

# インシリコ(コン 毒性予測の問題と

株式会社 インシリコ

# コンピュータ) による 解決に向けた提案

データ 湯田浩太郎

# インシリコ(コンピュータ)による毒性予測を 困難にする要因と問題点

## ◆毒性の特徴:

1. メカニズムが複雑で詳細不明
2. 多種多様な毒性

## ◇予測対象化合物の特徴:

1. 化合物の構造変化性が極めて高い
2. 予測対象化合物数が極めて多い

## ★予測における問題点

**予測率が低い !!**

# インシリコ(コンピュータ)予測へのアプローチ手法

## 1. データ解析によるアプローチ

---

基本技術:ケモメトリックス

- ・ コンピュータケミストリー
- ・ 統計／多変量解析／パターン認識等のデータ解析手法

## 2. 人工知能によるアプローチ

---

- ・ コンピュータケミストリー
- ・ 人工知能技術

## 3. 物理シミュレーションによるアプローチ

---

- ・ 物理方程式
- ・ シミュレーション技術

# データ解析によるアプローチに必要な技術

## 1. コンピュータケミストリー関連技術

化学関連情報をコンピュータ上で扱う為の技術

◇化学データ解析を行う時前に必要な技術

① 化合物構造式関連技術

一次元、二次元、三次元化合物構造式の創出と取り扱い技術

② 化合物構造式情報を数値データ(パラメータ)に変換する技術

トポロジカルパラメータ、トポグラフィカルパラメータ、物理化学パラメータ、理論化学パラメータ、物性パラメータ、部分構造パラメータ、その他

## 2. データ解析関連技術(統計／多変量解析／パターン認識)

種々数値データを用いて解析目的に従ってデータ解析(予測等)を行う技術

◇化学データ解析を行う技術

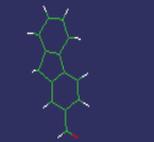
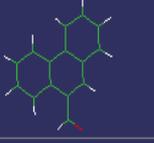
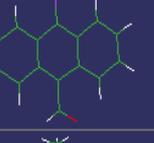
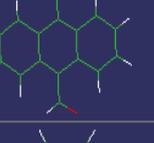
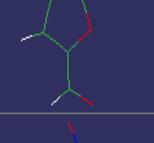
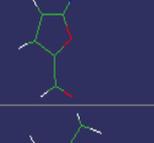
① 種々データ解析基本手法

