

reliability study)，藉以評估各國間評分者一致性概況。而問卷背景變項之信度分析則以樣本加權過後之 Cronbach's alpha 值與驗證性因素分析(CFA)之結果為信度指標參考依據。

第三節 TIMSS 大型測驗之探討

TIMSS 主要目的為進行學生數學與科學教育成就趨勢調查研究，測試對象為 4 年級與 8 年級之學生，欲評估學生能否掌握參與社會所需的知識與技能，並藉由國際評比來比較參與地區或國家的教育成效。自 1999 年進行 TIMSS-R 評量後，IEA 計畫每隔四年辦理國際數學與科學教育成就研究一次，並改名為 TIMSS。以下將簡要說明 TIMSS 實施時幾個重要之技術層面 (Martin, Mullis, & Chrostowski, 2004)。

壹、評量架構、測驗設計與問卷之發展

一、評量架構

TIMSS 施測數學與科學兩學科，各學科的基礎架構由內容領域 (content domain) 與認知領域 (cognitive domain) 組成。TIMSS 2007 數學四年級的內容領域包含數 (number)、幾何圖形與測量 (geometric shapes and measures)、資料呈現 (data display)，八年級內容領域包含數、代數 (algebra)、幾何 (geometry)、資料與可能性 (data and chance)；認知領域則包含瞭解 (knowing)、應用 (applying) 與推論 (reasoning)。TIMSS 2007 科學四年級的內容領域包含生活科學 (life science)、自然科學 (physical science)、地球科學 (earth science)，八年級內容領域包含生物 (biology)、化學 (chemistry)、物理 (physics)、地球科學 (earth science)；認知領域則包含瞭解 (knowing)、應用 (applying) 與推論 (reasoning)。

二、測驗設計

TIMSS 2003 四年級測驗包含 313 題試題，其中，161 題數學試題與 152 題科學試題；八年級測驗包含 383 題試題，其中，194 題數學試題與 189 題科學試題。

TIMSS 2007 測驗試題四年級 353 題、八年級 429 題，各別分配至 28 個試題區塊，其中 14 個區塊為數學 (M01-M14)，14 個區塊為科學 (S01-S14) (各區塊內僅包含數學或是科學單一領域題目)，四年級與八年級之單數區塊 (M01、M03...M13；S01、S03...S13) 為由 TIMSS 2003 年挑選出之定錨試題區塊。

三、背景問卷

TIMSS 問卷分為四種類型，考科問卷：包含參與國四年級與八年級關於數學及科學課程的主題；學校問卷：學生的校長提供關於學校背景的資訊與關於數學和科學的教學資源；教師問卷：關於教師的背景，準備和專業訓練等，也詢問關於教學的活動，並收集詳細的教學訊息，此乃因為學生四年級時數學及科學通常是同一位老師教授，而八年級則為不同老師教授所設計；還有學生問卷：包含學生在校生活與在家學習數學與科學的經驗。他們被有系統的整合在 TIMSS2007 之課程模式中，此模式包含三個面向，預期、執行與獲得，也就是預期學生該學會的數學與科學課程內容；老師該教授的相關知識，包含如何教授與該由誰教授等等；以及學生已經學會什麼樣的課程內容或知識三個部分。

貳、抽樣設計與抽樣權重

TIMSS 的目標母群是指各國提供施測的母群體，主要是由兩個目標母群中挑選施測樣本，各國可以自由參加其中一個群體，或者是兩個都參加，其中，兩個母群體分為 4 年級 (9 歲) 與 8 年級 (13 歲) 在學的學生。此外，目標母群排除之樣本包含：智力有缺陷的學生、功能上 (functionally) 有缺陷的學生、以及非母語說話的學生。

TIMSS 使用多階段分層之集群抽樣設計 (multistage stratified cluster design)，其中，第一階段進行學校樣本的分層抽樣，第二階段則根據抽樣學校進行施測班級的抽樣。由於各國之受試者被抽測到的機率不同，因此，對於每位受試者必須計算其抽樣權重，抽樣權重的計算根據三個階段程序選擇不同的機率，包含學校、班級、以及學生。

