実務直結! 分析カ向上ウェビナーシリーズ 機械学習によるビッグデータ分析の手法

#2 クラスター分析による分類 (1) 非階層的クラスタリング

2022年10月19日



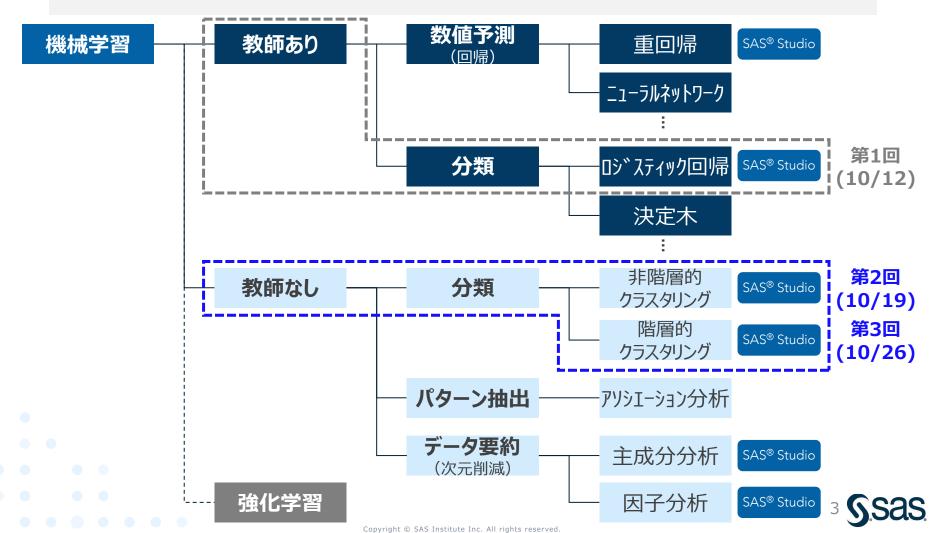
Agenda

- 相関行列によるデータ観察
 - 相関関係の全体把握
 - 散布図行列との同時活用
- クラスター分析による分類(1): 非階層的クラスタリング
 - 教師なし学習とクラスタリング
 - 非階層的クラスタリング(k-means法)のしくみ
 - グラフを活用した各クラスタの解釈方法
 - クラスタ数設定の考え方
 - 顧客データを用いて非階層的クラスタリングにより類似顧客をグルーピングする



代表的な機械学習手法

- 機械学習手法は、教師あり、教師なし、強化学習に大別される
- なかでも、教師あり分類、教師なし分類は極めて基本的かつ頻用される手法である



教師あり学習と教師なし学習

教師あり学習

= Cat あらかじめ「正解」を与えて、各データと正解の関係を学習させる = Dog

Dog

推論

学習



教師なし学習



「正解」を与えずに、 各データのパターン (距離の近さ、頻出の 組み合わせなど)を 学習する



グループ②!

※分類されたグループの 意味づけは人が行う

4 Ssas

推論

学習

教師なし学習のイメージ (クラスタリング)

• 各データ間の距離に基づき、近接データ (=類似度が高いデータ) 同士のグループ (クラスタ) を作り、 データを分類する手法

クラスタリング

• **学習データなし**でデータを大きく層別したい場合に有効

データ例

顧客ID	名前	年齢	年収	購入額	購入有無	•••
0001	XX	25	300万	35,000	購入	
0002	XX	35	600万	68,000	購入	
0003	XX	18	120万	0	非購入	
0004	XX	42	820万	85,000	購入	
	:	:	:	:		

説明変数

※目的変数は無し



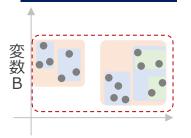
非階層的クラスタリング

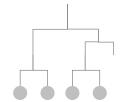


主な手法

- k-means法 (k平均法)
- ・混合ガウス

階層的クラスタリング





主な手法

- 最短距離法
- 最長距離法
- 群平均法
- ウォード法



クラスタリング手法の種類

- クラスタリング手法は、「非階層的」と「階層的」に大別される
- 階層的クラスタリングはさらに 凝集型 と 分割型 があり、凝集型が用いられるのが一般的

手法の分類

手法

非階層的クラスタリング



クラスタ内データの平均値をクラスタ重心として、 • k-means法(k平均法)

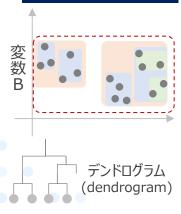
距離に基づき、事前に設定したクラスタ数k個に分割

SAS® Studio

混合ガウス法、招体積法など ■その他

本日ご説明

階層的クラスタリング



SAS® Studio クラスタ内のデータの平方和を最小にするように併合 ■ ウォード法 ■ 最短距離法 (最近隣法) 距離の近いデータから順番に併合 第3回 (10/26)**距離の遠いデータから順番に併合** ■ 最長距離法 (最遠隣法)

■重心法 クラスタ重心からの距離に基づき併合

各クラスタ同士で全データの距離の平均を基準に併合 SAS® Studio ■ 群平均法

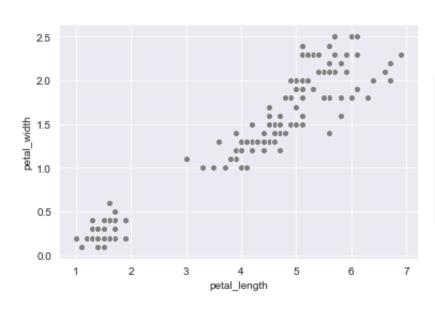
その他 メディアン法、可変法

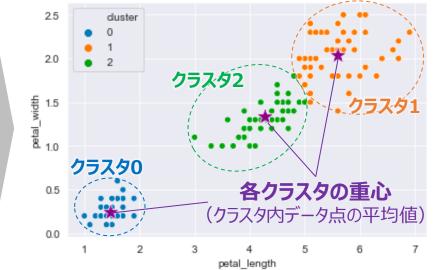
SAS® Studio

非階層クラスタリング:k-means法

クラスタリング手法の中で代表的かつ最もシンプルな手法が「k-means法」であり、
 各クラスタ内のデータ平均値 (means) を重心として、k個のクラスターに分類することができる

▼2次元のk-meansクラスタリング例





▼分類結果の特徴

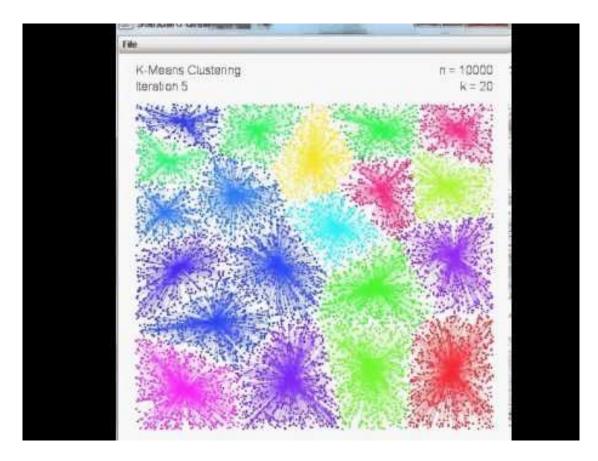
- 教師なしのため、各クラスタの意味解釈は人が行う
- 円状 (球状) のクラスタになりやすい
- クラスタサイズ (クラスタ内のデータ数) が同程度になりやすい

▼アルゴリズムの特徴

- クラスタ数を事前に明示的に決める必要がある
- 距離依存のため、データのスケールによって結果が変わる
- ■初期値(初期重心)に大きく依存



参考:k-means法のイメージ (動画)

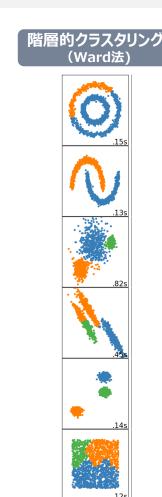


Source: https://www.youtube.com/watch?v=BVFG7fd1H30

参考: クラスタリング手法における分類結果の比較

• クラスタリング手法によって得意なデータパターンは異なり、様々な手法を試しながら、最適な手法を選択することが望ましい。中でも、k-meansは「重心からの距離」を用いて分類するため、円状のデータには強いが、楕円状や曲線状のデータは苦手

非階層的クラスタリング (k-means) 入力データ形式による違 は強



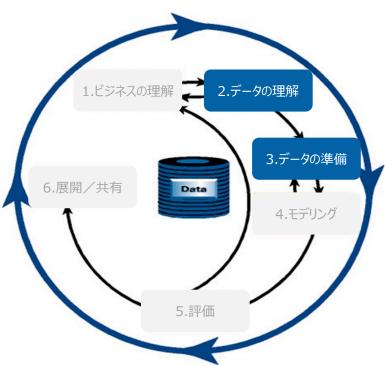
その他の参考手法: **DBSCAN**



ビッグデータ分析の進め方

• データマイニングの進め方に関する方法論「CRISP-DM」に基づいて、分析と評価を繰り返して試行錯誤しながら進めるのが一般的である

CRISP-DM: データマイニング方法論



(CRoss Industry Standard Process for Data Mining)

1.ビジネスの理解

- •ビジネス、データマイニング目標の決定
- •プロジェクトの立ち上げ

2.データの理解

- •データの収集
- •データの調査
- ・データ品質の検証

3.データの準備

- •データの選択や除外
- •データのクリーニング
- •データの構築や統合

4.モデル作成

- •モデリング手法の選択
- •モデルの作成
- •モデルの評価

5.評価

- •データマイニングの結果の評価
- •プロセスの見直し
- •実行可能なアクションリストの作成

6.展開/共有

- ・業務への導入計画
- •モニタリング、メンテナンスの計画

使用データ

- UCI Machine Learning Repositoryでは様々な分野のデータが公開
- 今回は、**銀行のマーケティングデータ**を活用し、分析を行う



Bank Marketing Data Set

Download: Data Folder, Data Set Description

Abstract: The data is related with direct marketing campaigns (phone calls) of a Portuguese banking institution. The classification goal is to predict if the client will subscribe a term deposit (variable y).

