



Mondragon
Unibertsitatea

Faculty of
Engineering

3. Estimación de estado de carga


Máster en Sistemas Inteligentes de Energía

Unai Iraola - Laura Oca

1

Estimación de estados de batería

Algoritmo principal de un BMS



G. Plett, Battery Management Systems. Vol. 2. Equivalent-circuit methods

- Estimación del SoC.
- Estimación del SoH. (Diagnóstico)
- Ecuilización de celdas o balanceo.
- Computar límites de energía y potencia. (SoE and SoP)
- Otros estados en bibliografía SoS

2

Estado de carga (SoC)

¿Qué es el estado de carga?


- El estado de carga es una variable similar al nivel de gasolina que tengo en un depósito de un coche de combustión.
- Sin embargo, el nivel de gasolina se puede medir pero **no hay sensor comercial capaz de medir el SoC de una batería, no existe.**
- Por lo tanto debemos combinar, las medidas que sí tenemos, tensión, corriente y temperatura, además de nuestros modelos de batería para hacer estimaciones de SoC.
- Hay métodos de estimación simples que dan resultados pobres, y hay métodos más complejos que dan muy buenos resultados, el hecho de tener precisión en esta medida requiere de un algoritmo complejo.
- Sin embargo, esta complejidad puede mejorar tu batería sobremanera:
 - **Durabilidad:** Saber con precisión el SoC ayuda a evitar sobrecargas y descargas profundas.
 - **Comportamiento:** Si tienes una mala estimación eres “segurola”, en cambio, si es buena, puedes sacar más de tu batería.
 - **Fiabilidad:** Un mal estimador no vale para cualquier perfil de corriente.
 - **Densidad de energía y economía:** Si podemos aprovechar mejor nuestra batería tendremos baterías más pequeñas y económicas.

¿Cómo se define el estado de carga?

- Existen varias definiciones en bibliografía para este término.
- El SoC se relaciona directamente con la concentración de litio, que por definición en un electrodo va de 0% a 100% en cada instante k .
- Estos límites se pueden exceder si se sobrecarga o se descarga demasiado una batería.
- La pega es que no hay una manera directa de medir las concentraciones y de ahí que tengamos que estimar su valor a partir de medidas de tensión, corriente y temperatura.
- El sensor de tensión está colocado en bornas de la batería, sabemos que no mide tensión en circuito abierto o OCV.
- Al final el SoC es un valor de 0 a 100 que muestra cuántos Ah me quedan en mi batería (Ah remanentes) respecto a su **capacidad total** (Ah totales).
- Dos problemas:
 - ¿Cómo se estima?
 - ¿Cómo validamos que nuestros estimadores son buenos si no tenemos contra qué compararlos?

Capacidad total y cómo resetear el SoC

- 100% de SoC se dará cuando la tensión en circuito abierto de una celda llegue a una tensión $v_{high}(T)$ tras una carga. Operativamente esto se hace con una carga CC+CV y a 25°C.




- 0% de SoC se dará cuando la tensión en circuito abierto de una celda llegue a una tensión $v_{low}(T)$ tras una descarga. Operativamente esto se hace con una descarga CC+CV y a 25°C. (Exactamente igual que en la carga)
- Por lo tanto cuando descargas una celda a una temperatura que no es 25°C hasta una tensión $v_{low}(T)$ no alcanzas el 0% de SoC. A la hora de evaluar estimadores es muy importante tener esto en cuenta.
- **EJEMPLO DE PROCESO A SEGUIR:** Cargas tu celda hasta el 100% a 25°C, varías la temperatura a 10°C, descargas a 1C durante 15 minutos, y tu estimador te da SoC = 72%. Vuelves a 25°C, y descargas tu baterías hasta el 0% de SoC.

Tipos de estimadores de SoC

1. BASADOS EN MEDIDAS DIRECTAS DE TENSION.

- Sabemos que: $v_k = OCV(z_k) - R_0 \cdot I - v_{C_1} - v_{C_2}$
- Y que cuando la celda se encuentra en reposo $v_k \approx OCV(z_k)$
- Por lo tanto, y sólo si se ignora la histéresis podemos obtener el SoC sabiendo la tensión en circuito abierto OCV de la celda para distintas temperaturas de trabajo. (Lookup table)




- La figura muestra distintas OCV vs SoC para distintas químicas.
- Las curvas en químicas LFP son muy planas y por lo tanto será extremadamente complicado saber en qué SoC está la celda.
- Si os dan a elegir, para estimación de SoC siempre mejor químicas tipo NMC.

