

第 11 回：Excel を用いた多言語データの作成・編集

本日のポイント：

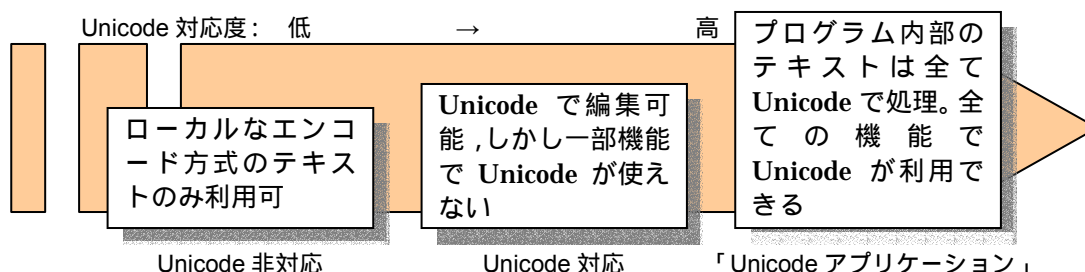
- 「Unicode アプリケーション」としての Excel
- Excel の復習
 - データの入力
 - データの並べ替え (ソート)
 - データの絞り込み (オートフィルタ)
- 多言語データの加工例：Excel と Word のソート機能

0. 「Unicode アプリケーション」としての Excel

第 5 回，第 10 回で学んだように，Unicode は近年急速に普及している新しい文字集合であるが常に利用できるとは限らない。Unicode 文字を入力・表示するためには，OS のほか，「フォント」「入力システム」「アプリケーションソフトウェア」の全てが Unicode に対応している必要がある。Windows XP は Unicode に対応しており，多くの国・地域の言語に対応した入力システムと Unicode フォントが標準で備わっているが，アプリケーションソフトウェアの Unicode 対応状況はさまざまである。

これまで授業で利用した Word 2002, Emeditor, Windows XP に付属する「メモ帳」，「ペイント」(!)¹，Internet Explorer などは，Unicode テキストを処理できるばかりでなく，プログラム自体が Unicode で書かれており，Unicode にほぼ完全に対応した「Unicode アプリケーション」といえる。

今回扱う Excel 2002 も「Unicode アプリケーション」であり，日本語はもちろん，さまざまな言語のテキストを Unicode で扱うことができる。



「Unicode アプリケーション」である，ということは，Unicode のいろいろな文字をそのソフトの中で使うことが可能である，ということであって，どんな言語のデータでも思い通りに処理してくれる魔法のツールである，ということではない。

今回は，文字の並べ替え(ソート)機能の利用を通じ，各ソフトの機能を自分のおこないたい作業に応じて使い分ける方法を学ぶ。

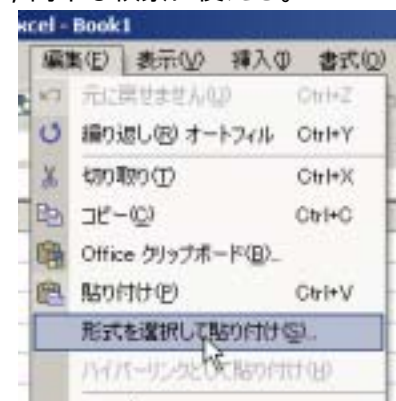

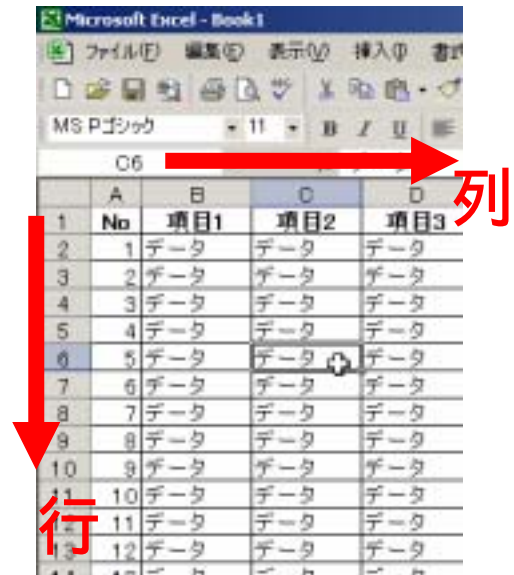
¹ 「ペイント」の文字入力機能で多言語テキストを利用することができる。描画ソフトは Unicode 対応が遅れており，例えば専門家むけドロー系描画ソフト PhotoShop は最新バージョン(CS)でやっと Unicode に対応した。

