

ベイズ推論に基づく製品信頼性の知識形成とつくり込み技法

経営研究科 経営専門職専攻
貝瀬 徹

ものづくり（品質・信頼性・安全性の概要）

経験知識（DRBFM）

③知識科学

設計・工程；

工学（狭義）；要求機能の実現
Ex. 材料力学，熱流体力学，
機械力学（振動）

要求機能（品質）のレベル

変化点・変更点

故障；機能喪失

不規則現象

故障物理

安全性

①演繹的方法

②帰納的方法

時間

0

t

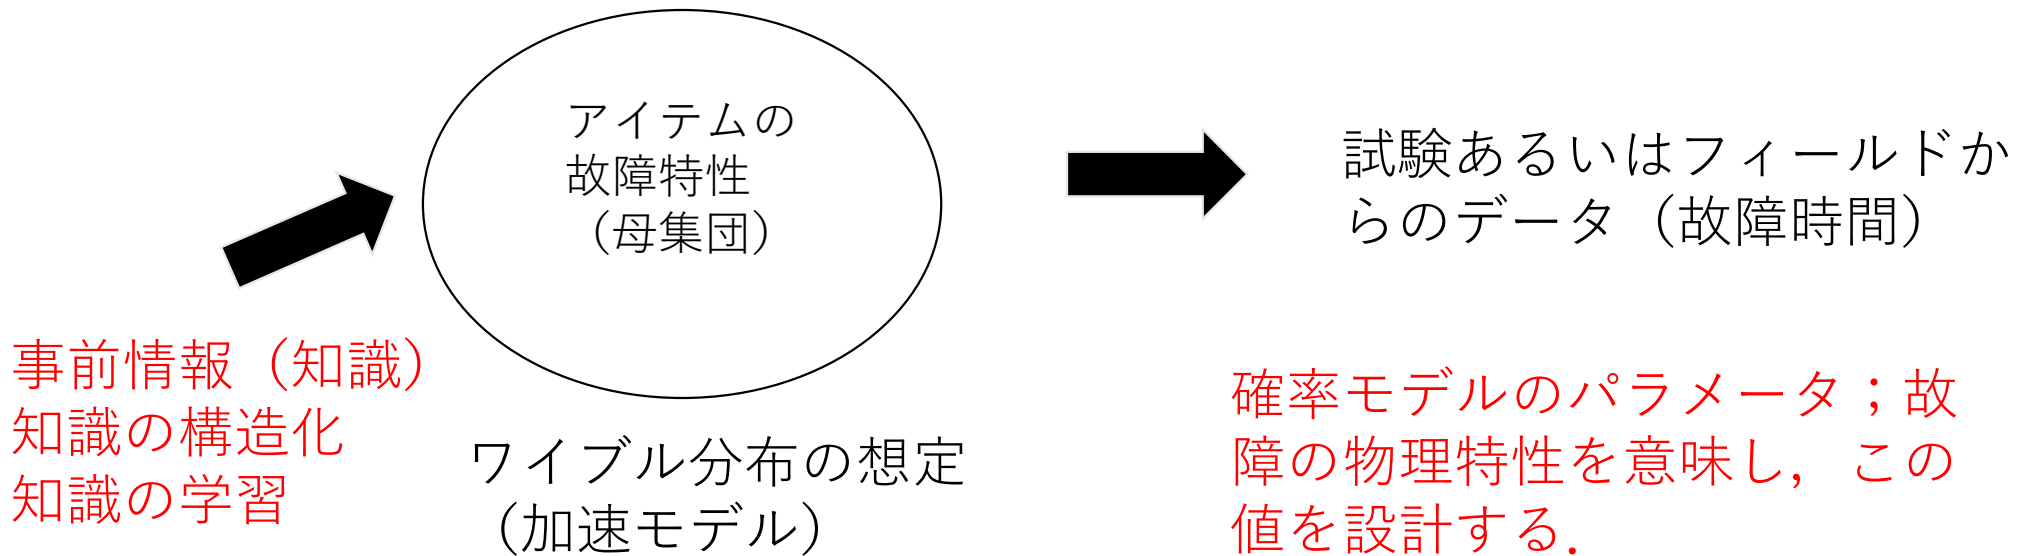
設計段階での信頼性のつくり込み

- 製品の信頼性
 - 出荷時点（要求機能を実現する品質を保証）以降に不具合が発生（故障による機能喪失）しないようにする。
- 永遠に故障しない製品は無理であり，設計段階で信頼性をつくり込む必要がある。
 - 要求される使用時間，要求される使用環境のもとでも故障しない性質（確率に基づく信頼度）を向上させる。
- 設計段階での信頼性のつくり込み：事前知識，知識構造化，学習
 - ①演繹的方法（科学法則） ②帰納的方法（データ）
 - ③知識科学（ノウハウ）

信頼性解析（集団のデータによる推測）

アイテムの信頼性 →得られたデータから
(統計学による母集団の推測)

信頼度（故障特性）を把握する。



個別の解析（推測）；ベイズおよび機械学習

- アイテムに負荷される環境因子は個別ごとに違う。
→ アイテムの使用状況や環境といった履歴による影響
(動的因子の影響特性を把握)

Ex.

振動, 温度, 湿度, その他 → 時間依存の変化




- 個別解析 ⇒ 動的因子の影響を考慮した設計・保全の改善
IoTによるモニタリング

モデルベース：故障同定への応用（ベイズ、機械学習など）

隠れた状態の推定

- ベイズ推論（階層モデルなど複雑なモデル構成も含む）：
データと事前情報を組合わせた解析
（データの他に知識も使うことが可能）
データと事前情報により更新された事後情報を導く
- ベイズ推論による機械学習：
事後情報と新たなデータにより学習が可能
- 予測：
学習された情報に基づいて未知の予測が可能

ワイブル分布のベイズ推定 (R StanによるMCMC)



```
data{
  int N;
  real X[N];
}

parameters{
  real<lower=0> m;
  real<lower=0> eta;
}

model{
  for(i in 1:N){
    X[i] ~ weibull(m,eta);
  }
}

# 事前情報の設定
m ~ uniform(0,10);
eta ~ uniform(0,1000);
}
```

モデリングと推定法の構成

- 階層ベイズモデリング（観測方程式、状態方程式、事前知識）

$$f(t_i | \lambda_i, \beta) = \lambda_i \beta t_i^{\beta-1} \exp[-\lambda_i t_i^\beta] \quad (1)$$

$$g(\lambda_i | a, b_i) = \frac{b_i^a}{\Gamma(a)} \lambda_i^{a-1} \exp[-\lambda_i b_i] \quad (2)$$

$$k(\beta) = \frac{h^c}{\Gamma(c)} \beta^{c-1} \exp[-\beta h] \quad (3)$$

$$\pi(a) = \frac{1}{\gamma} \quad (4)$$

状態推定を含むベイズ推論

ベイズ統計学の基本

事後分布 \propto 尤度 \times 事前分布

⇒ 階層ベイズモデルの各層で事後分布、周辺尤度を求める。変分ベイズと事前情報（制約条件）の下でパラメータ推定を行う。

モデル選択（情報規準EIC）

⇒ 事前情報を含めたモデルの良さを評価

まとめ

- 集団解析から個別解析への必要性を重視
- 信頼性に関する階層ベイズモデリング
- ボルツマンマシン・モデリング（深層学習の組み込み）
- 状態推定を含むベイズ推論の構成
- MCMCを用いたパラメータ推論のアルゴリズム
- 情報量規準EICの適用

⇒ モデルベースによる事前情報を用いた信頼性のつくり込み技法