



UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA ELÉCTRICA

ESTIMACIÓN Y PRONÓSTICO EN LÍNEA DEL ESTADO-
DE-CARGA DE BATERÍAS IÓN-LITIO EN BICICLETAS
ELÉCTRICAS BASADO EN FILTRO DE PARTÍCULAS

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL ELÉCTRICO

CRISTOBAL ANDRES INOSTROZA PIZARRO

PROFESOR GUÍA:
MARCOS ORCHARD CONCHA

MIEMBROS DE LA COMISIÓN:
JORGE SILVA SANCHEZ
JAIME ALEÉ GIL

SANTIAGO DE CHILE
2016

RESUMEN

La búsqueda de nuevas alternativas energéticas ha impulsado el uso de sistemas de almacenamiento de energía en diversas temáticas de operación, contribuyendo a la mantención preventiva y predictiva en sistemas autónomos o teleoperados de transporte, sistemas expertos industriales, vehículos eléctricos, entre otros. Es por esto, que el desarrollo de nuevas técnicas y metodologías en acumuladores, tanto en su monitoreo como en su control, abarcan un rubro que en la actualidad tiene mayor presencia, e incluso mayor criticidad en la industria. Ante la falta de un sistema robusto que genere un valor agregado al problema de pronóstico del tiempo de corte de un acumulador, bajo diferentes escenarios, o el seguimiento del Estado de Carga con la característica de proveer información en tiempo real, se presenta el desafío de cómo utilizar información conocida para el futuro estado de un acumulador en base modelos propuestos para el proceso de descarga continuada en acumuladores de Ión-Litio.

Con el objeto de solucionar esta problemática, se propone una metodología de estimación y predicción Bayesiano del Estado de Carga en un arreglo de celdas de Ión-Litio, aplicable bajo un modelo dinámico no lineal y estocástico para el proceso de descarga, garantizando una solución no necesariamente óptima, pero aproximada ante las diversas fuentes de incertidumbre presentes en el proceso que se buscan caracterizar de forma estadística, en nuestro caso, la corriente futura de descarga de la batería, las perturbaciones en datos medidos, etc. Con el fin de implementarse en tiempo real y maximizar la autonomía de una flota de bicicletas eléctricas tanto en la eficiencia de la información que se provee al usuario que toma las decisiones como en la escalabilidad de la solución en desafíos de mayor tamaño.

En este trabajo se prueba y analiza un pack de baterías de **37[V]** y **8[Ah]** de capacidad para el desarrollo e implementación de la solución propuesta. La validación se realiza con datos reales de diferentes rutas realizadas en bicicletas eléctricas provocando resultados deseables ante la búsqueda de parámetros de diseño óptimos en la solución, principalmente por motivos de presentar una numerosa cantidad de simulaciones con datos de distinta calidad, lo que implica la acción de reajustar la solución ante análisis de sensibilidad en los resultados, los cuales se miden mediante diversas métricas de evaluación enfocadas en la exactitud y precisión de los estadísticos presentes en el Estado de Carga o En el Fin de la Descarga sobre un pack de baterías de Ión-Litio en permanente operación.

Con el trabajo realizado se dan por cumplido los objetivos señalados, tales como maximizar la autonomía y la precisión de la información de monitoreo a disposición del usuario, reduciendo a su vez las fuentes de incertidumbre que obstaculizan el desempeño general del algoritmo en diversas formas y optando por el uso de múltiples realizaciones de predicción Bayesiano ante anomalías inminentes que afectan el buen funcionamiento del algoritmo.

