



Bayesian Update Methods for Effect-based Prognostics

2018 추계 KNS 워크숍

M - 원전 상태감시 및 진단 신기술과 적용

경희대학교 허 군 영

Introduction

- Monitoring

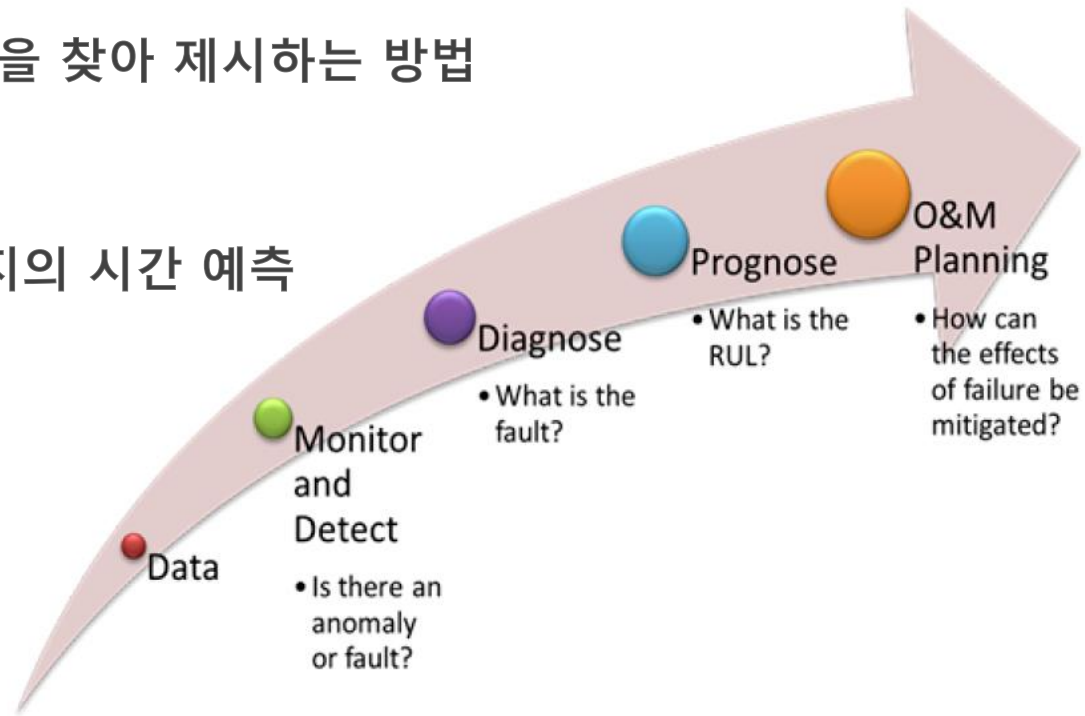
- 운전상태와 관련된 신호 및 특징을 감시 현재값과 예측값을 비교
- Where we should be vs Where we are

- Diagnostic

- 이상(Anomaly)의 근본 원인을 찾아 제시하는 방법
- 분류(Classification)의 문제

- Prognostic

- 고장(Failure)로 진전되기까지의 시간 예측



▪ Prognostics의 특징

– 신뢰도 공학과 다른 점

- 신뢰도 공학은 주로 과거 Generic Data에 기반하여 잔여 수명을 예측하는 것으로 설계 단계에서 중요시 다룸

– 진단 공학과 다른 점

- 진단 공학은 주로 현재 측정 Data에 기반하여 고장의 종류를 판단하는 것으로서 일반적으로 잔여 수명을 예측하지는 않음

▪ 따라서 현재 측정 Data를 반영하여 잔여 수명을 예측한다는 점에서 기존 학문 분야와 차이가 남

Prognostic (가용한 데이터에 따른 분류)


- Type I (Reliability based)
 - 전통적인 신뢰도분석, 평균적인 기기/시스템의 평균적인 운전조건을 고려 유효수명 예측
- Type II (Stressor based)
 - 운전조건을 고려하여 예측, 평균적인 기기/시스템의 특정 운전조건을 고려 유효수명 예측
- Type III (**Effect based**)
 - 운전조건 및 경년열화를 고려하여 예측, 특정 기기/시스템의 특정 운전조건을 고려 유효수명 예측

