

AIを活用した 遠隔型の耐故障制御システムの構築

自然科学学域 中村幸紀

産業機器の故障：生産ラインの停止や事故の要因



正確で速やかな故障検知が必要

IoT技術の進展により通信機能を有するセンサや制御装置が開発され、遠隔メンテナンスへの応用が期待



本研究：ネットワークを介した故障診断技術の開発

ソフトセンシング(状態推定)による故障検知

※ソフトセンシング:

- ・対象の数理モデル(e.g. 運動方程式, 回路方程式)
- ・センサ出力

から対象の状態を推定すること

応用：遠隔型の故障検知システム

課題

対象の数学モデルの構築と同定

NN

実機検証

故障検知アルゴリズムの開発

非線形フィルタリング

GPUの活用
遅延計測

実時間推定

実験環境の構築


センサ信号の送受信

理論：ソフトセンシング

1. 実験環境の構築

- ・無線を介してアームの関節角情報を送信
- ・故障検知アルゴリズムをMatlabにより実装

1. 実験環境の構築



センサ出力をPCに表示(無線通信による信号の送受信できることも確認)

2. 故障検知アルゴリズムの開発


対象の数学モデルに基づくフィルタリング手法

フィルタリング	数学モデル (状態方程式)	数学モデル (出力方程式)	雑音
線形カルマンフィルタ	線形	線形	正規性
拡張カルマンフィルタ	非線形※ (※線形近似可)	非線形※ (※線形近似可)	正規性
アンサンブル カルマンフィルタ	非線形	線形	システム雑音(任意) 観測雑音(正規性)
粒子フィルタ	非線形	非線形	任意

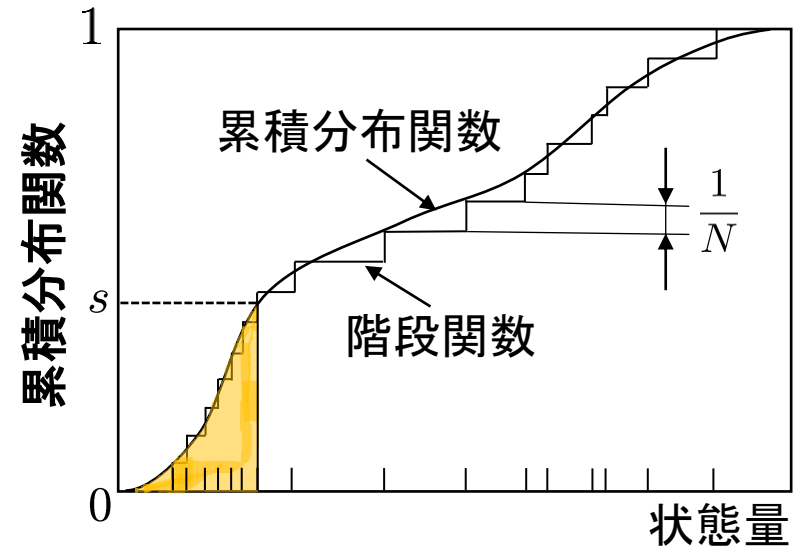
粒子フィルタ




- 対象の状態量の確率分布を粒子で近似するアルゴリズム
- 非線形なシステム, 雑音の分布が非ガウスのモデルに対しても適用可能
- それぞれの粒子が状態量と尤度をもつ



▶
積分



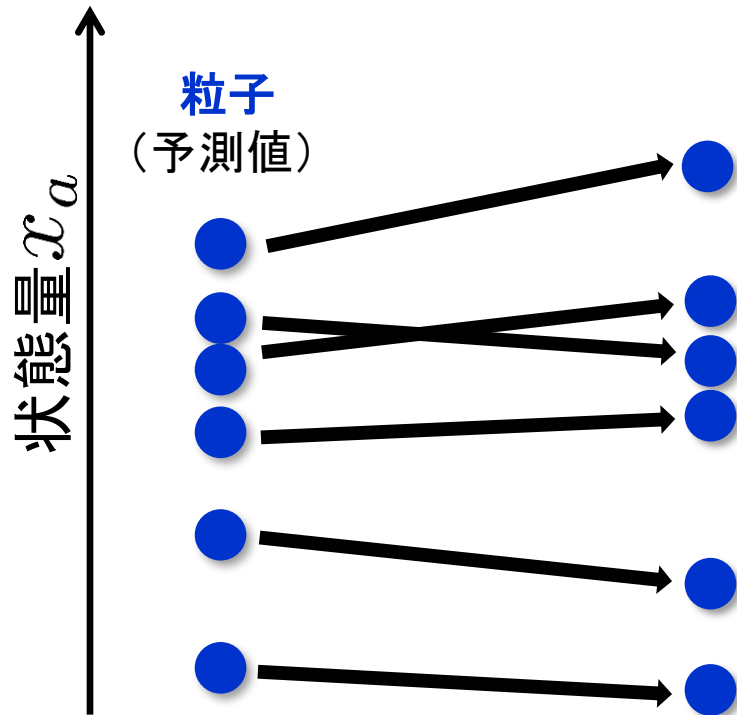
粒子フィルタのアルゴリズム



粒子フィルタのアルゴリズム(予測)



予 測



状態量 x_a の時間変化を数学モデルより算出


粒子フィルタのアルゴリズム(尤度計算)



尤度: センサ出力 y が得られたときの状態量 x_a の尤もらしさ.
条件付き確率 $p(y|x_a)$

状態量 x_a

尤度計算




※円が大きいほど
尤度が高い

粒子フィルタのアルゴリズム(リサンプリング)

