

# 後設資料與內容標誌：淺談數位化的文章和其內容標誌處理

謝清俊 銘傳大學講座教授

## 【摘要】

本文為 2007 年 5 月臺灣大學佛學研究中心舉辦「佛學專題與數位資源之運用工作坊」研習課程之講稿，主題為「後設資料與內容標誌」，談數位化的文章和語意之處理，分別就文章數位化之後其呈現、內容表現手法與語文的應用等生態變遷，來探討後設資料與內容標誌在數位化文章的重要性，並以《心經》實作為例，說明後設資料與內容標誌的重要。

【關鍵詞】：後設語言；後設資料；內容標誌；情境；語意；數位化文章

## 前言

本次課程的主題是後設資料（metadata）與內容標誌（content markup）。本次課程之前的課已介紹了標誌（markup）和 TEI（Text Encoding Initiative，即文本加碼推動計畫，此處之加碼即指標誌）。TEI 就是一種標誌。最近，標誌很流行，做數位化的人都知道標誌，也有很多人把很多事都用標誌做。今天所講的課，比較偏向於思考方面。談談何謂「後設資料」？何謂「內容標誌」？這兩者有何關係？有何一樣或不一樣之處。

## 一、從數位化看文章生態的變遷

今天的課從數位化看文章的生態談起，因為文章的生態從數位化以後就開始改變了；接著談文章與後設資料的問題、內容標誌與文章的問題，最後再演繹《心經》版本和內容標誌之間的關係。

大家知道數位化改變了溝通的生態。請大家想想，在沒有網路的時候，沒有用手機的時候，沒有用數位化產品的時候，我們的生活是什麼樣的情形，而現在又是什麼樣的情形。這樣一比較就知道數位化對我們的生活，不管是工作、食衣住行、娛樂，都產生很大的影響。這影響主要的原因是來自溝通（communication）的改變。有人說網際網路真厲害，數位化產品真厲害；其實，是網際網路厲害嗎？不是！是數位化產品厲害嗎？也不是！是網際網路帶來的溝通厲害：它的成本大幅降低，它的功能急遽增長，而使得各種前所未有的應用，出人意表的層出不窮。

因為數位化改變了溝通的生態，擔任溝通中介的文字紀錄或文章，其生態也必然風行草偃。如：現在網際網路上有很多「輕薄短小」的文章；很多人寫電郵（e-mail），碰到標點符號不好打就換行，所以現在很多電郵寫起來像新詩的形式—那麼美麗。這好像很酷（cool）！但是，如果看看電郵的內容，簡直是支離破碎、慘不忍睹。也有些迎合青少年口味的出版品，圖文夾雜，「圖多字少，膚淺花俏」，甚至於做立體書。諸如此類，無非是受到數位化、網路改變的結果。此外，在學術界，包括教育、傳播、心理學、認知科學、人工智能等，有關青少年

閱讀習慣和認知行為變遷的研究報告指出，青少年閱讀習慣和認知行為的改變，可能會改變青少年腦袋裡認知所產生的結構。換言之，時下青少年和我們這種 LKK（老人家）的腦袋，構造都可能不太一樣。像我這一代（近古稀之年），大概都看文字，在我腦袋裡的知識結構都是文字關係建構，比較少圖形建構；但是現在青少年就可能不一樣。同樣的，電腦中的文章經數位化後，存在資料庫裡，這也和傳統的文章生態所有不同，而首先引起異議的，是文章定義（界定）和範疇的問題。

### （一）文章定義與範疇的問題

前面說的，都是數位化帶給文章生態的改變。但是，我們今天不再講這些，只談一個問題，那就是：文章經過數位化存到電腦中時，與傳統的文章究竟有什麼不一樣。

我們把一篇文章存到電腦裡，必須把一些有關背景的情境資料（context information）也存起來，如作者、出版處、出版時間，諸如此類，並與文章作適當的連接。如果沒有情境資料，所存的文章將無法分類，無法檢索，也就沒辦法構成資料庫，所以，也就沒辦法管理和利用了。所以，文章存到電腦裡以後，就已經和我們一般傳統的文章不一樣。