1. Excel の復習

一定の規則でデータをたくさん集めたものを**データベース**という。データベースの規模はデータの件数やデータの内容、構造により大きく異なる。数10~数千件のデータ程度で構造が比較的シンプルな小規模のデータベースは、表計算ソフト Excel を用いて簡単に作成することができる。


1.1. データの入力



- Excel のワークシートを使ってデータベースを作成する場合、縦方向(「**行**」)をデータの単位とし、項目を横方向(「**列**」)に入力するのが普通である。
- データベースにはタイトル行を作成するよう習慣づける。後で何のデータか分からなくなってしまうことがある。
- リストの入力のヒント
 - 列方向にセルを移動: **Tab** キー
 - 行方向にセルを移動: **Enter** キー
 - 再編集: セルをダブルクリックするか、**F2** キーを押す。
- いくつかの便利な機能
 - **オートコンプリート**: すでに入力されているデータを候補として提示し、入力の手間を省く (**Enter** を押して自動入力, **BackSpace** で候補をキャンセルし, 通常入力を続行)。また **Alt** + **[]** キーで候補の一覧を表示できる。
解除は [ツール] [オプション] の「編集」タブからおこなう。
 - **オートフィル**: 各フィールドに設定された書式や計算式は、データを追加した際に隣接したセルに自動的にコピーされる。連番 (1, 2, 3...) のような特定のパターンで数字を入力する場合には、複数のセルにパターンを入力し、それらのセルをマウスで選択しておいてオートフィルをおこなう(右図)。
 - **フォーム**: [データ] [フォーム] ... 入力のほか、簡単な検索に使える。
 - **高度なコピー「形式を選択して貼り付け」**: テキストだけ、データの書式だけ、計算式ではなく計算した結果だけ、など、コピーしたい内容はさまざま。[編集] [形式を選択して貼り付け] で詳細に貼り付ける内容を選べる (右図)。



1.2. データの並べ替え (ソート sort)

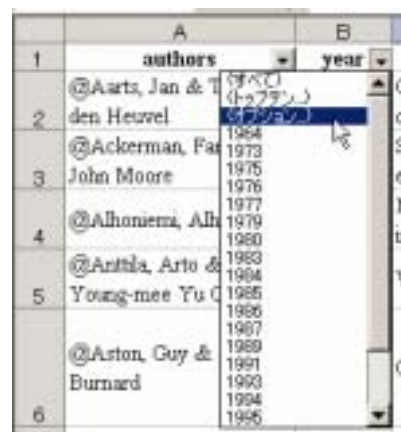
Excel は数値の大小や日付, アルファベット順などでデータを並べ替える(ソートする)機能をもつ。



- Excel は「昇順 ascending」「降順 descending」というふたつの方法でソートできる。
 - ⇒ 昇順・・・数字の小さい順, 文字ならば abc 順・50 音順にデータを並べ替える。
 - ⇒ 降順・・・数字の大きい順, 文字ならば abc 順・50 音順の逆順 (c, b, a, お, え, う, い, あ) にデータを並べ替える (文字の降順はあまり使わない)。
- ソートの方法
 - 並べ替えの基準となる列 (基準列) を決める。
 - ソートする基準列 (列のどの部分でもよい) をクリックする。(特定の列だけを選択しないこと! その列の中だけでソートがおこなわれてしまう!)
 - 以下のボタンをクリックする。 昇順:  降順: 
 - データが並べ替えられる。
- 複数の列で並べ替えるなど, より細かい指示を行いたい場合には [データ] [並べ替え] を選択し, ソートのダイアログボックスを表示する。
- 【注意】ソートを一旦おこなうと, 元の順番を復元できなくなる恐れがある。入力した順番に戻す必要がある場合を考え, 通し番号や入力日時など, 一貫した情報をつける列を用意しておくことよい。