Prognostic (모델링 방법에 따른 분류)

- 고장예지 방법은 모델의 사용 여부에 따라, 데이터 기반 방법과 모델 기반 방법으로 분류됨

데이터 기반 방법 :

정형화된 모델없이, 과거의 고장 데이터로부터 추출된 열화 특성을 미래 시점으로 외삽하는 기술



모델 기반 방법 :

정형화된 모델의 모수에 과거의 고장 데이터로부터 추출된 정보를 입력하고, 그 모델을 이용하여 열화 특성을 외삽하는 기술

Kalman Filter

- Optimal Bayesian
- 시스템 모델 및 측정이 선형으로 표현
- 모델 및 측정 오차가 가우시안 분포를 따른다고 가정

Grid-based Method

- Optimal filter for Discrete State Space
- Hidden Markov Model으로도 불리고, 분포 및 적분을 차별화하여 계산 가능

Extended KF

- Approximated Bayesian
- 시스템 모델 및 측정이 비선형인 경우 Taylor series를 이용하여 선형으로 근사화

Unscented KF

- Approximated Bayesian
- 시스템 모델 및 측정이 비선형인 경우 가우스 커널을 중첩하여 근사화

Particle Filter

- 몬테카를로 시뮬레이션을 통한 Recursive 베이지 필터
- Sequential Importance Sampling과 Resampling 방법에 따라 다양하게 세부 분류

예시문제

– Data (기존에 수집된 열화 패턴)

x	1	2	3	4	5
y	1.8	6.3	14	24	36.3

 $\sigma_{y_i}^2 = 1$

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \epsilon_i \quad \epsilon \sim N(0, \sigma^2)$$

$$\beta_{prior} = \begin{bmatrix} 1.502 \\ 0.517 \\ 0.938 \end{bmatrix} \quad \sigma_{\beta_{prior}}^2 = \begin{bmatrix} 13.088 \\ 2.283 \\ 0.018 \end{bmatrix}$$

2차 다항식으로 모델 구성

Method – Kalman Filter

- **칼만 필터** : 시스템 모델을 이용한 상태 예측과 측정값 업데이트를 반복적으로 수행
 - 순차적으로 들어오는 관측데이터를 이용해 대상의 상태에 대해 연속적인 베이지안 업데이트를 수행
 - 시스템 모델과 측정 모델에 대해 Gaussian Noise와 Linear 모델을 가정
 - Bayesian Filter 개념 : 시스템 모델 $f(y_{i-1}, \theta)$ 를 이용하여 상태 y_i 를 예측하고, 예측값을 관측값 z_i 로 보정

$$y_i = Ay_{i-1} + B + w_i \quad w_i \sim N(0, Q_i)$$

$$z_i = Hy_i + v_i \quad w_i \sim N(0, R_i)$$

Method

- ① Prediction: 이전 스텝의 상태를 가지고, 현재 스텝의 상태를 예측하는 것

$$\bar{\mu}_{y_i} = A\mu_{y_{i-1}} + B$$

$$\bar{Q}_i = A Q_{i-1} A^T$$

Method

② Update: 지금 스텝의 관측값을 가지고 지금 스텝의 예측된 상태를 업데이트 하는 것

- Kalman Gain

$$K_i = \bar{Q}_i H^T (H \bar{Q}_i H^T + R_i)^{-1}$$

- Measurement update

$$\begin{aligned}\mu_{y_i} &= \bar{\mu}_{y_i} + K_i (z_i - H \bar{\mu}_{y_i}) \\ Q_i &= (I - K_i H) \bar{Q}_i\end{aligned}$$

Method

- Bayesian update – Gaussian distribution

$N(\mu_1, \sigma_1^2) : \text{prior}$
 $N(\mu_2, \sigma_2^2) : \text{Likelihood}$

$$\begin{aligned}\mu'_1 &= \frac{\mu_1 \sigma_2^2 + \mu_2 \sigma_1^2}{\sigma_1^2 + \sigma_2^2} \\ &= \mu_1 - \mu_1 \frac{\sigma_1^2 + \sigma_2^2}{\sigma_1^2 + \sigma_2^2} + \frac{\mu_1 \sigma_2^2 + \mu_2 \sigma_1^2}{\sigma_1^2 + \sigma_2^2} \\ &= \mu_1 + \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} (\mu_2 - \mu_1)\end{aligned}$$

$$\begin{aligned}\sigma_1'^2 &= \frac{\sigma_1^2 \sigma_2^2}{\sigma_1^2 + \sigma_2^2} \\ &= \sigma_1^2 - \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} \sigma_1^2\end{aligned}$$