有一位法國的文學家 Julia Kristeva，她曾提出一個「互為文本（inter-textuality）」的理論，其主要的概念是：世界上沒有一段文字是可以獨立存在的，任何一段文字一定和其他文章一些相關的文字有某些關係。「互為文本」以我們中國人看來並不是新的概念，然而，這個理論可說明：文章存在電腦以後，它不是一個孤島；它的內容、字串必須與其他的文章有點關係。這個關係是怎麼建立的呢？當然，就是加標誌。這也表示：文章存在電腦裡經標誌後，其結構也就變了，變得和傳統紙面的文章不一樣。

另外，文章內容與外界的聯繫（hyperlinks），也可以用標誌來表達。這聯繫不一定是文章和文章之間有聯繫；文章和實物也可以有聯繫。比方說，可以把《紅樓夢》裡的食譜跟台北有名餐館提出類似的餐點連結起來，那麼我們去吃飯的時候就可以試點一道《紅樓夢》裡的菜；又，《紅樓夢》裡提到很多植物、花、草，也可以跟植物園、植物研究所的東西連起來，彼此便有個照應、參照。所以數位化後，文章內容與外界的聯繫也成了文章的一部份，這也引起數位文章的定義與範疇的問題。

### （二）表現內容的手法與語文的應用

一般來講，我們在電腦裡面表現文章內容的手法和以下這些有關：

第一是呈現（presentation）。文章放在電腦裡以後，怎樣呈現出來：怎麼樣輸出到各種不同的週邊設備、網路設備、螢幕、列印設備……，這是呈現的問題。

第二是內容之外化。舉個例子，中央研究院的二十五史資料庫，採取的是標點版。因為，如果不採取標點版，看起來會很辛苦。因此，文章存在電腦裡以後，

標點符號、句讀、標題、文章的章節段落……，還有版面的位置、字體、色彩、加網加邊、美工加工……，以及標誌與內容標誌（content markup），包括通用結構（DTD，如：版面的、結構的、語文的、內容上的……）、標籤集（tag set），諸如此類，都必需增添。為了增添這些東西，就需要用到一個非常重要的工具，叫做後設語言（meta-language）。關於細節本文以下會陸續介紹。

### （三）數位化文章的界定

數位化的文章，該不該包含傳統文章外的情境信息？這問題其實不用回答，因為目前已經這樣做了，例如：

第一，文章與其後設資料，通常都會在資料庫裡面。也就是說，我們把一篇文章、一本書或是一本雜誌放到電腦裡去以後，一定有一個資料叫做書目資料。這個書目資料包括作者、寫作日期、標題、出版處、發行人、字數、……，這些都是所謂的後設資料，不是書的內容資料，是和書的背景有關的資料。

第二，以前出書的時候，不必提供書目資料。一本書進入圖書館，圖書館要做的第一件事就是要編目，編目後才能上架。編目就是整理書目資料。現在的圖書館員比較方便了，現在的出版公司，出書時大都提供一個電子檔的書目資料，入館時不用再編目。這是出版界和圖書館界推動資訊共享的成果。

第三，以前投稿一篇文章，就只是投稿一篇文章；現在投稿一篇文章需附檢摘要、索詞和作者的信息（如：作者的姓名、年齡、籍貫、地址、工作職位）等，這些都是背景資料，也就是後設資料。

以上的例子，都和電腦化、數位化有關，這可說明：在電腦中，只有文章本身是不夠的，必須和情境信息一起打包，文章才算完成。

### （四）情境（context）

許多人以為 context 只是「上下文」的意思；其實「上下文」是 context 在語言修辭「情境」下的意義。看一篇文章裡的一個詞、一句話，最接近的情境就是文章裡面該字句的上下文。所以，以「上下文」譯 context，就是在那個情境之下 context 的意思。

