979 :92) ได้ศึกษาวิเคราะห์ความถูกต้องของข้อสอบระหว่างกลุ่มผู้สอบที่มีเชื้อชาติต่างกัน คัวบิชีวิเคราะห์ 3 วิชี คือ วิธีไก่ลักษณะข้อสอบ 3 พารามิเตอร์ วิธีไก่ลักษณะข้อสอบตามแบบจำลองของราศี และวิธีไกสแควร์ การศึกษาครั้งนี้ใช้ข้อมูลจริง จากการใช้แบบทดสอบ ไอ อี เอ (IEA : The International Association for the Evaluation of Education Achievement) โดยศึกษาเก็บกลุ่มนักเรียนที่มีอายุ 14 ปี ชาวอังกฤษ อเมริกัน และนิวซีแลนด์ จำนวน 8,601 คน

ผลการศึกษาพบว่า วิธีวิเคราะห์ความถูกต้องทั้ง 3 วิธี มีค่าสหสัมพันธ์อยู่ระหว่าง 0.51-0.98 โดยที่วิธีวิเคราะห์แบบไกสแควร์ และวิธีไก่ลักษณะข้อสอบตามแบบจำลองของราศี มีค่าสหสัมพันธ์สูงถึง .98

เบอร์ก (Berk, 1982 : 196 ; quoting Shepard, Camilli and Averill, 1981) ได้ศึกษาเปรียบเทียบวิธีวิเคราะห์ความถูกต้องของข้อสอบ ระหว่างกลุ่มผู้สอบที่มีเชื้อชาติต่างกัน โดยวิธีวิเคราะห์ความถูกต้องด้วยวิธีไกสแควร์ วิธีกำหนดคุณภาพเดียว หรือวิธีเปล่งค่าความยาก วิธีพอยท์ไบเซอร์ค วิธีไก่ลักษณะข้อสอบแบบ 3 พารามิเตอร์ และวิธีไก่ลักษณะข้อสอบแบบ 1 พารามิเตอร์ (Rasch Model) จากแบบทดสอบ Lorge-Thorndike ที่เป็นแบบทดสอบที่วัดความสามารถทางสมอง แบ่งเป็น 2 ฉบับ คือ ฉบับภาษา และไม่ใช่ภาษา การวิเคราะห์ความถูกต้องของข้อสอบผู้วัดใช้เกณฑ์ภาษาอังกฤษ และเกณฑ์ภาษาใน โดยที่เกณฑ์ภาษาใน คือ คะแนนจาก Raven's Colored Progressive Matrices ส่วนเกณฑ์ภาษาใน คือ คะแนนรวมจากแบบทดสอบ กลุ่มตัวอย่างที่ใช้มี 3 เชื้อชาติ จำนวน 1,500 คน เป็นนักเรียนผิวขาว ผิวดำ และชิคาโน (Chicano) เชื้อชาติละ 500 คน

ผลการศึกษาพบว่า วิธีไก่ลักษณะข้อสอบแบบ 3 พารามิเตอร์ เป็นวิธีที่เหมาะสมในทางทฤษฎีถูกต้อง และตรงที่สุด แต่มีช่องจำกัด คือ ต้องใช้กลุ่มตัวอย่างขนาดใหญ่ ส่วนวิธีอื่น ๆ ก็

สามารถใช้ได้ ถ้าผลการวิเคราะห์มีความสอดคล้องกับวิธี ได้แก่ลักษณะข้อสอบแบบ 3 พารามิเตอร์ ชี้งเชปาร์ด และคณที่ได้เสนอว่า ในทางปฏิบัติสามารถใช้วิธีไคสแควร์ (Chi-square) แทนวิธี ได้แก่ ลักษณะข้อสอบแบบ 3 พารามิเตอร์ และวิธีแปลงค่าความยาก (Angoff) สามารถนำมาใช้แทนวิธี ได้แก่ลักษณะข้อสอบแบบ 1 พารามิเตอร์ (Rasch Model) ได้