Data Set Characteristics:	Multivariate	Number of Instances:	45211	Area:	Business
Attribute Characteristics:	Real	Number of Attributes:	17	Date Donated	2012-02-14
Associated Tasks:	Classification	Missing Values?	N/A	Number of Web Hits:	1577437

Source:

[Moro et al., 2014] S. Moro, P. Cortez and P. Rita. A Data-Driven Approach to Predict the Success of Bank Telemarketing. Decision Support Systems, Elsevier, 62:22-31, June 2014

Data Set Information:

The data is related with direct marketing campaigns of a Portuguese banking institution. The marketing campaigns were based on phone calls. Often, more than one contact to the same client was require ('yes') or not ('no') subscribed.

There are four datasets:

- 1) bank-additional-full.csv with all examples (41188) and 20 inputs, ordered by date (from May 2008 to November 2010), very close to the data analyzed in [Moro et al., 2014]
- 2) bank-additional.csv with 10% of the examples (4119), randomly selected from 1), and 20 inputs.
- 3) bank-full csv with all examples and 17 inputs, ordered by date (older version of this dataset with less inputs).
- 4) bank.csv with 10% of the examples and 17 inputs, randomly selected from 3 (older version of this dataset with less inputs).
- The smallest datasets are provided to test more computationally demanding machine learning algorithms (e.g., SVM).

The classification goal is to predict if the client will subscribe (yes/no) a term deposit (variable y).

https://archive.ics.uci.edu/ml/datasets/bank+marketing



データの概要

• 4,521人分の顧客について、顧客情報や営業アプローチ状況、最終的な狙いである「定期預金の契約有無」に関する情報(計17列)が格納されている

※クラウド型のSAS Studio (SAS OnDemand for Academics) において 列名を日本語にする場合、全角6文字以内を推奨

				クレジット 債務不履行		年間平:				最終連終 会話時間		キャンペーン連絡回		冬連絡からの 圣過日数	キャンペーン連絡回		ニャンペーン)結果
	年齢	職業	結婚歴	学歴	クレカ債務	年間平均 残高	住宅 ローン	個人ローン	連絡手段	最終連 絡日	最終連 絡月	最終会話 時間	CP中連絡 回数	最終連絡 日数	CP前連絡 回数	前回CP結果	定期預金 契約
A.	30	unemployed	married	primary	no	1787	no	no	cellular	19	oct	79	1	-1	0	unknown	no
	33	services	married	secondary	no	4789	yes	yes	cellular	11	may	220	1	339	4	failure	no
	35	management	single	tertiary	no	1350	yes	no	cellular	16	apr	185	1	330	1	failure	no
	30	management	married	tertiary	no	1476	yes	yes	unknown	3	jun	199	4	-1	0	unknown	no
	59	blue-collar	married	secondary	no	0	yes	no	unknown	5	may	226	1	-1	0	unknown	no
	35	management	single	tertiary	no	747	no	p		23	feb	141	2	176	3	failure	
ı	36	self-employed	married	tertiary	no	307	yes	製料田]変数	14	may	341	1	330	2	other	的変数
	39	technician	married	secondary	no	147	yes	ши		6	may	151	2	-1	0	unkno	
	41	entrepreneur	married	tertiary	no	221	yes	no	unknown	14	may	57	2	-1	0	unknown	no
ı	43	services	married	primary	no	-88	yes	yes	cellular	17	apr	313	1	147	2	failure	no
ı	39	services	married	secondary	no	9374	yes	no	unknown	20	may	273	1	-1	0	unknown	no
ı	43	admin.	married	secondary	no	264	yes	no	cellular	17	apr	113	2	-1	0	unknown	no
1	36	technician	married	tertiary	no	1109	no	no	cellular	13	aug	328	2	-1	0	unknown	no
ı	20	student	single	secondary	no	502	no	no	cellular	30	apr	261	1	-1	0	unknown	yes
. [31	blue-collar	married	secondary	no	360	yes	yes	cellular	29	jan	89	1	241	1	failure	no
L	40					101		T	11 1	20		100	_	4	^		

予測(分析)対象を説明するための変数

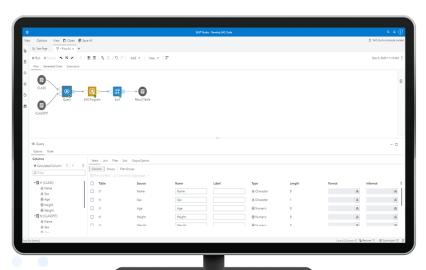
予測(分析) したい対象



SAS Studio について

- 今年のウェビナーでは、SAS Studio でデモを行います。
- SAS Studio はすべてのSAS製品に付帯しているGUI で、今回は学習用に自宅でもお使い 頂けるクラウド型無償版 SAS OnDemand for Academics を使っています。
 (※無償版の登録については、SAS からの申込完了メールをご参照ください)
- ・ なお、SAS Studio起動時はコード入力画面となっていますが、画面右上の「SASプログラマ」を「ビジュアルプログラマ」に変更するとデモと同様の入力画面となります。

▼SAS Studio 画面イメージ



▼GUI画面への変更方法

(ビジュアルプログラマ)

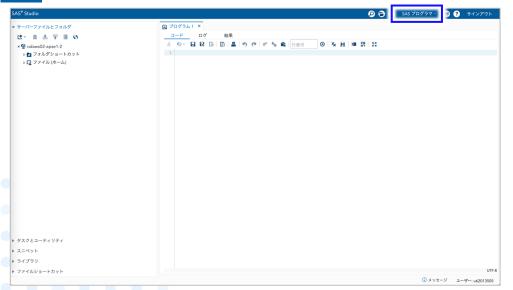


https://www.sas.com/ja_jp/software/studio.html



参考: SAS Studio 起動方法

- SAS OnDemamd for Academics にログイン後、Dashboard より SAS Studio を起動
- 起動後、前頁の通り、右上メニューより「ビジュアルプログラマ」を選択
- **SAS OnDemand for Academics** にログイン https://welcome.oda.sas.com/login
- 2 SAS OnDemand for Academics Dashboardより "SAS® Studio" をクリックして起動
- 3 SAS Studioが起動/右上よりビジュアルプログラマを選択



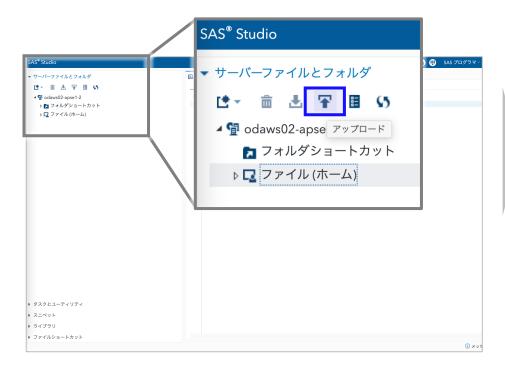




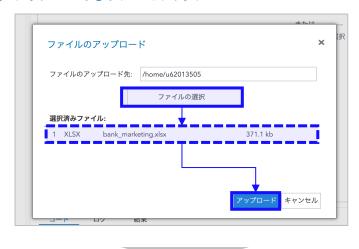


データの読み込み (1/2)

①左パネル内の「アップロード」アイコン をクリック



- ②「ファイルの選択」ボタンをクリックし、ファイル選択画面で "bank_marketing.xlsx" を選択し、OKボタン
- ③「アップロード」ボタンをクリック



④ 左パネル内にファイルがアップロードされていることを確認

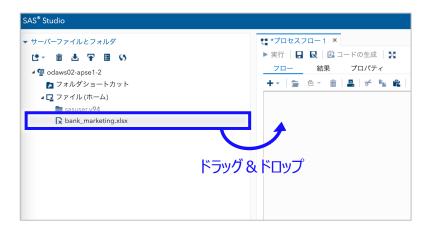






データの読み込み (2/2)

