

より手軽に、より正確に、より大規模に

マイニング自動化への大きな一歩

Visual Mining Studio

次期バージョン (V7.1) のご紹介

2012年1月21日リリース

(株)数理システム
徐 良為

主な新機能

- **モデル最適化: パラメータチューニング、変数選択**
 - 最適なモデル構築に必要なパラメータ調整、及び説明変数の選択を自動的に行える
 - 試行錯誤の負担を大幅に軽減
 - 目的関数をユーザが自由に定義可能
 - メタヒューリスティック最適化アルゴリズム採用
- **VMX新機能**
- **ビジュアルプログラミング機能**
 - 行毎実行
 - パラメータ毎実行
 - より手軽に実現
- **自動欠損補填機能 (GUIインターフェース)**
 - 正常データの分布に従い、データの欠損部分を自動的に補填する
 - データの欠損処理、データフュージョンに利用される

主な新機能 (ユーザビリティ)

【スクリプト】 optimize関数、最適化関数

【全体】 全処理アイコンの立ち上げ速度改善 (大規模データ)

【行選択】 大規模データでも手軽に処理可能にした

【スクリプト】 下記の関数に、デフォルト値指定可能にした

- get_win_env
- get_usr_env
- get_prj_env

【スクリプト】 新規関数 get_scr_env

外部から、sys_proc_opt によって、スクリプトへ値を引き渡す機能を実現するため、スクリプト側に取り入れる機能

【Loop】 処理フロー上の繰り返しループ処理機能

【全体】 処理実行をしながら、他のタスクを干渉しないようにした

【DB連携】 DBに含まれる特殊な区切り文字に対応可能とした

【スクリプト】 read_file で固定長のテキストファイル内容を読み込み機能

【スクリプト】 長文スクリプト定義 (数万行) の処理速度が遅くなる問題を解消

【その他】 GUI機能改善、不具合フィックスなど多数

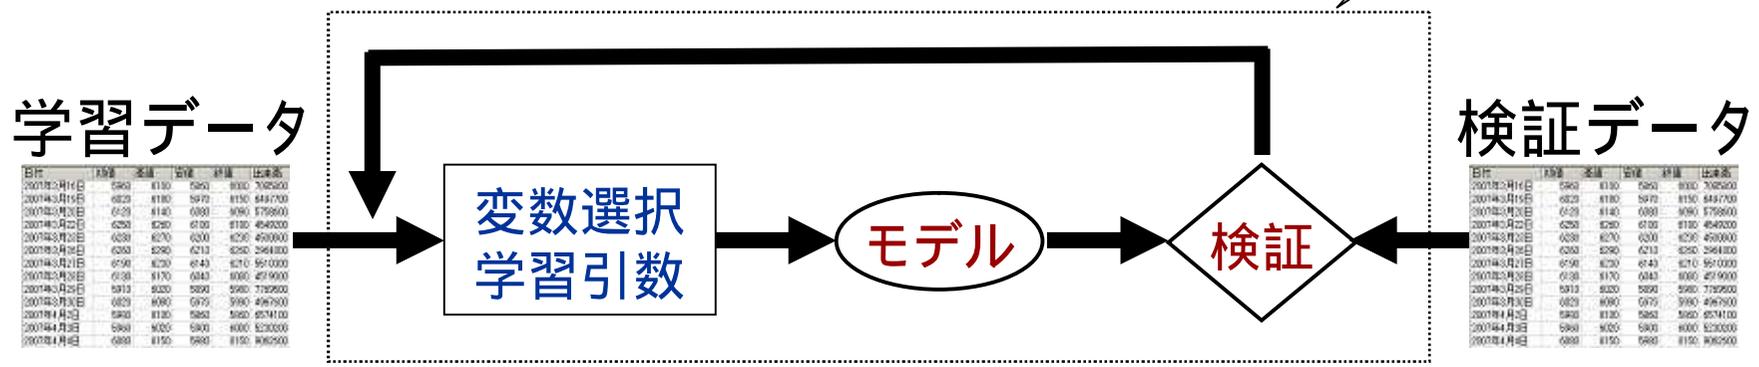
主要新機能のイメージ

モデル最適化支援関数

● モデル構築時の難点

- 手元にある観測サンプルのみで母集団を推定
- 通常、サンプルデータは誤差を含み、雑多である
- 事前に、知ることができないもの
 - ◇ 有力な説明変数
 - ◇ 問題にフィットした学習パラメータ、引数

試行
錯誤



モデル最適化支援関数

- モデル構築作業の定式化

$$\max_{v \subseteq V, p \in S} f(v, p, \text{train}, \text{test})$$

f: モデル構築、検証、モデルの評価値を算出

V: 説明変数全候補

p: モデル作成時に使用する引数

S: 引数候補集合

train: 学習用データ

test: 検証用データ

モデル最適化支援関数

- VMStudioの新関数

optimize(f, par, table, ...)