แฮมเบิลตัน และคนอื่นๆ (Hambleton and Other, 1986) ได้ศึกษาเปรียบเทียบวิธี การวิเคราะห์ความถูกต้องของข้อสอบ 4 วิธี คือวิธีของแม่นเทล-แซนส์เซล วิธีการลงจุดค่าความยาก วิธีค่าความแตกต่างของค่าเฉลี่ยกำลังสอง (The Root Mean Squared Difference) และวิธีของพื้นที่รวม ซึ่ง 2 วิธีหลังนี้เป็นวิธีการที่ใช้ทฤษฎีการตอบข้อคำถาม แบบทดสอบที่ใช้ในการศึกษาเป็นแบบทดสอบที่ใช้ความสามารถในการอ่านของ กลุ่มแพนด์ มีข้อสอบจำนวน 75 ข้อ โดยใช้กลุ่มตัวอย่างจำนวน 937 คน เป็นชาย 451 คนและเป็นหญิง 486 คน ใช้คะแนนจุดตัดในการแปลงความหมายค่าสถิติที่แสดงความถูกต้อง ได้จากการจำลองข้อมูลขึ้น

ผลการศึกษาพบว่าวิธีวิเคราะห์ทั้ง 4 วิธี ให้ผลการวิเคราะห์ข้อสอบที่มีความถูกต้องได้ใกล้เคียงกัน แต่ปัญหาอยู่ที่ความไม่ชัดเจนในการกำหนดจุดตัด ความคลาดเคลื่อนชนิดที่หนึ่ง และการประมาณค่าพารามิเตอร์ที่ไม่ดี ข้อค้นพบที่เหตุได้อย่างเด่นชัด อยู่ที่ความสำคัญของการเลือกใช้ช่วงคะแนนความสามารถในการวัดความถูกต้อง นอกจากนี้ พบว่า สามารถใช้วิธีของแม่นเทล-แซนส์เซล แทนวิธีที่ใช้ทฤษฎีการตอบข้อคำถาม เมื่อจากประหัดกว่าทั้งเงินและเวลา

ดูลิตเทล (Doolittle, 1987) ได้ศึกษาความแตกต่างในการตอบข้อสอบ ระหว่างผู้ที่มี เพศต่างกัน จากข้อสอบ 3 ประเภท ได้แก่ การคำนวณทางคณิตศาสตร์ เรขาคณิต และการใช้ เหตุผลในการสอบ ACT (Assessment Mathematics Usual Test) ซึ่งมี 8 ฟอร์ม ให้นักเรียนที่เป็น กลุ่มตัวอย่าง 8 กลุ่มทำ โดยจับคู่กลุ่มตัวอย่างชายและหญิง ซึ่งเป็นนักเรียนชั้นมัธยมศึกษาตอน ปลายด้วย Profile ของวิชาวิทยาศาสตร์ที่ได้เรียนมาก่อน แล้ว ได้ออกแบบการวิเคราะห์ข้อมูลโดย ใช้วิธี Split Plot Factorial Design ชนิด $2 \times 3 \times 8 \times 8$ (เพศ x ประเภทของข้อสอบ x ภูมิหลัง ค้านคณิตศาสตร์ x ฟอร์มของแบบทดสอบ) จุดที่ต้องการเน้นในการศึกษารึ้งนี้คือ ปฏิสัมพันธ์ ระหว่างเพศกับประเภทของข้อสอบ

ผลการศึกษาแสดงให้เห็นว่า นักเรียนชายและนักเรียนหญิง ทำข้อสอบคำนวณได้ดี พอ ๆ กัน แต่นักเรียนหญิงจะทำข้อสอบเรขาคณิต และข้อสอบเชิงเหตุผล ได้น้อยกว่านักเรียนชาย ซึ่งต้องใช้กระบวนการวางแผนก่อนการปัญหา ผลกระทบที่ใหญ่ที่สุดจากการศึกษารึ้งนี้ คือ ผลกระทบที่เกิดจากภูมิหลังค้านคณิตศาสตร์ และเพศของกลุ่มตัวอย่าง