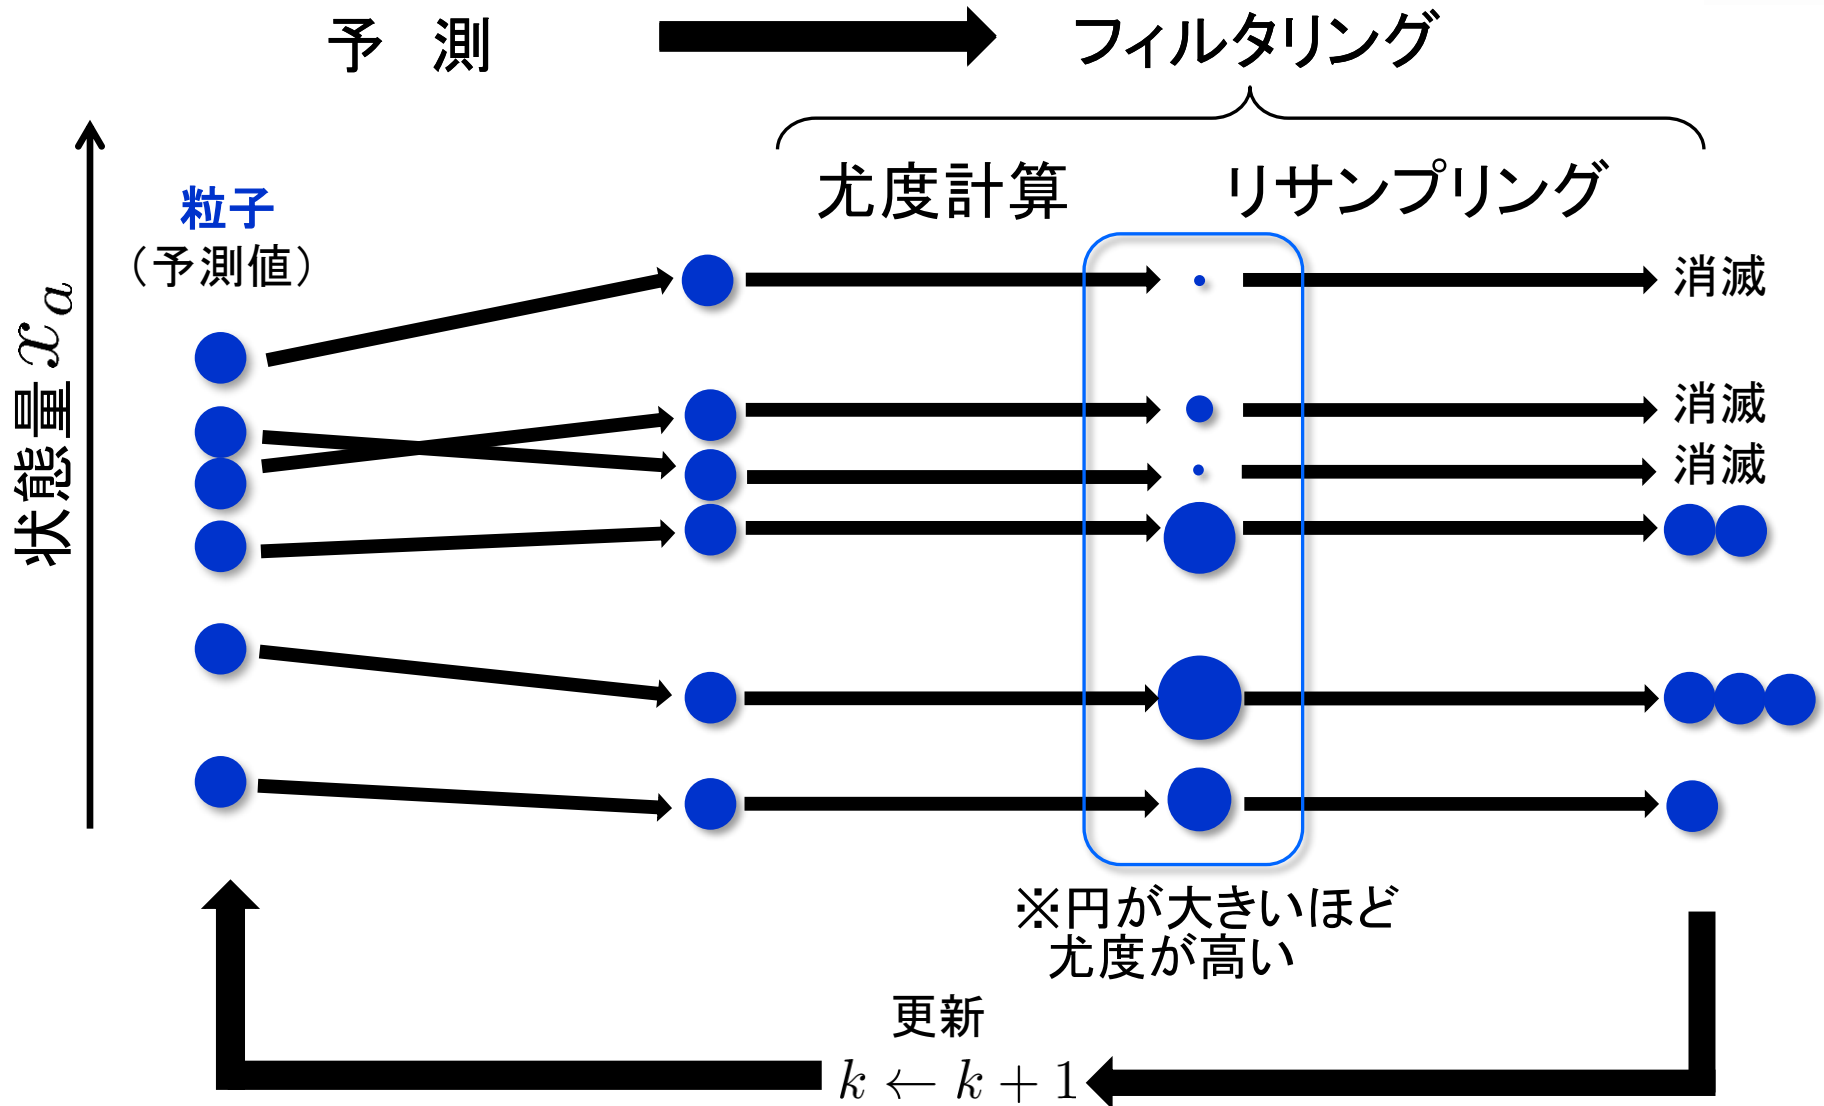


OKAYAMA UNIV.



