



# Redes de Sensores

## Filtrado no lineal

Manuel A. Vázquez  
Joaquín Míguez  
Jose Miguel Leiva

4 de febrero de 2024


# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo
- 6 Importance sampling
- 7 Filtrado de partículas

# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo
- 6 Importance sampling
- 7 Filtrado de partículas

# Linealidad



“Utilizar un término como ciencia no lineal es como referirse al grueso de la zoología como el estudio de los animales que no son elefantes.”

— Stanislaw Ulam

# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido**
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo
- 6 Importance sampling
- 7 Filtrado de partículas

# Modelo dinámico no lineal

Consideramos la misma ecuación de estado que antes

- $\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{v}_t,$

# Modelo dinámico no lineal

Consideramos la misma ecuación de estado que antes

- $$\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{v}_t,$$

...pero ahora la relación entre el estado y las observaciones viene dada por la función (vectorial)  $\mathbf{h} : \mathbb{R}^M \rightarrow \mathbb{R}^N$  (más ruido gaussiano aditivo)

- $$\mathbf{y}_t = \mathbf{h}(\mathbf{x}_t) + \mathbf{w}_t,$$

siendo  $\mathbf{h}$  un vector de funciones escalares de variable vectorial,

$$\mathbf{h}(\mathbf{x}_t) = \begin{bmatrix} h_1(\mathbf{x}_t) \\ h_2(\mathbf{x}_t) \\ \vdots \\ h_N(\mathbf{x}_t) \end{bmatrix}$$

# Modelo dinámico no lineal

Consideramos la misma ecuación de estado que antes

- $$\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{v}_t,$$

...pero ahora la relación entre el estado y las observaciones viene dada por la función (vectorial)  $\mathbf{h} : \mathbb{R}^M \rightarrow \mathbb{R}^N$  (más ruido gaussiano aditivo)

- $$\mathbf{y}_t = \mathbf{h}(\mathbf{x}_t) + \mathbf{w}_t,$$

siendo  $\mathbf{h}$  un vector de funciones escalares de variable vectorial,

$$\mathbf{h}(\mathbf{x}_t) = \begin{bmatrix} h_1(\mathbf{x}_t) \\ h_2(\mathbf{x}_t) \\ \vdots \\ h_N(\mathbf{x}_t) \end{bmatrix}$$

**No** podemos aplicar el filtro de Kalman!!



# Modelo dinámico linealizado

## Objetivo

Aplicar el KF sobre el modelo no lineal para estimar  $\mathbf{x}_t$  dado  $\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_t$

Podemos construir una aproximación lineal de la ecuación de observación<sup>1</sup> utilizando una **serie de Taylor** de primer orden

$$\mathbf{h}(\mathbf{x}_t) \approx \mathbf{h}(\mathbf{x}^0) + \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t = \mathbf{x}^0} (\mathbf{x}_t - \mathbf{x}^0),$$

siendo

$$\left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right] = \begin{bmatrix} \frac{\partial h_1}{\partial x_{1,t}} & \frac{\partial h_1}{\partial x_{2,t}} & \dots & \frac{\partial h_1}{\partial x_{M,t}} \\ \frac{\partial h_2}{\partial x_{1,t}} & \frac{\partial h_2}{\partial x_{2,t}} & \dots & \frac{\partial h_2}{\partial x_{M,t}} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial h_N}{\partial x_{1,t}} & \frac{\partial h_N}{\partial x_{2,t}} & \dots & \frac{\partial h_N}{\partial x_{M,t}} \end{bmatrix}$$

es el Jacobiano (de derivadas parciales) de  $\mathbf{h}$ .

<sup>1</sup>Podríamos hacer lo mismo con una ecuación de estado no lineal!!!

# Derivando el filtro de Kalman extendido

EKF define unas observaciones transformadas,

$$\tilde{\mathbf{y}}_t = \mathbf{y}_t - \mathbf{h}(\mathbf{x}^0) + \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t = \mathbf{x}^0} \mathbf{x}^0,$$

que dan lugar a un modelo dinámico aproximado que es lineal y gaussiano

$$\mathbf{x}_t = \mathbf{F}\mathbf{x}_{t-1} + \mathbf{v}_t$$

$$\tilde{\mathbf{y}}_t = \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t = \mathbf{x}^0} \mathbf{x}_t + \mathbf{w}_t$$



**Conseguido!!**

Es inmediato aplicar el KF sobre el modelo anterior.

# Filtro de Kalman extendido

- Predicción

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}\hat{\mathbf{x}}_{t-1|t-1}$$

$$\mathbf{P}_{t|t-1} = \mathbf{Q} + \mathbf{F}\mathbf{P}_{t-1|t-1}\mathbf{F}^T$$

# Filtro de Kalman extendido

- Predicción

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}\hat{\mathbf{x}}_{t-1|t-1}$$

$$\mathbf{P}_{t|t-1} = \mathbf{Q} + \mathbf{F}\mathbf{P}_{t-1|t-1}\mathbf{F}^\top$$

- Actualización

$$\mathbf{K}_t = \mathbf{P}_{t|t-1} \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0}^\top \left( \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0} \mathbf{P}_{t|t-1} \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0}^\top + \mathbf{R} \right)^{-1}$$

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t(\mathbf{y}_t - \mathbf{h}(\hat{\mathbf{x}}_{t|t-1}))$$

$$\mathbf{P}_{t|t} = \mathbf{P}_{t|t-1} - \mathbf{K}_t \left( \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0} \mathbf{P}_{t|t-1} \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0}^\top \right) \mathbf{K}_t^\top,$$

siendo  $\mathbf{Q}$  la covarianza de  $\mathbf{v}_t$  y  $\mathbf{R}$  la de  $\mathbf{w}_t$ .

# Filtro de Kalman extendido

- Predicción

$$\hat{\mathbf{x}}_{t|t-1} = \mathbf{F}\hat{\mathbf{x}}_{t-1|t-1}$$

$$\mathbf{P}_{t|t-1} = \mathbf{Q} + \mathbf{F}\mathbf{P}_{t-1|t-1}\mathbf{F}^\top$$

- Actualización

$$\mathbf{K}_t = \mathbf{P}_{t|t-1} \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0}^\top \left( \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0} \mathbf{P}_{t|t-1} \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0}^\top + \mathbf{R} \right)^{-1}$$

$$\hat{\mathbf{x}}_{t|t} = \hat{\mathbf{x}}_{t|t-1} + \mathbf{K}_t(\mathbf{y}_t - \mathbf{h}(\hat{\mathbf{x}}_{t|t-1}))$$

$$\mathbf{P}_{t|t} = \mathbf{P}_{t|t-1} - \mathbf{K}_t \left( \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0} \mathbf{P}_{t|t-1} \left[ \frac{\partial \mathbf{h}}{\partial \mathbf{x}_t} \right]_{\mathbf{x}_t=\mathbf{x}^0}^\top \right) \mathbf{K}_n^\top,$$

siendo  $\mathbf{Q}$  la covarianza de  $\mathbf{v}_t$  y  $\mathbf{R}$  la de  $\mathbf{w}_t$ .