ดูลิตเทลล์ และเคลียร์ (Doolittle and Cleary, 1987) ได้ศึกษาวิธีวิเคราะห์ความถูกต้องของข้อสอบ โมเดลโลจิสติกแบบ 3 พารามิเตอร์ ที่วิเคราะห์ค่าดัชนี Z ของลินน์ และฮาร์นิช (Linn and Harnisch, 1981) ระหว่างผู้สอบที่มีเพศต่างกัน โดยใช้ข้อสอบในแบบทดสอบวัดผลสัมฤทธิ์ทางการเรียนวิชาคณิตศาสตร์ กลุ่มตัวอย่างที่ใช้มีประมาณ 1,300-1,400 คน เป็นหญิงประมาณร้อยละ 55 และแต่ละกลุ่มนิมีความเท่าเทียมกัน กลุ่มตัวอย่างจะแบ่งเป็นจำนวน 8 กลุ่มให้ทำแบบทดสอบ ACT (Assessment Mathematics Test) รวม 8 ฟอร์ม ดัชนี Z ที่ได้เป็นบวกแสดงว่าข้อสอบข้อนี้นั้นง่ายสำหรับกลุ่มเปรียบเทียบ ถ้าเป็นลบแสดงว่าข้อสอบข้อนี้นั้นยากสำหรับกลุ่มเปรียบเทียบ

ผลการศึกษาพบว่า ดัชนี Z ที่คำนวณได้มีค่าเป็นลบ ในข้อสอบที่วัดด้านเรขาคณิต และการใช้เหตุผลเชิงพิชณิต สำหรับข้อสอบที่วัดด้านเรขาคณิต การใช้เหตุผลเชิงพิชณิต และเรขาคณิตในทุกฟอร์ม แสดงว่าง่ายสำหรับเพศชายมากกว่าเพศหญิง สำหรับดัชนี Z ที่เหลือส่วนมากมีค่าเป็นบวก

คิม และโคเคน (Kim and Cohen, 1991) ได้ศึกษาความถูกต้องของข้อสอบที่สร้างขึ้นอย่างจะให้ถูกต้องโดยการเปรียบเทียบผลการคำนวณพื้นที่ความแตกต่างระหว่างโรงที่ใช้จากทฤษฎีการตอบข้อคำถาม ของกลุ่มตัวอย่างผู้ชาย และผู้หญิง 2 วิชี ได้แก่ การคำนวณพื้นที่ภายในได้ความสามารถที่มีขอบเขตจำกัด และที่ไม่มีขอบเขตจำกัด

จำนวนกลุ่มตัวอย่างที่ใช้ก่อรุ่นละ 1,000 คนซึ่งสูงมาจากเดิมที่มีผู้ชาย 1,021 คน และผู้หญิง 1,008 คน เพราะข้อจำกัด ในการใช้โปรแกรม BILOG ตัวข้อมูล-คอมพิวเตอร์ เครื่องมือที่ใช้ในการเก็บรวบรวมข้อมูล คือ แบบทดสอบคำศัพท์ที่เป็นแบบเลือกตอบ ชนิด 4 ตัวเลือก จำนวน 50 ข้อ เป็นคำศัพท์ภาษาอังกฤษมาตรฐาน 40 ข้อ อีก 10 ข้อ เป็นคำศัพท์ที่มีความถูกต้องสำหรับกลุ่มผู้หญิง มากกว่ากลุ่มผู้ชาย

การวิเคราะห์ความเป็นมิติเดียว (Unidimensionality) ด้วยการวิเคราะห์องค์ประกอบสำคัญ (Principal Component Analysis) พบว่า องค์ประกอบแรกที่ได้โดยไม่มีการหมุนแกน และใช้ก้าสหสัมพันธ์แบบเดดรีส์โคลอวิช แสดงถึงความเป็นมิติเดียวได้พอเพียงในการแบบจำลองทฤษฎี การตอบข้อคำถาม โดยขอรับความประปรวนได้ร้อยละ 25 ในกลุ่มผู้สอบผู้ชาย ในขณะที่ขอรับได้ก่อนข้างน้อยในกลุ่มผู้สอบผู้หญิง คือขอรับได้ร้อยละ 16

การคำนวณพื้นที่ความแตกต่างระหว่างโรงของกลุ่มตัวอย่าง 2 กลุ่ม โดยใช้โมเดลการตอบข้อคำถามแบบ 2 พารามิเตอร์และแบบ 3 พารามิเตอร์ ชนิดบังคับให้คำสัมภาษณ์ที่การเดาของทั้งสองกลุ่มนิมีค่าเท่ากัน ($C = C_R = C_F = .23$) และใช้วิธีการวัดพื้นที่ได้ทาง 4 วิชี จากค่า