情境對文章而言，可泛指文章作成時所有相關的背景，包括：1. 與其他文章相關的背景，如：一篇學術文章後面一定要有參考資料、一定要有註；2. 作者相關的背景，如：作者生平、成書時間、著作時的身心狀態……，舉個比方，如果我們曉得當初曹雪芹寫《紅樓夢》時的心情、際遇是如何？那麼我們再來看《紅樓夢》，理解就會比較深刻一點；3. 時代相關的背景，如：政治背景、經濟背景、軍事背景、天災人禍、社會重大事件……；4. 文化相關的背景，如：三武之亂、滿清的辮子……；5. 社會情境的變遷，如：有電視、手機、網路之後；……。所以，情境這個詞，可泛指除了本體之外，所有外部和這個本體曾有的關聯。

這個情境有一個很重要的特徵，就是：一旦作品完成，情境信息即已固定，且恆久不變。正因如此，這些情境的信息，也就文章的這些背景信息，可以和文章永遠連在一起，不會改變；而這個合在一起的記錄，就是一個文化歷史的見證。

這是一個很重要的觀念，此所以文物之可以做文化記錄，這也是數位化的紮根理論。

情境會影響我們對作品的瞭解，也影響我們對作品的解釋。意義是依情境而定的，情境既已固定，則作者創作的原意亦隨之固定。如：佛陀所說的經，究竟其真實義是什麼，有時我們必須設法把自己的心意放在佛說法的那個情境之下去理解。

文章的意義可有兩層，一是作者的原意和讀者理解到的意思。作者的原意和讀者理解的意思，經常並不完全相同，而且有時可以差很遠。這兩者都屬文章本義的範疇。其次，還有文章的延伸義，也就是說對該文章所作的詮釋意義。例如，我們現在有時候故意把這些古詩詞拿來做另一種解釋，比方說，一個人學成或開悟的境界，像是「眾裡尋他千百度，驀然回首，那人正在燈火闌珊處」。辛棄疾這首詞原來並不是說學成或開悟的狀況，但是王國維把它拿來如此詮釋時，大家都覺得他說得真好。這是王國維對辛棄疾這首詞的詮釋義。

對文章意義的詮釋是對原有文字賦予新的意義，是閱聽者可以依閱聽的情境、生活周遭的情境而作的創新。【注：詮釋是有章法的，可參考釋義學或詮釋學的書籍】理想上，文章數位化後應設法表達文章的這兩層意義，而這兩者相關的情境卻南轅北轍，大不相同。

那麼現在我們可不可以允許在電腦裡的文章由我來詮釋？現在沒有一個電腦資料庫可以做到這樣的程度，因為目前電腦沒有描述情境的功能。情境的描述和語意是非常有關係的。我們了解作者產生作品時的情境，可以幫助我們了解作者表達的原意。如果電腦可以描繪情境，才可能去描述意義、處理意義；若無法描述情境，則無法真正處理語意，而目前的電腦就是笨電腦，根本不懂什麼叫意義。例如，電腦會做  $1+1=2$ ，它了解  $1+1$  的形式以後，它就說答案  $=2$ ，但是它不了解  $1+1$  的意思。所以，電腦能不能描繪情境，就是目前一個非常挑戰的研究工作。

情境並不是很陌生的信息，我剛剛講過：像後設資料、書目資料都是情境的一種。然而，如果有一天，我們電腦可以描述一般的情境，這些這些情境存在電腦裡一定要遵從一些標準或規範。為什麼？因為情境信息必須不分國家、種族，甚至於不分電腦機種，都要能夠處理。不能說英文的書目資料是這樣，中文的書目和英文的書目資料不能夠合併，那就很糟糕(早期確實是如此，中、英文沒辦法合併)。所以，當電腦裡要處理情境的時候，需要用一種電腦會處理的通用人工語言 (general artificial language)，也就是後設語言(meta-language)來描述，而不用自然語言，不用中文、英文、法文、德文...因為用那些語文之間，都有隔閡。