$$= \max_{opt} f(par, table, \dots)$$

f: モデル構築関数

(ユーザ定義可能な任意のスクリプト関数)

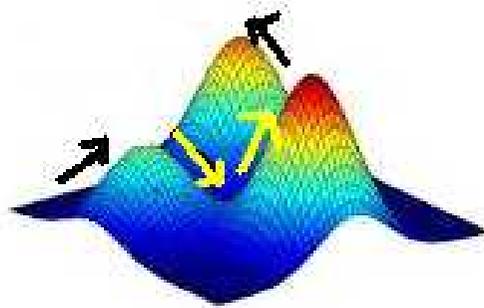
par: 変数候補、モデル作成引数候補など

table: データテーブル(複数可)

optimize: f が最大となるような opt セット(トップN)

モデル最適化支援関数

- optimize の実装について
 - f を単純な数式で表すことができない、微分不可
 - 厳密な最適解を求めるには、NP困難である
多項式の計算時間内で解くことの出来ない問題
 - 近似解を求めるしかない
 - 一種のメタヒューリスティックの山登り手法を採用



「optimize」の適用例

- 最適制御モデル(製造、風力発電、電力消費等)

$$y = f(x, z)$$

y: **出力**(例: 発電効率)

x: **制御可能**要因

S: xの選択可能な範囲(例: 向き、大きさ)

z: **制御不可**要因(風力、気温)



「optimize」の適用例

- 最適制御

一般に、**f** が理論上計算不可能(理想状態除く)

- データない場合、**実験計画法** (Experimental Design)
- データが集められた場合、**マイニングのモデル作成**

- **最適化**

$$\max_{x \in S} y = f(x, z)$$

微分不可、式表現なし、**近似解法**

VMX - Visual Mining eXpress新機能

パスワード | 設定 | ログアウト

Visual Mining eXpress

ホーム | 前処理 | モデリング | クラスタリング | アソシエーション分析 | 実行履歴 | ヘルプ

予測モデルの作成 [?] COMMENT

再計算 結果オプション

1. モデルの自動チューニング機能を導入！
(VMStudio の optimize 機能参照)
2. ユーザビリティの大幅向上 (VAP機能)