クラス分類、フィッティング、マッピング、クラスタリング、チャート、他

② 解析目的に合わせたアプローチ

構造-活性／物性／毒性相関、インシリコスクリーニング、脱毒性デザイン、他



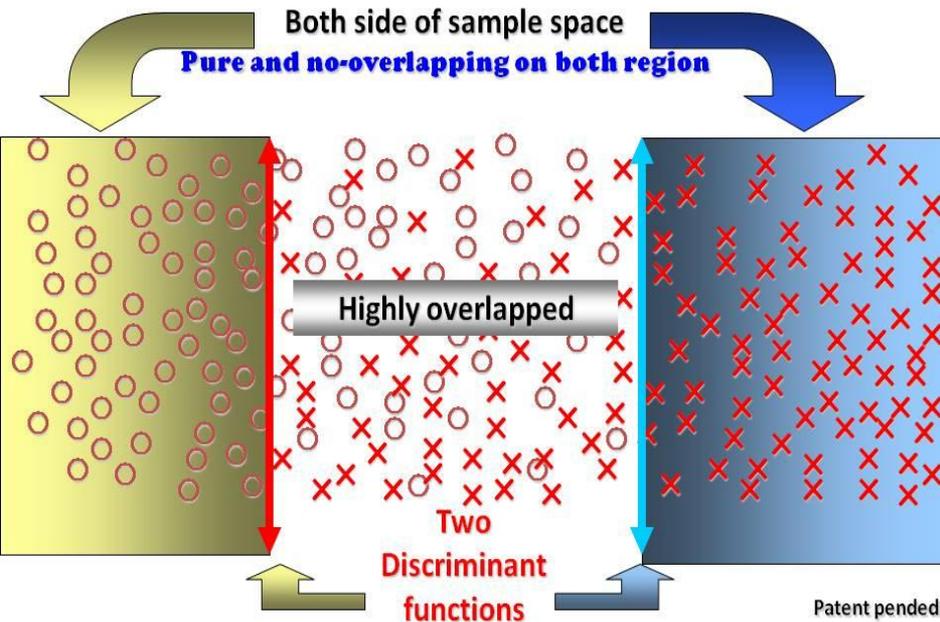
Row ID	Whole Molecule	Name (Whole Molecule)	Molecular V (Whole Mol)	#Bromir (Whole)	#Carboi (Whole)	#Chlorir (Whole)	#Fluorin (Whole)	#Haloge (Whole)	#Hetero (Whole)	#Hydroc (Whole)	#Hydroc (Whole)	#Nitroge (Whole)	#Oxyge (Whole)	#Sulphu (Whole)	Chi 0 (a (Whole)	Chi 1 (b (Whole)	Chi 2 (p (Whole)	Chi (Whole)
5		2-FLUORENECARBOXALDEHYDE	194.23	0	14	0	0	0	1	1	0	0	1	0	10.251	7.3813	6.4554	0.80
6		PHENANTHRENE-9-CARBOXALDEHYDE	206.24	0	15	0	0	0	1	1	0	0	1	0	10.958	7.8982	6.7246	0.74
7		10-CHLORO-9-ANTHRALDEHYDE	240.69	0	15	1	0	1	2	1	0	0	1	0	11.828	8.3257	7.1556	0.87
8		10-METHYLANTHRACENE-9-CARBOXALDEHYDE	220.27	0	16	0	0	0	1	1	0	0	1	0	11.828	8.3257	7.1556	0.87
9		FURFURAL	96.086	0	5	0	0	0	2	2	0	0	2	0	5.1129	3.4319	2.5587	0.20
10		5-NITRO-2-FURALDEHYDE	141.08	0	5	0	0	0	5	2	0	1	4	0	7.5605	4.7364	4.0914	0.70
11		5-METHYLFURFURAL	110.11	0	6	0	0	0	2	2	0	0	2	0	5.9831	3.8257	3.1925	0.49

# KY (K-step Yard sampling)法の提案

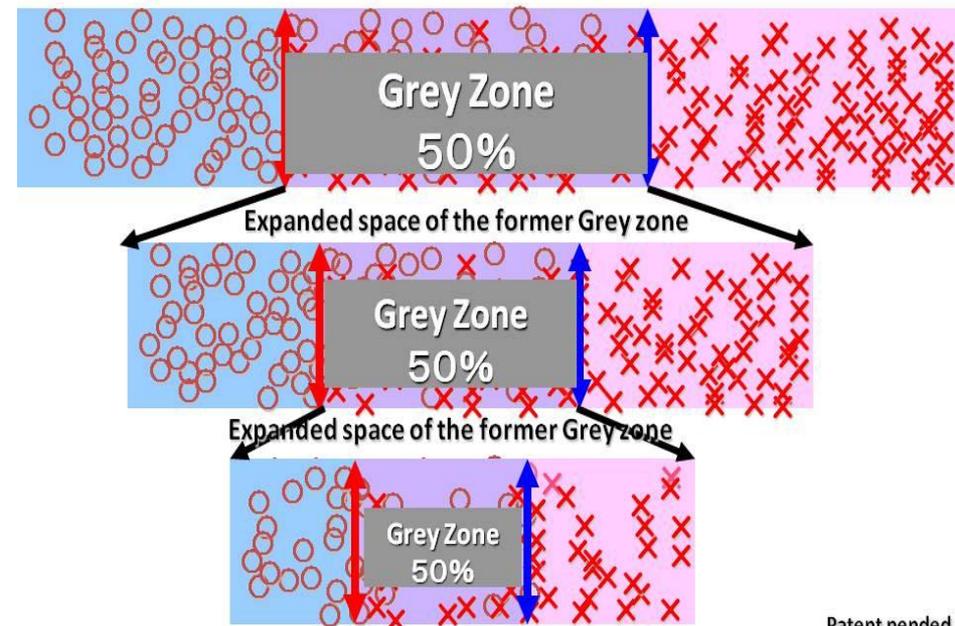
- ◇ 究極のデータ解析手法 (1)
- ◆ 2クラス分類: 完全分類 (100%) 達成