พารามิเตอร์ของข้อสอบที่ปรับແຕ່ວ້າ ຄືອ ພື້ນທີ່ແບນເປີດປົກເກົ່າງໝາຍ (Exact Unsigned Area: EUA) ໄດ້ຈາກການຄໍານະວັນພື້ນທີ່ຕົກລົດຊ່ວງຄວາມສາມາຮັດ ໂດຍໃນ່ຈຳກັດຂອບເບດເພື່ອໃຫ້ໄດ້ພື້ນທີ່ແນ່ນອນພື້ນທີ່ແບນເປີດໄຟຄົດເກົ່າງໝາຍ (Exact Unsigned Area: EUA) ພື້ນທີ່ແບນປົກຄົດເກົ່າງໝາຍ (Closed-Interval Signed Area: CSA) ແລະ ພື້ນທີ່ແບນປົກໄຟຄົດເກົ່າງໝາຍ (Closed-Interval Unsigned Area: CUA) ກຣີບທີ່ເປັນພື້ນທີ່ ທີ່ຄົດເກົ່າງໝາຍນັ້ນກຸ່ມອ້າງອີງ (R) ອືກກຸ່ມຜິວຕໍາ ດັ່ງນັ້ນດ້າວ່າ CSA ມີ ESA ທີ່ຄໍານະວັນໄດ້ນີ້ກ່າວເປັນນັກ ແສດວ່າຂໍ້ອສອນຂ້ອນນັ້ນຄໍາເລື່ອງເຂົ້າຂ້າງກຸ່ມຜິວຕໍາ

ຂໍ້ອສອນທີ່ສ່ວັງເພື່ອໃຫ້ເກີດຄວາມຄໍາເລື່ອງເຂົ້າຂ້າງຜິວຕໍາ 10 ຊົ້ວ ມີຄ່າເປັນ 1 ອີກ 40 ຊົ້ວທີ່ເໜີມີຄ່າເປັນ 0 ແລ້ວຫາຄ່າສາຫນັ້ນພັນໆແບນພອບທໍໃນໝີເວີບ ຮະຫວ່າງຄ່າດັ່ງກ່າວກັບການວັດທັງ 4 ວິທີ ເພື່ອອຸປະກອດການຕ່າງໆ ແລະຫາຄ່າສາຫນັ້ນຮ່ວມມືກ່າວວິທີຕໍ່າງໆ ເພື່ອອຸປະກອດຄໍາດ້າຍຄລິ່ງກັນ

ການປະ່ານມາຄ່າອັດຕາຄວາມຄວາມຄຸດເກີດຂອງການວັດທັງໝົດ ກະທຳໄດ້ມີຂໍ້ອ ຕກລົງວ່າການວັດພື້ນທີ່ແຕ່ລະວິທີນີ້ການກະຈາຍເປັນແບນປົກຕິ ຄ່າເລື່ອງແລະຄ່າຄວາມເບື່ອງແບນມາຕາງໝາງ ຂອງການວັດແຕ່ລະວິທີຈະປະມາເນັດຈາກຂໍ້ອສອນ 40 ຊົ້ວ ກໍານົດຄ່າວິກຖຸດແບນທາງດີຍົວເປັນ 2 ກ່າວ ສື່ບໍ່ທີ່ຮ່ວມມືກ່າວວິທີ .05 ແລະ .01 ຊົ້ວທີ່ພື້ນທີ່ໃຫຍ່ກ່າວວິກຖຸດຈະເປັນຂໍ້ອສອນທີ່ມີຄວາມຄໍາເລື່ອງ ການຈັດປະເກດຂໍ້ອສອນເຫັນນີ້ທ່ານໃຫ້ເກີດຄວາມຄວາມຄຸດເກີດຂອນ 2 ຊົ້ວ ໄດ້ແກ່ ຄວາມຄວາມຄຸດເກີດຂອນນີ້ຈະບຸວ່າໄຟນີ້ໄດ້ເລື່ອງ ຖ້າ ທີ່ຂໍ້ອສອນນັ້ນຄໍາເລື່ອງ (FN = False Negatives) ແລະຮະບຸວ່າຂໍ້ອສອນຄໍາເລື່ອງທັງໆ ທີ່ໄຟນີ້ຄໍາເລື່ອງ (FP = False Positives) ແລະເນື້ອໃຊ້ຄ່າວິກຖຸດທີ່ $p = .05$ ພບວ່ານີ້ FP ນາກກວ່າທີ່ຄ່າວິກຖຸດ $p = .01$