①左パネル内の "bank_marketing.xlsx" を選択し、 画面右側のプログラムエリアにドラッグ & ドロップ



③詳細設定画面が開くので、実行ボタンをクリック (特に各設定は変更不要)



②右側のプロセスフローにノードが生成されるので、当該ノードをダブルクリック



④「結果」のタブ画面に読み込んだデータの概要が出力



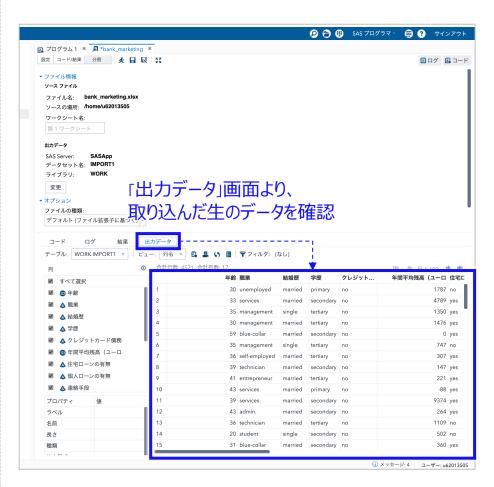


読み込んだデータの確認

データ概要の確認



生データの確認







作成したプロセスフローの保存(別名で保存)

プロセスフローをクリックしてプロセスフロー画面に戻る



「名前を付けてプロセスフローを保存」アイコンをクリックし、 保存場所、ファイル名を指定して保存ボタン



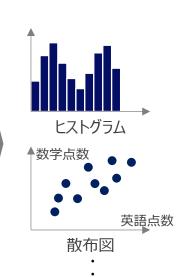
データの特徴の捉え方

・ビッグデータでは個々のデータをくまなく見るのは難しいため、グラフ(ヒストグラムや散布図)や要約統計量(平均値や標準偏差)を用いて全体傾向を把握する

グラフ化

視覚的にデータの特徴や傾向を把握

ID	英語	数学	
1	55	48	
2	70	47	
3	66	44	
:	:	:	
18	65	55	
19	57	51	
20	68	43	



数値化(データ要約)

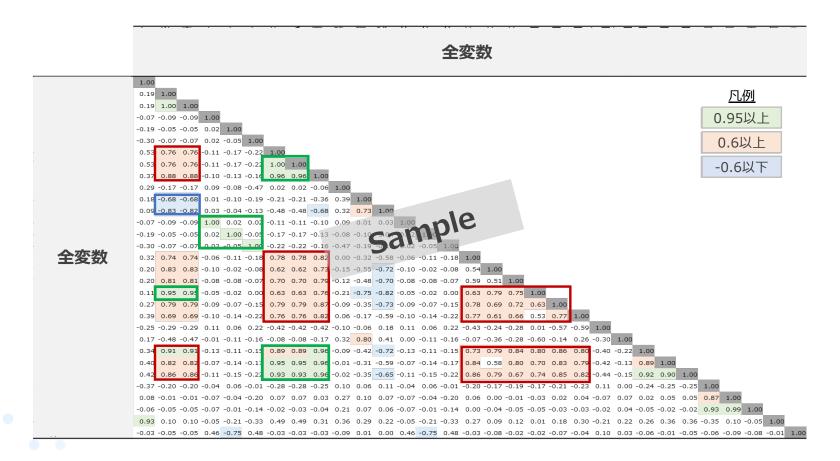
データの特徴を示す値に要約し 比較可能な客観的傾向を掴む (**要約統計量**)

ID	英語	数学	
1	55	48	
2	70	47	
3	66	44	
:	:	:	
18	65	55	
19	57	51	
20	68	43	

- 平均値=XXX
- 中央値=XXX
- 標準偏差 = X X X

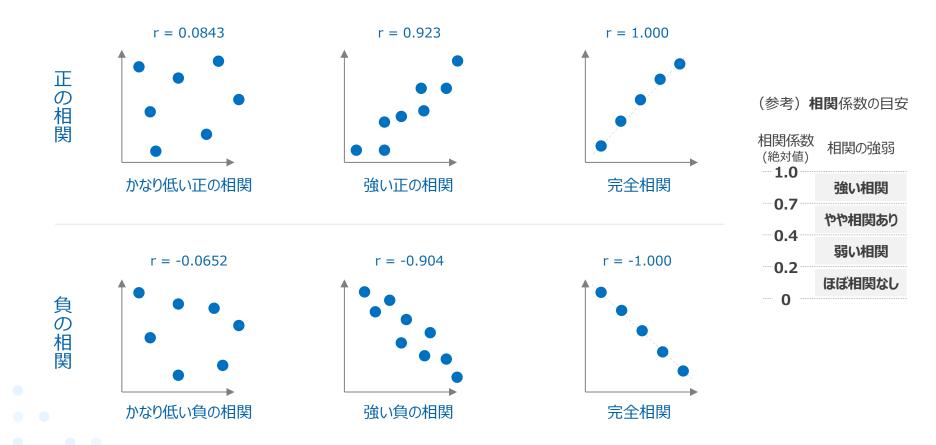
相関行列

- 事前に各変数間の相関係数を総当たりで調べておくと、後々の結果解釈に役立つ(相関行列)
- また、共線性が高い変数 (相関の高い) が複数混ざっていると、その変数の影響を強く受け、 偏った分析結果になることがある。この場合、共線性が高い変数は除外することが有効



相関係数について

- 相関係数r (correlation coefficient) とは、2つの変数間の相関の度合いを表す指標
- -1 ≤ r ≤ 1 の値を取り、正の場合は正相関、負の場合は負相関、0の場合は無相関





SAS Studio での実装方法

- 相関分析
- 散布図との比較
- グループ分析を設定した相関分析





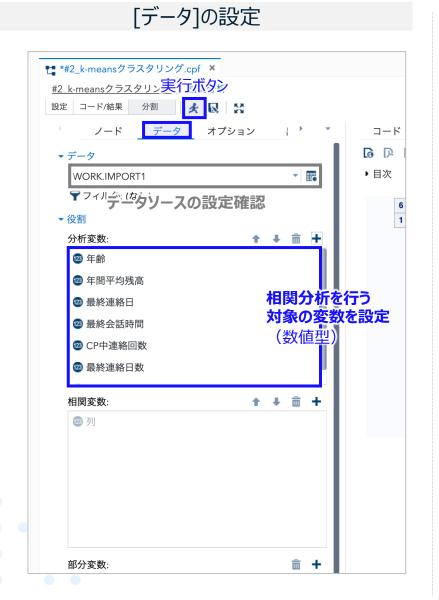
相関分析の出力 - 実行方法 (1/2)

- ①[タスクとユーティリティ]→[タスク]→[統計量]→[**相関分析**] を選択し、 データインポートノードのコントロールポートに ドラッグ&ドロップ
- ②生成された [相関分析] ノードをダブルクリックして、詳細設定画面を開く

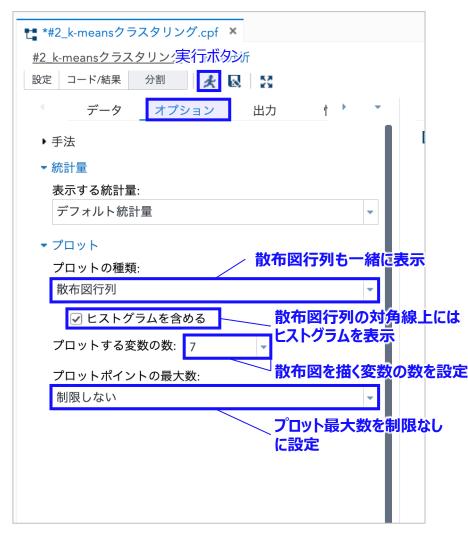




相関分析の出力 - 実行方法 (2/2)



[オプション]の設定





相関分析の出力 - 実行結果 (相関行列)

			Pearson の	相関係数, N = 4	521		
	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数
年齢年齢	1.00000	0.08382	-0.01785	-0.00237	-0.00515	-0.00889	-0.00351
年間平均残高 年間平均残高	0.08382	1.00000	-0.00868	-0.01595	-0.00998	0.00944	0.02620
最終連絡日 最終連絡日	-0.01785	-0.00868	1.00000	-0.02463	右上部分とは対象	左下部分 ⁴³⁵	-0.05911
最終会話時間 最終会話時間	-0.00237	-0.01595	-0.02463	1.00000	-0.06838	0.01038	0.01808
CP中連絡回数 CP中連絡回数	-0.00515	-0.00998	0.16071	-0.06838	1.00000	-0.09314	-0.06783
最終連絡日数 最終連絡日数	-0.00889	0.00944	-0.09435	0.01038	-0.09314	1.00000	0.57756
CP前連絡回数 CP前連絡回数	-0.00351	0.02620	-0.05911	0.01808	-0.06783	0.57756	1.00000