參、試題分析

TIMSS2007 之試題特性分析部份與 TIMSS2003 方法類似，皆為診斷性評量，估計所有施測試題的心理計量測量學上的參數，使用 IRT 試題反應理論。包含描述試題基本之參數估計，不同類型之信度分析，以及整合全部試題之分析內容。數學與科學試題包含選擇題及開放性試題，而開放性試題又分為二元計分試題與多點計分試題（0、1、2 三點計分），也就是填充題與應用題，其中，選擇題與二元計分試題分析採用 2PL 與 3PL 之 IRT 模式，多點計分試題則使用 GPCM；然而，進行量尺化程序前，測驗試題需進行簡單的描述性統計分析，包含整體測驗之統計描述、試題在各國之間之影響、測驗資料之信度研究等等。

肆、量尺化程序

藉由增加測驗的題數可以減少測量誤差，因此成就測驗時，題數常超過 70 題以獲取足夠的訊息，如此一來，伴隨每一 θ 的不確定性就可以被忽略，則 θ 的分布或是 θ 和其他變數的聯合分布就可以使用所估計 θ 近似而得。

當母群很大時，可以使用矩陣抽樣設計(matrix-sampling design)更有效率估計母群的能力分布，像是 TIMSS 所使用的。所謂矩陣抽樣設計：測驗內容範圍廣泛，每一位抽樣到的學生僅需做答部份測驗內容，當所有學生的答題反應被收集集合之後，可涵蓋所有的測驗內容。然而在這樣的設計之下，將無法準確的估計個體的能力，則上述的優勢將會無法存在，也就是個體能力的估計的不確定性將會太大而無法忽略，在這種其況下，集合個體的能力值估計母群的特性將會產生嚴重的偏誤(Wingersky,Kaplan,&Beaton,1987)。

可能值是解決此一問題之一方法，沒有先估計個體的能力然後再計算母群參數，可能值使用所有可得的資料，包含學生的答題反應和背景變項資料直接估計母群和次群體的參數。可能值是從估計的能力分布抽取而來，可以用在標準的統計分析軟體

1. 可能值方法簡介

y ：所有抽樣學生背景資料的反應

θ ：預估計的能力

假如所有抽樣的學生 θ 是知道的，則可以計算統計量 $t(\theta, y)$ ，如樣本平均數或樣本百分點，而後推論相對應的母群參數 T ，可惜的是 θ 是未知的。將 θ 視為遺失資料並且用條件期望值近似 $t(\theta, y)$ 。

給予學生的答題反應 x_j ，學生背景變數 y_j ，試題參數，從能力值的條件分布中隨機抽樣(可能值)可以近似 t^* ，計算 t 的 θ 值是從學生的條件分布中重複隨機抽取，Rubin(1987)指出這種重複的歷程可以將插補的不確定性量化，如透過不同的可能值集合，可以計算不同的 t ，這些 t 的平均，就是 t^* 的數值近似，他們所呈現的變異，反應無法直接觀察 θ 的不確定性。需注意的是，這種變異並未包含抽樣的變異，抽樣的變異藉由 jackknife variance estimation procedure 估計而得。

可能值並非估計學生的個別分數，而是對相似的學生(學生有相似的答題反應和背景變項)插補分數，這樣估計母群時會較準確。當模式被正確介定時，可能值可以提供母群參數的一致性估計，但他們並非個體能力的不偏估計，使用可能值的平均並不能代表個別學生的能力 Mislevy, Beaton, Kaplan, & Sheehan (1992)。

每一個學生 j 的可能值從條件分佈 $P(\theta_j | x_j, y_j, \Gamma, \Sigma)$ 抽取

Γ ：背景變數的回歸係數矩陣

Σ ：殘差共變異矩陣

$$P(\theta_j | x_j, y_j, \Gamma, \Sigma) \propto P(x_j | \theta_j, y_j, \Gamma, \Sigma) P(\theta_j | y_j, \Gamma, \Sigma) = P(x_j | \theta_j) P(\theta_j | y_j, \Gamma, \Sigma)$$

$P(x_j | \theta_j)$ ：試題反應模式

$P(\theta_j | y_j, \Gamma, \Sigma)$ ：在背景變項 y_j 、參數 Γ 和 Σ 的條件下，能力值的多變量聯合密度函數。在計算的過程中，試題參數是固定的並且被視為是母群的值。