ພລກາຮົມກົມພວບວ່າ ໃນການວັດທັງໝົດ ຂໍຄວາມຄໍາເລື່ອງຂອງຂໍ້ອສອນດ້ວຍການຄໍານະວັນພື້ນທີ່ແບນ ຊ່ວງເປີດ ແລະແບນຊ່ວງເປີດທັງໝົດທີ່ສອງວິທີເກີດໄຟນີ້ໄຟນີ້ມີຄວາມແຕກຕ່າງ ເນື້ອພິຈາລາຍການໃຊ້ພື້ນທີ່ແບນໄຟຄົດເກົ່າງໝາຍໄຟວ່າຈະເປັນແບນຊ່ວງເປີດໂທີ່ມີຄວາມໄວ້ຕ່ອງການກວດກັນຄວາມຄໍາເລື່ອງຂອງຂໍ້ອສອນນັ້ນກ່າວແນບທີ່ຄົດເກົ່າງໝາຍ ນອກຈາກນັ້ນຂັ້ງພວກວ່າການຄໍານະວັນພື້ນທີ່ແບນຊ່ວງເປີດ ພື້ນທີ່ ຜົນຍົດເກົ່າງໝາຍແລະໄຟຄົດເກົ່າງໝາຍແລະໄຟຄົດເກົ່າງໝາຍ ມີຄວາມສັນພັນທີ່ກັນນາກກວ່າ ພື້ນທີ່ ຜົນຍົດເກົ່າງໝາຍ ແລະໄຟຄົດເກົ່າງໝາຍຂອງການຄໍານະວັນພື້ນທີ່ແບນຊ່ວງເປີດ

ໃນດ້ານຂອງຄວາມຄວາມຄຸດເກີດຂອນໃນການວັດທັງໝົດ ພບວ່າ ວິທີຄໍານະວັນພື້ນທີ່ແບນ 3 ພາຣາມີເຕືອນ ໂດຍໃຊ້ພື້ນທີ່ແບນຄົດເກົ່າງໝາຍນີ້ອັດຕາຄວາມຄວາມຄຸດເກີດຂອນຕໍ່ກ່າວວິທີອື່ນໆ ແລະໄຟນີ້ ຄວາມຄວາມຄຸດເກີດຂອນເລັດທີ່ຮ່ວມມືກ່າວວິທີ .01 ແຕ່ມີຄວາມຄວາມຄຸດເກີດຂອນໃນການຮະບຸວ່າຂໍ້ອສອນຄໍາເລື່ອງ ໂດຍທີ່ໄຟນີ້ຄໍາເລື່ອງໃຈງົງ ຈຳນວນ 2 ຊົ້ວ ທີ່ຮ່ວມມືກ່າວວິທີ .05 ສ່ວນວິທີຄໍານະວັນພື້ນທີ່ແບນ 3 ພາຣາມີເຕືອນ ແນວ່າໄຟນີ້ເກົ່າງໝາຍຈະມີອັດຕາຄວາມຄວາມຄຸດເກີດຂອນສູງກ່າວວິທີອື່ນໆ ເລື່ອນຍ້ອນ

ราช และคนอื่นๆ (Raju and Others, 1993) ได้ศึกษาเบริชบเทียบผลการทดสอบไกสแควร์ ของลอร์ด การทดสอบ Z ของราช (1990) ในการวัดพื้นที่ความแตกต่างระหว่างไฟลักษณะข้อสอบทั้งพื้นที่ชนิดที่คิดเครื่องหมายและไม่คิดเครื่องหมาย โดยใช้โมเดล 2 พารามิเตอร์ และวิธีไกสแควร์ของแมนเกล-แ昏ส์เซลล์ ในการวิเคราะห์ความถ้วนความสำคัญของข้อสอบใช้เกณฑ์การตัดสินความถ้วนความสำคัญ ดังนี้คือ χ^2 ของ Lord มีค่าเท่ากับ 13.80 Z มีค่าอยู่ระหว่าง ± 8.30 และไกสแควร์ของแมนเกล-แ昏ส์เซลล์ มีค่าเท่ากับ 10.83 โดยใช้ข้อมูลจากผลการตอบแบบทดสอบ Gater-Mac Ginitie Reading Tests (GMRT) เฉพาะแบบทดสอบย่อยที่วัดคำศัพท์ 45 ข้อ เป็นแบบเดียวกับชนิด 5 ตัวเลือก กลุ่มตัวอย่างที่ใช้เป็นนักเรียนระดับ 10 และ 12 ในปี 1987 จำนวน 839 คน เป็นนักเรียนผู้ชาย 245 คน นักเรียนผู้หญิง 436 คน นักเรียนหกุ่ง 440 คนและนักเรียนชาย 399 คน