- El punto de linealización  $\mathbf{x}^0$  tiene que ser suficientemente cercano a  $\mathbf{x}_t$  para que el algoritmo funcione correctamente. Normalmente es suficiente tomar  $\mathbf{x}^0 = \hat{\mathbf{x}}_{t|t-1}$ .

# Ejemplo de función no lineal en seguimiento

## Objetivo

Localización y seguimiento de un objeto con velocidad constante y conocida  $\mathbf{c}$ .

$S_2$  ○ ×

○  $S_4$

$S_1$  ○

○  $S_3$

# Ejemplo de función no lineal en seguimiento

## Objetivo

Localización y seguimiento de un objeto con velocidad constante y conocida  $\mathbf{c}$ .

La misma ecuación de estado que antes,

- $$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{c}T + \mathbf{v}_t,$$

$S_2^o \times$

$S_4^o$

$S_1^o$

$S_3^o$

# Ejemplo de función no lineal en seguimiento

## Objetivo

Localización y seguimiento de un objeto con velocidad constante y conocida  $\mathbf{c}$ .

 $S_2$  ×

 $S_4$ 
 $S_1$ 
 $S_3$ 

La misma ecuación de estado que antes,

- $$\mathbf{x}_t = \mathbf{x}_{t-1} + \mathbf{c}T + \mathbf{v}_t,$$

...una ecuación de observación más *realista* basada en Received Signal Strength Indicator (RSSI),

- $$y_{t,i} = \underbrace{k_1 - k_2 \log \|\mathbf{x}_t - \mathbf{s}_i\|}_{\text{RSSI}_i} + w_{t,i}, \quad i = 1, \dots, N$$


con  $k_1$  y  $k_2$  constantes conocidas y  $\mathbf{s}_i$  la posición del sensor correspondiente.

( antes,  $\mathbf{y}_t = \mathbf{x}_t + \mathbf{w}_t$  )




# Ejemplo

- Trayectoria real




# Ejemplo

- Lectura de los sensores



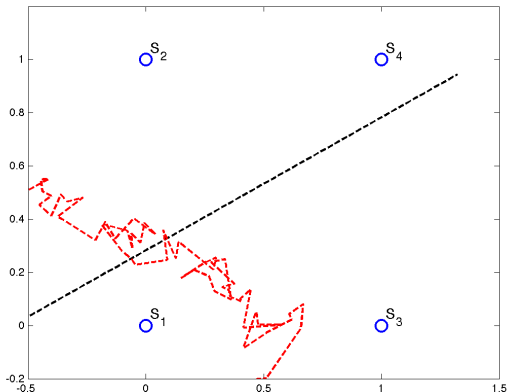
# Ejemplo

- Resultado de filtrado usando solo el Sensor 2



# Ejemplo


- Resultado de filtrado usando los sensores 1 y 2.



- En este caso los sensores no han podido resolver la ambigüedad de la dirección.

# Ejemplo

- Resultado de filtrado usando los cuatro sensores.



# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented**
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo
- 6 Importance sampling
- 7 Filtrado de partículas

## Filtro de Kalman *unscented*

- Otra extensión no lineal del filtro de Kalman (alternativa al EKF)...

## Filtro de Kalman *unscented*

- Otra extensión no lineal del filtro de Kalman (alternativa al EKF)...
- El modelo:

$$\begin{aligned}\mathbf{x}_t &= \mathbf{f}(\mathbf{x}_{t-1}, \mathbf{v}_t), & \mathbf{v}_t &\sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_n) \\ \mathbf{y}_t &= \mathbf{H}_t \mathbf{x}_t + \mathbf{w}_t, & \mathbf{w}_t &\sim \mathcal{N}(\mathbf{0}, \mathbf{R}_n)\end{aligned}$$

La ecuación de observación es lineal...pero la de estado **no** lo es ( $\mathbf{f}$  es una función vectorial arbitraria)



# Filtro de Kalman *unscented*

- Otra extensión no lineal del filtro de Kalman (alternativa al EKF)...
- El modelo:

$$\begin{aligned}\mathbf{x}_t &= \mathbf{f}(\mathbf{x}_{t-1}, \mathbf{v}_t), & \mathbf{v}_t &\sim \mathcal{N}(\mathbf{0}, \mathbf{Q}_n) \\ \mathbf{y}_t &= \mathbf{H}_t \mathbf{x}_t + \mathbf{w}_t, & \mathbf{w}_t &\sim \mathcal{N}(\mathbf{0}, \mathbf{R}_n)\end{aligned}$$

La ecuación de observación es lineal...pero la de estado **no** lo es ( $\mathbf{f}$  es una función vectorial arbitraria)

- Se basa en la...

## transformación *unscented*

un método para calcular los momentos de una variable aleatoria *gaussiana* tras una transformación no lineal

...que a su vez hace uso de una...

## Representación con puntos *sigma*

Sea  $p(\mathbf{x}_t | \mathbf{y}_{1:t}) = \mathcal{N}(\mathbf{x}_t | \hat{\mathbf{x}}_t, \mathbf{P}_t)$ .

## Representación con puntos *sigma*

Sea  $p(\mathbf{x}_t | \mathbf{y}_{1:t}) = \mathcal{N}(\mathbf{x}_t | \hat{\mathbf{x}}_t, \mathbf{P}_t)$ . Podemos representar esta distribución utilizando un conjunto (determinista) de **puntos sigma**

$$\begin{aligned}\mathbf{X}_t(0) &= \hat{\mathbf{x}}_t, & \mathbf{W}_t(0) &= \kappa / (M + \kappa) \\ \mathbf{X}_t(i) &= \hat{\mathbf{x}}_t + \left( \sqrt{(M + \kappa) \mathbf{P}_t} \right)_i, & \mathbf{W}_t(i) &= 1 / (2(M + \kappa)) \\ \mathbf{X}_t(i + M) &= \hat{\mathbf{x}}_t - \left( \sqrt{(M + \kappa) \mathbf{P}_t} \right)_i, & \mathbf{W}_t(i + M) &= 1 / (2(M + \kappa))\end{aligned}$$

para  $i = 1, \dots, M$ , donde  $\kappa \in \mathbb{R}$  y  $\left( \sqrt{(M + \kappa) \mathbf{P}_t} \right)_i$  es la  $i$ -ésima columna de la raíz cuadrada (matricial) de  $(M + \kappa) \mathbf{P}_t$ .