Ames試験: 6965サンプルの100%分類実現

## First basic concept of KY method Spatial region on sample space



## Second basic concept of KY method Multi-steps for 100% classification



# KY (K-step Yard sampling)法の提案

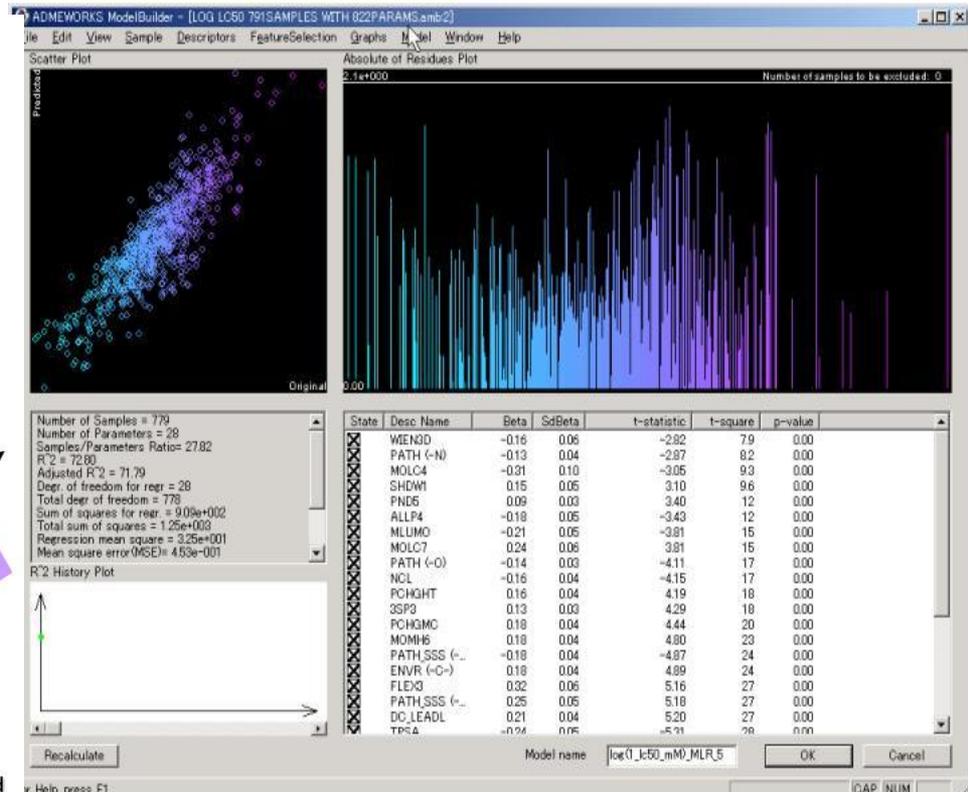
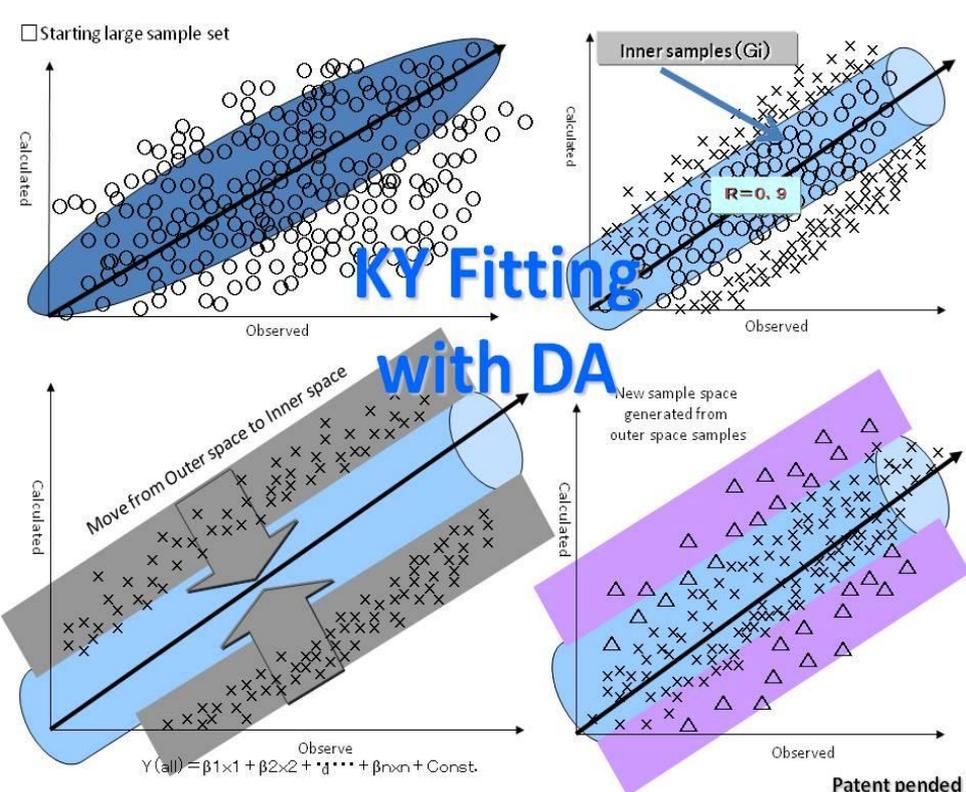
## ◇ 究極のデータ解析手法 (2)