尤度の高い粒子ほど複製を多く作成

粒子フィルタのアルゴリズム



2. 故障検知アルゴリズムの開発

課題：通信遅延が発生し、ネットワークの利用状況に応じて
遅延時間が不規則に変動
(故障検知の精度低下の要因)



対策：タイムスタンプ(信号の送信時刻情報)に基づく推定法※



本研究：故障検知へ応用したアルゴリズムの開発

故障検知のアルゴリズム



対象の数学モデル: 離散時間非線形システム

$$x(k) = f(x(k-1), \theta, u(k), v(k)) \quad k = 1, 2, \dots$$

$$y(k) = h(x(k), \xi) + w(k)$$

- 状態量: $x \in \mathbb{R}^n$
- パラメータ: $\theta \in \mathbb{R}^{m_1}, \xi \in \mathbb{R}^{m_2}$
- 入力: $u \in \mathbb{R}^l$
- システム雑音: $v \in \mathbb{R}^n$ (確率密度関数 \tilde{v} は既知)
- 出力: $y \in \mathbb{R}^p$
- 観測雑音: $w \in \mathbb{R}^p$ (確率密度関数 \tilde{w} は既知)
- 遅延: d (遅延の最大値 h_d は既知)

仮定: 遅延 d は時変かつ有界 ($h_d = \max_{k \in \mathbb{N}} d(k) < \infty$)

故障検知のアルゴリズム

対象の数学モデル: 離散時間非線形システム

$$x(k) = f(x(k-1), \theta, u(k), v(k)) \quad k = 1, 2, \dots$$

$$y(k) = h(x(k), \xi) + w(k)$$

- 状態量: $x \in \mathbb{R}^n$
- パラメータ: $\theta \in \mathbb{R}^{m_1}, \xi \in \mathbb{R}^{m_2}$
- 入力: $u \in \mathbb{R}^l$
- システム雑音: $v \in \mathbb{R}^n$ (確率密度関数 \tilde{v} は既知)
- 出力: $y \in \mathbb{R}^p$
- 観測雑音: $w \in \mathbb{R}^p$ (確率密度関数 \tilde{w} は既知)
- 遅延: d (遅延の最大値 h_d は既知)

仮定: 遅延 d は時変かつ有界 ($h_d = \max_{k \in \mathbb{N}} d(k) < \infty$)

出力 y からセンサの故障検出を行う

故障検知のアルゴリズム

対象の数学モデル

$$x(k) = f(x(k-1), \theta, u(k), v(k)) \quad k = 1, 2, \dots$$

$$y(k) = h(x(k), \xi) + w(k)$$



センサの故障検知

$$y(k) = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_p) h(x(k), \xi) + w(k)$$

$\alpha_1, \alpha_2, \dots, \alpha_p$: センサ故障の有無を判別するパラメータ
(検知パラメータ)

$$\tilde{h}(x(k), \tilde{\xi}) = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_p) h(x(k), \xi)$$

$$y(k) = \tilde{h}(x(k), \tilde{\xi}), \quad \tilde{\xi} = \begin{bmatrix} \xi & \alpha_1 & \alpha_2 & \dots & \alpha_p \end{bmatrix}^T$$

$\tilde{\xi}$ を推定することでセンサの故障を検知

故障検知のアルゴリズム

検知パラメータ: センサ故障の有無を表すパラメータ

$$y(k) = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_p)h(x(k), \xi) + w(k)$$



センサ正常時 $\alpha_i = 1$

センサ故障時 $\alpha_i = 1$ とは限らない

例: $y(k) = \alpha_1 x(k) + w(k)$

$y, x \in \mathbb{R}$ (スカラ)