## Representación con puntos *sigma*

Sea  $p(\mathbf{x}_t | \mathbf{y}_{1:t}) = \mathcal{N}(\mathbf{x}_t | \hat{\mathbf{x}}_t, \mathbf{P}_t)$ . Podemos representar esta distribución utilizando un conjunto (determinista) de **puntos sigma**

$$\begin{aligned} \mathbf{X}_t(0) &= \hat{\mathbf{x}}_t, & W_t(0) &= \kappa / (M + \kappa) \\ \mathbf{X}_t(i) &= \hat{\mathbf{x}}_t + \left( \sqrt{(M + \kappa) \mathbf{P}_t} \right)_i, & W_t(i) &= 1 / (2(M + \kappa)) \\ \mathbf{X}_t(i + M) &= \hat{\mathbf{x}}_t - \left( \sqrt{(M + \kappa) \mathbf{P}_t} \right)_i, & W_t(i + M) &= 1 / (2(M + \kappa)) \end{aligned}$$

para  $i = 1, \dots, M$ , donde  $\kappa \in \mathbb{R}$  y  $\left( \sqrt{(M + \kappa) \mathbf{P}_t} \right)_i$  es la  $i$ -ésima columna de la raíz cuadrada (matricial) de  $(M + \kappa) \mathbf{P}_t$ .

### Teorema: Puntos sigma

Este conjunto de muestras ponderadas tiene la misma media muestral y covarianza que la distribución original.

## Operación del filtro de Kalman unscented

Una vez calculados los puntos sigma, el **paso de predicción** en el instante  $t + 1$  se puede llevar a cabo de la siguiente forma:

# Operación del filtro de Kalman unscented

Una vez calculados los puntos sigma, el **paso de predicción** en el instante  $t + 1$  se puede llevar a cabo de la siguiente forma:

- 1 Propagar cada punto sigma mediante la función (no lineal)  $\mathbf{f}$

$$\mathbf{X}_{t+1|t}(i) = \mathbf{f}(\mathbf{X}_t(i), 0).$$

# Operación del filtro de Kalman unscented

Una vez calculados los puntos sigma, el **paso de predicción** en el instante  $t + 1$  se puede llevar a cabo de la siguiente forma:

- 1 Propagar cada punto sigma mediante la función (no lineal)  $\mathbf{f}$

$$\mathbf{X}_{t+1|t}(i) = \mathbf{f}(\mathbf{X}_t(i), 0).$$

- 2 Calcular la media predictiva

$$\hat{\mathbf{x}}_{t+1}^- = \sum_{i=0}^{2M} W_t(i) \mathbf{X}_{t+1|t}(i).$$

# Operación del filtro de Kalman unscented

Una vez calculados los puntos sigma, el **paso de predicción** en el instante  $t + 1$  se puede llevar a cabo de la siguiente forma:

- 1 Propagar cada punto sigma mediante la función (no lineal)  $\mathbf{f}$

$$\mathbf{X}_{t+1|t}(i) = \mathbf{f}(\mathbf{X}_t(i), 0).$$

- 2 Calcular la media predictiva

$$\hat{\mathbf{x}}_{t+1}^- = \sum_{i=0}^{2M} W_t(i) \mathbf{X}_{t+1|t}(i).$$

- 3 Calcular la covarianza predictiva

$$\mathbf{P}_{t+1}^- = \sum_{i=0}^{2M} W_t(i) (\mathbf{X}_{t+1|t}(i) - \hat{\mathbf{x}}_{t+1}^-) (\mathbf{X}_{t+1|t}(i) - \hat{\mathbf{x}}_{t+1}^-)^\top$$



# Operación del filtro de Kalman unscented

Una vez calculados los puntos sigma, el **paso de predicción** en el instante  $t + 1$  se puede llevar a cabo de la siguiente forma:

- 1 Propagar cada punto sigma mediante la función (no lineal)  $\mathbf{f}$

$$\mathbf{X}_{t+1|t}(i) = \mathbf{f}(\mathbf{X}_t(i), 0).$$

- 2 Calcular la media predictiva

$$\hat{\mathbf{x}}_{t+1}^- = \sum_{i=0}^{2M} W_t(i) \mathbf{X}_{t+1|t}(i).$$

- 3 Calcular la covarianza predictiva

$$\mathbf{P}_{t+1}^- = \sum_{i=0}^{2M} W_t(i) (\mathbf{X}_{t+1|t}(i) - \hat{\mathbf{x}}_{t+1}^-) (\mathbf{X}_{t+1|t}(i) - \hat{\mathbf{x}}_{t+1}^-)^\top$$

El *paso de actualización* es igual que en el FK estándar.

# Notas

- El vector de medias y la matriz de covarianza calculadas propagando los puntos sigma a través de la no-linealidad siguen siendo **estimaciones**, pero son más precisas que las dadas por el EKF. Son exactas hasta el orden 2 dado por un desarrollo de Taylor. ✓

# Notas

- El vector de medias y la matriz de covarianza calculadas propagando los puntos sigma a través de la no-linealidad siguen siendo **estimaciones**, pero son más precisas que las dadas por el EKF. Son exactas hasta el orden 2 dado por un desarrollo de Taylor. ✓
- Las aproximaciones todavía son gaussianas, por lo que el método no es adecuado cuando se espera que las distribuciones a posteriori sean multimodales. ✗

# Notas

- El vector de medias y la matriz de covarianza calculadas propagando los puntos sigma a través de la no-linealidad siguen siendo **estimaciones**, pero son más precisas que las dadas por el EKF. Son exactas hasta el orden 2 dado por un desarrollo de Taylor. ✓
- Las aproximaciones todavía son gaussianas, por lo que el método no es adecuado cuando se espera que las distribuciones a posteriori sean multimodales. ✗
- Aunque el UKF no requiere derivadas, conlleva una linealización implícita del modelo (i.e., el UKF se puede reescribir como un método de linealización). ✓

# Notas

- El vector de medias y la matriz de covarianza calculadas propagando los puntos sigma a través de la no-linealidad siguen siendo **estimaciones**, pero son más precisas que las dadas por el EKF. Son exactas hasta el orden 2 dado por un desarrollo de Taylor. ✓
- Las aproximaciones todavía son gaussianas, por lo que el método no es adecuado cuando se espera que las distribuciones a posteriori sean multimodales. ✗
- Aunque el UKF no requiere derivadas, conlleva una linealización implícita del modelo (i.e., el UKF se puede reescribir como un método de linealización). ✓
- Los puntos sigma se pueden elegir de otra manera. Por ejemplo, si se utiliza la regla de cuadratura Gauss-Hermite, se necesitan más puntos pero las aproximaciones son más precisas.