### ◆ フィッティング: 極めて高い相関および決定係数の実現

Fish: 96 hours LC50、 Number of samples: 791、 Log(1/LC50\_Mm) (Max/Min) : 6.376 / -2.963

サンプル数: 779、 パラメータ数: 28、 信頼性指標: 27.8

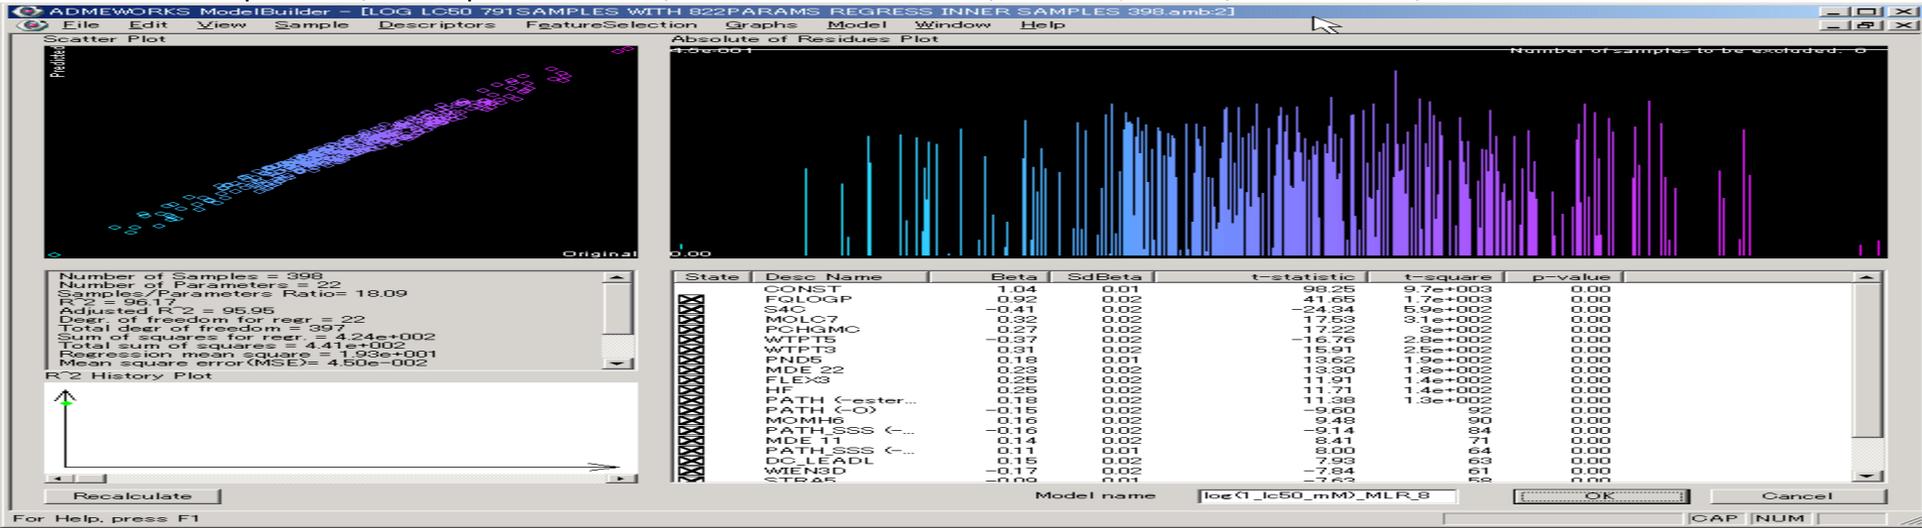
R2: 72.8、 R: 85.3、 F値: 71.7、 クロスバリデーション: 69.6



