

cluster linkage - 階層型クラスタ分析 【評価版】

Stata の `cluster` (及び `clustermat`) コマンドは分割型と並んで階層型のクラスタ分析機能をサポートしていますが、それは本 whitepaper に記す `linkage` コマンド群によって提供されます。

- | | |
|---|-------------------------------------|
| <ol style="list-style-type: none"> 1. 階層型クラスタ分析 2. 階層クラスタリングの用例 | Example 1
Example 2
Example 3 |
|---|-------------------------------------|

1. 階層型クラスタ分析

Stata がサポートする階層型クラスタ分析の機能は凝集型(agglomerative) と呼ばれるタイプに属するわけですが、グループ間の比較に用いられる手法 — 連結法(linkage method) — に種々のものがあるため、それぞれの手法ごとに別個のコマンドが対応する形となっています。具体的なコマンドとしては次の 7 種類があります。なお、これらの連結法の特質については [MV] `cluster` (*mwp-110*) をご参照ください。

コマンド	機能
<code>cluster singlelinkage</code>	単連結 (single linkage) 法によるクラスタ分析
<code>cluster averagelinkage</code>	平均連結 (average linkage) 法によるクラスタ分析
<code>cluster completelinkage</code>	完全連結 (complete linkage) 法によるクラスタ分析
<code>cluster waveragelinkage</code>	加重平均連結 (weighted-average linkage) 法によるクラスタ分析
<code>cluster medianlinkage</code>	メディアン連結 (median linkage) 法によるクラスタ分析
<code>cluster centroidlinkage</code>	重心連結 (centroid linkage) 法によるクラスタ分析
<code>cluster wardslinkage</code>	Ward 連結 (Ward's linkage) 法によるクラスタ分析

2. 階層クラスタリングの用例

▷ Example 1: 単連結法

[MV] `cluster linkage` の Example 1 には単連結法を用いた階層クラスタリングの例が記載されています。使用するのは Example データセット `labtech.dta` です。

```
. use http://www.stata-press.com/data/r15/labtech.dta *1
```

このデータセット中には熱帯雨林で収集された同一種と見られる植物標本 50 体に対する計測データが記録されています。変数である `x1-x4` は計測に用いられた化学物質の種類を表しています。次に示すのは先頭 10 件のデータです。

```
. list in 1/10 *2
```

	x1	x2	x3	x4	labtech
1.	17.4	78.6	101.4	109.3	Jen
2.	87	30.1	79.1	6.6	Jen
3.	.1	.6	.9	.2	Sam
4.	106	10	44.6	57.6	Deb
5.	140.6	122	114.8	122.8	Jen
6.	.5	.8	.2	.5	Sam
7.	140.5	27	71.2	69.6	Bill
8.	.5	.3	.5	.7	Sam
9.	18	74.4	26.4	116	Al
10.	3.6	143.6	12.8	70.1	Deb

これらの標本はすべて同一種の植物であると想定されますが、その中にサブグループが存在しないか、あるいは他と異なる特異な標本が存在しないかを見るためにクラスタ分析を実行してみます。連結法としては単連結法を、距離の尺度としてはデフォルトである L2(ユークリッド距離)^{*3}を用いることにし、分析結果には `sngueuc` という名称を付けることにします。

- Statistics > Multivariate analysis > Cluster analysis > Cluster data > Single linkage と操作
- Main タブ: Variables: `x1 x2 x3 x4`
 (Dis)similarity measure: Continuous (デフォルト)
 L2 or Euclidean (デフォルト)
 # for L(#) or Lpower(#): 空白
 Name this cluster analysis: `sngueuc`

*¹ メニュー操作 : File > Example Datasets > Stata 15 manual datasets と操作、Multivariate Statistics Reference Manual [MV] の `cluster linkage` の項よりダウンロードする。

*² メニュー操作 : Data > Describe data > List data

*³ 類似度/非類似度尺度については [MV] `cluster` (mwp-110) を参照。

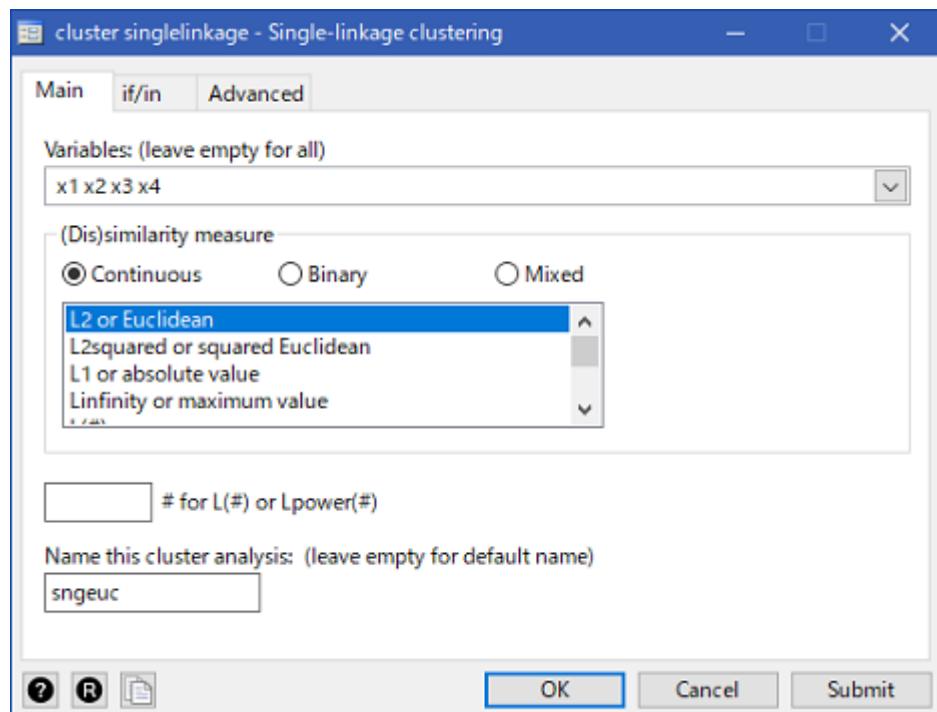


図 1 cluster singlelinkage ダイアログ - Main タブ

```
. cluster singlelinkage x1 x2 x3 x4, measure(L2) name(sngeuc)
```