故障: $y(k) = y(k_f), k \geq k_f$

k_f : 故障時間

$$y(k_f) = \alpha_1 x(k) + w(k), k \geq k_f$$

この場合 $\alpha_1 = 1$ とは限らない

本手法: 検知パラメータ α_i の値により故障の有無を判断


故障検知のアルゴリズム

$$x(k) = f(x(k-1), \theta, u(k), v(k))$$

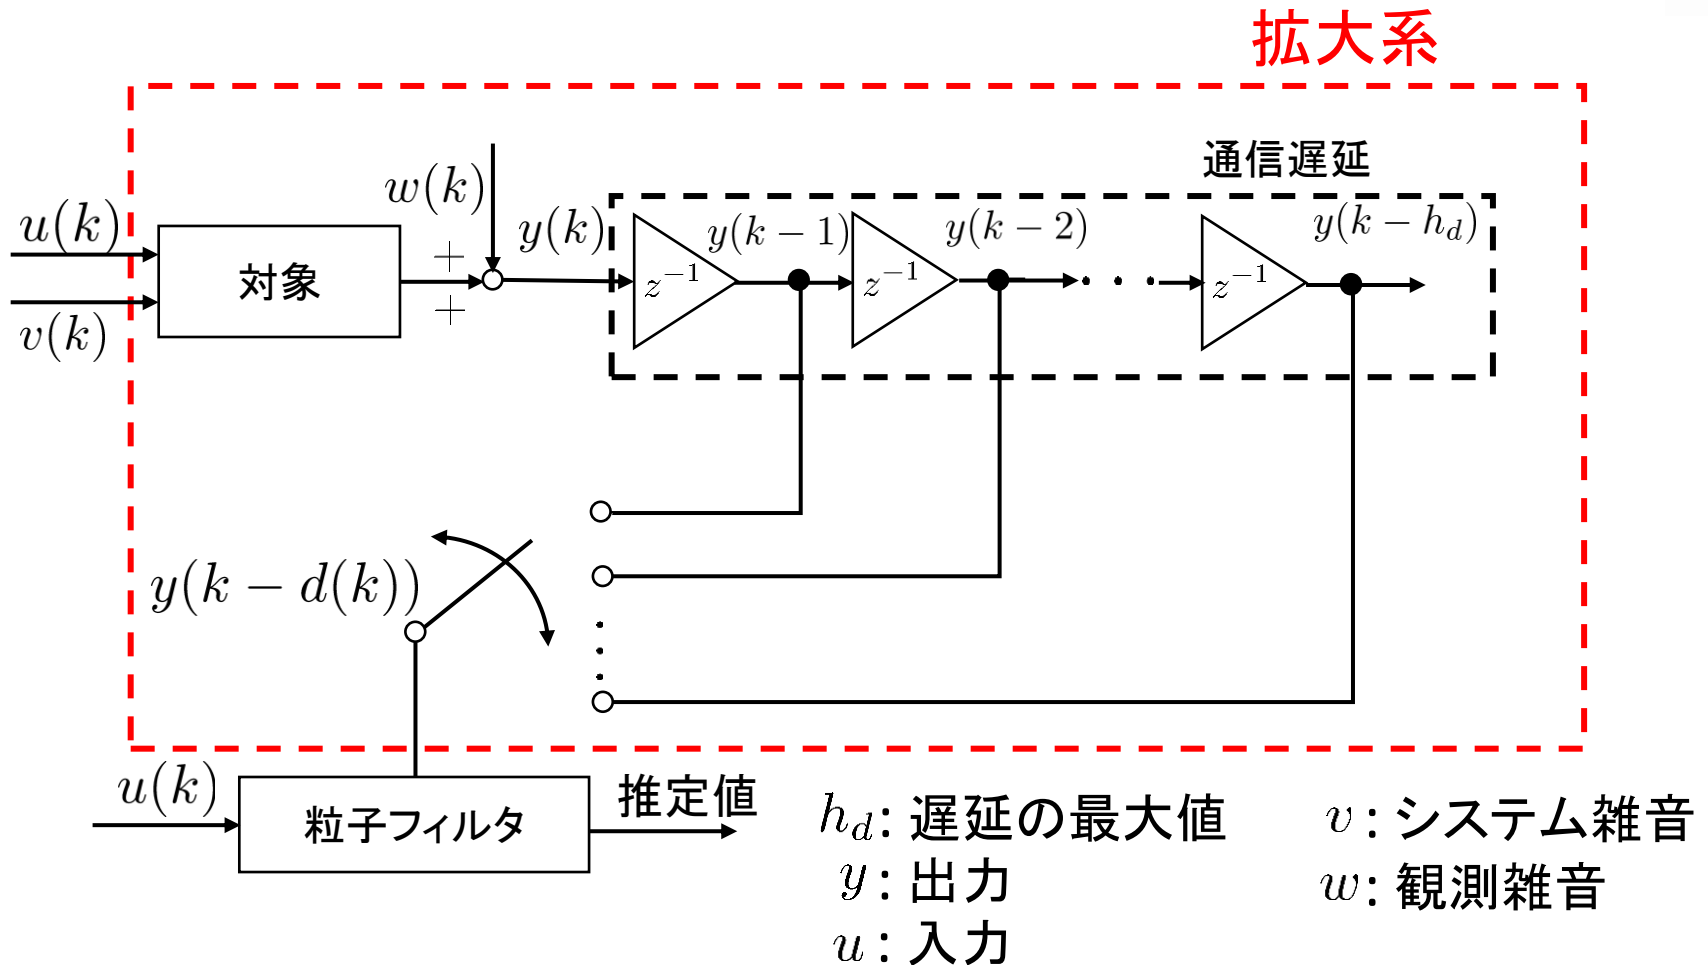
$$y(k) = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_p) h(x(k), \xi) + w(k)$$

↑
故障検出に用いる
パラメータ

- センサ正常時検出パラメータ α_i は1
- センサ故障によりパラメータ α_i が変化
- 検出パラメータ α_i の変化を
粒子フィルタにより推定し,
推定値に基づいて故障を検知



推定対象の記述



拡大系に対して推定を行う

- 拡大系の状態ベクトル x_a

$$x_a(k) = \left[x^T \quad \theta^T \quad \xi^T \quad y^T(k-1) \quad \cdots \quad y^T(k-h_d) \quad \alpha \right]^T$$

$$\alpha = \left[\alpha_1 \quad \alpha_2 \quad \cdots \quad \alpha_p \right]^T \quad \text{検知パラメータ}$$

- 拡大系の数学モデル

$$x_a(k) = f_a(x_a(k-1), u(k), v_a(k)) \quad v_a(k) = \left[v^T(k) \quad w^T(k) \right]^T$$

$$y(k-d(k)) = C_a(d(k))x_a(k) + q_a(k) \quad q_a: \text{通信時に加わる雑音}$$

$$f_a(x_a(k-1), u(k), v_a(k)) = \begin{bmatrix} f(x(k-1), \theta, u(k), v(k)) \\ \theta \\ \xi \\ \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_p)h(x(k), \xi) + w(k) \\ y_d(k) \\ \alpha \end{bmatrix}$$

$$y_d(k) = \begin{bmatrix} y^T(k-1) & y^T(k-2) & \dots & y^T(k-h_d+1) \end{bmatrix}^T$$

$$C_a(d) = \begin{bmatrix} \mathbf{0}_{p \times r_1} & I_p & \mathbf{0}_{p \times r_2} \end{bmatrix}$$