後設語言不僅僅可以描述情境信息，文章內容的注疏、註釋，以及文章之間彼此的參照 (hyperlink)，甚至於文章內容與實物之間的聯繫關係等，也都可以用後設語言描述。後設語言大家也都不陌生，像 HTML、XML 都是。

## (五) 數位化文章的表達

文章的結構在電腦中產生了根本的改變，變成以自然語言和後設語言相輔表達的雙重結構：以自然語言寫文章本身、以後設語言描述數位化的文章與外界各種關係。

一篇文章到了電腦裡去以後，就變成兩種語言的表達，文章本身是以自然語言寫，如：用中文寫、用英文寫，但是這篇文章寫好了以後，它和其他文章與外界種種關係，就必須要用後設語言來描述。(見表一)

表一、文章數位化後信息之表達

數化之文章		表現系統
文章本身		自然語言
文章與外界的關係	情境描述 (metadata)	後設語言
	參照聯繫 (hyperlinks)	
	內容詮注 (content markup)	

表一的向度有數位化之文章、文章本身、文章與外界的關係；文章與外界的關係有情境描述 (metadata)、參照聯繫 (hyperlinks)、內容詮注 (content markup)；使用的表現系統有文章本身的自然語言、文章與外界的關係是用後設語言。所以，文章數位化以後，就形成雙重語言的描述結構，一是自然語言，二是後設語言。像象大家用 TEI 標誌一些資料庫的內容或文章，事實上也是這樣雙重的語言結構。

有些學者認為，後設語言愈來愈重要，往後的年輕人除了母語外，其次最重要的不是外語，而是後設語言。年輕人如果有空多學一些後設語言，多學一些 XML、HTML、TEI，一輩子可以享用不盡，因為它是超越國界、不分種族、文化，能跨越時空、讓你充分表達思想、意念的人類共同工具。

## 二、後設資料

### (一) 後設資料的認知

目前一般人對後設資料的認知不是很正確的，所以特別在此和各位說明一下。有人引據國外的文章，說後設資料就是「資料的資料(data of data 或 data about data)」。有了這樣的說法，許多人便認定：「除了文物數位化的本身之外，所有其他的資料都屬後設資料」。又如，有些老師教學生時，他會把後設資料定義說成「後設資料就是資料的資料」。這些都錯了，都是對後設資料錯誤的認知，都犯了嚴重的錯誤。

說後設資料是「資料的資料」，沒有錯，可是要明白：只是為了闡明後設資料這個概念的性質，並不可將後設資料定義為「資料的資料」。因為，後設資料

固然是「資料的資料」，可是並不是所有的「資料的資料」都是後設資料。將後設資料界定為「資料的資料」這種認知，與「不吃豬肉的都是回教徒」犯了同樣的邏輯錯誤。

## （二）後設資料的範疇

現行的任何後設資料，有其固定表達的方式、訂定的規格，以及標籤（tag）或欄位（field）的選擇和數目等，都限制了後設資料的範疇。這很明顯表示：不是所有的「資料的資料」都是後設資料。要明白數位化的後設資料，不能把資料二分為資料和「資料的資料」這樣籠統的概念去理解。如果你把電腦裡的資料分成兩種，一個是資料，一個是資料的資料，那你在電腦裡所發展的系統、發展的程式，保證會出問題，因為在邏輯上這變成自我參照，自我參照的邏輯有時候就會出現矛盾。

## （三）時下後設資料的性質

目前的後設資料都是為了某類文物訂定的。比方說，書目資料是一般書籍的後設資料，新聞有新聞的後設資料，玉器、青銅器、畫作、雕刻……等都有各自的後設資料。後設資料既然是描述「某類」文物的資料，那麼就有它的特徵和它的侷限：它適合敘述某類文物的共同現象（共相），而無法顧及個別現象（別相）。