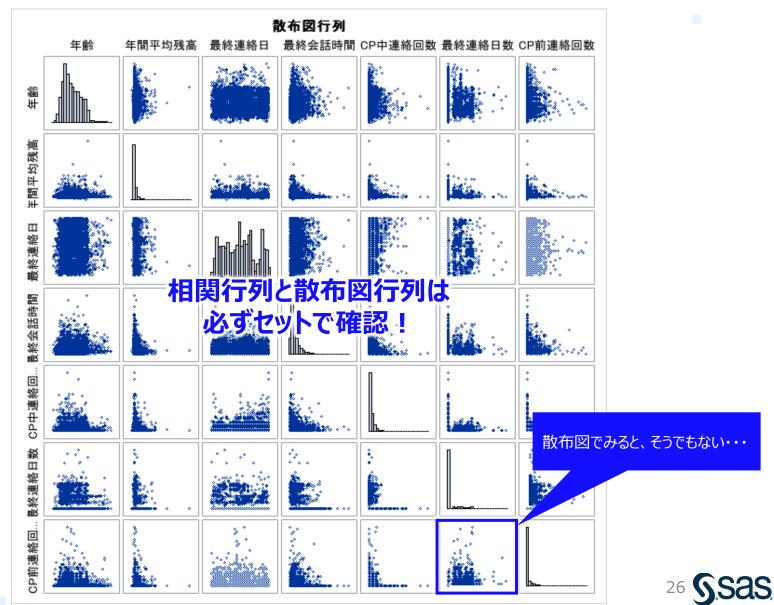


「最終連絡からの経過日数」と 「キャンペーン前の連絡回数」とで 相関係数が高い





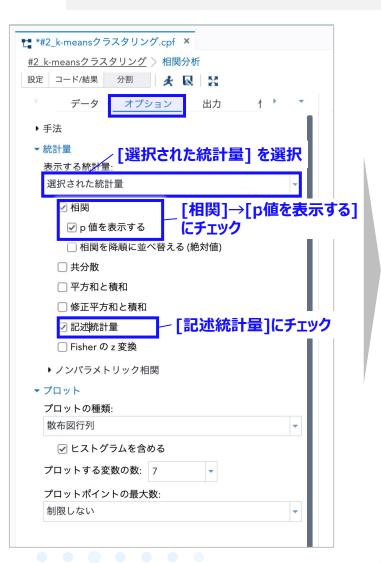
相関分析の出力 - 実行結果(散布図行列)





(参考) 相関分析の出力:各種統計量·p値の表示

• オプションで追加設定をすることで、基本的な要約統計量や相関係数のp値も同時出力可能



基本的な要約統計量

	単純統計量													
変数	N	平均	標準偏差	合計	最小値	最大値	ラベル							
年齢	4521	41.17010	10.57621	186130	19.00000	87.00000	年齢							
年間平均残高	4521	1423	3010	6431836	-3313	71188	年間平均残高							
最終連絡日	4521	15.91528	8.24767	71953	1.00000	31.00000	最終連絡日							
最終会話時間	4521	263.96129	259.85663	1193369	4.00000	3025	最終会話時間							
CP中連絡回数	4521	2.79363	3.10981	12630	1.00000	50.00000	CP中連絡回数							
最終連絡日数	4521	39.76664	100.12112	179785	-1.00000	871.00000	最終連絡日数							
CP前連絡回数	4521	0.54258	1.69356	2453	0	25.00000	CP前連絡回数							

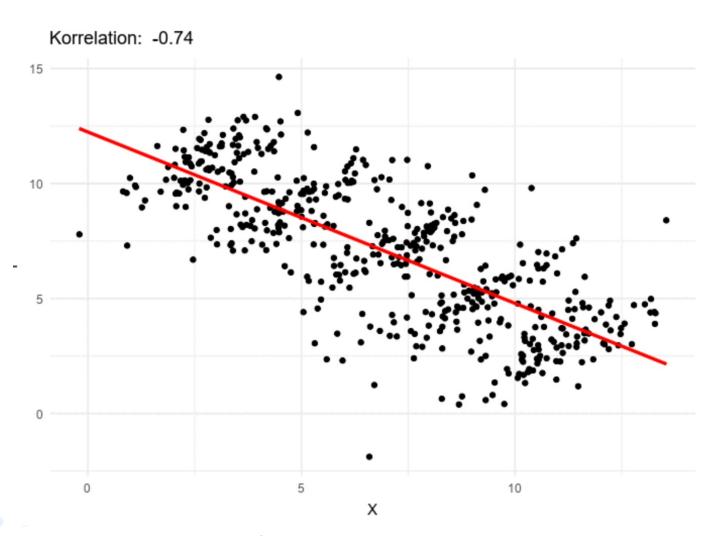
Pearson の相関係数, N = 4521 H0: Rho=0 に対する Prob > Irl

	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数
年齢	1.00000	0.08382	-0.01785	-0.00237	-0.00515	-0.00889	-0.00351
年齢		<.0001	0.2301	0.8736	0.7293	0.5500	0.8134
年間平均残高	0.08382	1.00000	-0.00868	-0.01595	-0.00998	0.00944	0.02620
年間平均残高	<.0001		0.5597	0.2836	0.5025	0.5259	0.0782
最終連絡日	-0.01785	-0.00868	1.00000	-0.02463	0.16071	-0.09435	-0.05911
最終連絡日	0.2301	0.5597		0.0978	<.0001	<.0001	<.0001
最終会話時間	-0.00237	-0.01595	-0.02463	1.00000	-0.06838	0.01038	0.01808
最終会話時間	0.8736	0.2836	0.0978		<.0001	0.4853	0.2242
CP中連絡回数	-0.00515	-0.00998	0.16071	-0.06838	1.00000	-0.09314	-0.06783
CP中連絡回数	0.7293	0.5025	<.0001	<.0001		<.0001	<.0001
最終連絡日数	-0.00889	0.00944	-0.09435	0.01038	-0.09314	1.00000	0.57756
最終連絡日数	0.5500	0.5259	<.0001	0.4853	<.0001		<.0001
CP前連絡回数	-0.00351	0.02620	-0.05911	0.01808	-0.06783	0.57756	1.00000
CP前連絡回数	0.8134	0.0782	<.0001	0.2242	<.0001	<.0001	

相関係数のp値



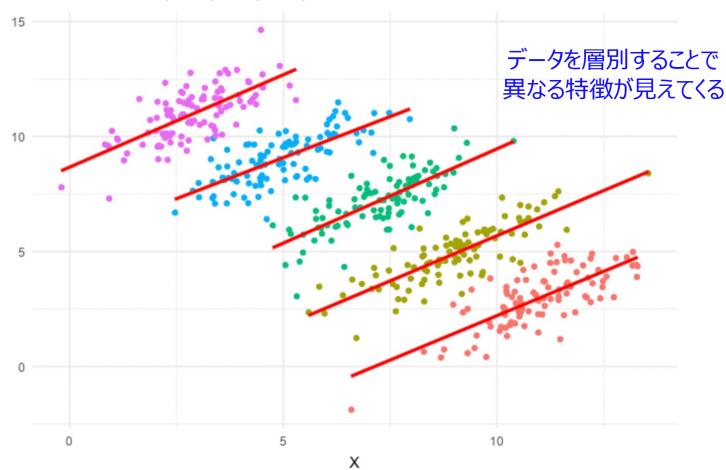
データ層別の重要性





データ層別の重要性

Korrelation: 0.74, 0.82, 0.75, 0.72, 0.69



出典: シンプソンのパラドックス (Wikipedia) https://w.wiki/qrf



相関分析の出力:グループ分析 - 実行方法

• グループ分析変数に目的変数を設定することで、目的変数で層別した相関分析が可能



契約者

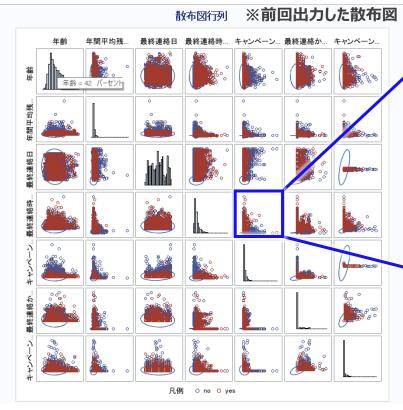
			Pearson 0	D相関係数, N = 5	521		
	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数
年齢 年齢	1.00000	0.16845	-0.05207	-0.03633	-0.06583	0.05072	-0.01192
年間平均残高 年間平均残高	0.16845	1.00000	-0.03858	-0.12007	-0.02804	0.01352	0.02050
最終連絡日 最終連絡日	-0.05207	-0.03858	1.00000	0.03610	0.13780	-0.03734	-0.05123
最終会話時間 最終会話時間	-0.03633	-0.12007	0.03610	1.00000	0.23432	-0.15489	-0.15549
CP中連絡回数 CP中連絡回数	-0.06583	-0.02804	0.13780	0.23432	1.00000	-0.08488	-0.09863
最終連絡日数 最終連絡日数	0.05072	0.01352	-0.03734	-0.15489	-0.08488	1.00000	0.51823
CP前連絡回数 CP前連絡回数	-0.011				「の連絡回 間」に弱し		1.00000