# ◇ Fitting KY method Step1 (Inner sample set)

## Step1: Inner sample set

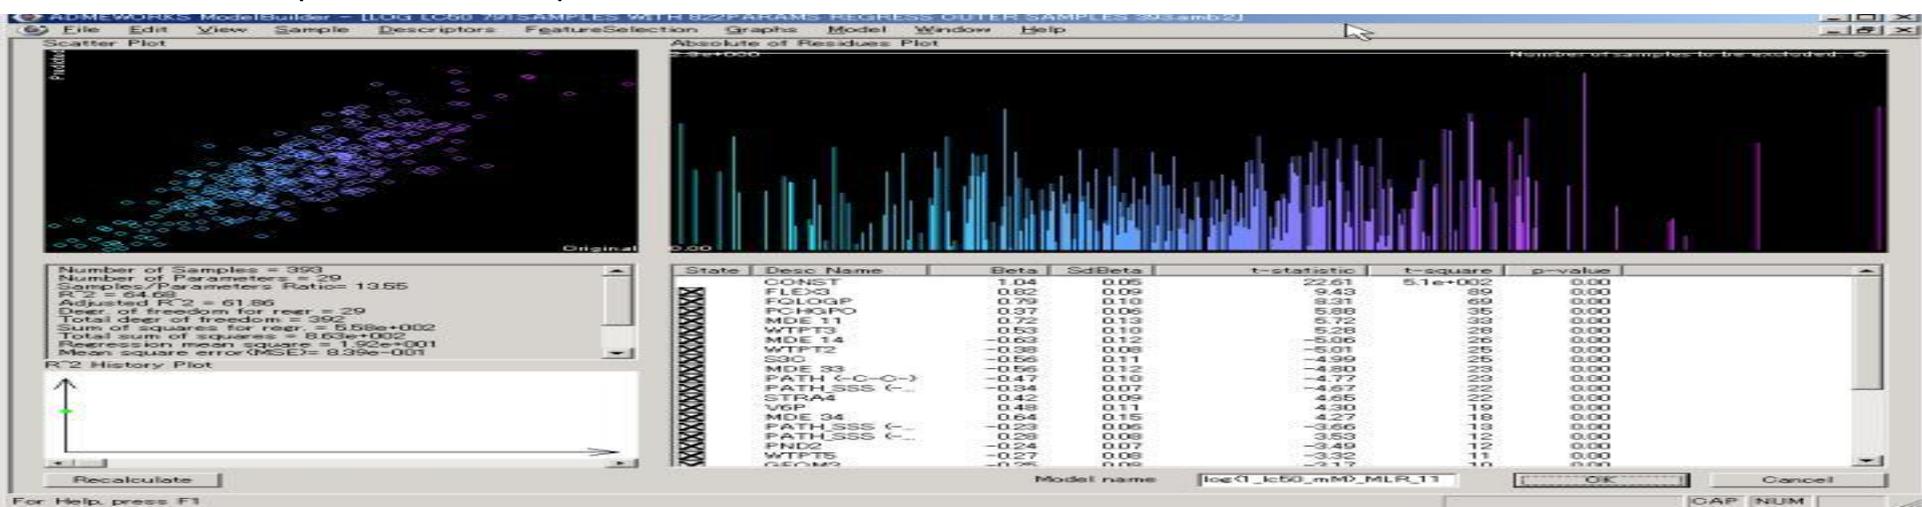
Number of samples: 398, Used parameters: 22, Confidence ratio: 18.1, **R2: 96.2, R: 98.1**, F-value: 428, CV: 94.4