一般而言後設資料敘述的多屬事實、屬性這類較客觀可考的共相資料，也就是說後設資料所描述的都是些情境資料，是相關的事實、相關的屬性這類比較客觀可以考據的資料，不涉及文本內容的理解、感受、比較、批評，以及詮釋等（別相）。所以，後設資料是可以由具技術專業人士查訪、考證的；但是，它不可以作詮釋。比方說，我們可以考證《紅樓夢》的作者是誰，卻不能詮釋《紅樓夢》的作者是誰。所以，時下的後設資料都是一些屬於事實的陳述和屬性的陳述，是事實陳述和屬性的陳述，這些東西是可以查訪、考證的，但是這些東西是無法去理解、感受、批評、比較、詮釋。

後設資料的內容是依應用的目的而異，一件數位文物的後設資料可以有許多種。例如新聞稿，對記者而言，有一種後設資料；對報社來說，同一則新聞有編輯用的、管理用的，甚至於是與其他通訊社交流用的各種後設資料。這些後設資料之間，會有些重複，但也有獨特之處。所以，應用時會要求獨特者能彼此互通，重複者需彼此一致。

人世間的事情常有變化，所以後設資料不會是固定不變的，它是一個時間的函數，會與時遷移，需要花很多力氣更新、維護和保養。有人說在電腦裡建一個資料庫，或是在網路裡建一個資料庫，這個負擔比生一個小孩還沉重。為什麼？因為小孩二十多歲就能夠獨立了，但是做一個資料庫，就要照顧它一輩子，說不定你的兒子、兒子的兒子、孫子，還要去照顧它。

後設資料既然如此複雜，就不是電腦常用的欄位結構可以處理得了的。所以，描述後設資料現在都用後設語言。只有語言才有能力描述後設資料的種種規

格和後設資料之間的相容關係，以符合應用的需求。

### 三、內容標誌 (content markup)

了解了後設資料再來談內容標誌就方便了，因為內容標誌要照顧的，正是後設資料無法觸及，關於文物個別內容描述的這一部分。以文章而言，對文本內容的理解（解釋）、感受、比較、批評、詮釋等，正是內容標誌的主要工作。所以，內容標誌的重要不言可喻。內容標誌的工作觸及人文、歷史、社會、美學、哲學等學門的核心問題。這些工作需要真正了解內容的專業人士為之。如：故宮有一幅宋朝的畫，把它數位化放在電腦裡，關於這一幅宋朝的畫，它的內容怎麼去理解、去欣賞、去感受，這一幅畫和別的畫有什麼關係，再怎麼去批評這幅畫好在哪裡、不好在哪裡，怎麼去對畫裡的東西做詮釋，是需要教授級的人物去做。所以，內容標誌的工作，坦白來講，是需要該相關學門真正了解的專業人士來做。這倒不像後設資料只要專業人士做考證、考據就可以了。專業人士做考證的時候，可以去考據這一幅畫的作者是誰，但是他對於這一幅畫，對於美術、對於藝術、對於畫派的理解不見得很內行，他只要考據專業的工夫就勉強可以了。

內容標誌，無論作理解（解釋）、感受、比較、批評或詮釋，均觸及一個人文方面最根本的問題——意義（meaning）和了解（understanding）。談到意義和了解這兩個問題，就踩到了電腦的痛處。電腦碰到意義和了解，到目前為止是一籌莫展，這是認知科學、語言學、記號學等近幾年來致力研究的重點，也是電腦迄今未能處理的痛處。內容標誌正是為了解決這個困局而設。內容標誌事實上有個前提假設，認為電腦不可能直接去了解一篇文章的意義，也不可能直接去了解一篇文章。因此，電腦要能處理語義，這就必須和人充分合作：意義和了解的部分由人去做，後續的處理才由電腦去做。所以，發展電腦做內容標誌的前題是建議一個人機合作的構想，由人（專業人士）負責意義和了解的部分，再由機器來處理其餘的工作。