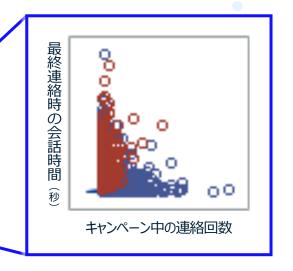
未契約者

			Pearson の	相関係数, N = 4	000		
	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数
年齢 年齢	1.00000	0.07291	-0.01165	-0.01836	0.00446	(参考)相関	係数の目安
年間平均残高 年間平均残高	0.07291	1.00000	-0.00539	-0.00858	-0.00762	(絶対値)	関の強弱
最終連絡日 最終連絡日	-0.01165	-0.00539	1.00000	-0.03679	0.16339	-1.0 	金い相関
最終会話時間 最終会話時間	-0.01836	-0.00858	-0.03679	1.00000	-0.09611	4.11	や相関あり
CP中連絡回数 CP中連絡回数	0.00446	-0.00762	0.16339	-0.09611	1.00000	0.2	弱い相関
最終連絡日数 最終連絡日数	-0.02733	0.00694	-0.10334	0.00179	-0.08961	- 0	ま相関なし
CP前連絡回数 CP前連絡回数	-0.00819	0.02507	-0.05957	0.00563	-0.05856	0.58368	1.00000



散布図行列 (層別) との比較





散布図と相関係数を併せて確認することでより深い洞察や、外れ値の発見につながる

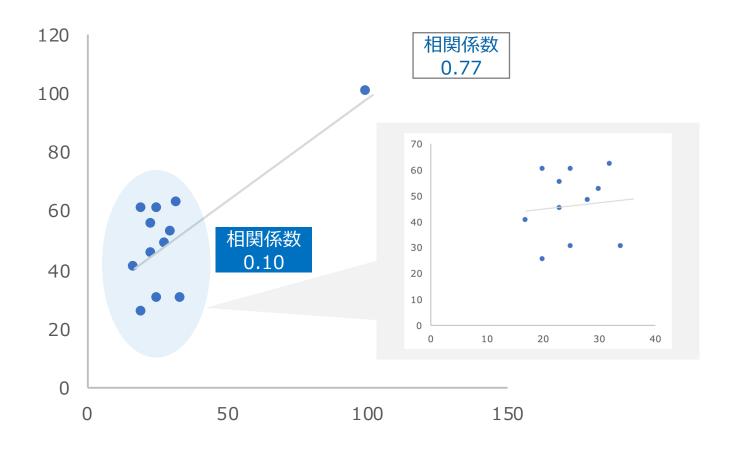
	契約者													
	Pearson の相関係数, N = 521													
	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数							
年齢 年齢	1.00000	0.16845	-0.05207	-0.03633	-0.06583	0.05072	-0.01192							
年間平均残高 年間平均残高	0.16845	1.00000	-0.03858	-0.12007	-0.02804	0.01352	0.02050							
最終連絡日 最終連絡日	-0.05207	-0.03858	1.00000	0.03610	0.13780	-0.03734	-0.05123							
最終会話時間 最終会話時間	-0.03633	-0.12007	0.03610	1.00000	0.23432	-0.15489	-0.15549							
CP中連絡回数 CP中連絡回数	-0.06583	-0.02804	0.13780	0.23432	1.00000	-0.08488	-0.09863							
最終連絡日数 最終連絡日数	0.05072	0.01352	-0.03734	-0.15489	-0.08488	1.00000	0.51823							
CP前連絡回数 CP前連絡回数	-0.01192	0.02050	-0.05123	-0.15549	-0.09863	0.51823	1.00000							

	Deeveen の知用反数 N = 4000													
Pearson の相関係数, N = 4000														
	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数							
年齢 年齢	1.00000	0.07291	-0.01165	-0.01836	0.00446	-0.02733	-0.00819							
年間平均残高 年間平均残高	0.07291	1.00000	-0.00539	-0.00858	-0.00762	0.00694	0.02507							
最終連絡日 最終連絡日	-0.01165	-0.00539	1.00000	-0.03679	0.16339	-0.10334	-0.05957							
最終会話時間 最終会話時間	-0.01836	-0.00858	-0.03679	1.00000	-0.09611	0.00179	0.00563							
CP中連絡回数 CP中連絡回数	0.00446	-0.00762	0.16339	-0.09611	1.00000	-0.08961	-0.05856							
最終連絡日数 最終連絡日数	-0.02733	0.00694	-0.10334	0.00179	-0.08961	1.00000	0.58368							
CP前連絡回数 CP前連絡回数	-0.00819	0.02507	-0.05957	0.00563	-0.05856	0.58368	1.00000							



(参考) 外れ値の影響例

• 相関係数は外れ値の影響を大きく受けるため、数字だけに惑わされぬよう、 散布図の確認も併せて行うことが重要である



相関分析の注意点:「アイスクリーム売上」と「溺死件数」の関係

あなたは、あるシンクタンクの社員として働いている。

今回、とある省庁から、様々な消費者データと社会データについての調査を任された。

調査の結果、

「アイスクリームが売れると、海の溺死件数が増える」

という衝撃的なデータが得られた。

これが事実なら、即刻、アイスクリームの販売に規制をかけるべきである。

あなたの見解は?

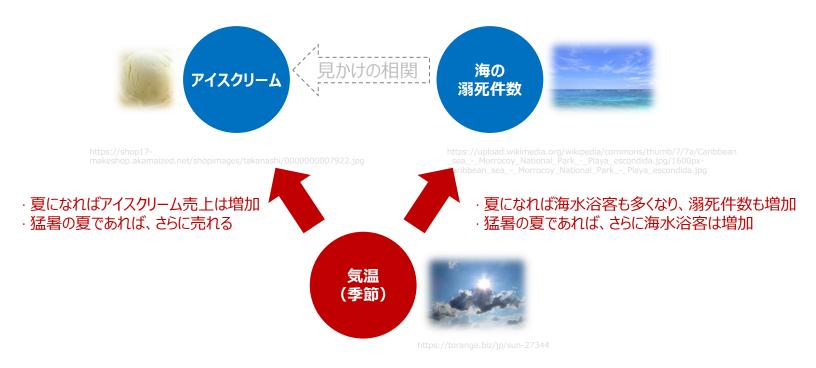


https://upload.wikimedia.org/wikipedia/commons/thumb/7/7a/Caribbean _sea__Morrocoy_National_Park_-_Playa_escondida.jpg/1600px-Caribbean_sea_-_Morrocoy_National_Park_-_Playa_escondida.jpg



相関分析の注意点:相関と因果の違い

- 相関が高くても(連動しているように見えても)、必ずしも因果があるとは限らない
- このケースでは、両者の間に気温(季節)という**潜伏変数**が介在しており、 これが両者に影響を与えることで**見かけの相関(疑似相関)**となって現れた可能性が高い



潜伏変数

参考:変数の尺度(名義尺度・順序尺度・間隔尺度・比例尺度)

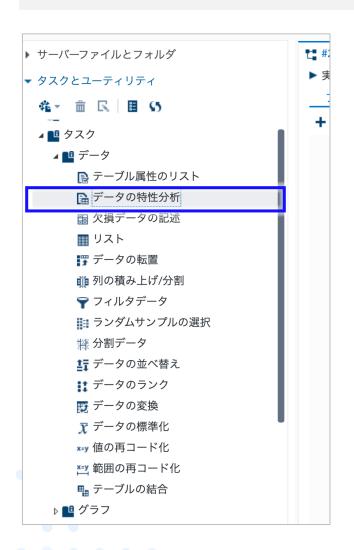
• 変数の種類は大きく「**質的データ**」と「**量的データ**」に分けられ、それぞれの特性に合わせて扱う必要がある