1.3. 絞り込み検索 (オートフィルタ) 今回の授業では扱わないので, 各自練習しておくことよい。

Excel の一覧表にあるデータのなかから, 特定の条件を満たすものだけを取り出して表にするには, Excel の「オートフィルタ」という機能を使用する。



	A	B
1	authors	year
2	@Aarts, Jan & den Heuvel	1964
3	@Ackerman, Fa	1973
4	John Moore	1975
5	@Alhoniemi, Alh	1976
6	@Anttila, Arto &	1977
7	Young-mee Yu C	1979
8	@Aston, Guy & Burnard	1980
9		1983
10		1984
11		1985
12		1986
13		1987
14		1989
15		1991
16		1993
17		1994
18		1995

- [データ] [フィルタ] [オートフィルタ]と選択してオートフィルタを起動する。
 - 【注意】オートフィルタを利用する場合には, タイトル行の各列に必ず見出しをつけておくこと。
- 各見出しに絞り込み用のプルダウンメニューがつく。
- 細かい条件を設定する場合には, プルダウンメニューから「オプション」を選択する。「オプション」では 2 つまでの条件を AND, OR 検索できる。



「抽出条件」には Unicode の多言語テキストを利用することができる。

- 複数のフィールドに抽出条件を指定して複雑な絞り込み検索をおこなうことができる。不要な条件を解除する場合には, プルダウンメニューから「すべて」を選択する。
- オートフィルタの解除: オートフィルタの機能を使い終わったときは, メニューから再度, [データ] [フィルタ] [オートフィルタ] と選択する。

2. 多言語データの加工例：Excel と Word のソート機能

Excel は表計算ソフトであるので、数値の大小や日付、アルファベット順など、基本的なソートの機能も持っている。さらに、Excel はデータベースの検索機能 (§ 1.3.) をもち、規則的なデータの入力を効率よくおこなうことができる (§ 1.2.)。

Excel2002 は Unicode 対応アプリケーションであり、日本語はもちろん、さまざまな言語のテキストを Unicode で扱うことができる。しかし、Excel が持っているソート機能は、基本的に文字のコード値の大小を利用するものなので、各言語固有の文字の順番に対応したきめ細かなソートはできない。

- アルファベット言語のテキスト：辞書の見出し語の順番は、言語によって大きく異なる。以下のヨーロッパ各言語のアルファベット順を比べてみよう。

スペイン語	A, B, C, Ch, D, E, F, G, H, I, J, K, L, Ll, M, N, Ñ, O, P, Q, R, S, T, U, V, W, X, Y, Z
ドイツ語	A (a, ä), B, C, D, E, F, G, H, I, J, K, L, M, N, O (o, ö), P, Q, R, S (ss, ß), T, U (u, ü), V, W, X, Y, Z
フィンランド語	A, B, C, D, E, F, G, H, I, J, K, L, M, N, O, P, Q, R, S, T, U, V (v, w), X, Y, Z, Ä, Ö, Å
フランス語	A (a, à, â), B, C (c, ç), D, E (e, é, è, ê), F, G, H, I (i, î), J, K, L, M, N, O (o, ô), P, Q, R, S, T, U (u, û), V, W, X, Y, Z

Excel はこのような言語ごとのアルファベット順でのソートには対応していない。

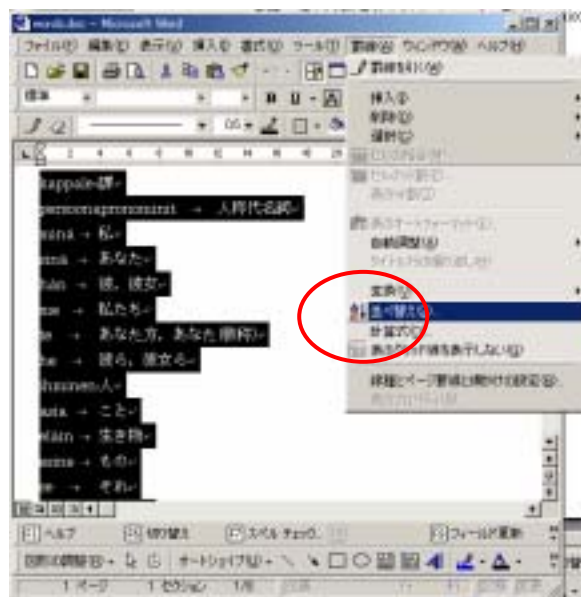
- 漢字圏の言語のテキストのソート：漢字圏の言語の場合、「ふりがな」や中国語のピンインなど、一貫した並べ替えをおこなうための項目をあらかじめ用意しておくことで、Excel でも並べ替えができる。