# Notas

- El vector de medias y la matriz de covarianza calculadas propagando los puntos sigma a través de la no-linealidad siguen siendo **estimaciones**, pero son más precisas que las dadas por el EKF. Son exactas hasta el orden 2 dado por un desarrollo de Taylor. ✓
- Las aproximaciones todavía son gaussianas, por lo que el método no es adecuado cuando se espera que las distribuciones a posteriori sean multimodales. ✗
- Aunque el UKF no requiere derivadas, conlleva una linealización implícita del modelo (i.e., el UKF se puede reescribir como un método de linealización). ✓
- Los puntos sigma se pueden elegir de otra manera. Por ejemplo, si se utiliza la regla de cuadratura Gauss-Hermite, se necesitan más puntos pero las aproximaciones son más precisas.
- El UKF parece sencillo de implementar. Sin embargo, su rendimiento depende de diversos factores, como por ejemplo el número de puntos.

# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación**
- 5 Monte Carlo
- 6 Importance sampling
- 7 Filtrado de partículas

# Modelos en espacio de estados

- Planetamiento formal del problema de estimación...



# Modelos en espacio de estados

- Planetamiento formal del problema de estimación...
- ...desde el punto de vista bayesiano

# Modelos en espacio de estados

- Planetamiento formal del problema de estimación...
- ...desde el punto de vista bayesiano
- Modelo de espacio de estados no lineal

$$\left\{ \begin{array}{l} \mathbf{x}_t = \mathbf{f}(\mathbf{x}_{t-1}, \mathbf{v}_t) \\ \mathbf{y}_t = \mathbf{h}(\mathbf{x}_t, \mathbf{w}_t) \end{array} \right\} \Leftrightarrow \left\{ \begin{array}{l} \mathbf{x}_0 \sim p(\mathbf{x}_0) \\ \mathbf{x}_t \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}) \\ \mathbf{y}_t \sim p(\mathbf{y}_t | \mathbf{x}_t) \end{array} \right\}$$

donde

- $\mathbf{f}, \mathbf{h} \equiv$  funciones de transición y observación;
- $\mathbf{v}_t, \mathbf{w}_t \equiv$  ruido del estado y las observaciones;
- $p(\mathbf{x}_0) \equiv$  fdp *a priori* del estado;
- $p(\mathbf{x}_t | \mathbf{x}_{t-1}) \equiv$  fdp de transición del estado;
- $p(\mathbf{y}_t | \mathbf{x}_t) \equiv$  fdp condicional de las observaciones (verosimilitud del estado).

# Filtrado estocástico

## Objetivo

Hacer seguimiento de la distribución *a posteriori*,  $p(\mathbf{x}_t|\mathbf{y}_{1:t})$ , que permite calcular la esperanza de cualquier función de interés,  $\mathbf{g}$ , como

$$\mathbb{E}[\mathbf{g}(\mathbf{x}_t)] = \int \mathbf{g}(\mathbf{x}_t)p(\mathbf{x}_t|\mathbf{y}_{1:t})d\mathbf{x}_t$$

# Filtrado estocástico

## Objetivo

Hacer seguimiento de la distribución *a posteriori*,  $p(\mathbf{x}_t|\mathbf{y}_{1:t})$ , que permite calcular la esperanza de cualquier función de interés,  $\mathbf{g}$ , como

$$\mathbb{E}[\mathbf{g}(\mathbf{x}_t)] = \int \mathbf{g}(\mathbf{x}_t)p(\mathbf{x}_t|\mathbf{y}_{1:t})d\mathbf{x}_t$$

Utilizando el teorema de Bayes, se puede demostrar fácilmente

$$p(\mathbf{x}_t|\mathbf{y}_{1:t}) \propto p(\mathbf{y}_t|\mathbf{x}_t) \int p(\mathbf{x}_t|\mathbf{x}_{t-1})p(\mathbf{x}_{t-1}|\mathbf{y}_{1:t-1})d\mathbf{x}_{t-1}$$

# Filtrado estocástico

## Objetivo

Hacer seguimiento de la distribución *a posteriori*,  $p(\mathbf{x}_t|\mathbf{y}_{1:t})$ , que permite calcular la esperanza de cualquier función de interés,  $\mathbf{g}$ , como

$$\mathbb{E}[\mathbf{g}(\mathbf{x}_t)] = \int \mathbf{g}(\mathbf{x}_t)p(\mathbf{x}_t|\mathbf{y}_{1:t})d\mathbf{x}_t$$

Utilizando el teorema de Bayes, se puede demostrar fácilmente

$$p(\mathbf{x}_t|\mathbf{y}_{1:t}) \propto p(\mathbf{y}_t|\mathbf{x}_t) \int p(\mathbf{x}_t|\mathbf{x}_{t-1})p(\mathbf{x}_{t-1}|\mathbf{y}_{1:t-1})d\mathbf{x}_{t-1}$$

## Filtrado estocástico

Hay incertidumbre en las observaciones o en el ruido que determina la evolución del sistema...por eso hablamos de **filtrado estocástico**<sup>a</sup>.

<sup>a</sup>El filtro de Kalman también entra en esta categoría!!

# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo**
- 6 Importance sampling
- 7 Filtrado de partículas

# Integración por Monte Carlo

Siendo  $X$  una v.a. con fdp  $p(x)$ , considere el problema que consiste en aproximar

$$\mathbb{E}[h(X)] = \int h(x)p(x)dx$$

para una función  $h$  integrable.

# Integración por Monte Carlo

Siendo  $X$  una v.a. con fdp  $p(x)$ , considere el problema que consiste en aproximar

$$\mathbb{E}[h(X)] = \int h(x)p(x)dx$$

para una función  $h$  integrable.



## Una manera de abordar el problema

Si somos capaces de **obtener  $N$  muestras i.i.d.**,  $x^{(1)}, \dots, x^{(N)}$ , de  $p(x)$  y la varianza de la v.a.  $Y = h(X)$  es finita, entonces

$$\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=1}^N h(X^{(n)}) = \mathbb{E}[h(X)]$$

casi seguramente (c.s.).



# Muestreo

En muchos problemas no es posible directamente obtener muestras de  $p(x)$ ...



## Ejemplo

$$\mathbf{y}_t = \mathbf{H}^H \mathbf{x}_t + \mathbf{w}_t$$

Queremos estimar  $\mathbf{x}_t$  a partir de  $\mathbf{y}_t$ , i.e., queremos aproximar  $p(\mathbf{x}_t | \mathbf{y}_t)$ ...pero no es posible obtener directamente muestras de ella (¿¿cómo??)