ผลการศึกษาพบว่าในกรณีการวิเคราะห์ความถ้วนความสำคัญระหว่างนักเรียนผู้ชาย และนักเรียนผู้หญิง จากการทดสอบด้วย χ^2 และ Z ทั้งพื้นที่ชนิดคิดเครื่องหมายและไม่คิดเครื่องหมาย ทั้ง 3 วิธี พนข้อสอบที่มีความถ้วนความสำคัญ 1 ข้อ ได้แก่ ข้อ 41 ส่วนวิธีไกสแควร์ของแมนเกล-แ昏ส์เซลล์ พนข้อสอบที่มีความถ้วนความสำคัญ 2 ข้อ คือ ข้อ 14 และ 27 ซึ่งข้อสอบทั้ง 3 ข้อ เป็นข้อสอบที่มีค่าความยากต่างกันมากระหว่างกลุ่มผู้สอบผู้ชายและผู้หญิง

ส่วนผลการวิเคราะห์ความถ้วนความสำคัญระหว่างนักเรียนชายและนักเรียนหกุ่ง 3 วิธีแรก พนข้อสอบที่มีความถ้วนความสำคัญ 4 ข้อ ส่วนวิธีไกสแควร์ของแมนเกล-แ昏ส์เซลล์ พนข้อสอบที่มีความถ้วนความสำคัญ 5 ข้อ ซึ่งกับ 3 วิธีแรก 4 ข้อ คิดเป็นร้อยละ 80 ได้แก่ ข้อ 2, 18, 23, 33 และข้อสอบที่ไม่มีความถ้วนความสำคัญ 3 วิธีแรก คือข้อ 41 และข้อสอบทุกข้อมีความยากสูงกว่าข้อสอบที่ไม่มีความถ้วนความสำคัญ

จากการศึกษาพบว่า วิธีไกสแควร์ของแมนเกล-แ昏ส์เซลล์ คันพนข้อสอบที่มีความถ้วนความสำคัญ ได้มากกว่าวิธีที่ใช้ทฤษฎีการตอบข้อคำถามเช่นนี้ ค้านกับการค้นพบของสวามินารานและโรเจอร์ส (1990) ที่พบว่าวิธีที่ใช้ทฤษฎีการตอบข้อคำถามสามารถค้นพบข้อสอบที่มีความถ้วนความสำคัญ ได้มากกว่าวิธีของแมนเกล-แ昏ส์เซลล์

ข้อควรสังเกตจากการวิจัยครั้งนี้ คือ การทดสอบ Z ของราช อาจให้ผลที่ถูกต้องกว่า การกำหนดเกณฑ์ตัดสินความแตกต่างระหว่างพื้นที่ที่ได้ໄกส์และข้อสอบตามอ้างอิง เพราะอาจเกิดค่าความคลาดเคลื่อนมาตรฐานในการวัด ซึ่งเป็นด้วหนึ่งที่การมาเก็บข้อมูล ทำให้ข้อสอบที่มีความแตกต่างของพื้นที่น้อยกว่าเป็นข้อสอบที่มีความถ้วนความสำคัญ และข้อสอบที่มีค่าความแตกต่างของพื้นที่มากกว่าเป็นข้อสอบที่ไม่มีความถ้วนความสำคัญได้