そこで、アルファベット言語のテキストについて、Excel で作成したデータを Word2002 を使いソートしてみることにする。Word2002 (および 2000, 2003) には、単純な文字コード順ではなく、ソートに使用する言語を指定できるより高度な機能が搭載されている。

1. Excel のワークシートを「Unicode テキスト」として保存する。データは Unicode (UTF-16LE) のテキストファイルとして保存され、各セルはタブ(Tab)によって区切られる。EmEditor で開いて確認しよう²。
Excel のデータ全体をマウスで選択後、コピーをおこない、Word 上に「Unicode テキスト」として貼り付けても OK ([編集] [形式を選択して貼り付け]。単なる「テキスト」では多言語テキストは正しく貼り付けられないので注意。また、単純に「貼り付け」をおこなった場合には、フォントなど Excel の書式情報がそのまま Word でも使われる)。
2. Word に「エンコードされたテキスト」として読み込む。(Word のオプション設定をあらかじめ変更しておくこと。)
3. ソートする範囲を指定する (文書全体をソートする場合に指定はしなくても OK。一緒にソートされないよう、見出しの行は除外する)。

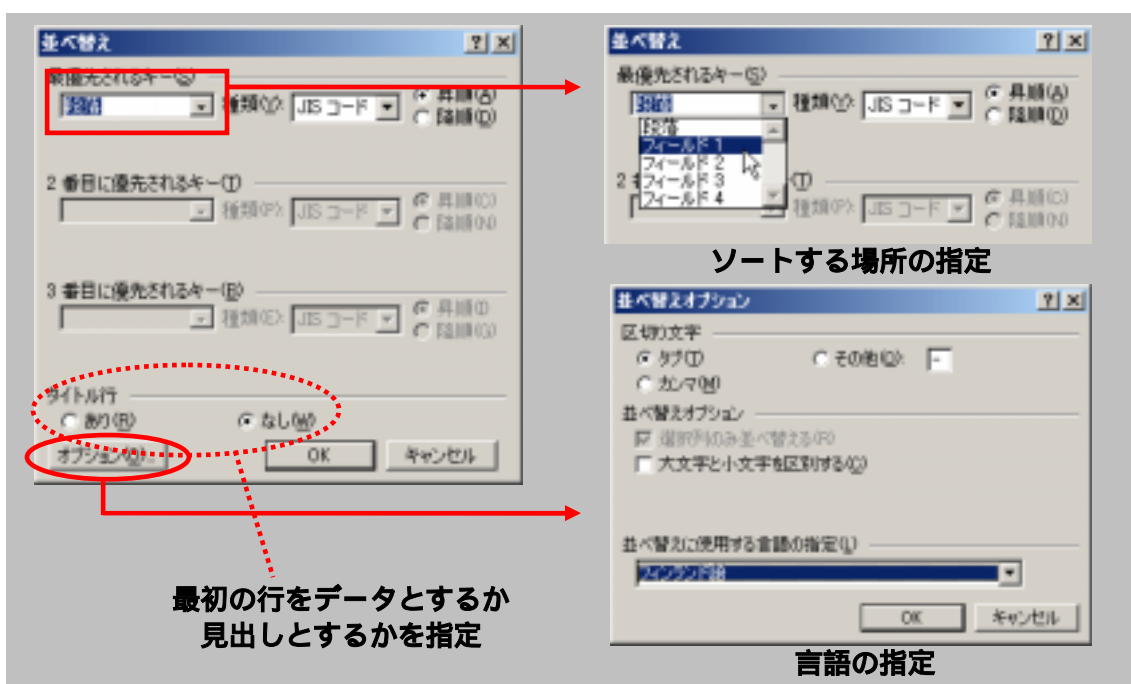
² EmEditor の [ツール] [現在の設定のプロパティ] で画面表示の詳細を設定できる。「記号」タブで「タブ表示」をチェックすると Tab が入っている箇所が青い矢印で表示され、見やすくなる。