---

<sup>2</sup>Digamos  $p(x) = Kf(x)$  siendo conocida la función  $f(x)$ , pero no la constante  $K$ .

# Muestreo

En muchos problemas no es posible directamente obtener muestras de  $p(x)$ ...



## Ejemplo

$$\mathbf{y}_t = \mathbf{H}^H \mathbf{x}_t + \mathbf{w}_t$$

Queremos estimar  $\mathbf{x}_t$  a partir de  $\mathbf{y}_t$ , i.e., queremos aproximar  $p(\mathbf{x}_t | \mathbf{y}_t)$ ...pero no es posible obtener directamente muestras de ella (¿¿cómo??)

...sin embargo, tal vez  $p(x)$  puede ser evaluada *hasta una constante de proporcionalidad*<sup>2</sup>:



$$p(\mathbf{x}_t | \mathbf{y}_t) = \frac{p(\mathbf{y}_t | \mathbf{x}_t)p(\mathbf{x}_t)}{p(\mathbf{y}_t)} \propto p(\mathbf{y}_t | \mathbf{x}_t)p(\mathbf{x}_t)$$

<sup>2</sup>Digamos  $p(x) = Kf(x)$  siendo conocida la función  $f(x)$ , pero no la constante  $K$ .

# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo
- 6 Importance sampling**
- 7 Filtrado de partículas

## Muestreo enfatizado (Importance sampling)

Supongamos que la fdp de interés,  $p(x)$ , (la **fdp objetivo**) puede ser evaluada hasta una constante de proporcionalidad y

# Muestreo enfatizado (Importance sampling)

Supongamos que la fdp de interés,  $p(x)$ , (la **fdp objetivo**) puede ser evaluada hasta una constante de proporcionalidad y

- *elijamos* una fdp,  $q(x)$ , conocida como **función tentativa** tal que

$$p(x) > 0 \Rightarrow q(x) > 0$$

# Muestreo enfatizado (Importance sampling)

Supongamos que la fdp de interés,  $p(x)$ , (la **fdp objetivo**) puede ser evaluada hasta una constante de proporcionalidad y

- *elijamos* una fdp,  $q(x)$ , conocida como **función tentativa** tal que

$$p(x) > 0 \Rightarrow q(x) > 0$$

- definamos la función de peso como

$$w(x) = c \frac{p(x)}{q(x)}$$

donde  $c$  es una constante arbitraria (posiblemente desconocida)

# Muestreo enfatizado (Importance sampling)

Supongamos que la fdp de interés,  $p(x)$ , (la **fdp objetivo**) puede ser evaluada hasta una constante de proporcionalidad y

- *elijamos* una fdp,  $q(x)$ , conocida como **función tentativa** tal que

$$p(x) > 0 \Rightarrow q(x) > 0$$


- definamos la función de peso como

$$w(x) = c \frac{p(x)}{q(x)}$$

donde  $c$  es una constante arbitraria (posiblemente desconocida)

entonces podemos calcular la esperanza de cualquier función arbitraria  $h(x)$  **con respecto a  $p(x)$** ...**utilizando muestras de  $q(x)$** !!

# Importance sampling: $q(x)$




## ★ Restricción

El soporte de  $q(x)$  debe incluir el de  $p(x)$ ,

$$p(x) > 0 \Rightarrow q(x) > 0$$



## Importance sampling: $q(x)$



### ★ Restricción

El soporte de  $q(x)$  debe incluir el de  $p(x)$ ,

$$p(x) > 0 \Rightarrow q(x) > 0$$

### Cómo elegirla

Por motivos de eficiencia, la función tentativa debería ser la más parecida posible a la objetivo.

## Importance sampling: procedimiento

...para aproximar  $\mathbb{E}[h(X)]$  respecto de  $p(x)$  utilizando muestras de  $q(x)$

## Importance sampling: procedimiento

...para aproximar  $\mathbb{E}[h(X)]$  respecto de  $p(x)$  utilizando muestras de  $q(x)$

- 1 Muestrear  $\mathbf{x}^{(i)} \sim q(x)$  para  $i = 1, \dots, N$

## Importance sampling: procedimiento

...para aproximar  $\mathbb{E}[h(X)]$  respecto de  $p(x)$  utilizando muestras de  $q(x)$

- 1 Muestrear  $\mathbf{x}^{(i)} \sim q(x)$  para  $i = 1, \dots, N$
- 2 Calcular

$$w(\mathbf{x}^{(i)}) = c \frac{p(\mathbf{x}^{(i)})}{q(\mathbf{x}^{(i)})} \triangleq w^{*(i)} \text{ (peso sin normalizar)}$$

para  $i = 1, \dots, N$

## Importance sampling: procedimiento

...para aproximar  $\mathbb{E}[h(X)]$  respecto de  $p(x)$  utilizando muestras de  $q(x)$

- 1 Muestrear  $\mathbf{x}^{(i)} \sim q(x)$  para  $i = 1, \dots, N$
- 2 Calcular

$$w(\mathbf{x}^{(i)}) = c \frac{p(\mathbf{x}^{(i)})}{q(\mathbf{x}^{(i)})} \triangleq w^{*(i)} \text{ (peso sin normalizar)}$$

para  $i = 1, \dots, N$

- 3 Normalizar los pesos mediante

$$w^{(i)} = \frac{w^{*(i)}}{\sum_{j=1}^N w^{*(j)}}$$

## Importance sampling: procedimiento

...para aproximar  $\mathbb{E}[h(X)]$  respecto de  $p(x)$  utilizando muestras de  $q(x)$

- 1 Muestrear  $\mathbf{x}^{(i)} \sim q(x)$  para  $i = 1, \dots, N$
- 2 Calcular

$$w(\mathbf{x}^{(i)}) = c \frac{p(\mathbf{x}^{(i)})}{q(\mathbf{x}^{(i)})} \triangleq w^{*(i)} \text{ (peso sin normalizar)}$$

para  $i = 1, \dots, N$

- 3 Normalizar los pesos mediante

$$w^{(i)} = \frac{w^{*(i)}}{\sum_{j=1}^N w^{*(j)}}$$

- 4 Aproximar  $\mathbb{E}[h(X)]$  como

$$\mathbb{E}[h(X)] \approx \sum_{i=1}^N w^{(i)} h(\mathbf{x}^{(i)}) \quad (1)$$

## Importance sampling: interpretación

IS da lugar a un conjunto de pares (muestra, peso):


$$\left\{ \left( \mathbf{x}^{(1)}, w^{(1)} \right), \left( \mathbf{x}^{(2)}, w^{(2)} \right), \left( \mathbf{x}^{(3)}, w^{(3)} \right), \dots \right\}$$

## Importance sampling: interpretación

IS da lugar a un conjunto de pares (muestra, peso):

$$\left\{ \left( \mathbf{x}^{(1)}, w^{(1)} \right), \left( \mathbf{x}^{(2)}, w^{(2)} \right), \left( \mathbf{x}^{(3)}, w^{(3)} \right), \dots \right\}$$

El peso se puede *interpretar* como la probabilidad de la muestra correspondiente





# Importance sampling en sistemas dinámicos

## ? IS recursivo

¿Podemos aplicar IS **recursivamente** para estimar el estado en un sistema dinámico?