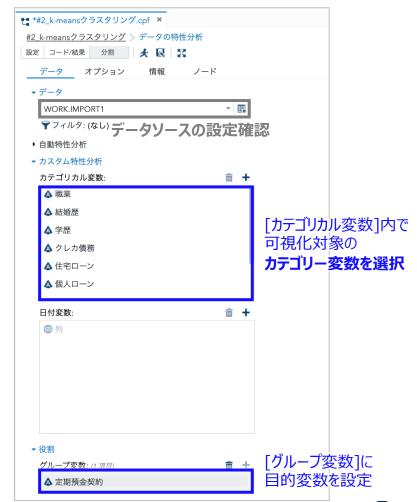
種類 概要 データの例 変数の尺度 扱い方 大小 差分 比率 (A < B) (A - B) (A/B)■性別、血液型、顧客ID 単にデータを区別するための分類ラベル。 名義尺度 •作業者、個品ID、 **浦**算不可で、順序も意味をなさない 良品/不良品 ※集計によるカウントのみ可能 質的データ (カテゴリーデータ) 順序(大小関係)にのみ意味がある尺度。 ■顧客満足度、震度 順序尺度 したがって、平均値は意味を持たないが、順 ■不良レベル、工程順序 序統計量(最大・最小など)は算出可能 数値演算可能だが、値の差のみに意味が •年齢、西暦、偏差値 間隔尺度 ある尺度。 温度(℃)、製造日時 0はあくまで相対的な位置関係でしかない 量的データ (数量データ) 数値演算可能で、値の差に加え、値の比 ■身長、売上金額 比例尺度 にも意味がある尺度。 •寸法、圧力、作業時間、 0が「何もない」という絶対的な意味を持つ 絶対温度



カテゴリー変数可視化の便利な方法

• データの特性分析ノードを使えば、カテゴリー変数の頻度集計棒グラフを一度に出力可能

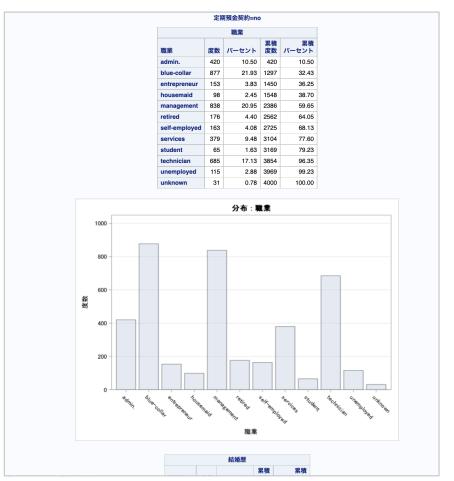


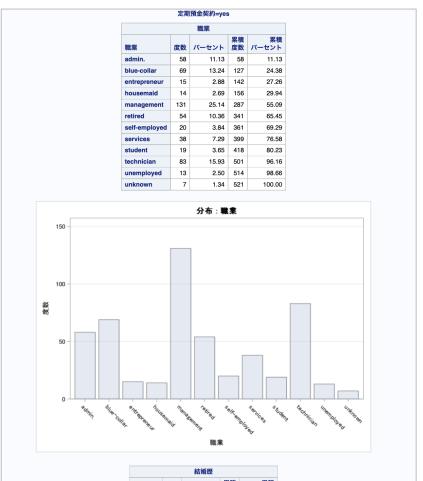




カテゴリー変数可視化の便利な方法

• データの特性分析ノードを使えば、カテゴリー変数の頻度集計棒グラフを一度に出力可能

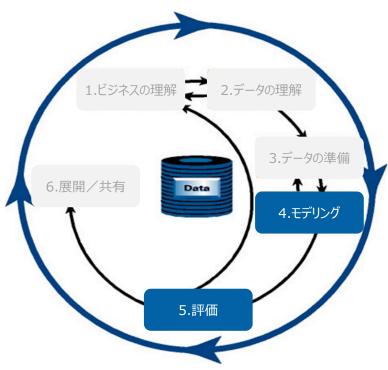




ビッグデータ分析の進め方

• データマイニングの進め方に関する方法論「CRISP-DM」に基づいて、分析と評価を繰り返して試行錯誤しながら進めるのが一般的である

CRISP-DM: データマイニング方法論



(CRoss Industry Standard Process for Data Mining)

- 1.ビジネスの理解
- ビジネス、データマイニング目標の決定プロジェクトの立ち上げ
- 2.データの理解
- •データの収集
- •データの調査
- ・データ品質の検証
- 3.データの準備
- •データの選択や除外
- •データのクリーニング
- データの構築や統合
- 4.モデル作成
- •モデリング手法の選択
- •モデルの作成
- •モデルの評価

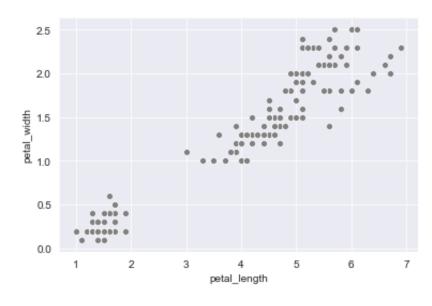
5.評価

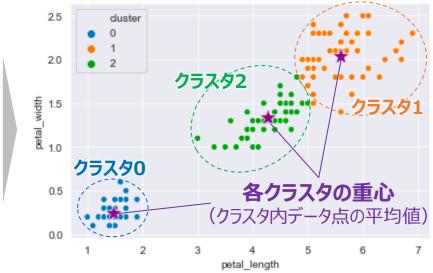
- •データマイニングの結果の評価
- •プロセスの見直し
- •実行可能なアクションリストの作成
- 6.展開/共有
- •業務への導入計画
- •モニタリング、メンテナンスの計画

非階層クラスタリング:k-means法

クラスタリング手法の中で代表的かつ最もシンプルな手法が「k-means法」であり、
 各クラスタ内のデータ平均値 (means) を重心として、k個のクラスターに分類することができる

▼2次元のk-meansクラスタリング例





▼分類結果の特徴

- 教師なしのため、各クラスタの意味解釈は人が行う
- 円状 (球状) のクラスタになりやすい
- クラスタサイズ (クラスタ内のデータ数) が同程度になりやすい

▼アルゴリズムの特徴

- クラスタ数を事前に明示的に決める必要がある
- 距離依存のため、データのスケールによって結果が変わる
- ■初期値(初期重心)に大きく依存 ※後述

足サイズ

- (参考) クラスタリングにおける変数スケールの影響と標準化
- ・ k-means法などの「距離」に基づくによるクラスタリング手法は、データの「スケール」に大きく影響を受ける。このため、必要に応じて、「標準化」の処理を行なった上でクラスタリングが必要
- SAS Studioでは、クラスタリング時に、デフォルトで標準化が適用できる(ォフにすることも可能)

クラスタリング結果が スケール大の変数に引っ張られる

た足サイズ

標準化した身長

平均0、分散1

身長

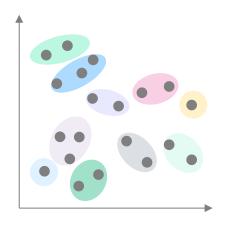
▼SAS Studioでの設定(デフォルト)





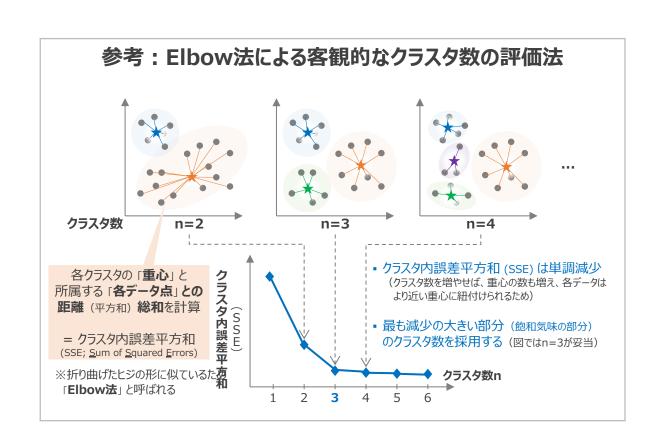
クラスタ数設定の考え方

- クラスタ数を客観的に評価する「Elbow法」などの手法もあるが、一般的には、まずは**人間が解釈可能なレベルの3~5個程度**から着手してみることが賢明
- 階層的クラスタリングや、自動的にクラスタ数を決めてくれる手法 (DBScanなど) を活用する



細かくクラスタを分けすぎても、 解釈(=各クラスタの意義付け)が困難

人間が解釈しやすい3~5個程度 から始めてみることが有効





SAS Studio での実装方法

- 非階層的クラスタリング(k-means)
- クラスタ数の設定と変更
- クラスタリング結果の解釈
- クラスタ番号の出力と追加分析
- グループ変数の設定





非階層的クラスタリング (k-means) - 実行方法 (1/2) ノードの設置

- ①左パネルより、「タスクとユーティリティ]→「タスク] →「クラスター分析]→「**K-Meansクラスタリング**]を選択
- ②右側のプロセスフロー内のインポートノードの 右端の四角 (コントロールポート) の上へドラッグ&ドロップ