- Word メニューバーから[罫線] [並べ替え]を選ぶ (右図)。
- 「並べ替え」ウィンドウの「オプション」ボタンを押し、並べ換えに使用する言語を指定する (下図)。




並べ替えの対象となる単語のある場所が行の先頭ではない場合、「最優先されるキー」のある列(「フィールド」)を指定する必要がある。

「オプション」では、区切り文字 (Excel の「Unicode テキスト」の場合はタブ) の種類、大文字と小文字の区別など、その他の設定も指定できる。



- ソートが終わったら、結果を確認する。
日本語や中国語のように、読み方が文字と対応していない言語は、文字によるソート自体が難しくなる。そこで、50音やピンインなどでソートする場合には、読みを別に入力しておき、その読みがなによってソートをおこなうのが確実である(日本語版 Excel の場合、「ふりがな機能」を使った並べ替えもできるが、この場合ふりがなデータは Excel ブック形式のデータにしか保存されない)。
- 必要に応じ、ソート結果を保存し、さらに編集する(例えば再度 Excel に読み込んで加工したり、Word 文書として保存しデータのレイアウトやフォントを調整することができる)。

Word 文書の中でデータを表として整形する場合には、例えば、単語データ全体(見出しを含む)を選択し、「表の挿入」ボタン  を押すと、Tab の区切りを自動的に判別して表を作成することができる。

Word でソートしたデータを再び Excel に読み込み、データを Excel で保存することもできる。Word でソート後、データ部分をマウスで選択しコピーをおこない、Excel のワークシート上に「Unicode テキスト」として貼り付ける ([編集] [形式を選択して貼り付け])。単なる「テキスト」では多言語テキストは正しく貼り付けられないので注意)。Word のタブ (Tab) ないし表の区切りに従って Excel 上にデータが貼り付けられる。

実習： Kadai サーバの [schiba]→[2004fl]→[No11]フォルダに、フィンランド語、簡体字中国語、繁体字中国語の単語集のサンプルがそれぞれ words_finnish.xls, words_simplifiedchinese.xls, words_traditionalchinese.xls という名前が入っている。これらを使ってソートの練習をしてみよう。

- フィンランド語のデータを Excel のソート機能でソートし、結果をこの資料の2ページにあるフィンランド語の正しいアルファベット順と比べてみよう。
- フィンランド語のデータを Unicode テキストとして words_finnish.txt というファイル名で保存し、Word に読み込んで並べ替えてみよう。(Excel の機能を使ってソートした結果を2枚目のワークシートに入れておくので、比較してみよう。)
- 簡体字中国語、繁体字中国語のファイルには、2枚のワークシートにそれぞれピンインありとなしのデータが入っている。Excel のソート機能でソートし、結果を比べてみよう。

課題：外国語を1つ選択し、Unicode アプリケーションである Excel および Word を使い、その言語の単語集を作りなさい。とりあげる単語は50単語以上100単語程度とする(自分の第1外国語を取り上げる場合は原則として100単語とする。また英語以外の言語を積極的に選択することを期待する)。「フランス語の感情と身体動作を表す動詞100」「ドイツ語インターネット必須用語100」「中国語による世界の有名人100人の表しかた」「Yahoo! China に出てくる電腦語彙100」「台湾と大陸で異なる表現100」「『冬ソナ』のキメ台詞(せりふ)で覚える韓国語単語勝手にベスト100」「ドイツで体を壊したときの必須単語100」「英語で学ぶ大相撲用語」など、各自内容を工夫しなさい。