2. 條件(Conditioning)

$P(\theta_j | y_j, \Gamma, \Sigma)$ 被假設為是一多變量常態分布，共變異數是 Σ ，平均數是迴歸參數 Γ 的線性模式。在 TIMSS 中使用 PCA 減少背景變數的個數然後使用在 Γ 中可以解釋原始資料 90% 的變異的成分被使用，這些成分就是條件變數，以 y^c 表示，模式如下：

$$\theta = \Gamma'y^c + \varepsilon$$

ε 是常態分布，平均數是 0，變異數是 Σ

Γ 是一矩陣每一欄是每一個能力量尺的效果(effects)

Σ 是量尺之間的殘差變異矩陣。

為了要正確估計上述的函數 $\theta = \Gamma'y^c + \varepsilon$ ，對於所有的背景變數， $P(\theta | y)$ 需正確被界定。如果在估計包含條件變數的函數 Γ 時不是在此種情況下 ($P(\theta | y)$ 需正確被界定)，將會因為不正確的界定(misspecification)而產生誤差。

在 TIMSS2007，以幾乎所有背景變項為基礎的主成分分數被使用。這些背景變項高度反應教育政策和教育實務，透過這些變數所計算的 θ 的邊際平均和百分點幾乎是最佳的。

3. 產生成能力值(generating proficiency scores)

步驟一：從一個近似常態的分配 $P(\Gamma, \Sigma | x_j, y_j)$ ，固定 Σ 為 $\hat{\Sigma}$ ，抽取一個 Γ 。

步驟二：在 Γ 的條件下，(且固定 $\Sigma = \hat{\Sigma}$)，公式 7 後驗分佈的平均 θ_j 和變異數 \sum_j^p 使用 EM 的演算法則計算。

步驟三：能力值從一個多變量常態分佈(平均 θ_j 、變異數 \sum_j^p)獨立抽取。

這三個步驟重複五次，每一位學生產生 5 個 θ_j 的差補值。

學生們雖然被施測較少的題數，但是學生的 Γ 和 Σ 是固定的，因此所有的學生不管施測的題數都被指定一組可能值。

4. 條件變數

(1) 對於類別變項，每一個選項使用虛擬變項編碼，假如學生沒有作答(遺漏)或沒有被施測，那一題的虛擬編碼被設定是 0。

(2) 連續變項的背景資料，像是出生年，家中人口數是使用效標量尺(criterion scaling)重新編碼。就是每一個反應選項使用 interim achievement score 代替。

(3) 每一個國家，所有的虛擬編碼的變數和效標量尺(criterion-scaled)的變數被包含入主成分分析。這些主成分需能解釋背景變項 90% 的變異。因為每一個國家的主成分分析是分開計算的，因此每一個國家的主成分個數可能不大一樣。

(4)除了主成分分析萃取的成分，性別(dummy-coded)、試卷使用的語言(dummy-coded)、學生所隸屬的學校班級(criterion-scales)、特定選擇的國家變數(dummy-coded)是主要的條件變數，如此一來，將能解釋最大的學生之間的變異並且保留教室之間和教室內的變異。

在TISSS2007技術報告中明確指出，要將IRT量尺化和可能值方法應用於TIMSS2007評量中有四個主要的工作：

1. 校準測驗試題（估計各個試題參數）
2. 在學生問卷的條件變數中找出主要成分
3. 建立數學與科學整體的 IRT 量尺（精熟分數）、數學與科學在各個內容與認知領域的 IRT 量尺（精熟分數）
4. 將量尺上的精熟分數與前一次測驗做比較

本研究主要目的為建立一套適合 TASA 之標準化流程，因此，首先就國外大型測驗（NAEP、TIMSS、PISA）進行相關文獻之整理與分析，同時探討各研究步驟之優缺點，以發展適用於 TASA 之標準化測驗。根據文獻探討，本計畫整理欲探討大型標準化測驗實施時之重要程序，主要針對以下部分：抽樣權重、測量模式、試題特性與背景變項分析、量尺化程序及結果報告之呈現。