③プロセスフロー 上に K-Meansクラスタリング ノードが 牛成されるのでダブルクリックして詳細設定画面を開く

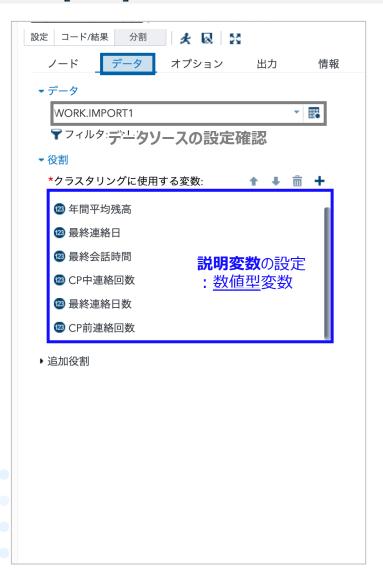




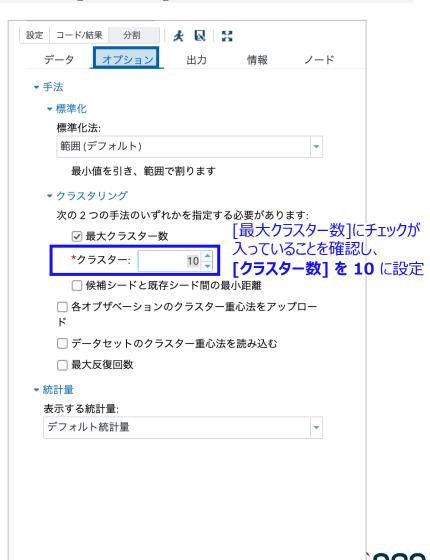


非階層的クラスタリング (k-means) - 実行方法 (2/2) 説明変数・オプション

[データ]の設定 (説明変数・目的変数)



[オプション]の設定(各種出力)





非階層的クラスタリング (k-means) - 実行結果

- 教師なし学習のクラスタリングでは、各クラスタの特徴は人間が解釈を行う必要がある。具体的には、各クラスタにおける説明変数の値傾向 (=クラスタ内での平均値) を確認していく
- ただし、クラスタ数が多すぎると、分析結果が複雑化し、解釈が非常に難しくなる

入力した説明変数

各口	
1	
=	
ノ	
h	
1	
の	
117	
均	
均	
疝	
- 112	

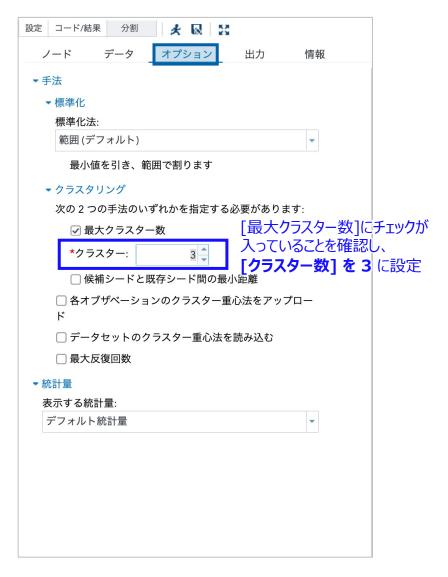
クラスター平均											
クラスター	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数				
1	0.2930672269	0.0580246286	0.7619047619	0.5061710881	0.0553935860	0.0267447575	0.0142857143				
2	0.2784474446	0.0629810558	0.4825136612	0.0907255767	0.0240046838	0.3600212438	0.1006557377				
3	0.5049847212	0.0648683352	0.2758441558	0.0754145226	0.0277498012	0.0154950554	0.0107532468				
4	0.29960784	の個のク	フ人夕釵	(E) (\$\frac{1}{3}\frac{1}\frac{1}{3}\frac{1}{3}\frac{1}{3}\frac{1}{3}\frac{1}{3}\frac{1}	M語果	の解釈	CD101333333				
5	0.3860294118	0.6093106133	プク目の	D特徴出	一曲六十八十二	= 件00000000	0.0000000000				
6	0.3120204604	0.0017710000	0.1102700020	0.0700012010	0.0200001012	0.00 1000 100 1	0.1084057971				
7	0.2184991446	0.058220 24	フラスタ	牧を減ら	.029/14==3	87271	0.0069351230				
8	0.3158757436	0.0641564482	0.7179026217	0.0765807884	0.0401375831	0.0180579322	0.0103370787				
9	0.2979302832	0.0613663152	0.8728395062	0.0446994495	0.4799697657	0.0000000000	0.0000000000				
10	0.3231707317	0.0731065649	0.4471544715	0.0885750963	0.0243902439	0.2246587603	0.4682926829				

各クラスターの標準偏

クラスター標準偏差										
クラスター	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数			
1	0.1332833775	0.0136267926	0.1462041770	0.1425972931	0.0955384223	0.0688703511	0.0395744560			
2	0.1234821079	0.0411433833	0.1166294759	0.0847113930	0.0342251454	0.1070186226	0.0663664562			
3	0.1186118589	0.0395683638	0.1347649153	0.0601729245	0.0404789000	0.0497285794	0.0417398457			
4	0.1174068148	0.0274275236	0.1282979071	0.1220312667	0.0339841904	0.0585922721	0.0425210042			
5	0.1515847656	0.2761522243	0.0816496581	0.0209185053	0.0552655674	0.0000000000	0.0000000000			
6	0.1272852521	0.0355211221	0.0696669625	0.0625609989	0.0358977458	0.1163699904	0.0817620401			
7	0.0733710808	0.0286117341	0.1212532235	0.0480523917	0.0531900103	0.0377270024	0.0312236852			
8	0.1466440802	0.0378032407	0.1618197979	0.0661433663	0.0569974549	0.0579437388	0.0376313479			
9	0.1496153680	0.0373506863	0.1630471163	0.0911274848	0.1648636801	0.0000000000	0.0000000000			
10	0.1416462697	0.0442681558	0.1277966287	0.0890310869	0.0374142118	0.1097536993	0.2084694515			



非階層的クラスタリング (k-means): クラスタ数変更 - 実行方法





非階層的クラスタリング (k-means): クラスタ数変更 - 実行結果

▼各クラスタの概要

各力	ラス	夕に	所属	する	データ	の数
			. / / 1 /1-49	ים כו		

クラスターの要約											
クラスター 度数FRMS オブザベーション 半径 最も近い クラスタ クラスター 重心間の距											
1	1881	0.0953	0.9847		2	0.4724					
2	2105	0.0967	0.9738		3	0.3352					
3	535	0.1143	0.9479		2	0.3352					

必要に応じて、 2段階クラスタリングも有効

▼各クラスタにおける説明変数の値傾向 (平均値)

	クラスター平均											
クラスター	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数					
1	0.3107076962	0.0632798060	0.7658692185	0.0818016574	0.0479770856	0.0204026016	0.0108665603					
2	0.3486866005	0.0637319316	0.2957086302	0.0895692150	0.0302002036	0.0047004729	0.0034584323					
3	0.2907641561	0.0639111035	0.3451713396	0.0871519303	0.0218195689	0.3048379491	0.1315887850					

クラスタ3は年齢が若め

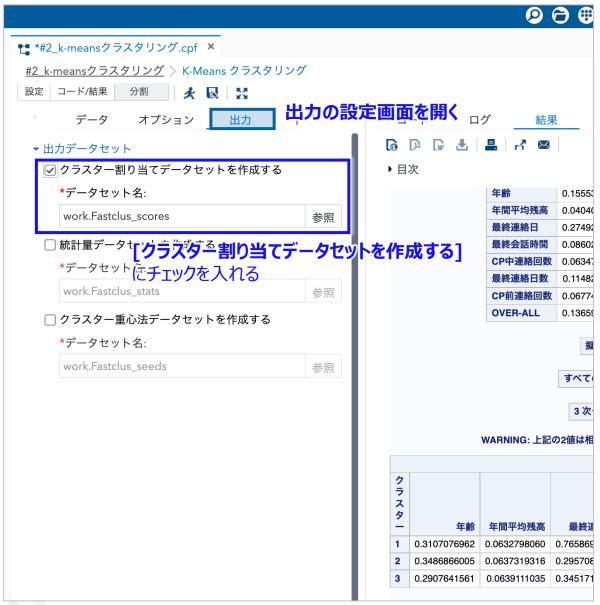
クラスタ2は 最後の会話が長い CP中連絡回数、最終連絡日数、CP前連絡回数が クラスタ2 <クラスタ1 <クラスタ3の順

▼各クラスタにおける説明変数の値傾向 (標準偏差)

クラスター標準偏差											
クラスター	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数				
1	0.1494764209	0.0363567636	0.1427522516	0.0851396155	0.0791419042	0.0668549819	0.0395526010				
2	0.1638910422	0.0440847172	0.1583476932	0.0878893150	0.0506141033	0.0262431917	0.0232405855				
3	0.1271532836	0.0387549810	0.1782289260	0.0809842315	0.0333549441	0.1303417255	0.1318504823				



(参考) クラスター番号のデータ化 と 追加分析 (1/3)





(参考) クラスター番号のデータ化 と 追加分析 (2/3)