# Importance sampling en sistemas dinámicos

## ? IS recursivo

¿Podemos aplicar IS **recursivamente** para estimar el estado en un sistema dinámico?

Consideramos un modelo dinámico en formato de espacio de estados definido por

$$\mathbf{x}_0 \sim p(\mathbf{x}_0), \quad \mathbf{x}_t \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}), \quad \mathbf{y}_t \sim p(\mathbf{y}_t | \mathbf{x}_t)$$

# Importance sampling en sistemas dinámicos

## ? IS recursivo

¿Podemos aplicar IS **recursivamente** para estimar el estado en un sistema dinámico?

Consideramos un modelo dinámico en formato de espacio de estados definido por

$$\mathbf{x}_0 \sim p(\mathbf{x}_0), \quad \mathbf{x}_t \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}), \quad \mathbf{y}_t \sim p(\mathbf{y}_t | \mathbf{x}_t)$$

Ya sabemos como aproximar cualquier distribución de interés, por lo que podríamos aproximar

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}), p(\mathbf{x}_{t+1} | \mathbf{y}_{1:t+1}), p(\mathbf{x}_{t+2} | \mathbf{y}_{1:t+2}), \dots$$

pero están relacionadas

# Importance sampling en sistemas dinámicos

## ? IS recursivo

¿Podemos aplicar IS **recursivamente** para estimar el estado en un sistema dinámico?

Consideramos un modelo dinámico en formato de espacio de estados definido por

$$\mathbf{x}_0 \sim p(\mathbf{x}_0), \quad \mathbf{x}_t \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}), \quad \mathbf{y}_t \sim p(\mathbf{y}_t | \mathbf{x}_t)$$

Ya sabemos como aproximar cualquier distribución de interés, por lo que podríamos aproximar

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}), p(\mathbf{x}_{t+1} | \mathbf{y}_{1:t+1}), p(\mathbf{x}_{t+2} | \mathbf{y}_{1:t+2}), \dots$$

pero están relacionadas

### Objetivo

Construir (utilizando importance sampling) una aproximación de  $p(\mathbf{x}_{t+1} | \mathbf{y}_{1:t+1})$  utilizando una de  $p(\mathbf{x}_t | \mathbf{y}_{1:t})$ .

# Índice

- 1 Un mundo lineal
- 2 Filtro de Kalman extendido
- 3 Filtro de Kalman unscented
- 4 Un planteamiento más general del problema de estimación
- 5 Monte Carlo
- 6 Importance sampling
- 7 Filtrado de partículas**

## Importance sampling en sistemas dinámicos

Supongamos que tenemos una aproximación de  $p(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})$ ,

$$\hat{p}^N(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1}) = \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}} w_{t-1}^{(i)}$$

## Importance sampling en sistemas dinámicos

Supongamos que tenemos una aproximación de  $p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})$ ,

$$\hat{p}^N(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) = \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}} w_{t-1}^{(i)}$$

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}) = \frac{p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t | \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t | \mathbf{y}_{1:t-1})}$$

## Importance sampling en sistemas dinámicos

Supongamos que tenemos una aproximación de  $p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})$ ,

$$\hat{p}^N(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) = \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}} w_{t-1}^{(i)}$$

$$\begin{aligned} p(\mathbf{x}_t | \mathbf{y}_{1:t}) &= \frac{p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t | \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t | \mathbf{y}_{1:t-1})} \\ &\propto p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) \end{aligned}$$



## Importance sampling en sistemas dinámicos

Supongamos que tenemos una aproximación de  $p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})$ ,

$$\hat{p}^N(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) = \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}} w_{t-1}^{(i)}$$

$$\begin{aligned} p(\mathbf{x}_t | \mathbf{y}_{1:t}) &= \frac{p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t | \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t | \mathbf{y}_{1:t-1})} \\ &\propto p(\mathbf{y}_t | \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t | \mathbf{y}_{1:t-1}) \\ &= p(\mathbf{y}_t | \mathbf{x}_t) \int p(\mathbf{x}_t | \mathbf{x}_{t-1}, \mathbf{y}_{1:t-1})p(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1})d\mathbf{x}_{t-1} \end{aligned}$$

## Importance sampling en sistemas dinámicos

Supongamos que tenemos una aproximación de  $p(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})$ ,

$$\hat{p}^N(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1}) = \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}} w_{t-1}^{(i)}$$

$$\begin{aligned} p(\mathbf{x}_t \mid \mathbf{y}_{1:t}) &= \frac{p(\mathbf{y}_t \mid \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t \mid \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t \mid \mathbf{y}_{1:t-1})} \\ &\propto p(\mathbf{y}_t \mid \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t \mid \mathbf{y}_{1:t-1}) \\ &= p(\mathbf{y}_t \mid \mathbf{x}_t) \int p(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{y}_{1:t-1})p(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})d\mathbf{x}_{t-1} \\ &\approx p(\mathbf{y}_t \mid \mathbf{x}_t) \int p(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{y}_{1:t-1})\hat{p}^N(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})d\mathbf{x}_{t-1} \end{aligned}$$

## Importance sampling en sistemas dinámicos

Supongamos que tenemos una aproximación de  $p(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})$ ,

$$\hat{p}^N(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1}) = \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}} w_{t-1}^{(i)}$$

$$\begin{aligned} p(\mathbf{x}_t \mid \mathbf{y}_{1:t}) &= \frac{p(\mathbf{y}_t \mid \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t \mid \mathbf{y}_{1:t-1})}{p(\mathbf{y}_t \mid \mathbf{y}_{1:t-1})} \\ &\propto p(\mathbf{y}_t \mid \mathbf{x}_t, \mathbf{y}_{1:t-1})p(\mathbf{x}_t \mid \mathbf{y}_{1:t-1}) \\ &= p(\mathbf{y}_t \mid \mathbf{x}_t) \int p(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{y}_{1:t-1})p(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})d\mathbf{x}_{t-1} \\ &\approx p(\mathbf{y}_t \mid \mathbf{x}_t) \int p(\mathbf{x}_t \mid \mathbf{x}_{t-1}, \mathbf{y}_{1:t-1})\hat{p}^N(\mathbf{x}_{t-1} \mid \mathbf{y}_{1:t-1})d\mathbf{x}_{t-1} \\ &= p(\mathbf{y}_t \mid \mathbf{x}_t) \sum_{i=1}^N p(\mathbf{x}_t \mid \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1})w_{t-1}^{(i)} \end{aligned}$$