Kalman gain


$$\begin{aligned}\mu'_1 &= \mu_1 + \boxed{\frac{H \sigma_1^2}{H^2 \sigma_1^2 + \sigma_2^2}} (\mu_2 - H \mu_1) \\ \mu_1 &\rightarrow H \mu_1 \quad \sigma_1'^2 = \sigma_1^2 - \boxed{\frac{H \sigma_1^2}{H^2 \sigma_1^2 + \sigma_2^2}} H \sigma_1^2 \\ \sigma_1 &\rightarrow H \sigma_1\end{aligned}$$

$$K_i = \bar{Q}_i H^T (H \bar{Q}_i H^T + R_i)^{-1}$$

$$\mu_{y_i} = \boxed{\bar{\mu}_{y_i}} + K_i \boxed{z_i - H \bar{\mu}_{y_i}}$$

prediction color: green error

$$Q_i = (I - K_i H) \bar{Q}_i$$



Method

② Update: 지금 스텝의 관측값을 가지고 지금 스텝의 예측된 상태를 업데이트 하는 것

- Measurement uncertainty

$$K_i = \bar{Q}_i H^T (H \bar{Q}_i H^T + R_i)^{-1}$$

Low uncertainty	High uncertainty
$R \rightarrow 0$	$R \rightarrow \infty$
$K_i = \bar{Q}_i H^T (H \bar{Q}_i H^T + 0)^{-1}$ $= \bar{Q}_i H^T H^{T-1} \bar{Q}_i^{-1} H^{-1}$ $= H^{-1}$	$K_i = \bar{Q}_i H^T (H \bar{Q}_i H^T + \infty)^{-1}$ $= \bar{Q}_i H (\infty)^{-1}$ $= 0$
$\mu_{y_i} = \bar{\mu}_{y_i} + K_i (z_i - H \bar{\mu}_{y_i})$ $= \bar{\mu}_{y_i} + H^{-1} z_i - H^{-1} H \bar{\mu}_{y_i}$ $= \boxed{H^{-1} z_i} \rightarrow \text{측정값}$	$\mu_{y_i} = \bar{\mu}_{y_i} + K_i (z_i - H \bar{\mu}_{y_i})$ $= \boxed{\bar{\mu}_{y_i}} \rightarrow \text{예측값}$
$Q_i = (I - K_i H) \bar{Q}_i$ $= 0$	$Q_i = (I - K_i H) \bar{Q}_i$ $= \bar{Q}_i$

Example 1

– Data

x	1	2	3	4	5
y	1.8	6.3	14	24	36.3

 $\sigma_{y_i}^2 = 1$

$$y_i = \beta_0 + \beta_1 x_i + \beta_2 x_i^2 + \epsilon_i \quad \epsilon \sim N(0, \sigma^2)$$

$$\beta_{prior} = \begin{bmatrix} 1.502 \\ 0.517 \\ 0.938 \end{bmatrix} \quad \sigma_{\beta_{prior}}^2 = \begin{bmatrix} 13.088 \\ 2.283 \\ 0.018 \end{bmatrix}$$

– Model

- State

$$\beta_i = A\beta_{i-1} + B + w_i, \quad w_i \sim N(0, Q_i), \quad \beta_i = [\beta_{0,i}, \beta_{1,i}, \beta_{2,i}]^T, A = I_3, B = \emptyset, \quad Q_i = \begin{bmatrix} \sigma_{\beta_{0,i}}^2 & 0 & 0 \\ 0 & \sigma_{\beta_{1,i}}^2 & 0 \\ 0 & 0 & \sigma_{\beta_{2,i}}^2 \end{bmatrix}$$

- Measurement

$$y_i = H_i \beta_i + v_i, \quad v_i \sim N(0, R_i), \quad (H_i = [1, i, i^2] (\because x_i = i), R_i = \sigma_{y_i}^2)$$