โโคเคน และคิม (Cohen and Kim, 1993) ได้ศึกษาเปรียบเทียบการใช้ทดสอบที่ก่อตัวขึ้น 2 แบบ 2 พารามิเตอร์ โดยใช้การทดสอบ χ^2 ของลอร์ด และการทดสอบความแตกต่างของพื้นที่ระหว่างโครงสร้างของข้อสอบชนิดคิดเครื่องหมาย โดยใช้สถิติ Z ของราฐ จากข้อมูลจำลองขึ้น ตามทฤษฎีการตอบข้อสอบ 2 พารามิเตอร์ ซึ่งจำลองข้อสอบ 2 ขนาดคือ 20 และ 60 ข้อ จำนวนผู้สอบ 2 ขนาด คือ 100 และ 500 คน และมีจำนวนข้อสอบลำดับอ้างในแบบทดสอบที่จำลอง 3 แบบ คือ มีข้อสอบที่สำเนียงร้อยละ 0, 10 และ 20

ผลการศึกษา พบว่า แบบทดสอบขึ้นขาวการระบุข้อสอบสำเนียงผิดพลาด (FP) จะมากขึ้น และถ้ามีจำนวนข้อสอบสำเนียงอยู่ในแบบทดสอบน้อย จำนวนข้อสอบที่ถูกระบุสำเนียงผิดพลาดจะยิ่งเพิ่มมากขึ้นด้วย องค์ประกอบที่มีอิทธิพลต่อการระบุว่าข้อสอบสำเนียงผิดพลาด (FP) อีกประการ คือ ระดับนัยสำคัญ (α) ถ้าค่าระดับนัยสำคัญยิ่งมากจะเกิด FP มาก นั่นคือที่ $\alpha = .05$ จะเกิด FP มากกว่าที่ $\alpha = .01$ สำหรับการทดสอบ Z ของราฐเกิดในทุกสถานการณ์ที่ศึกษา แต่การทดสอบ χ^2 ของลอร์ด จะเกิดในบางสถานการณ์เท่านั้น

และพบว่าแบบทดสอบที่ขาวกว่า มีร้อยละของข้อสอบสำเนียงมากกว่าจะมีข้อสอบที่ถูกระบุว่าไม่สำเนียงผิดพลาด (FN) มากกว่า แต่จะเกิดขึ้นกับการทดสอบด้วย Z ของราฐ มากกว่า การทดสอบด้วย χ^2 ของลอร์ด

กรณีที่จำนวนผู้สอบเท่ากับ 100 คน พบว่า ความแตกต่างในการระบุว่าข้อสอบไม่สำเนียงผิดพลาด สำหรับ Z ของราฐ และ χ^2 ของลอร์ด ไม่แตกต่างกันมากเท่ากับกรณีที่ใช้กลุ่มตัวอย่าง 500 คน ซึ่งมีการระบุว่าไม่สำเนียงผิดพลาด สำหรับ χ^2 ของลอร์ด น้อยกว่า Z ของราฐ โดยเฉพาะอย่างยิ่งในกรณีที่มีข้อสอบสำเนียงในแบบทดสอบมากที่สุด คือร้อยละ 20

โโคเคน และคิม ได้ให้ความเห็นว่า การทดสอบด้วย χ^2 ของลอร์ด ให้ผลการตรวจสอบข้อสอบสำเนียงได้ดีกว่าการทดสอบ Z ของพื้นที่ ที่คิดเครื่องหมายอาจเป็นเพราะ Z (ESA) ใช้การเปรียบเทียบเฉพาะค่าความยาก (b) ในขณะที่ χ^2 ใช้ทั้งค่าความยากและค่าอำนาจจำแนก (b และ a) แต่ไม่สามารถอธิบายความแตกต่างได้ในกรณีใช้ Z(H) ซึ่งทดสอบพื้นที่ที่ไม่คิดเครื่องหมายเพราะ Z(H) ก็ใช้ทดสอบค่าพารามิเตอร์ทั้ง 2 ตัวเข่นกัน

อย่างไรก็ตาม จากการวิจัยเปรียบเทียบวิเคราะห์ความสำเนียงของข้อสอบที่ก่อตัวมาปรากฏว่าวิเคราะห์ความสำเนียงของข้อสอบไม่ว่าจะศึกษาจากข้อมูลสมมติ (Simulate Data) หรือศึกษาจากข้อมูลจริง (Empirical Data) ทุกวิธีมีบางส่วนที่สัมพันธ์กัน และมีบางส่วนที่แตกต่างกัน และให้ผลสรุปที่คล้ายคลึงกัน