評価版では割愛しています。

cluster dendrogram コマンドを使用するとクラスタリングに関するデンドログラム（樹形図）を作成することができます。

- Statistics > Multivariate analysis > Cluster analysis > Postclustering > Dendograms と操作
- Main タブ: Cluster analysis: sngeuc

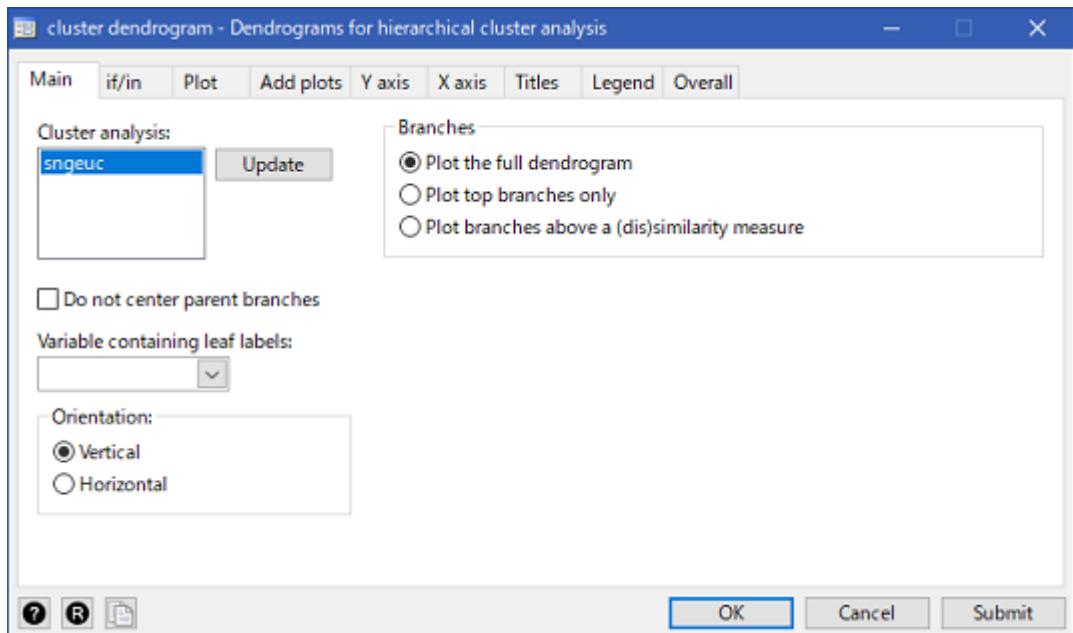
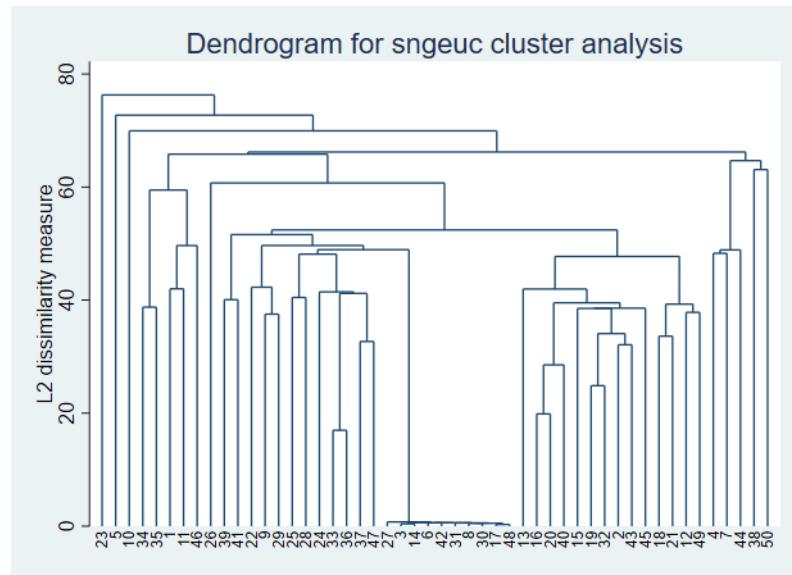


図3 cluster dendrogram ダイアログ - Main タブ

- X axis タブ: Major tick/label properties: Labels タブ: Size: Small
Angle: 90°

```
. cluster dendrogram sngueuc, xlabel(, labsize(small) angle(ninety))
invalid line in style file anglestyle-ninety:
*label "90 degrees"
```



このデンドログラムから見て取れることはまず最初に、横軸中央部に位置する観測データ群が短い縦棒の長さで示されているように互いに近接しており、長い縦棒を有する他の観測データからは大きく隔たっているということです。次にこれらの 10 個の観測データを除外して考えるなら、残されたデンドログラムからは明確なクラスタリングが読み取れないことがわかります。これはデンドログラム上部における縦棒の長さがみな比較的短いことに示されています。

評価版では割愛しています。

▷ Example 2: 2 値データ

評価版では割愛しています。