# Filtrado de partículas

- **Inicialización**

# Filtrado de partículas

- **Inicialización**

- Se toman muestras de la prior,

$$\mathbf{x}_0^{(i)} \sim p(\mathbf{x}_0), i = 1, \dots, N,$$

- se inicializan todos los pesos al mismo valor

$$w_i^{(0)} = 1/N, i = 1, \dots, N$$

# Filtrado de partículas

- Inicialización**

- Se toman muestras de la prior,

$$\mathbf{x}_0^{(i)} \sim p(\mathbf{x}_0), i = 1, \dots, N,$$

- se inicializan todos los pesos al mismo valor

$$w_i^{(0)} = 1/N, i = 1, \dots, N$$

- Recursión** en el instante  $t$

- tomar muestras,  $\mathbf{x}_t^{(1)}, \mathbf{x}_t^{(2)}, \dots$ , de la función tentativa elegida

$$\mathbf{x}_t^{(i)} \sim q(\mathbf{x}_t | \mathbf{y}_{1:t})$$

- calcular los pesos

$$w_t^{(i)} \propto \frac{p(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})}{q(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})} = \frac{p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \sum_{i=1}^N p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}}{q(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})}$$

# Filtrado de partículas

- Inicialización**

- Se toman muestras de la prior,

$$\mathbf{x}_0^{(i)} \sim p(\mathbf{x}_0), i = 1, \dots, N,$$

- se inicializan todos los pesos al mismo valor

$$w_i^{(0)} = 1/N, i = 1, \dots, N$$

- Recursión** en el instante  $t$

- tomar muestras,  $\mathbf{x}_t^{(1)}, \mathbf{x}_t^{(2)}, \dots$ , de la función tentativa elegida

$$\mathbf{x}_t^{(i)} \sim q(\mathbf{x}_t | \mathbf{y}_{1:t})$$

- calcular los pesos

$$w_t^{(i)} \propto \frac{p(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})}{q(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})} = \frac{p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \sum_{i=1}^N p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}}{q(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})}$$

Este esquema es conocido como **filtrado de partículas** o *importance sampling* secuencial (SIS). Con muestras, se puede utilizar (1) para aprox. cualquier integral respecto de  $p(\mathbf{x}_t | \mathbf{y}_{1:t})$ .

## El filtro *bootstrap*

Si elegimos como función tentativa

$$q(\mathbf{x}_t | \mathbf{y}_{1:t}) = \sum_{i=1}^N p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}$$



# El filtro *bootstrap*

Si elegimos como función tentativa

$$q(\mathbf{x}_t | \mathbf{y}_{1:t}) = \sum_{i=1}^N p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}$$

el cálculo de los pesos es muy sencillo

$$\begin{aligned} w_t^{(i)} &\propto \frac{p(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})}{q(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})} = \frac{p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \sum_{i=1}^N p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}}{\sum_{i=1}^N p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}} \\ &= p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \end{aligned}$$

# El filtro *bootstrap*

Si elegimos como función tentativa

$$q(\mathbf{x}_t | \mathbf{y}_{1:t}) = \sum_{i=1}^N p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}$$

el cálculo de los pesos es muy sencillo

$$\begin{aligned} w_t^{(i)} &\propto \frac{p(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})}{q(\mathbf{x}_t^{(i)} | \mathbf{y}_{1:t})} = \frac{p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \sum_{i=1}^N p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}}{\sum_{i=1}^N p(\mathbf{x}_t^{(i)} | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}} \\ &= p(\mathbf{y}_t | \mathbf{x}_t^{(i)}) \end{aligned}$$

El algoritmo resultante es el filtro *bootstrap*, considerado el primer filtro de partículas

## El filtro *bootstrap*: la función tentativa

Muestrear de la función tentativa

$$q(\mathbf{x}_t | \mathbf{y}_{1:t}) = \sum_{i=1}^N p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}$$

se puede interpretar como un procedimiento que consta de dos pasos:

## El filtro *bootstrap*: la función tentativa

Muestrear de la función tentativa

$$q(\mathbf{x}_t | \mathbf{y}_{1:t}) = \sum_{i=1}^N p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}$$

se puede interpretar como un procedimiento que consta de dos pasos:

- **remuestrear** la aproximación previa

$$\left\{ \left( \mathbf{x}_{t-1}^{(1)}, w_{t-1}^{(1)} \right), \left( \mathbf{x}_{t-1}^{(2)}, w_{t-1}^{(2)} \right), \left( \mathbf{x}_{t-1}^{(3)}, w_{t-1}^{(3)} \right), \dots \right\}$$

para obtener  $\mathbf{x}_{t-1}^{(j_1)}, \mathbf{x}_{t-1}^{(j_2)}, \dots, \mathbf{x}_{t-1}^{(j_t)}$  con  
 $j_1, j_2, \dots, j_t \in \{1, \dots, N\}$

## El filtro *bootstrap*: la función tentativa

Muestrear de la función tentativa

$$q(\mathbf{x}_t | \mathbf{y}_{1:t}) = \sum_{i=1}^N p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}, \mathbf{y}_{1:t-1}) w_{t-1}^{(i)}$$

se puede interpretar como un procedimiento que consta de dos pasos:

- **remuestrear** la aproximación previa

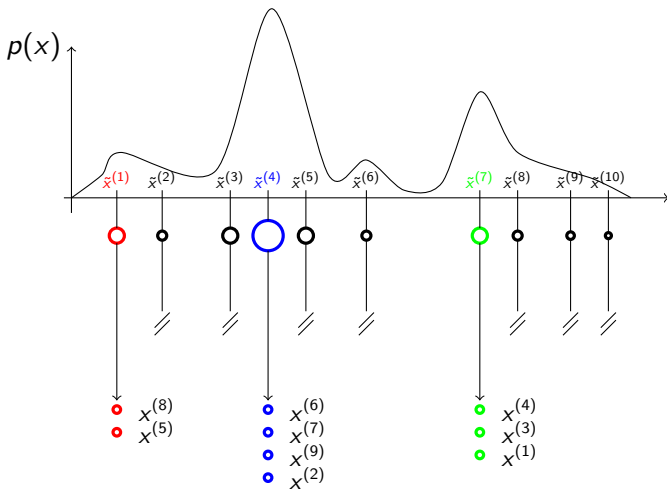
$$\left\{ \left( \mathbf{x}_{t-1}^{(1)}, w_{t-1}^{(1)} \right), \left( \mathbf{x}_{t-1}^{(2)}, w_{t-1}^{(2)} \right), \left( \mathbf{x}_{t-1}^{(3)}, w_{t-1}^{(3)} \right), \dots \right\}$$

para obtener  $\mathbf{x}_{t-1}^{(j_1)}, \mathbf{x}_{t-1}^{(j_2)}, \dots, \mathbf{x}_{t-1}^{(j_t)}$  con  
 $j_1, j_2, \dots, j_t \in \{1, \dots, N\}$