$$r_1 = n + m_1 + m_2 + pd - p \quad r_2 = p(h_d - d)$$


$$y(k - d(k)) = C_a(d(k))x_a(k) + q_a(k)$$

C_a が遅延 d に応じて変化するため未知

▶ 数学モデルを用いる粒子フィルタの適用が困難

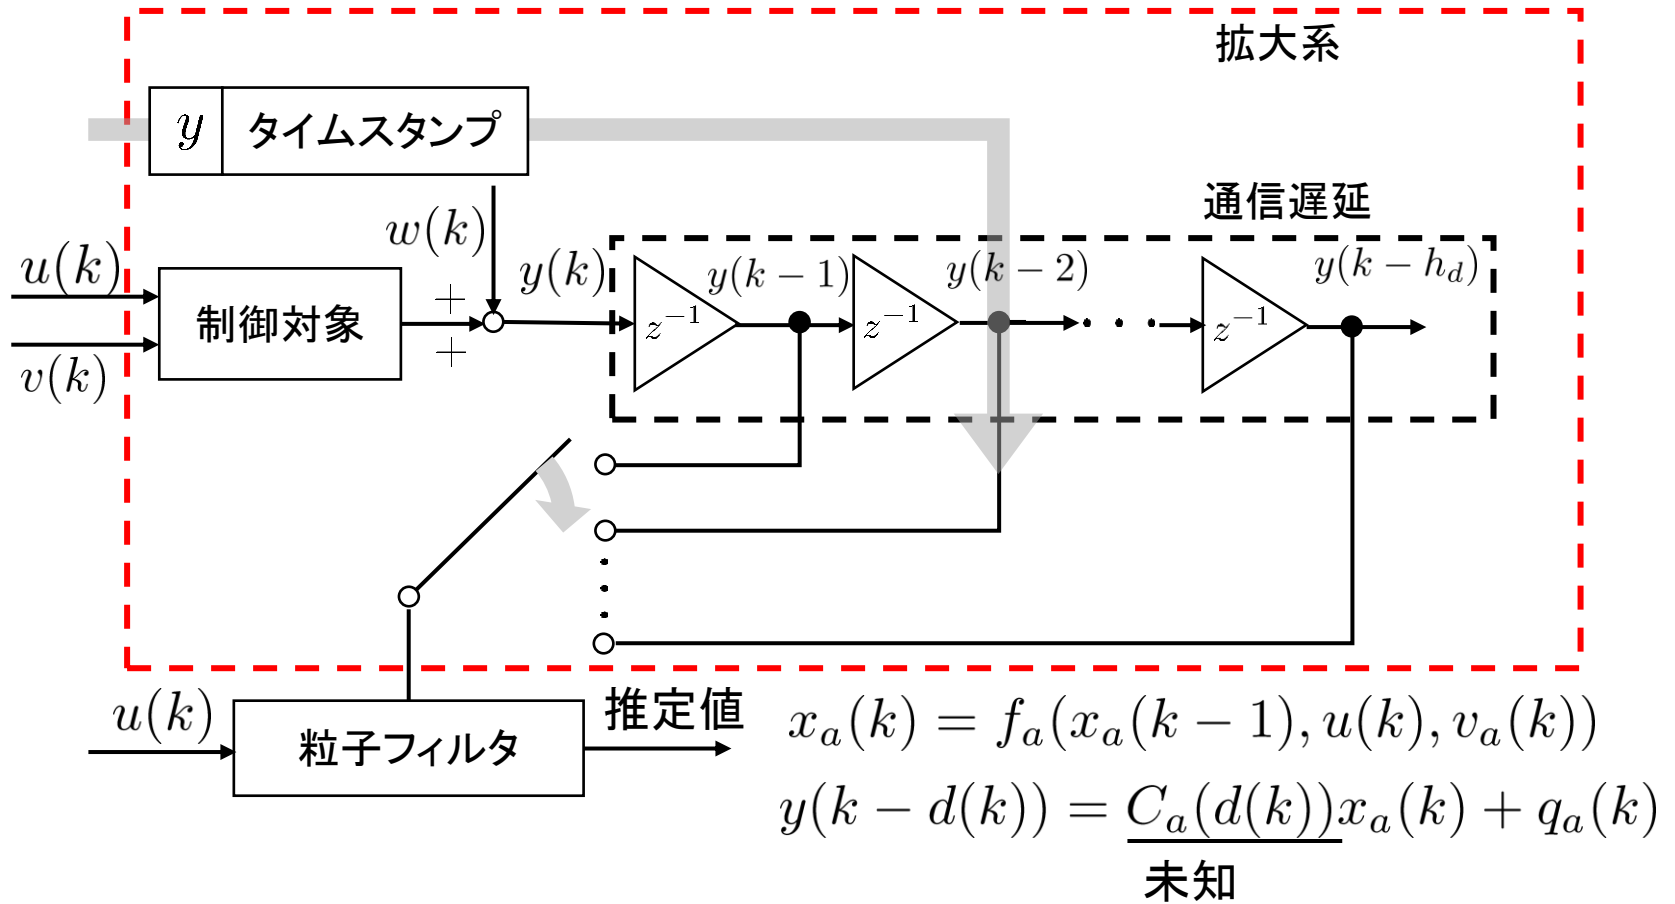
タイムスタンプ(送信時刻情報)

