

書誌レコードの遡及入力についての報告

別府大学附属図書館

財前聡担

<遡及入力について>

図書館では、今年度後半から遡及入力を開始した。作業内容は、本学図書館が現在所蔵している蔵書の目録データを国立情報学研究所（以下、N I I）が所蔵する全国標準の高品位なデータに更新し、同時に本学の蔵書でN I Iに所蔵登録されていないデータを登録するというものである。

現在本学のデータベースには約27万件の目録データが入力されているが、そのうち20万件は良質とは言えないデータである。例えば、著者名のヨミで「大宅（オオヤ）」が「ダイタク」になっていたり「土方（ヒジカタ）」が「ドカタ」になっていたり、蔵書検索の際に何かと支障をきたす状況である。また、古いデータについては書名や刊行年等がN I Iのデータと異なっている場合が多い。これらは当時の基準で作成されており、致し方ない面もあるが、現在のようにコンピューターが普及しO P A CやI L L等全国規模のネットワーク環境が整備され、本学もそれらに参加しているという状況を考えれば、標準化を進めていかないと相互協力において支障が生じてくる。

本学に限らず、現在多くの大学や研究機関でこの作業が進められている。N I Iも平成16年度よりこの遡及入力に対する支援事業を行っている。これは事業計画書による公募方式で、平成18年度は108件の応募があり、37機関57件が採択された。対象となる事業は、多言語資料の遡及入力、人文社会科学関係資料の遡及入力、自動登録支援である。本学が応募したのは自動登録支援で、これに採択されたのは上記の57件のうち、本学を含めて7件であった。

今回の遡及入力は、このN I Iの支援とN C - A u t oという遡及入力専用ソフトによる全自動、半自動入力の二本立てで並行的に実施した。N I Iの具体的な支援内容は以下のとおりである。

まずN I IよりN C - A u t oの提供を受け、それを使って本学のデータをN I Iのサーバーにアップロードする。検索キーが一致しヒットしたデータは自動的にN I Iへ所蔵登録がなされ、N I I所蔵の良質なデータが本学のコンピューターにダウンロードされるが、ヒットしなかったデータについての入力作業（半自動入力と新規入力）をT R C（株式会社図書館流通センター）が請負い、その費用をN I Iが補助するというものである。

以下、作業手順や結果等について述べるが、初めての試みであり、またN C - A u t oについての簡単な操作マニュアルしかなかったため、ほとんど手探りといってよい状況であった。途中何度か方針を変更したりしているため、データが統一していない部分もあり、そのために記述が煩雑になっている部分もあるかと思うが、ご容赦願いたい。

<NC-Autoについて>

NC-AutoとはNECが作成した書誌レコード遡及入力専用ソフトの名称である。これはISBN、タイトル、著者名等を検索キーとしてN I Iのデータと照合し、前述のとおり所蔵登録やダウンロードを自動的に行う機能を有するものである。

ダウンロードされたデータは、ローカルシステムへのアップロード用のファイルとプルーフファイル、エラーファイルの3つに分かれて保存される。

下にプルーフファイルにダウンロードされたN I I書誌レコードの1つを例として掲げる。

〈N I I 書誌レコードの例〉

FTITLEKEY: 近代日本の児童文化 AUTH: 滑川道夫 YEAR:1972

LOC=2F 閲覧室 CLN=909:N2 RGTN=0235861

DBNAME:BOOK

ID:BN01848740

TRD: 近代日本の児童文化 / 滑川道夫, 菅忠道編著

PUBL: 新評論 PUBDT:1972.4

DBNAME:BHOLD

ID:CC0950524301

FANO:FA009097

LIBABL: 別府大

LOC:2F 閲覧室

<対象とするデータの選択>

支援事業の対象となるデータは1万件程度である。本学システム所蔵のデータをEXCELにダウンロードして詳しく見てみると、現在のシステムが導入された2000年以降は比較的良質なデータが入っているようである。また検索キーとして最も有効と思われるISBNが入力されているデータが全体で10万件程あった。(表1参照)

そこで、今回はISBNの無いデータのうち2000年以前の古いデータの中から1万件を選ぶことにした。ちょうど昨年2F閲覧室の蔵書点検を行っていたので、所在が2F閲覧室になっているデータを抽出してみたところ13,424件だった。ちょうど良い数字だが、アップロードファイル作成作業と通常業務との兼合い等の事情で、結果的にはこの中から12,000件を対象とした。

【表1】

データの種類	件数	左の件数のうち	
		1999/12/11以前の データ件数 (日付なしを含む)	2000/01/01 以降のデータ件数
ISBN 有	102,776	64,895	37,881
ISBN 無 2F 閲覧室 (内数)	164,466	131,175	33,291
	14575	13424	1151
合 計	267,242	196,070	71,172

<アップロードファイルの作成>

データをアップロードするには、まずアップロードファイルを作成しなければならない。

本学システムからダウンロードした目録データはタイトルや著者名、出版社等々全ての書誌情報が区切りもなく連なって入っているので、その中から検索キーとなるタイトルや著者名等を抽出しなければならないのである。

この作業を EXCEL で行うことにしたが、12,000件の書誌情報は膨大なので、これを資料番号順に2,000件ずつに分け、それぞれを職員に1人ずつ割り当て計6人で作業を行うことにした。

各々通常業務もあるのでこの作業に専念できない状況だったが、所要時間は3日～5日といったところであろう。

<アップロード>

上記の作業が終わったものから順にN I I へのアップロードを行った。EXCEL のファイルではアップロードできないのでテキストファイルに変換して行う。検索キーとして選んだのはFTITLE(フルタイトル) + AUTH (編著者名) + YEAR (刊行年) である。