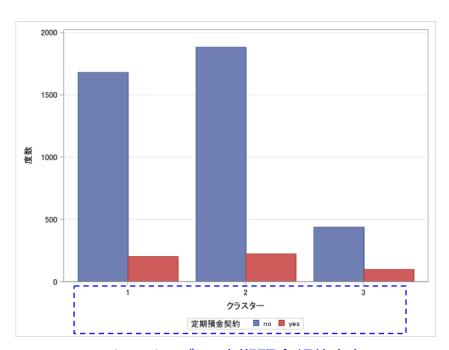




(参考) クラスター番号のデータ化 と 追加分析 (3/3)

- クラスター番号をデータ化することで、様々な切り口で層別した追加分析が可能となる
- 例えば、クラスターごとに「定期預金契約有無」の傾向を確認することができる

#2_k-meansクラスタリング 〉 棒グラフ
設定 コード/結果 分割 大 😡 🎇
データ 表示 情報 ノード
▼ データ
WORK.FASTCLUS_SCORES
♥フィルタ: (なし)
データを変更
・グラブの方向 (クラスターノードで出力したデータ)
○ 横方向
▼ 役割
*カテゴリ: (1 項目)
サブカテゴリ: (1 項目)
▲ 定期預金契約
▼ オプション:
グループ化バーの表示:
● クラスター (横方向)
○ 積み上げ
凡例の場所: 外側(デフォルト) ▼
メジャー: 度数カウント (デフォルト)
▶追加役割

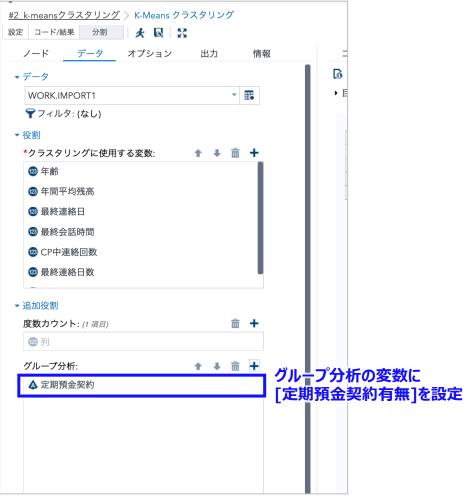


クラスターごとの定期預金契約有無



非階層的クラスタリング (k-means): グループ変数 - 実行方法

• 例えば 「契約者」 と 「未契約者」 で明確にグループを分けて、各々のグループ内でクラスタリング を実行したい場合は、「グループ変数」 を設定してクラスタリングを行う



非階層的クラスタリング (k-means): グループ変数 - 実行結果

- グループ変数を活用することで、「契約者」の中でのパターン分析、「未契約者」の中でのパターン 分析をそれぞれ行うことができる
- また、異なるグループ間でのクラスタ特性を比較することで新たな洞察を得られる可能性がある

クラスターの要約											
クラスター	シードから PMSシードから オブザベーション までの最大距離 超える カラスター 重心間の距离										
1	178	0.1252	0.9341		3	0.3519					
2	148	0.1381	0.9680		3	0.3617					
3	195	0.1479	0.8846		1	0.3519					

クラスター平均											
クラスター	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数				
1	0.2523959022	0.0835507389	0.7245318352	0.2529710261	0.0815828041	0.0207341754	0.0216693419				
2	0.2967011129	0.0988696446	0.1873873874	0.1611507455	0.0420094007	0.1081081081	0.1332046332				
3	0.4674208145	0.1121606234	0.5018803419	0.1566901639	0.0408026756	0.1301544832	0.0871794872				

クラスタ3は 年齢層が高め

クラスタ1は CP中連絡回数が特に多い

契約者は全般的に最終会話時間が長め

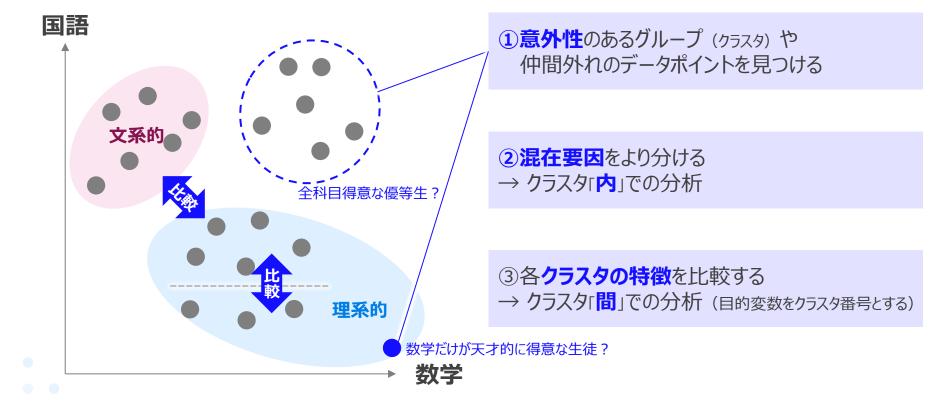
クラスターの要約 シードから **RMS** オブザベーション 最も近い クラスター クラスター 度数 クラスター 重心間の距離 1691 0.0921 0.9973 3 0.4710 436 0.1139 0.9584 3 0.3380 0.3380 1873 0.0932 0.9748

クラスター平均											
クラスター	年齢	年間平均残高	最終連絡日	最終会話時間	CP中連絡回数	最終連絡日数	CP前連絡回数				
1	0.3148185742	0.0632917973	0.7639858072	0.0691620318	0.0497592295	0.0169732909	0.0084210526				
2	0.2888196632	0.0639327358	0.3411314985	0.0737437327	0.0234506647	0.3079075835	0.1282568807				
3	0.3497222908	0.0631686716	0.2949991102	0.0775746143	0.0307811325	0.0036320087	0.0027976508				

52 **Sas**

非階層クラスタリングの活用方法のまとめ

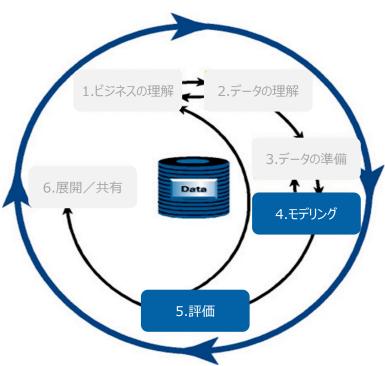
- クラスタリングでは、ある程度の「似たもの同士」がより分けられるため、同一クラスタ内でも存在する差異を分析したり、異なるクラスタ間での特徴の違いを分析することが有効である
- 一方、教師なし学習という特性から、「意外性」のあるグループやデータを見つけられることもある



ビッグデータ分析の進め方

• データマイニングの進め方に関する方法論「CRISP-DM」に基づいて、分析と評価を繰り返して試行錯誤しながら進めるのが一般的である

CRISP-DM: データマイニング方法論



(CRoss Industry Standard Process for Data Mining)

- 1.ビジネスの理解
- ビジネス、データマイニング目標の決定プロジェクトの立ち上げ
- 2.データの理解
- •データの収集
- •データの調査
- ・データ品質の検証
- 3.データの準備
- •データの選択や除外
- •データのクリーニング
- データの構築や統合
- 4.モデル作成
- •モデリング手法の選択
- •モデルの作成
- •モデルの評価

5.評価

- •データマイニングの結果の評価
- •プロセスの見直し
- •実行可能なアクションリストの作成
- 6.展開/共有
- ・業務への導入計画
- •モニタリング、メンテナンスの計画



まとめ

- 相関行列によるデータ観察
 - 相関分析を行うことにより、**変数間の関係性を全体把握**した
 - **目的変数別 (グループ変数設定) に相関分析**を行うことで、 異なるグループ間 (契約者/未契約者) で、変数の相関性に違いを見出した
- クラスター分析による分類(1):非階層的クラスタリング
 - 非階層的クラスタリング (k-means法) を適用することで、類似の顧客をグルーピングした
 - **クラスタ数をチューニング**することで、解釈しやすい結果を得た
 - 各クラスタにおける**説明変数の値傾向を確認することで、各クラスタの特徴を把握**した
 - クラスター番号を出力して元データに紐づけることで、別の視点で追加分析が行えた
 - **目的変数別 (グループ変数設定) にクラスター分析**を行い、 異なるグループ間 (契約者/未契約者) のクラスタ特性を比較することで、新たな洞察を得た

アンケートのお願い・ご質問

<u>10月19日 機械学習によるビッグデータ分析の手法-2</u>

今後の参考にさせていただくため、ぜひともアンケートにご協力を お願いします。

無記名所要時間目安: 1~3分

アンケートURL

https://sas.qualtrics.com/jfe/form/SV_1C6i14BbnisRffM



- ・本日のアーカイブは、2022年10月24日~2023年3月31日迄 視聴できます。
- ・本日の内容に関するご質問は、以下宛にご連絡ください。 que@datascience.co.jp

ご視聴ありがとうございました。

End of File