# ◇ Fitting KY method Step1 (Outer sample set)

## Step1: Outer sample set

Number of samples: 393, Used parameters: 29, Confidence ratio: 13.6, **R2: 64.7, R: 80.4**, F-value: 22.9, CV: 57.5

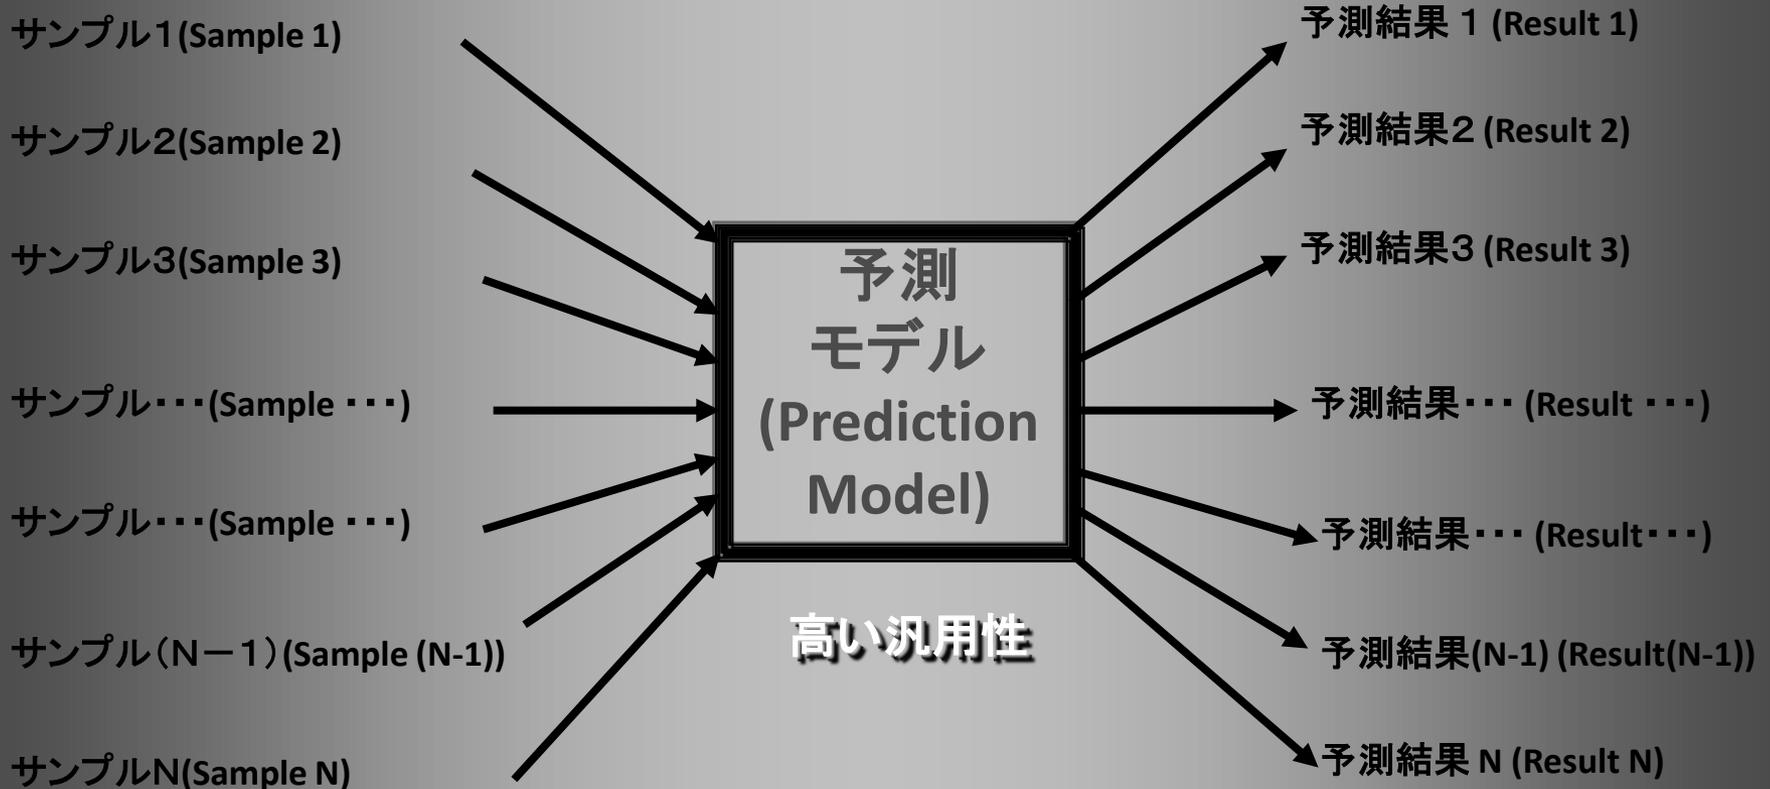


# 従来手法による予測アプローチ

(Prediction approach by traditional method)

特徴: 全てのサンプルを対象とした予測モデルの構築

Features: Generate a prediction model which can handle all samples



利点 (Merit) : 少ない数の予測モデル作成で済む (Small number of prediction models are generated)

難点 (Weakness) : 予測率の向上が困難である (Difficult to achieve high prediction ratio)

# 「テーラーメイド・モデリング」の提案

## 特徴: サンプル単位での予測モデルの構築

Features: Generate a prediction model which is designed for only 1 samples



# インシリコ(コンピュータ)による予測の提案

## ◆ 最大の問題点: 予測率が低い

- ◇ 解決手法の提案: 「KY法」や「テーラーメイドモデリング」の導入による分類率や予測率の総合的な向上を目指す

### \* 2クラス(バイナリ)データ(ポジ/ネガ)

1. 分類率は100%を実現可能(KY法)  
予測率は分類率を超えることは無い。従って分類率を最大まで高める。
2. サンプル数フリーなので、どんなにサンプル数が増えても解析精度は落ちず、予測信頼性はサンプル数の増大に伴い向上する。
3. KY法独自のステップ情報により、予測信頼性の向上がさらに促進される。
4. 「テーラーメイドモデリング」は予測率の向上が期待される手法となる。

### \* 連続データ

1. 極めて高い相関および決定係数値を実現
2. サンプル数が増えても、高い相関/決定係数を実現
3. KY法独自のステップ情報により、予測信頼性の向上がさらに促進される。