アップロードには下記のとおり時間が決められている。

月、火、水、金 12:00～13:00、17:00～20:00、22:00～翌朝8:00

木、土 12:00～13:00、17:00～18:00

2,000件のデータのアップロードはかなり時間がかかることが予想されたので、主に22:00以降の時間に行った。

<結果>

まず最初の2,000件をアップロードしたところヒット件数は50件と予想外に低い数字であった。アップロードファイル作成時から AUTH キーをどういう形で入力するか職員のあいだで問題になっていたのが原因はそこにあるだろうと考え、同じファイルからヒットしたデータを除いた1,950件のデータから AUTH キーのデータを消去して、FTITLE+YEAR で再度アップロードを実行したところ299件ヒットした。これ以上検索キーを減らすことはできないので結局最初の2,000件のヒット件数は349件であった。

次に同じく FTITLE+AUTH+YEAR の検索キーで4,000件を実行したところヒット件数は110件。ノーヒットデータから AUTH キーを削除して再度実行したところ473件で計583件であった。ヒット率は検索キーが FTITLE+AUTH+YEAR では最初の2,000件が 2.5%、次の4,000件が 2.75%。AUTH キーを削除して FTITLE+YEAR でヒットしたものを加えれば、最初が17.1%、次が14.6%でほぼ同じような割合である。

AUTH キーをどういう形で入力するかが問題になったというのは、編著者が複数の場合最初に記述された1名でよいのか、姓と名の間を1文字分空ける必要があるのか、また原著者が西洋人の場合カタカナ表記でよいのか等々である。重要な点であるが、NC-Autoの操作マニュアルやインターネットなどで調べてみても必要な情報はどこにもない。そこで姓のみの前方検索でやってみたり、「編」や「著」などの役割表示を入れてやってみたりしたが、大した効果はなかった。結局 FTITLE+AUTH+YEAR と FTITLE+YEAR の検索キーで10,000件のデータをアップロードしたが、【表2】の通り惨憺たる結果であった。

残りの2,000件については、AUTH キーの代わりに PUB（出版社名）を検索キーとして採用した。それは、NIIのホームページに筑波大学附属図書館外3機関が実施した自動登録の実証実験報告が掲載されているのを見つけ、それによるとどの機関も AUTH を検索キーとして採用しているところはなく、むしろ PUB を採用していたからである。

結果は格段に違った。【表2】を見ればわかるように、ヒット率は全体で30%近くもアップしている。全体で、というのは、最初に FTITLE+PUB+YEAR の検索キーでアップロードを行い、次にノーヒットのデータから YEAR を削除して FTITLE+PUB の検索キーで行ったからである。YEAR を削除したのは、古いデータの中には当時の目録規則に則って出版年を刷年で記述しているものがあるが、現行の目録規則では初版の出版年を記述することになっておりNIIのデータもこれに則っているからである。内訳は最初がヒット件数2,000件中609件で30.5%、次が残りの1,391件中322件で23.1%、計931件、46.6%である。上記の自動登録実証実験報告によると、ISBNの無いデータで全自動入力の場合多い所でせいぜい5割程度のヒット率で、46.6%はほぼそれに近い数字である。おそらく現状では ISBN の無いデータで全自動入力をした場合、これ以上の数字は見込めないのかもしれない。

【表 2】

検索キー	ヒット件数	ノーヒット件数	計	ヒット率
FTITLE + (AUTH) + YEAR	1,779	8,221	10,000	17.8%
FTITLE + PUB + (YEAR)	931	1,069	2,000	46.6%
計	2,710	9,290	12,000	22.6%

< ISBN が入力されているデータのアップロード >

試行錯誤の結果、多くのことを学んだが、12,000件中2,710件のヒット件数はあまりにも少ない。そこで ISBN のあるデータもアップロードしてみることにした。この場合検索キーは ISBN のみなのでアップロードファイルの作成は容易である。所在が 2 F 閲覧室になっているデータのうち ISBN が入力されているものは23,233件、その中から 1 回目は6,000件、2 回目は3,000件、計9,000件をアップロードした。結果は【表 3】を参照。

1 回目のヒット率が55.3%と低いので、新たに3,000件をアップロードしてみたのだが、これも最初は1,882件のヒットで、ヒット率62.7%だった。検索キーが ISBN ならばヒット率9割は堅いと思っていたのでショックであった。結局原因は検索キーではなく登録キーの CLN (請求記号) にあった。アップロードファイルを EXCEL からテキストファイルに変換した際、文字列を含むデータの中で、‘CLN=913.6:IKE’ のようにシングルクォーテーションで囲われた形で変換されているものがある。どうしてそうなるのか原因は不明だが、こういうデータが N I I のサーバーから無効なデータとしてはじかれていたようである。N I I へ登録するデータとしては、最低限 RGTN (資料番号) さえあれば十分なので、CLN を削除して残りの1,118件を再度アップロードしてみたところ新たに826件ヒットした。これで3,000件中計2,708件のヒット、ヒット率90.3%と見込み通りの9割を達成した。

これで一応ヒット件数の総数は8,736件となり、現在 TRC に半自動入力及び新規入力を委託している1,400件余のデータと合わせて10,000件を超えることができた。

【表 3】

	ヒット件数	ノーヒット件数	計	ヒット率
ISBN 有 1 回目	3,318	2,682	6,000	55.3%
ISBN 有 2 回目	2,708	292	3,000	90.3%
計	6,026	2,974	9,000	67.0%

(ざいぜん としひろ)