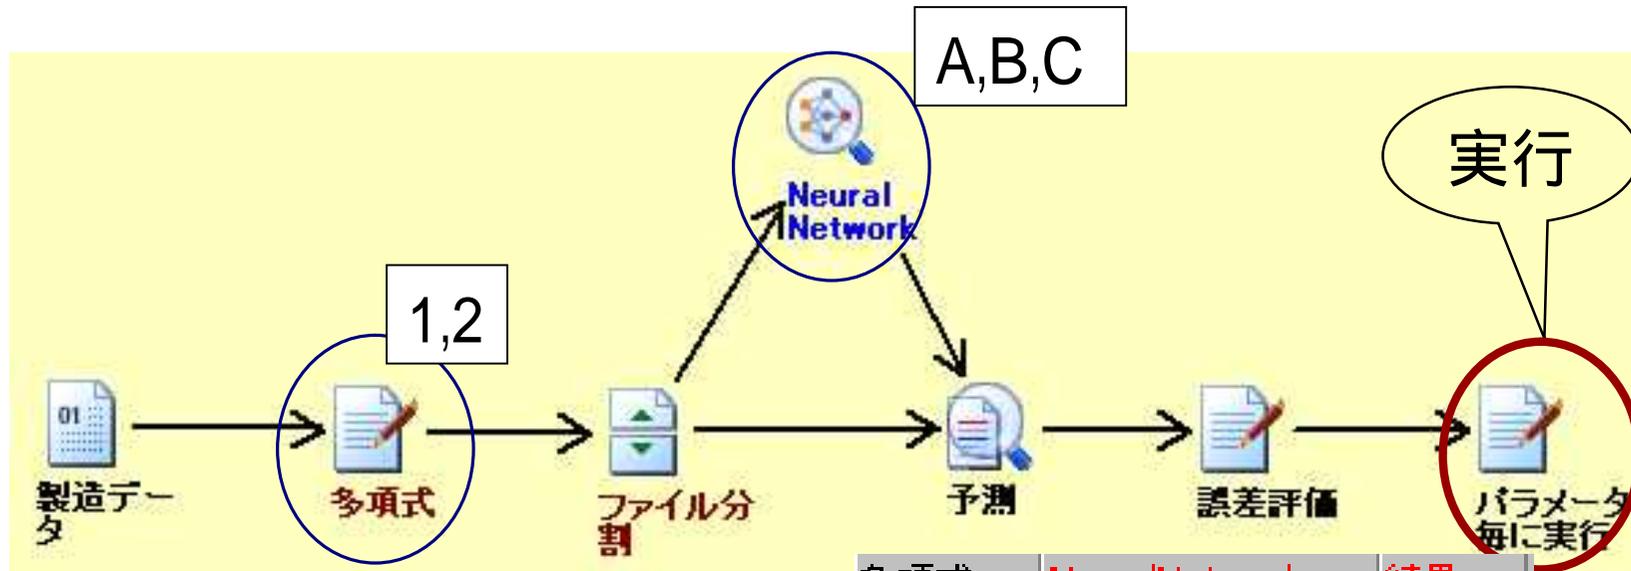
学習モデルの適合率

	学習回数	全体	H	L
1	1	69.9	83.838384	64.661654
2	2	74.5	77.631579	72.300469
3	3	80.3	78.378378	82.222222
4	4	83.8	84.705882	83.076923
5	5	86.8	87.719298	86.082474
6	6	86.0	85.795455	86.243386
7	7	88.8	88.202247	89.304813
8	8	89.3	89.655172	89.005236

- 長年蓄積されたマイニングの最新技術をWebブラウザから利用可能
- 煩雑なパラメータ設定、理解しにくいマイニング概念を一切省いて、初心者にも、データマイニング可能！

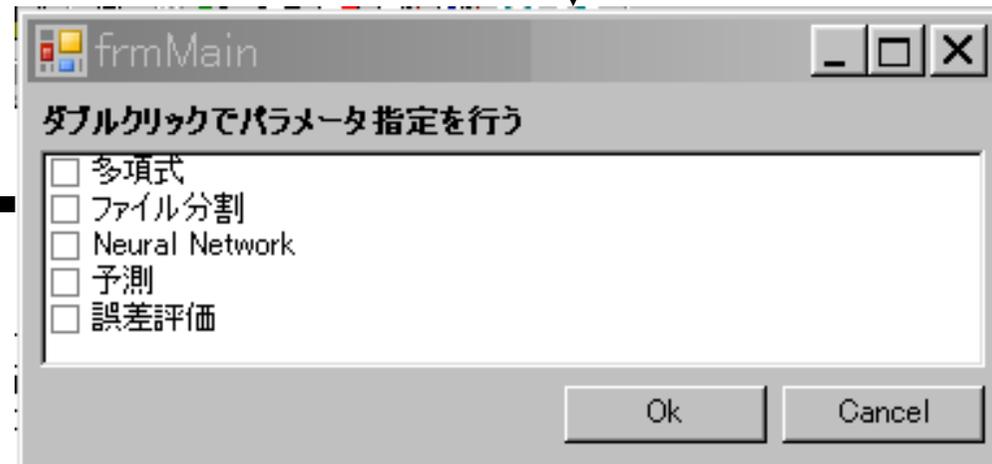
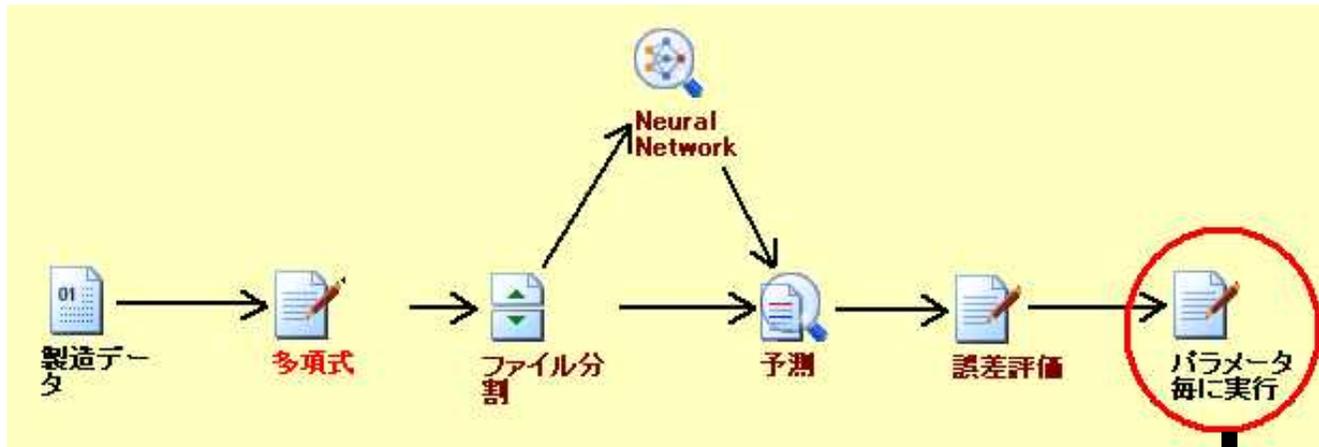
ビジュアルプログラミング