G. Plett, Battery Management Systems. Vol. 2. Equivalent-circuit methods

Tipos de estimadores de SoC

1. BASADOS EN MEDIDAS DIRECTAS DE TENSION.

- Si sabemos la R_0 y la corriente que circula a través de la batería también podemos estimar el SoC cuando hay carga. $v_k = OCV(z_k) - R_0 \cdot I$
- Filtrar la señal podría ser una solución pero los filtros añaden un retardo en la estimación.
- La histéresis es un problema importante.



G. Plett, Battery Management Systems. Vol. 2. Equivalent-circuit methods

Tipos de estimadores de SoC

2. BASADOS EN MEDIDAS DIRECTAS DE CORRIENTE.

- Coulomb counting es lo más típico:

- $$SoC(k) = \frac{Q_0 + \frac{1}{3600} \sum_0^n i_{meas}(k)}{Q_N} \cdot 100$$


- En la ecuación de encima suponemos una eficiencia coulombica del 100%, cuando será ligeramente inferior.

- $$i_{meas}(k) = i_{true}(k) + i_{noise}(k) + i_{bias}(k) + i_{nonlin}(k) + i_{sd}(k) + i_{leakage}(k)$$

- Esto hace que el método sea válido para tiempos que no sean demasiado largos cuando las condiciones iniciales son conocidas o cuando puedes resetear el método a unas condiciones conocidas.
- En algunos casos, este método se combina con el anterior de medida directa de tensión para resetear o corregir las estimaciones. (Se ve mucho)
- El método tiene muchos peros, imaginar que Q_0 o Q_N no están bien calculadas, el estimador nunca se recupera de esto.
- Aunque parezca algo simple termina por no serlo, por lo menos no para tener una estimación de SoC lo suficientemente robusta.

3. BASADOS EN MODELO

- En la transparencia anterior hablábamos de combinar ambos métodos, pero esta vez lo haremos de una manera distinta.
- Utilizaremos un modelo corriendo en paralelo en el BMS el cual estime la tensión en bornas de mi batería.
- Process noise = Error en el sensor de corriente.
- Sensor noise = Error en el sensor de tensión.
- El process noise hace que nuestro modelo no tenga como entrada la corriente real, y por tanto no sea del todo fiable.
- El sensor noise hace que nuestra medida real de tensión no sea perfecta y que no nos podamos fiar de ella del todo.



- Nuestro modelo lleva un coulomb counting dentro pero hay una diferencia. La predicción de tensión se compara con la medida de tensión.

3. BASADOS EN MODELO

- Si Measured = Estimated, entonces nuestras estimaciones serán buenas.
- Si Measured \neq Estimated, entonces el modelo no estará estimando bien.
- Por lo tanto, la comparación de ambos será el feedback necesario en nuestro modelo para corregir las estimaciones que estamos realizando.
- Sin embargo, el error que cometemos puede venir dado por varias razones:
 - Estimación de SoC, que es lo que queremos corregir.
 - Errores de medida. (Sensor noise)
 - Errores en el modelo. (Porque no es perfecto)
- Para ello, en bibliografía encontraréis el filtro de Kalman en sus distintas variantes:
 - Lineal. (No es válido para baterías, no es un problema lineal)
 - Extendido.
 - Sigma point Kalman filter.
- El filtro de Kalman es un algoritmo que computa una estimación probablemente buena a pesar de los errores que tengamos.
- Es un caso especial de una teoría más general llamada *sequential probabilistic inference*.

3. BASADOS EN MODELO

- Estos desarrollos se basan en tomar medidas de un sistema real para estimar los estados actuales de ese sistema. X_k
- Las medidas que hacemos nos permiten estimar qué está pasando dentro de la batería midiendo en este caso la tensión.
- Sin embargo, las medidas no son perfectas, por lo tanto, siempre habrá una cierta incertidumbre.
- Pero, las medidas siempre caerán cerca del valor real, nunca lejos de él. (Sin embargo, no es un proceso determinista, es decir, no podemos saber qué va a pasar)
- Por lo tanto, es importante conocer la teoría de *vector random processes*.
- Toda esta teoría la podéis encontrar en las *páginas 79 a 101 del libro “Battery Management Systems volumen 2 Equivalent-circuit methods”* de Gregory Plett.