#### （一）內容標誌與語意

##### 1. 標點符號

電腦目前不會處理語意，然而我們生活上卻使用了很多的語意工具，只是我們習而不察。例如：標點符號就是處理語意的工具。各位有沒有看過沒有標點符號的文章？文言文很多沒有標點符號，文言文為什麼沒有標點符號，是不是我們的老祖宗比較笨，沒有辦法發明標點符號？其實不是，因為以前竹簡、木簡，甚至紙張都是很貴的，古人希望在有限的面積容納最大的訊息，所以有意省略了標點符號。試將古文做一個統計，用 25 史的標點版平均起來兩個標點符號中間字串的長度差不多是 4.5；也就是說，如果你加標點符號的話，就會把版面從 4.5 加到 5.5，幾乎加了 18% 的版面。這可能使「學富五車」要改成學「富六車了」。或者說，原來一本 5 斤的書，加了標點符號就要變成 6 斤。所以，文言文裡省略了標點符號。省略了標點符號，就要付出文章講究修辭的代價：文言文不用標點

符號寫，要寫得別人只能看出一種意思，不會解釋成另外一種意思。要學寫文言文最困難的就在這一點。

標點符號用的不同，同一字串的意思就可能不一樣。舉一個不太雅的例子，有一個人家的牆角常常有人去小便，主人很生氣，就在牆上貼了幾個字「閒雜人等不得在此小便」，意思是「閒雜人等，不得在此小便」。但是他沒有點標點符號。有個路人看了以後哈哈一笑就在牆角小便，剛好被主人看到。他很生氣的說：「你不識字嗎？」那個人回答：「我識字啊，你看：『閒雜人，等不得，在此小便』，是你叫我在這裡小便的呀！」所以說，標點符號能改變了文章內容的表現方式，是一種處理語意的工具。

標點符號最重要的作用是把一些內隱的、隱晦的語意，用標點符號把它標示清楚，變成外顯的語意。無標點符號的文章內容較為隱晦(implicit)，需經分析、理解的過程才能窺見原意，讀的人水準要比較高。所以，標點符號是一個典型的工具可使語意表面化，讓我們一眼就可以看得很清楚。換言之，標點符號使內容較外顯(explicit)，使隱晦的語意(implicit meaning)變成外顯的語意(explicit meaning)。諸如：私名號的使用，已明顯的標出姓名或機構名稱，減少了斷詞的工作，句點、逗點、分號等，則已將斷句標明，表明前後文的關係。所以，標點符號有將部分文章內容由隱晦轉為外顯的功用。由此看來，標點符號是內容標誌的典型例子。

## 2. 句讀

除了標點符號之外，句讀也是文言文常用的內容標誌。句讀主要用途是作文章內容的標誌：標明文中之美辭、佳句、警句，或文中之不佳之處等；對詩詞韻文，也有用於標示韻腳和朗誦時的間歇者。有些影印的古書中，有前人的句讀：在精采的句子旁加紅圈，在警句旁加點，這些都是做的內容標誌。換言之，句讀就是把前人對於文章內容的理解、感受、批評、比較等，以符號的形式點在文章裡面。

標點符號或句讀這類的標誌，都是設計來幫助讀者理解文章內容的；但是它還有另外一個功能，就是它也幫做標誌人，把他們對文章的理解、詮釋、批評、比較透過標誌記錄下來。如：我們現在可以買到以前蘇東坡先生做過句讀的一些古本書，甚至我們可以買到一些曾國藩先生做過句讀標點的書，這些對我們來講，我們所買的就不只是是一本書了，這還包括蘇東坡、曾國藩先生他們對這本書內容的理解、詮釋的資料。因此，我們所講的內容標誌和語意，與西方現在講的所謂標誌很不一樣。