Example

① Prediction

$$\begin{aligned} \bar{\mu}_{\beta_i} &= A\mu_{\beta_{i-1}} \\ \bar{Q}_i &= AQ_{i-1}A^T \end{aligned} \quad \leftarrow \quad A = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}, \quad \mu_{\beta_i} = \begin{bmatrix} \mu_{\beta_{0,i}} \\ \mu_{\beta_{1,i}} \\ \mu_{\beta_{2,i}} \end{bmatrix}, \quad Q_i = \begin{bmatrix} \sigma_{\beta_{0,i}}^2 & 0 & 0 \\ 0 & \sigma_{\beta_{1,i}}^2 & 0 \\ 0 & 0 & \sigma_{\beta_{2,i}}^2 \end{bmatrix}$$

② Update

- Kalman Gain


$$K_i = \bar{Q}_i H^T (H \bar{Q}_i H^T + R_i)^{-1} \quad \leftarrow \quad H_i = [1, i, i^2], \quad R_i = \sigma_{y_i}^2$$

- Measurement update

$$\begin{aligned} \mu_{\beta_i} &= \bar{\mu}_{\beta_i} + K_i (y_i - H \bar{\mu}_{\beta_i}) \\ Q_i &= (I - K_i H) \bar{Q}_i \end{aligned}$$

Example


– Result



Example

$$K_i = \bar{Q}_i H^T (\underbrace{H \bar{Q}_i H^T}_{\text{Prior Information}} + \underbrace{R_i}_{\text{New Observation}})^{-1}$$

→ Adjust R_i from 0.1~50



Method – Particle Filter

- 파티클 필터 : 베이지안 업데이트 방법을 이용하여 모델 모수에 대해 관측 정보를 “순차적”으로 업데이트
 - 순차적으로 들어오는 관측데이터를 이용해 모델에 대해 연속적인 베이지안 업데이트를 수행
 - 대량의 난수를 이용하여 Non-Gaussian Noise, Non-Linear 모델에 대해서 적용 가능
 - Bayesian Filter 개념 : 시스템 모델 $f(y_{i-1}, \theta)$ 를 이용하여 상태 y_i 를 예측하고, 예측값을 관측값 z_i 로 보정

$$y_i = f(y_{i-1}, \theta_i)$$

$$z_i = h(y_i) + \epsilon$$

$$= y_i + \epsilon, \quad \epsilon \sim N(0, \sigma^2)$$

Method

① Prediction: 이전 스텝의 상태를 가지고, 현재 스텝의 상태를 예측하는 것

$$\theta_i^j \sim p(\theta_i | \theta_{i-1}) = p(\theta_{i-1}), \quad j = 1, 2, \dots, n_s$$

$$y_{i-1}^j \sim p(y_{i-1}), \quad j = 1, 2, \dots, n_s$$

$$y_i^j = f(y_{i-1}^j, \theta_i^j), \quad j = 1, 2, \dots, n_s$$

→ y_i 의 사전 분포 $p(y_i)$ 가 얻어짐

현 step 모델 파라미터 θ_i^j 샘플링 - 모델 파라미터는 step에 영향을 받지 않으므로 이전 step의 파라미터 분포로부터 현 step 파라미터 분포 샘플링

이전 step 상태 y_{i-1}^j 샘플링 - 이전 step 상태의 분포 $p(y_{i-1})$ 로부터 샘플링

이전 step 상태 y_{i-1}^j 와 현 step 모델 파라미터 θ_i^j 를 이용하여 시스템 모델로부터 현 스텝 상태 y_i^j 계산

Method

- 파티클 필터

- ② **Update:** 지금 스텝의 관측값을 가지고 지금 스텝의 상태를 업데이트 하는 것 (사후분포)
- Monte Carlo Integration

$$E[g(x)] = \int g(x)p(x)dx, \quad p(x) : PDF$$

- 1) $X^j \sim p(x), j = 1, 2, \dots, n_s$
- 2) $Y^j = g(X^j), j = 1, 2, \dots, n_s$
- 3) $E[g(x)] = \bar{Y} = \frac{1}{N} \sum_{j=1}^{n_s} Y^j$