- 送信側は出力の送信時にタイムスタンプを付加して送信
- 受信側は出力の受信時に現在時刻とタイムスタンプの差から遅延 d を計測

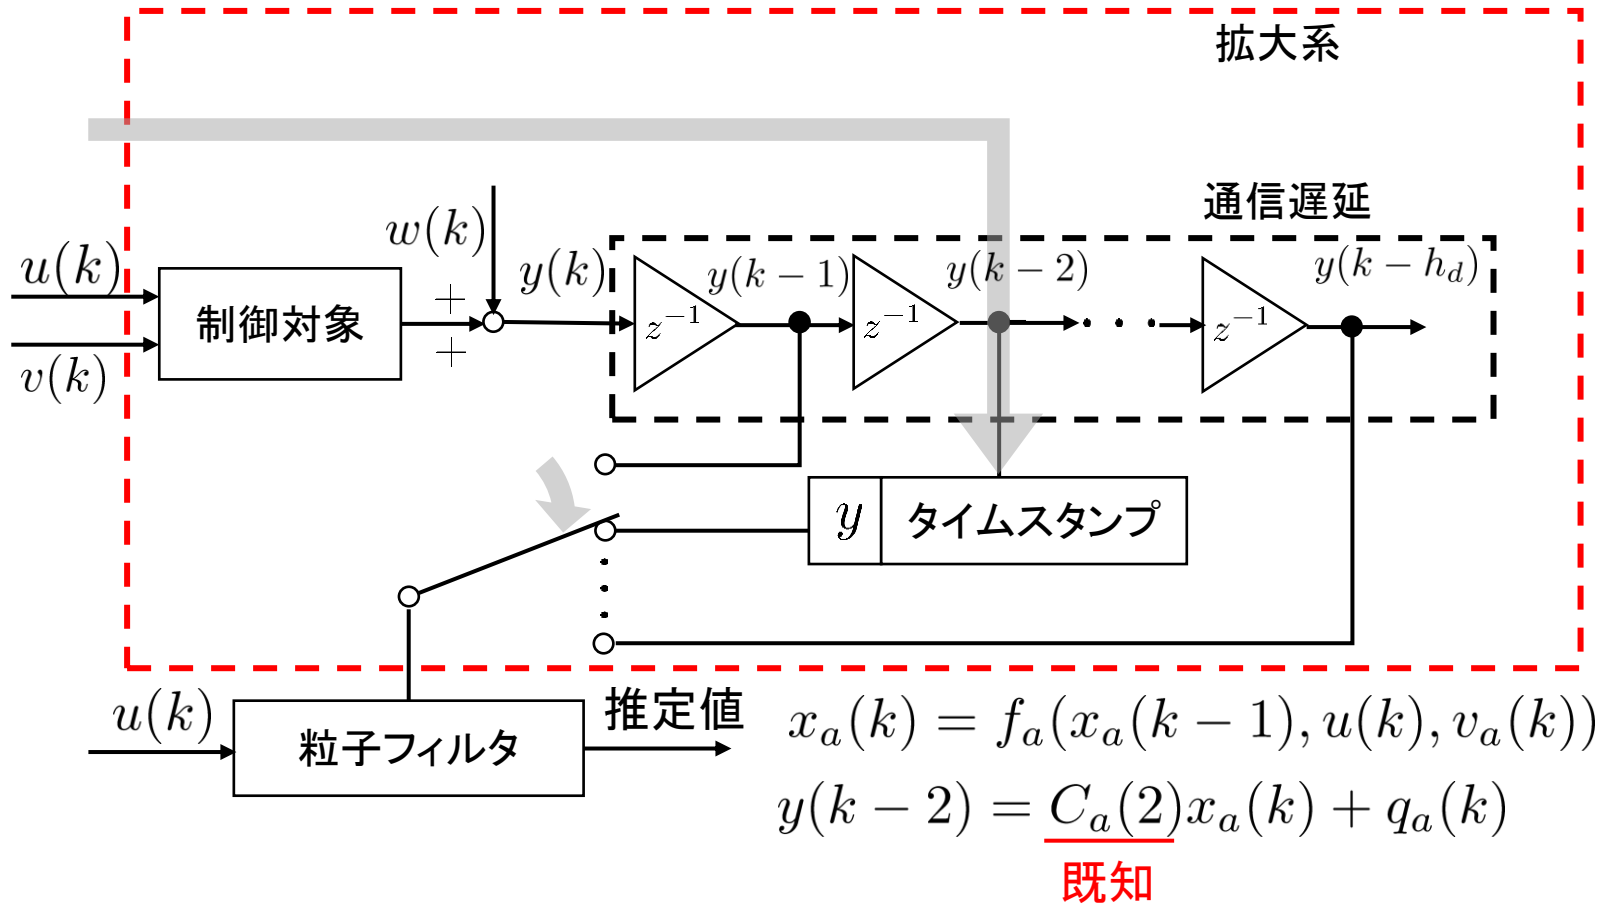


受信時刻	$k = 4$	$k = 5$	$k = 6$
出力	$y(2)$	$y(1)$	$y(3)$
遅延	$d = 2$	$d = 4$	$d = 3$

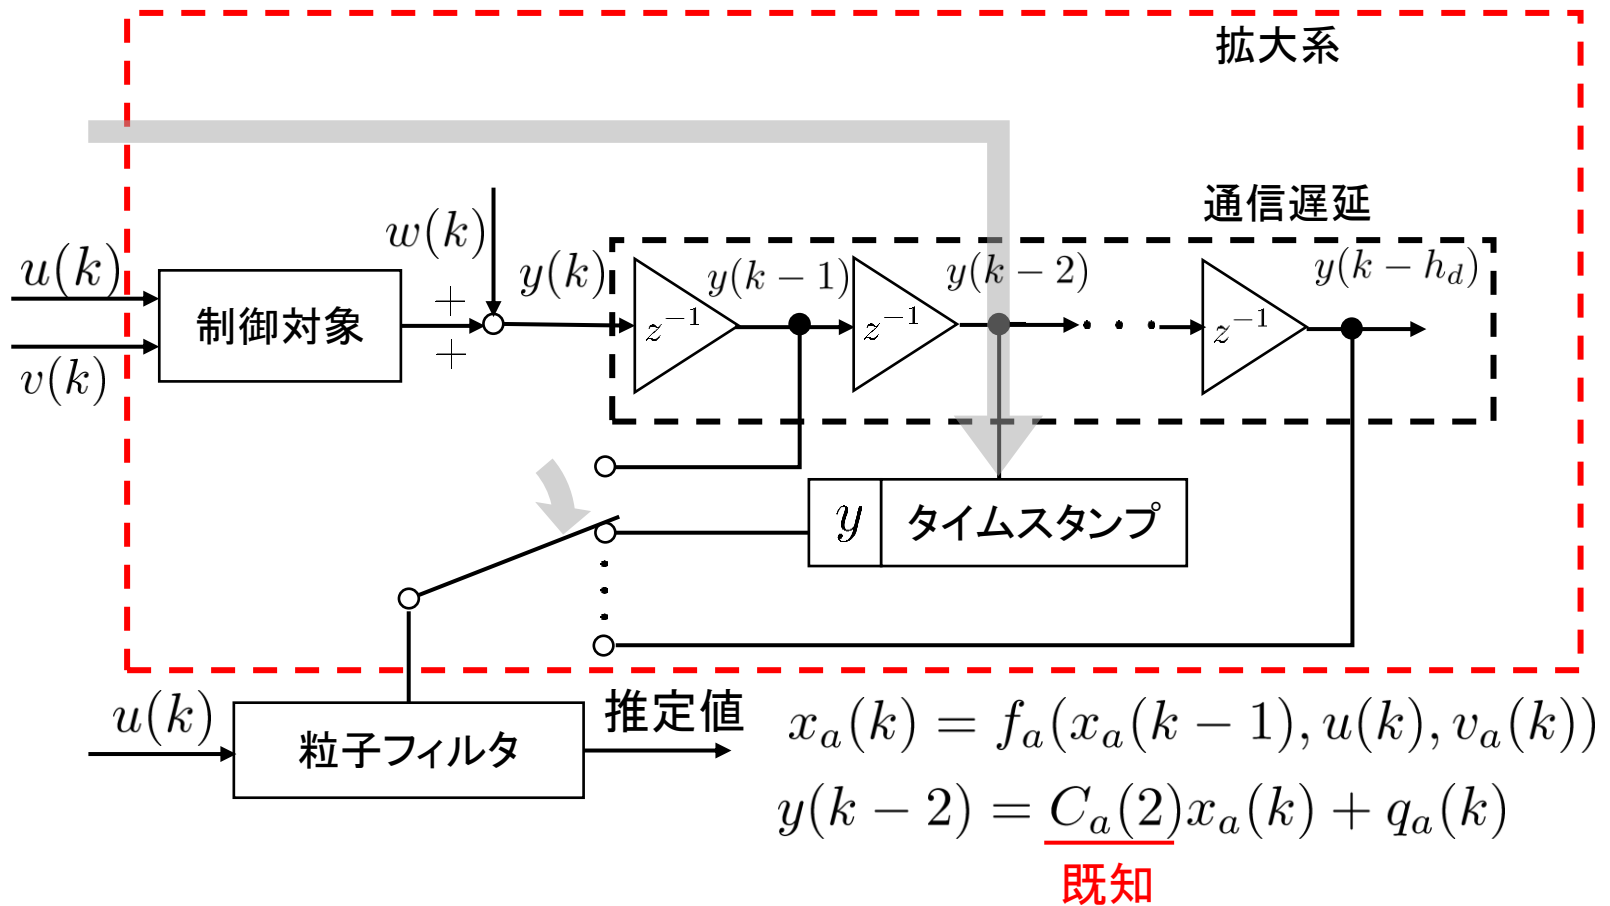
タイムスタンプ



タイムスタンプ



タイムスタンプ



タイムスタンプを用いることで C_a を既知とみなすことが可能

▶ 粒子フィルタを適用することが可能

シミュレーションによる検証

- 対象 : 2リンクアーム
- 目的 : 角度センサの故障検知
- 故障の種類:出力が一定となる固着型故障

シミュレーション条件

• 2リンクアームの数学モデル

$$\dot{x}(t) = \begin{bmatrix} x_3(t) \\ x_4(t) \\ \left[\begin{array}{cc} a_1 & b_1 \\ a_2 & b_2 \end{array} \right]^{-1} \begin{bmatrix} \tau_1 - c_1 - d_1 \\ \tau_2 - c_2 - d_2 \end{bmatrix} \end{bmatrix}$$

$$a_1 = I_1 + I_2 + M_1 l_{g2}^2 + M_2 (l_1^2 + 2l_1 l_{g2} \cos \theta_2)$$

$$b_1 = I_2 + M_2 (l_{g2}^2 + l_1 l_{g2} \cos \theta_2)$$

$$c_1 = M_1 g l_{g1} \cos \theta_1 - M_2 l_1 l_{g2} \sin \theta_2 (2\dot{\theta}_1 \dot{\theta}_2 + \dot{\theta}_2^2)$$


$$+ M_2 g \{ l_1 \cos \theta_1 + l_{g2} \cos(\theta_1 + \theta_2) \}$$

$$a_2 = I_2 + M_2 (l_{g2}^2 + l_1 l_{g2} \cos \theta_2)$$

$$b_2 = M_2 l_{g2}^2 + I_2$$

$$d_1 = B_1 \dot{\theta}_1$$

$$c_2 = M_2 l_1 l_{g2} \dot{\theta}_1^2 \sin \theta_2 + M_2 g l_{g2} \cos(\theta_1 + \theta_2) \quad d_2 = B_2 \dot{\theta}_2$$