- 処理アイコンに複数選択肢を手軽に試す

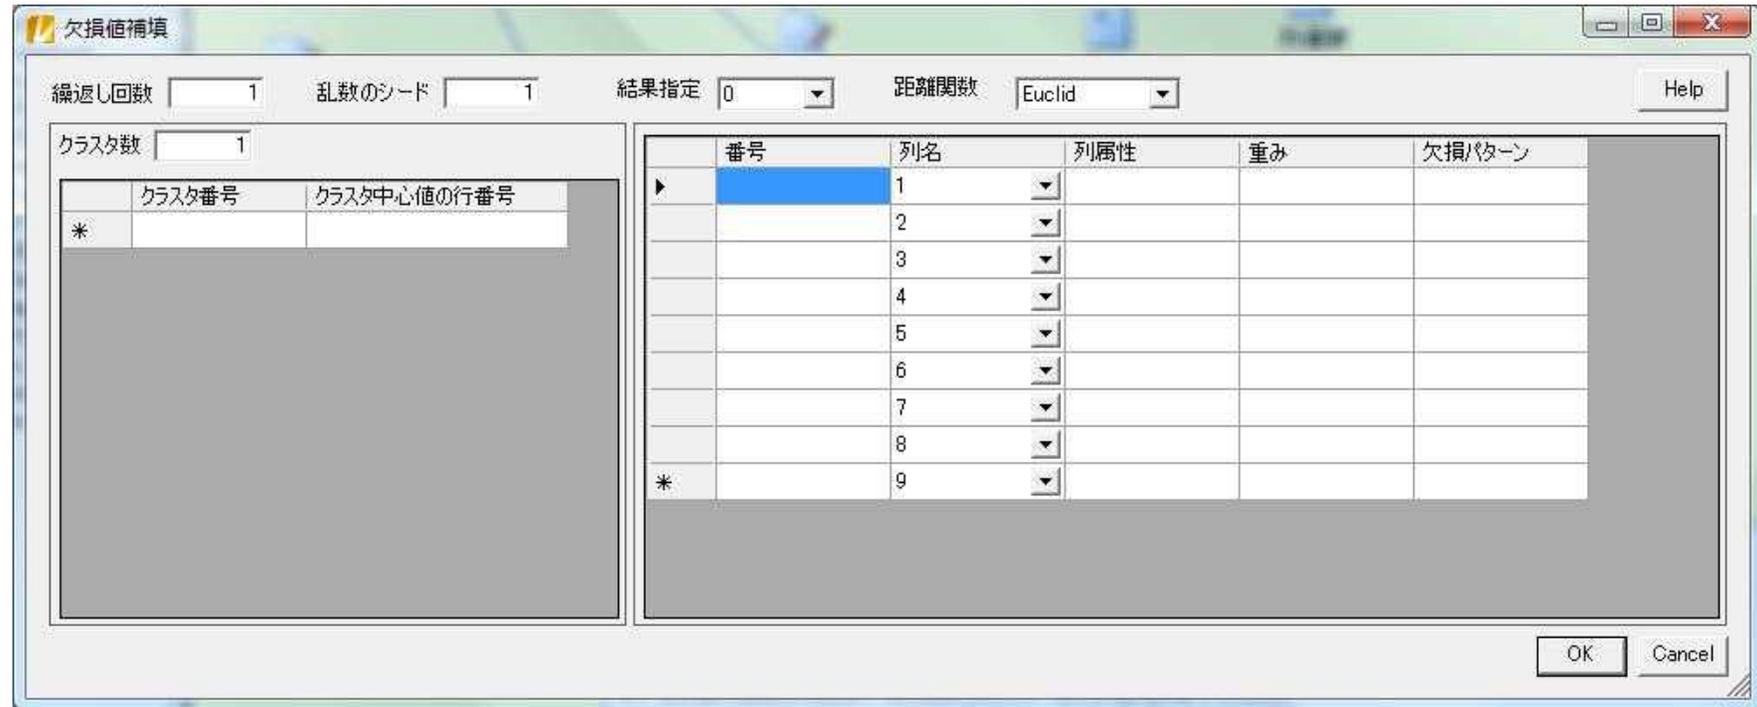


多項式	NerualNetwork	結果
1 A		...
1 B		...
1 C		...
2 A		...
2 B		...
2 C		...

ビジュアルプログラミング



自動欠損補填GUIツール



- 正常データの分布に従い、欠損部分の自動補填
- 欠損処理、データフュージョンに利用
- EMアルゴリズムを採用

後継バージョン

- より大規模に

- GB:ギガバイト

- 手軽なマイニング処理

- TB(PB):テラバイト(ペタバイト)

- Hadoop (MapReduce) との連携機能

- 無制限

- データストリームマイニング

- より手軽に

- VAP機能のGUI機能増強

- より正確に

- 新しいマイニング機能導入