3. BASADOS EN MODELO


- Lo primero de todo es plantear nuestro modelo en espacio de estados (es simplemente una forma de representación de las ecuaciones de nuestro modelo) con la forma matricial:

- $x_k = A_{k-1} \cdot x_{k-1} + B_{k-1} \cdot u_{k-1} + w_{k-1}$

- $y_k = C_k \cdot x_k + D_k \cdot u_k + v_k$

- Donde x_k es la matriz de estados del modelo, en nuestro caso estará compuesta por las tensiones en los tanques RC del modelo V_{c1} y V_{c2} y por el estado de carga SoC.
- Y donde y_k es la salida que en nuestro caso será la tensión de la celda.
- w_k será el ruido del proceso.
- v_k será el ruido del sensor de tensión.
- Las matrices A , B , C , D son las que multiplican tanto a las variables de estado como a la entrada, que en nuestro caso será la corriente.

3. BASADOS EN MODELO



$$[OCV, R_0, R_1, R_2, C_1, C_2]$$

$$= f(SOC, T, SOH \dots)$$

$$v_{batt}(t) = OCV(SOC(t)) + v_1(t) + v_2(t) + R_0 \cdot i_{batt}(t)$$

$$v_1(t) = \frac{1}{C_1} \int i_{C_1}(t) dt \Rightarrow i_{C_1}(t) = i_{batt}(t) - \frac{v_1(t)}{R_1}$$

$$v_2(t) = \frac{1}{C_2} \int i_{C_2}(t) dt \Rightarrow i_{C_2}(t) = i_{batt}(t) - \frac{v_2(t)}{R_2}$$

$$SOC(t) = \left(SOC(t_0) + \eta \cdot \frac{\Delta t}{Q_{nom}} i_{batt}(t) \right)$$

Continuos-time

$$v_{batt}[k] = OCV(SOC[k]) + v_1[k] + v_2[k] + R_0 \cdot i_{batt}[k]$$

$$v_1[k+1] = v_1[k] \cdot e^{-\frac{T_s}{R_1 \cdot C_1}} + R_1 \cdot \left(1 - e^{-\frac{T_s}{R_1 \cdot C_1}} \right) \cdot i_{batt}[k]$$

$$v_2[k+1] = v_2[k] \cdot e^{-\frac{T_s}{R_2 \cdot C_2}} + R_2 \cdot \left(1 - e^{-\frac{T_s}{R_2 \cdot C_2}} \right) \cdot i_{batt}[k]$$

$$SOC[k+1] = \left(SOC[k] + \eta \cdot \frac{\Delta t}{Q_N} i_{batt}[k] \right)$$


Discrete-time

3. BASADOS EN MODELO

- En el filtro de Kalman existe cierta nomenclatura importante que remarcar antes de ver los pasos que se siguen:
 - El superíndice “-” indica que es una **predicción** que se basa solamente en medidas anteriores.
 - El superíndice “+” indica que es una **estimación** que significa que se basa tanto en medidas anteriores como actuales.
 - El símbolo “^” indica que es algo estimado o que es una predicción: \hat{x}^+ o \hat{x}^-
 - El símbolo “~” indica un error, es decir, la diferencia entre un valor real y una predicción o estimación: $\tilde{x} = x - \hat{x}$
 - El símbolo “ Σ ” es la covarianza, se utiliza en uno de los pasos del filtro de Kalman. Representan la cantidad de ruido de tu sistema, simplificándolo mucho. Digamos que es lo que representa la incertidumbre que tienes tanto en el **process noise** como en el **sensor noise**.

Filtro de Kalman lineal

3. BASADOS EN MODELO






- Se divide en dos fases principales.
- La fase de predicción primero.
- La fase de corrección después.
- Hay que inicializar el filtro en el instante 0.
- Por el camino se utilizan las medidas de la corriente, representada como u_k y la tensión, representada como y_k .