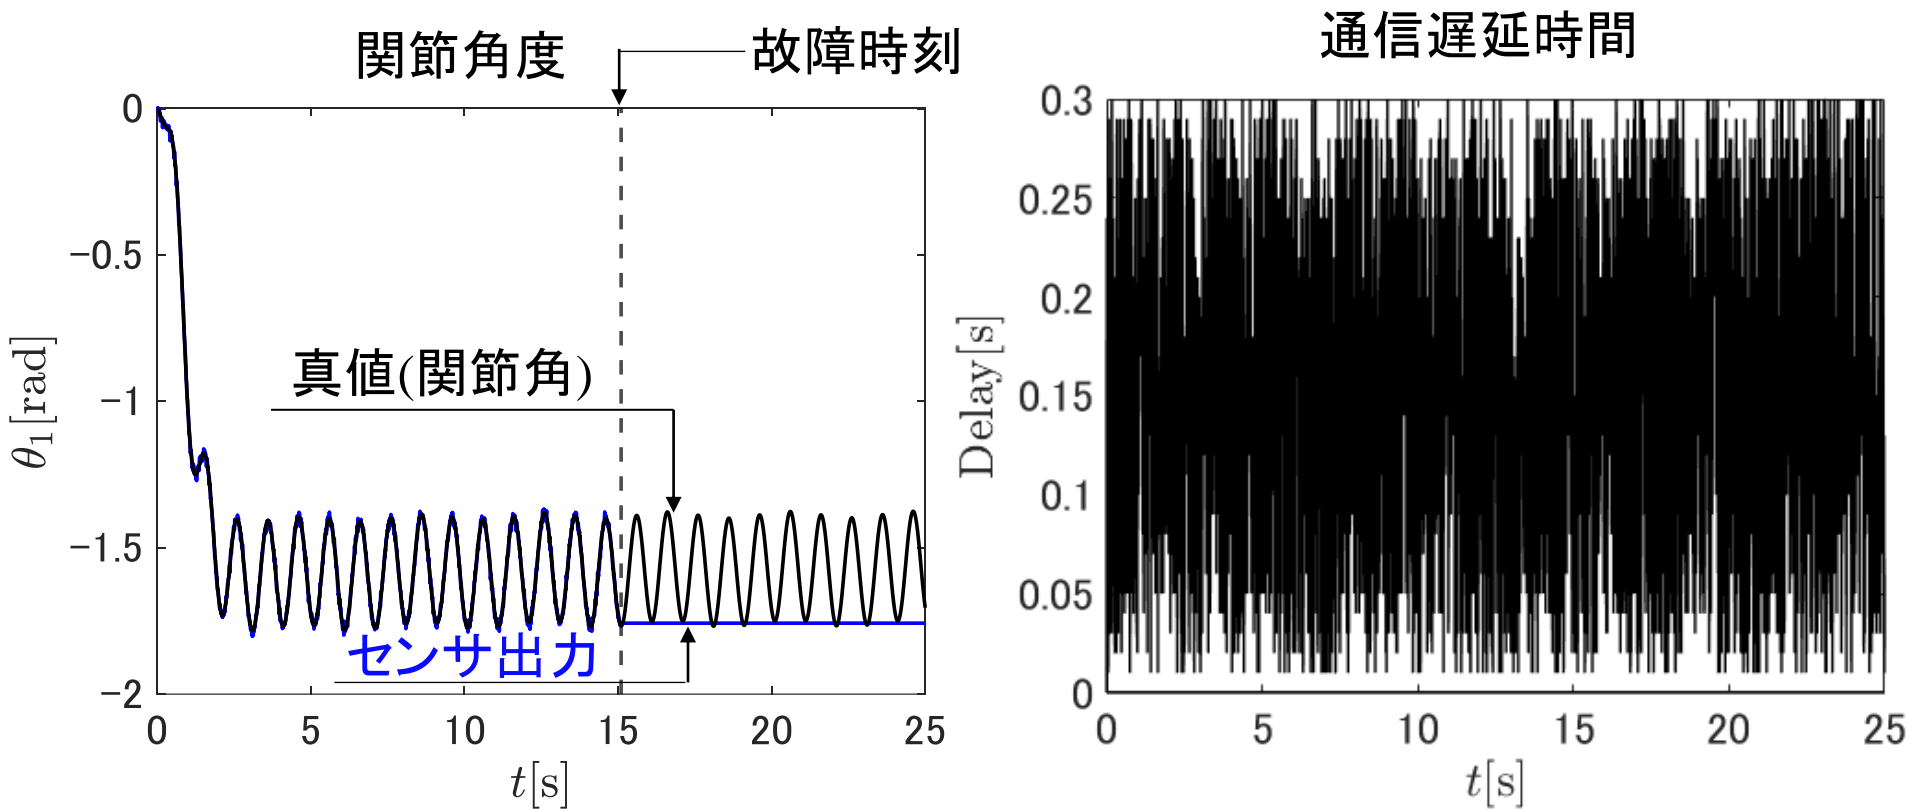


B_1, B_2 : 粘性摩擦係数

I_1, I_2 : 慣性モーメント

シミュレーション条件

- 開始から約15秒以降, センサ故障により出力 y が固定
- 遅延 d は一様分布に従うとして生成



評価方法

検知パラメータの推定値を評価

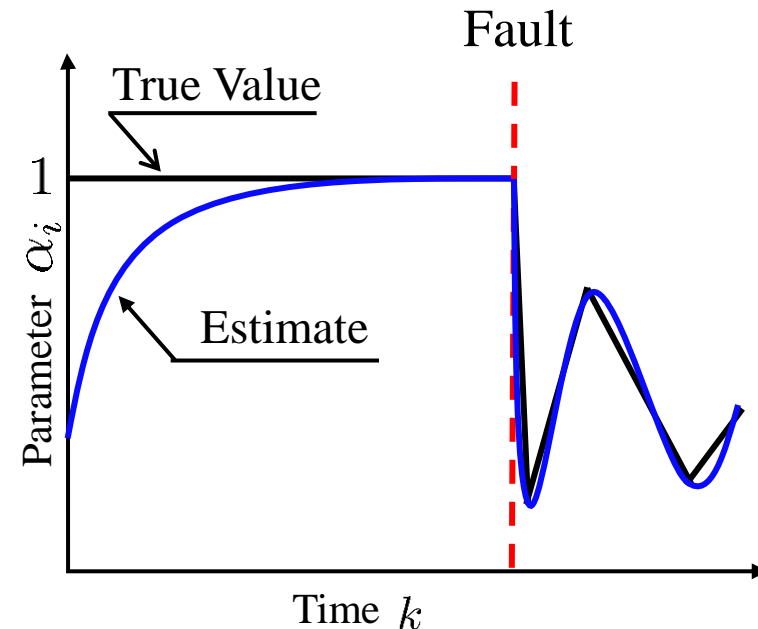
対象の数学モデル

$$x(k) = f(x(k-1), \theta, u(k), v(k))$$


$$y(k) = \text{diag}(\alpha_1, \alpha_2, \dots, \alpha_p) h(x(k), \xi) + w(k)$$

↑ 検知パラメータ

- センサ正常時検知パラメータ α_i は1
- センサ故障によりパラメータ α_i が変化
- 検知パラメータ α_i の変化を状態推定により把握し, 故障検出を行う




シミュレーション結果(故障検知パラメータ)



故障以降, 検知パラメータの推定値が真値に追従
(センサ故障の検知への有用性を確認)

- ・粒子フィルタによる推定: 複数の粒子(推定値の候補)を用意
- ・課題: 計算負荷の増加 ▶ GPU搭載のPCによる計算時間の評価



推定に要する計算時間がサンプリング周期未満(実時間処理を確保)

- ・故障検知アルゴリズム：
対象の数学モデルを用いて推定

$$x(k) = f(x(k-1), \theta, u(k), v(k))$$



- ・課題：実システムでは同定（推定）が困難な
非線形要素（例：摩擦，不感帯）を含む



展望：

- ・NNなどの学習手法を適用
- ・学習の精度を保証するため，線形要素など
モデル化可能な部分を除いた非線形要素のみを学習

まとめ

- 遠隔型の故障検知アルゴリズムの検討
- 粒子フィルタによる検知パラメータの推定
- 故障検知の実験環境の構築, シミュレーションによる検証

今後の展望

- 対象の非線形要素の同定(推定)
- 実機実験による検証