- **propagar** cada partícula remuestreada utilizando la fdp de transición,  $p(\mathbf{x}_t | \mathbf{x}_{t-1})$ ,

$$\mathbf{x}_t^{(i)} \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(j_i)}), i = 1, \dots, N$$

# Remuestreo



# El filtro *bootstrap*: implementación

- Inicialización**

- muestrear  $\mathbf{x}_0^{(i)}, i = 1, \dots, N$  de la *prior*  $p(\mathbf{x}_0)$

- Recursión**

dado  $\hat{p}^N(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) = \sum_{i=1}^N w^{(i)} \delta_{\tilde{\mathbf{x}}_{t-1}^{(i)}}$ ,

- remuestreo: sea  $\mathbf{x}_{t-1}^{(i)} = \tilde{\mathbf{x}}_{t-1}^{(j)}$  con probabilidad  $w^{(j)}, i = 1, \dots, N, j \in \{1, \dots, N\}$ .
- propagación (muestreo)

$$\tilde{\mathbf{x}}_t^{(i)} \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}), i = 1, \dots, N$$

- cálculo de los pesos...

$$w^{*(i)} = p(\mathbf{y}_t | \tilde{\mathbf{x}}_t^{(i)}), i = 1, \dots, N$$

...y normalización

$$w^{(i)} = \frac{w^{*(i)}}{\sum_{j=1}^N w^{*(j)}}, i = 1, \dots, N$$

# El filtro *bootstrap*: implementación

- **Inicialización**

- muestrear  $\mathbf{x}_0^{(i)}, i = 1, \dots, N$  de la *prior*  $p(\mathbf{x}_0)$

- **Recursión** dado  $\hat{p}^N(\mathbf{x}_{t-1} | \mathbf{y}_{1:t-1}) = \frac{1}{N} \sum_{i=1}^N \delta_{\mathbf{x}_{t-1}^{(i)}}$ ,

- 1 propagación (muestreo)

$$\tilde{\mathbf{x}}_t^{(i)} \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)}), i = 1, \dots, N$$

- 2 cálculo de los pesos...

$$w^{*(i)} = p(\mathbf{y}_t | \tilde{\mathbf{x}}_t^{(i)}), i = 1, \dots, N$$

...y normalización

$$w^{(i)} = \frac{w^{*(i)}}{\sum_{j=1}^N w^{*(j)}}, i = 1, \dots, N$$

- 3 remuestreo: sea  $\mathbf{x}_t^{(i)} = \tilde{\mathbf{x}}_t^{(j)}$  con probabilidad  $w^{(j)}, i = 1, \dots, N, j \in \{1, \dots, N\}$ .



# El filtro *bootstrap*: visión general

## 1. Inicialización

$$\mathbf{x}_0^{(i)} \sim p(\mathbf{x}_0) \text{ para } i = 1, \dots, N$$

2. **Paso recursivo:** partiendo de muestras en el instante  $t-1$

### 2.1. Propagación de muestras

$$\tilde{\mathbf{x}}_t^{(i)} \sim p(\mathbf{x}_t | \mathbf{x}_{t-1}^{(i)})$$

### 2.2. Cálculo de pesos y normalización


$$w^{(i)} \propto p(\mathbf{y}_t | \tilde{\mathbf{x}}_t^{(i)}), i = 1, \dots, N$$

### 2.3. Remuestreo

$$\mathbf{x}_t^{(i)} = \tilde{\mathbf{x}}_t^{(j)}, i = 1, \dots, N$$

con probabilidad  $w^{(j)}, j \in \{1, \dots, N\}$

muestras en el instante  $t$



## El filtro *bootstrap*: epílogo

En la implementación dada arriba, al final de cada iteración tenemos muestras

$$\mathbf{x}_t^{(1)}, \mathbf{x}_t^{(2)}, \dots, \mathbf{x}_t^{(N)}$$

que constituyen una aproximación de

$$p(\mathbf{x}_t \mid \mathbf{y}_{1:t}),$$

## El filtro *bootstrap*: epílogo

En la implementación dada arriba, al final de cada iteración tenemos muestras

$$\mathbf{x}_t^{(1)}, \mathbf{x}_t^{(2)}, \dots, \mathbf{x}_t^{(N)}$$

que constituyen una aproximación de

$$p(\mathbf{x}_t | \mathbf{y}_{1:t}),$$

pero el objetivo inicial era aproximar la esperanza de una función de interés (conocida),  $\mathbf{g}$ , con respecto a  $p(\mathbf{x}_t | \mathbf{y}_{1:t})$ , i.e.,

$$\mathbb{E}[\mathbf{g}(\mathbf{x}_t)] = \int \mathbf{g}(\mathbf{x}_t) p(\mathbf{x}_t | \mathbf{y}_{1:t}) d\mathbf{x}_t.$$

## El filtro *bootstrap*: epílogo

En la implementación dada arriba, al final de cada iteración tenemos muestras

$$\mathbf{x}_t^{(1)}, \mathbf{x}_t^{(2)}, \dots, \mathbf{x}_t^{(N)}$$

que constituyen una aproximación de

$$p(\mathbf{x}_t \mid \mathbf{y}_{1:t}),$$

pero el objetivo inicial era aproximar la esperanza de una función de interés (conocida),  $\mathbf{g}$ , con respecto a  $p(\mathbf{x}_t \mid \mathbf{y}_{1:t})$ , i.e.,

$$\mathbb{E}[\mathbf{g}(\mathbf{x}_t)] = \int \mathbf{g}(\mathbf{x}_t) p(\mathbf{x}_t \mid \mathbf{y}_{1:t}) d\mathbf{x}_t.$$

Simplemente utilizamos las muestras para obtener una

aproximación por Monte Carlo,

$$\mathbb{E}[\mathbf{g}(\mathbf{x}_t)] \approx \frac{1}{N} \sum_{n=1}^N \mathbf{g}(\mathbf{x}_t^{(n)})$$