以下の手順にしたがい、まず Excel を使ってデータを入力する。

- データの構成は以下の条件に従うこと。
 - 単語データは「単語(語形変化のある言語の場合は辞書形)」、「単語訳」、「例文」、「例文訳」を含むようにすること。項目は自由に増やして構わないので、各自単語集の内容にあわせて工夫するとよい。
 - 冒頭に必ず見出し(タイトル行)を入れること。
 - 中国語を選んだ場合には、単語とその訳の間に必ず「ピンイン」を加え、第1声～第4声、軽声をそれぞれ1-5の数字で表すこと。
例：大学 da4xue2
- 列ごとに適切なフォントを設定すること(標準ではフォントは「MS Pゴシック」という日本語フォントが使われている)。変更したい列のラベルをクリックして列全体を選択し(右図)、フォントを変更する。
- Excel でデータを入力している段階では、フォントの指定以外のレイアウトや文字飾り、罫線などの処理は特におこなう必要はない(Word 上でおこなう)。
- データの入力の際は単語の順番は気にせず、どんどん入力をしていってかまわない。(ソートはデータの入力が終了してから Word などを使って実行できる。)
- 作成したデータは words.xls というファイル名をつけて「Microsoft Excel ブック」形式で保存しなさい。



Excel で作成した単語データの入力が終わったら，そのファイルを用いてさらに以下の作業をおこない，Word で単語集を完成させなさい。

- Excel を使って作成した単語集データ (words.xls) が完成したら，以下のを，「Unicode テキスト」(タブ区切りの UTF-16LE テキスト)として保存しなさい。ファイル名は words.txt にしなさい。
- words.txt を Word2002 に読み込み，単語集を各言語の辞書の見出し語順にソートし(中国語の場合にはピンインを利用してソート)，データのレイアウトを整えて単語集として完成させ，words.doc として保存しなさい。
 - Word での Unicode テキストの開き方については第 5 回資料を参照すること。
 - ページ設定は縦でも横でもよい。その他のページ設定は任意。また，フォントや段落の書式設定等を調整し，ページ数を抑えられるよう，レイアウトを調整するとよい。
 - 日本語でソートしたバージョンも作成し，外国語 日本語の 2 つの言語で閲覧できる単語集を作成してもよい。(日本語でソートする場合には，「単語の訳」以外に「ふりがな」を入れた列を作成しておく必要がある。また項目の順番などを工夫するとよい。) 日本語でソートしたファイルのファイル名は適当につけてよい。
- words.doc を印刷したものに以下のように表紙をつけ，あらかじめステープラー(ホチキス)で綴じ，**期末試験時**に提出しなさい(遅れて提出することは認めない)。
 - 課題には表紙をつけ，表紙には「課題タイトル(単語集の内容にあわせ自由につけてよい)」，クラス名，学部学科，学籍番号，氏名，電子メールアドレスを入れること。また，表紙または単語集の冒頭に，作成した単語集の内容に関する解説と，利用したデータについての説明を入れること。
 - 印刷は紙資源を節約するため FinePrint を使い 2 ページを 1 枚に印刷してよい(ただし，1 枚あたり 2 ページよりも小さく印刷しないように)。
 - 期末試験の詳細については次回説明する。なお，期末試験を受験できない人は提出期日について必ず教員に相談すること。

補足：自宅で Excel 2000 を使って作業をする人へ：

自宅で Excel 2000 (cf. 大学の Excel は 2002) を使って作業をする人は，一部の外国語の表示フォントの指定がうまくいかないことがある。簡体字中国語や韓国語用のフォント (SimSun や Batang, BatangChe など) を指定すると文字化けが起こることがある。そのような場合，文字自体はきちんと入力されていれば，フォントを「Arial Unicode MS」に設定すると表示・編集がうまくできるようになる。(繁体字中国語は MingLiU などを使えば OK。また，簡体字中国語の場合は，ユニコード対応フォントの別名 N SimSun を指定すると，文字化けが回避できるようである。)

	A	B	C	D
	単語	単語訳	例文	例文訳
1				
2	mina	私	Minna omo Retsu CHIBA	私は千葉庄寿です。
3	nina	あなた		
4	han	彼、彼女		
5	me	私たち		
		あなた方、あなた(敬		
6	ta	特)		
7	he	彼ら、彼女ら		
8	thrusmaa	人		
9	ama	こと		
10	shain	生き物		
11	ama	もの		
12	ze	それ		
13	ne	それら		
14				