Method

- 파티클 필터

② Update

- Importance Sampling: 대상 분포가 알려지지 않아 직접 샘플링을 수행할 수 없는 경우, 알고 있는 분포 ($q(x)$, importance distribution)를 도입하여, 우리가 잘 알고 있는 분포로부터 샘플링을 수행하여 기댓값을 구할 수 있음

$$\begin{aligned}\int g(x)p(x)dx &= \int g(x)\frac{p(x)}{q(x)}q(x)dx & * q(x) : \text{Importance distribution} \\ &= \int g(x)w(x)q(x)dx\end{aligned}$$

$$1) X^j \sim q(x), j = 1, 2, \dots, n_s$$

$$2) Y^j = g(X^j)w(X^j), j = 1, 2, \dots, n_s$$

$$3) E[g(x)] = \bar{Y} = \frac{1}{N} \sum_{j=1}^{n_s} Y^j$$

Note: 여전히 $p(x)$ 를 구해야 하는 현안이 있음

Method

- 파티클 필터

- ② Update

- Update 단계에서는 관측값 z_i 를 이용하여 y_i 의 사후분포를 구하고자 함

$$p(y_i|z_i) =? \quad \frac{p(y_i|z_i)}{q(y_i)} q(y_i) = \frac{p(z_i|y_i)p(y_i)}{q(y_i)} q(y_i)$$

→ Importance distribution $q(y_i)$ 를 사전 분포 $p(y_i)$ 로 두면,

$$w(y_i) = \frac{p(z_i|y_i)p(y_i)}{p(y_i)} = p(z_i|y_i) \Rightarrow \text{Likelihood}$$

→ 정규분포일 경우, Likelihood 함수

$$w(y_i^j) = L(z_i|y_i^j) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(z_i - y_i^j)^2}{2\sigma^2}\right), \quad j = 1, 2, \dots, n_s$$

Method

- 파티클 필터

③ Resampling

- Normalized weight: 분자/분모에 모두 weight를 배치함으로써 사후분포를 계산할 때 분모에 들어가는 적분이 서로 상쇄되어 없앨 수 있음

$$w(y_i^j) = \frac{w(y_i^j)}{\sum_{j=1}^{n_s} w(y_i^j)}$$


- Normalized weight의 누적분포함수로부터 Inverse transform sampling 기법을 이용하여 Resampling 수행
 - 문제는 소위 degenerate라고 해서 weight의 variance가 계속 증가함. 그러면 얼마 후에는 weight 중에서 하나만 1이 되고 나머지는 모두 0이 되어, 가중치가 의미가 없어짐
- Update 단계에서 얻은 $w(y_i)$ 를 이용하여 Resampling 수행

Method

- 파티클 필터

③ Resampling

- Inverse transform sampling



Method


- 파티클 필터

③ Resampling

- y_i^j 는 y_{i-1}^j 와 θ_i^j 를 이용하여 계산됨 $\leftarrow y_i^j = f(y_{i-1}^j, \theta_i^j)$
- $w(y_i^j)$ 의 index j 를 이용하여 θ_i^j 또한 Resampling 수행
- $p(y_i|z_i)$, $p(\Theta_i|z_i)$ 사후 분포를 얻음

Method

- 파티클 필터



y_i : 예측된 상태
 θ_i : 모델 파라미터
 z_i : 관측된 상태

Method

- Balancing between Prior and Newly observed information

$$w(y_i^j) = L(z_i|y_i^j) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(z_i - y_i^j)^2}{2\sigma^2}\right), \quad j = 1, 2, \dots, n_s$$

$$\lim_{\sigma \rightarrow \infty} L = \begin{cases} 0, & z_i = y_i^j \\ 0, & z_i \neq y_i^j. \end{cases}$$


- Likelihood 분포가 넓게 퍼짐
- 모든 파티클들이 거의 균등하게 Resampling 됨
- 따라서, 사전 분포 \approx 사후 분포
- 관측 정보가 덜 반영됨

$$\lim_{\sigma \rightarrow 0} L = \begin{cases} \infty, & z_i = y_i^j \\ 0, & z_i \neq y_i^j. \end{cases}$$

- Likelihood 분포가 관측값에 가까운 파티클들에 집중됨
- 관측값 주변의 파티클들이 집중적으로 Resampling 됨
- 따라서, 사전 분포가 관측값 쪽으로 이동함
- 관측 정보가 많이 반영됨