G. Plett, Battery Management Systems. Vol. 2. Equivalent-circuit methods

Filtro de Kalman lineal

3. BASADOS EN MODELO

- Con un filtro de Kalman lineal puedes realizar una estimación, pero no es lo mejor, ya que la tensión en circuito abierto de cualquier celda es altamente no lineal, y por tanto resolverlo así va a hacer que cometamos un error.



G. Plett, Battery Management Systems. Vol. 2. Equivalent-circuit methods

3. BASADOS EN MODELO

- Tanto el filtro de Kalman extendido como con el Unscented / Sigma point Kalman filter se utilizan para sistemas no lineales como el caso de la batería.
- Los seis pasos vistos para el caso del filtro de Kalman lineal siguen existiendo de igual manera, pero dentro de esos pasos la formulación es diferente.
- Toda la información la podéis encontrar en las *páginas 114 a 129 del libro “Battery Management Systems volumen 2 Equivalent-circuit methods”* de Gregory Plett.

Filtro de Kalman extendido (Ecuaciones)

3. BASADOS EN MODELO

Summary of the nonlinear extended Kalman filter

Nonlinear state-space model:

$$x_k = f(x_{k-1}, u_{k-1}, w_{k-1})$$

$$y_k = h(x_k, u_k, v_k),$$

where w_k and v_k are independent, Gaussian noise processes with means \bar{w} and \bar{v} and covariance matrices $\Sigma_{\bar{w}}$ and $\Sigma_{\bar{v}}$, respectively.

Definitions:

$$\hat{A}_k = \left. \frac{df(x_k, u_k, w_k)}{dx_k} \right|_{x_k = \hat{x}_k^+}$$

$$\hat{B}_k = \left. \frac{df(x_k, u_k, w_k)}{dw_k} \right|_{w_k = \bar{w}_k}$$

$$\hat{C}_k = \left. \frac{dh(x_k, u_k, v_k)}{dx_k} \right|_{x_k = \hat{x}_k^-}$$

$$\hat{D}_k = \left. \frac{dh(x_k, u_k, v_k)}{dv_k} \right|_{v_k = \bar{v}_k}$$

Initialization: For $k = 0$, set

$$\hat{x}_0^+ = \mathbb{E}[x_0]$$

$$\Sigma_{\bar{x},0}^+ = \mathbb{E}[(x_0 - \hat{x}_0^+)(x_0 - \hat{x}_0^+)^T].$$

Computation: For $k = 1, 2, \dots$ compute:

State-prediction time update: $\hat{x}_k^- = f(\hat{x}_{k-1}^+, u_{k-1}, \bar{w}_{k-1})$

Error-covariance time update: $\Sigma_{\bar{x},k}^- = \hat{A}_{k-1} \Sigma_{\bar{x},k-1}^+ \hat{A}_{k-1}^T + \hat{B}_{k-1} \Sigma_{\bar{w}} \hat{B}_{k-1}^T$

Output estimate: $\hat{y}_k = h(\hat{x}_k^-, u_k, \bar{v}_k)$

*Estimator gain matrix:** $L_k = \Sigma_{\bar{x},k}^- \hat{C}_k^T [\hat{C}_k \Sigma_{\bar{x},k}^- \hat{C}_k^T + \hat{D}_k \Sigma_{\bar{v}} \hat{D}_k^T]^{-1}$

State-estimate meas. update: $\hat{x}_k^+ = \hat{x}_k^- + L_k (y_k - \hat{y}_k)$

Error-covariance meas. update: $\Sigma_{\bar{x},k}^+ = \Sigma_{\bar{x},k}^- - L_k \Sigma_{\bar{y},k} L_k^T$

*If a measurement is missed for some reason, then simply skip the measurement update for that iteration. That is, $L_k = 0$ and $\hat{x}_k^+ = \hat{x}_k^-$ and $\Sigma_{\bar{x},k}^+ = \Sigma_{\bar{x},k}^-$.

G. Plett, Battery Management Systems. Vol. 2. Equivalent-circuit methods



**Mondragon
Unibertsitatea**

Faculty of
Engineering

Eskerrik asko
Muchas gracias
Thank you

Unai Iraola

uiraola@mondragon.edu

Laura Oca

lauraoca@mondragon.edu