電腦的文章標誌，是近年來西方資訊科技發展出來的，如：XML、TEI等。而漢語文獻的標誌，則是我們先人留下的智慧。目前的電腦標誌，很多是對文章的外形作標誌，如：通用結構(DTD)，版面的、結構的、語文辭彙的……，標籤集(tag set)；傳統漢語文獻的標誌，則側重於文章內容的標誌。



## (二) 語意處理的問題

談到文章內容的標誌，我們免不了要談語意處理的問題：也就是，希望電腦有一天能幫我們處理「意義」，幫我們做一些「了解」方面的例行公事。近年來，計算語言學和人工智能均致力於處理意義的研究，也取得一些成果。例如，詞網（word net）、主題圖（topic map）、知識本體結構（ontology）等。然而這些東西在西方所有研究中，還是只做文章的外觀形式方面，如：把一些詞與詞之間的關係標清楚。詞和詞之間的關係當然和語意有關，但是真正這些標誌、這些工作，還只是做形式上而沒有做內容上的標誌。這些研究現在都號稱為語意處理研究，如：word net、主題圖是知識結構，他們都號稱：「我們現在電腦裡已經可以處理一部分語意問題。」是不是呢？坦白講，答案：「是，也不是。」這就看我們對語意處理的界定在哪裡了。

它們將詞彙間的關係在電腦中作了適當的表達（representation），並構成資料庫和研發為數位工具。詞彙間的關係是語意中的一種，將它數位化，對意義的處理是有助益。可是助益有限，並沒有突破性的進展，原因是囿於形式和內容（意義）是一對一的前提，因此，並無能力處理意義的癥結——多義問題（ambiguity）。

如果詞和詞之間的一些關係，這個詞是那個詞的廣義詞、狹義詞、反義詞，這些都算是語意關係的話，當然他們做的算是語意處理，但是真正的語意處理，不是指做形式方面的東西，是要處理多義的語意問題。ambiguity 很多工程人員把它翻成歧異的，就是不同、有衝突的意思，事實上翻譯成多義反而更恰當一點。

多義問題，是指一個詞依情境變化時有好多不同的意思。例如，作數目字時，「十、拾」通用，如：十元，也可寫成拾元；可是情境變為「路不拾遺」時，就不可以作「路不十遺」。為什麼「路不拾遺」的「拾」只能用「拾」，不能用「十」，因為「拾」這個字是多義詞，它在「路不拾遺」的情境裡面，只能用「撿起來」的意思，所以只能用「拾」；在數目字的情境下，十元、拾元都可以。所以，真正處理多義問題，關鍵就在一個情境表達的問題。在電腦裡，若有辦法區別不同的情境，就無法真正處理語意問題。所以，多義問題，簡單說，就是當一種形式可能對應到好幾種意義時，如何作正確選擇的問題。因此，電腦裡要做這些處理，便必須要能夠描述這個意義的情境。這種語意隨情境而轉移的現象，在語言學稱為「義隨境轉」。

人面對多義或義隨境轉問題並無太大難色，所有的自然語言都有濃厚的義隨境轉色彩，因為人很聰明，人可以在溝通的過程當中，或者在閱讀的過程當中，了解相關的背景、相關的情境，對「意義」會作適當的「了解」，可以去區別不同的環境作正確的解釋。所以，人才可以作適當的選擇，作適當的了解。但電腦顯然是沒有這方面的能力。如果電腦無法描述情境資料的話，它就無法作理解的事情，因為語意和情境是絕對非常密切的連在一起。所以，電腦處理意義問題的先決條件，是要會表達情境，可是目前學界在這方面的努力，還沒有顯著的成績。