Method

- 관측 정보의 반영
 - 관측 정보의 불확실성에 따라 관측 정보를 어느 정도로 반영할 것인지 결정
 - 관측 정보의 불확실도 $\uparrow \rightarrow$ 기존 모델을 더 신뢰 \rightarrow 업데이트 $\downarrow \rightarrow$ 기존 모델의 예측 결과를 그대로 사용
 - 관측 정보의 불확실도 $\downarrow \rightarrow$ 관측 정보를 더 신뢰 \rightarrow 업데이트 $\uparrow \rightarrow$ 관측값 쪽으로 예측 분포 수정



Example 2

– Data

x	1	2	3	4	5
y	1.8	6.3	14	24	36.3

 $\sigma_{y_i}^2 = 1$

$$\beta_{prior} = \begin{bmatrix} 1.502 \\ 0.517 \\ 0.938 \end{bmatrix} \quad \sigma_{\beta_{prior}}^2 = \begin{bmatrix} 13.088 \\ 2.283 \\ 0.018 \end{bmatrix}$$

– Model

- State

$$\beta_{ki} = f(\beta_{ki-1}) = \beta_{ki-1}, \quad k = 0, 1, 2$$

- Measurement

$$\begin{aligned} y_i = h(\beta_{ki}) + \epsilon &= \beta_{0i} + \beta_{1i}x_i + \beta_{2i}x_i^2 + \epsilon \\ &= \beta_{0i} + \beta_{1i}i + \beta_{2i}i^2 + \epsilon, \quad \epsilon \sim N(0, \sigma_{y_i}^2) (\because x_i = i) \end{aligned}$$

Example

① Prediction

$$\begin{aligned}\beta_{ki-1}^j &\sim p(\beta_{ki-1}), & j = 1, 2, \dots, n_s \\ \beta_{ki}^j &= f(\beta_{ki-1}^j), & j = 1, 2, \dots, n_s\end{aligned} \quad \rightarrow p(\beta_{ki}) : \text{prior}$$

② Update


$$w(\beta_{ki}^j) = L(y_i | \beta_{ki}^j) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(y_i - h(\beta_{ki}^j))^2}{2\sigma^2}\right), \quad j = 1, 2, \dots, n_s$$

$$w(\beta_{ki}^j) = \frac{w(\beta_{ki}^j)}{\sum_{j=1}^{n_s} w(\beta_{ki}^j)}, \quad j = 1, 2, \dots, n_s$$


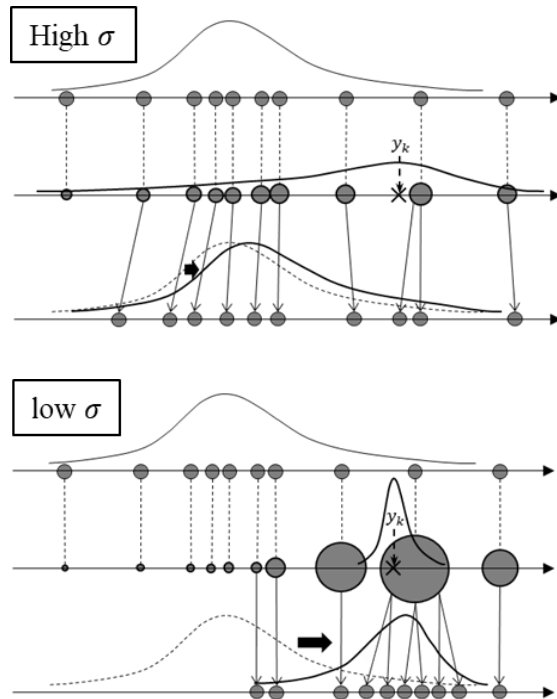
③ Resampling

$$\beta_{ki}^j \sim w(\beta_{ki}), \quad j = 1, 2, \dots, n_s \quad \rightarrow p(\beta_{ki} | y_i) : \text{posterior}$$

Example



Example



실례에서의 어려운 점

- 고장과 명시적인 상관성을 갖는 열화 현상을 찾을 수 있는지 여부
- 열화 정도가 측정가능한지 여부
- 측정 가능한 열화를 나타내는 기존 모델에서 채택하고 있는 계수의 uncertainty (standard deviation)과 현재 측정값의 uncertainty를 정량화하는 문제

EOD