#### 四、內容標誌之例：《心經》 黃色部份下次刊登

以下要做一個示範，這個示範就是要做一個內容標誌的實例。這個內容標誌是把《心經》各版本與其科文間內容的對應。科文就是大綱，大家如果看過中小學的參考書，如：選了一篇文章叫「桃花源記」，參考書把「桃花源記」這篇文章的內容大要做一個？(請補英文)，樹狀的表達，讓學生能好好去了解。這個在佛經裡就叫做佛經的科文。佛經的科判、科文，事實上就是一個經文的結構與大綱。給大家看這個資料庫，包括《心經》各版本與科文中間內容的對應；也就是說，這些科文如果用我們剛剛看過的名詞來講，這就是一個經典所謂的知識結構，ontology，就是從語言上去解釋經典的知識結構，現在一般叫做 linguistic ontology，簡稱 ontology。ontology 和哲學裡講存在理論的 ontology 是不一樣的。

這資料庫裡面有不同的科文，科文和《心經》各版本之間產生了一個 N 對 N 的？(請補英文)，也就是多對多的對應關係。一個科文可以對應到不同版本的《心經》，一個《心經》可以對應到不同不同本的科文，有這樣子內容對應的關係。這是一種給人用的標誌介面，是要做內容標誌。內容標誌很彈性，沒有固定的標籤集，標籤集是可以由使用者自己隨意去界定的。因為內容標誌，是一些別相，而非共相，只有共相才有共用的標籤集，如果是別相，就是個別標籤集。可以有內容與結構 (ontology) 間的對應：對本文的詮釋、版本間內容的對應：對本文呈現的不同形式、結構間的對應：對本文不同的詮釋、……。這些內容的對應，在這些示範中都有。

以上展現的內容處理，都沒有用到檢索常用的詞語聯繫 (morphological linking) 結構。我們通常用主體詞、檢索詞做的索引 (index)，都是屬於語言學上叫做 morphological link，就是詞彙聯繫的關係。這些詞彙聯繫的關係，和內容標誌的關係又不一樣，因為詞彙聯繫的關係，多半是根據辭典上的意思，辭典上的意思是大家公認的意思，不包括用在特殊況之下那個詞的語意，例如：春風又綠江南岸，這個詞是大家都熟讀的，綠的意思是個動詞，你查字典查不到綠是動詞，因為春風又綠江南岸，只有在這個句子裡做這樣的解釋，這就是個別的意思。所以，語意的表現，內容的標誌，通常我們除了可以運用字典裡所謂語言學的意思以外，言語的意思也要包含進去。言語的意思就像我們講話、書寫的前後文有關係，它有它特殊的涵意。這樣的聯繫就不叫做 morphological link，因為 morphological link 都是語言的關係，而不是言語的關係。所以，大家看展示的時候，希望大家重視一點，就是看看何謂「別相」？這些內容標誌，什麼地方是「別相」、什麼地方不是「別相」，也請注意到內容聯繫間的彈性，可以做跨語文、跨作者、跨版本、知識結構的延伸。這些就像前面所講的，你真正做到一個內容標誌，應該是跨國家、跨語文、跨文化，是一個大家可以理解的內容關係。

#### 五、結語

(一) 後設資料和內容標誌相輔相成、相得益彰

後設資料和內容標誌並不相互排擠，它們是兩種類型完全不一樣的工作。若認為除了文物數位化的本身之外，所有其他的資料都屬後設資料，那麼就犯了不可原諒的大錯——它扼殺了內容標誌生存的空間；換言之，後設資料和內容標誌兩者都是不可缺的，且彼此相輔相成、相得益彰。

## **(二) 語義處理的問題**

未來，電腦可能以兩種方式來處理意義問題：其一是逐漸將所有的多義關係轉化為單義的語法關係。例如，建立「常識庫」讓電腦能辨識「情境」。其次是與人合作，以人機共建的系統來做「了解」和處理「意義」問題。這就是內容標誌想做的事。

【編者按】本文為錄音謄稿，經講者撥冗審閱刊載。