TABLA DE CONTENIDO

RESUMEN	i
TABLA DE CONTENIDO	ii
ÍNDICE DE FIGURAS	iv
ÍNDICE DE TABLAS	v
LISTA DE ACRÓNIMOS	1
CAPITULO 1	2
INTRODUCCIÓN	2
1.1. MOTIVACIÓN	2
1.2. ALCANCES.....	3
1.3. OBJETIVOS	4
1.4. ESTRUCTURA DEL INFORME.....	4
CAPITULO 2	5
REVISIÓN BIBLIOGRÁFICA	5
2.1. ANTECEDENTES GENERALES DEL ESTADO DE CARGA EN DISPOSITIVOS ACUMULADORES DE ENERGÍA	5
2.1.1. ESTIMACIÓN Y PREDICCIÓN DEL ESTADO DE CARGA	6
2.2. INFERENCIA BAYESIANA Y FILTRO DE PARTÍCULAS.....	7
2.2.1. MUESTREO SECUENCIAL DE IMPORTANCIA.....	11
2.2.2. REMUESTREO SECUENCIAL DE IMPORTANCIA	12
2.2.3. PRONÓSTICO DE EVENTOS BASADO EN FILTRO DE PARTÍCULAS	14
2.3. K-MEANS CLUSTERING.....	16
2.4. CADENAS DE MARKOV	17
2.5. MODELO ESTOCÁSTICO EN ECUACIONES DE ESTADO PARA LA ESTIMACIÓN DEL SOC EN EL PROCESO DE DESCARGA	19
2.6. CONTEXTUALIZACIÓN Y ESPECIFICACIONES DEL ESD OPERADO EN LA E-BIKE.....	23

CAPITULO 3	31
DESARROLLO METODOLÓGICO.....	31
3.1. ESTIMACIÓN OFFLINE DE PARÁMETROS PARA MODELO DE DESCARGA DEL SOC	32
3.1.1. PRUEBA DE DESCARGA CONTROLADA	33
3.1.2. ESTIMACIÓN DE PARÁMETROS Y CURVA CARACTERÍSTICA OCV- SOC.....	37
3.2. DESARROLLO Y ADAPTACIÓN MODULAR DEL AEP	39
3.2.1. MÓDULO DE ESTIMACIÓN BASADO EN FILTRO DE PARTÍCULAS	40
3.2.2. CARACTERIZACIÓN ESTADÍSTICA DEL PERFIL DE USO FUTURO DEL ESD.....	44
3.2.3. MÓDULO DE PRONÓSTICO BASADO EN FILTRO DE PARTÍCULAS	48
3.2.4. DETERMINACIÓN DE POTENCIA MÁXIMA DISPONIBLE DE ESD	51
 CAPITULO 4	 53
ANÁLISIS DE RESULTADOS Y VALIDACIÓN.....	53
4.1. ANÁLISIS DE DESEMPEÑO EN PRUEBAS FUERA DE LÍNEA	53
4.1.1. SET DE DATOS UTILIZADOS FUERA DE LÍNEA.....	53
4.1.2. RESULTADOS Y OPTIMIZACIÓN OFFLINE DE AEP.....	56
4.2. ANÁLISIS DE IMPLEMENTACIÓN EN LÍNEA	78
4.2.1. SET DE DATOS Y ANÁLISIS PRELIMINAR DEL AEP EN APLICACIÓN MÓVIL.....	78
4.2.2. RESTRICCIONES Y OPERATIVIDAD EN LÍNEA.....	81
 CAPITULO 5	 83
CONCLUSIONES.....	83
BIBLIOGRAFÍA	85

ÍNDICE DE FIGURAS

FIGURA 2.2.1: Esquema general del filtro de partículas con remuestreo de importancia	14
FIGURA 2.5.1: Modelo de batería litio-ion mediante circuito eléctrico DC equivalente [5].....	20
FIGURA 2.6.1: Esquema general de conexión del hardware E-Bike	24
FIGURA 2.6.2: Configuración de celdas de Ión-Litio en pack de baterías.....	25
FIGURA 2.6.3: Curva característica de descarga de celda ICR26650 por capacidad (datasheet)	26
FIGURA 2.6.4: Curva característica de descarga de celda ICR26650 por tiempo (datasheet).....	27
FIGURA 2.6.5: Sensor de corriente de efecto hall.....	28
FIGURA 2.6.6: Circuito maestro de adquisición y transmisión de datos	29
FIGURA 2.6.7: Nuevo concepto de acumuladores Elibatt	30
FIGURA 3.1: Diagrama general de proyecto de supervisión de batería.....	31
FIGURA 3.1.1: Identificación de la resistencia óhmica en pulsos controlados de voltaje [5].....	34
FIGURA 3.1.2: Corriente y voltaje de prueba controlada de celda Ión-Litio	35
FIGURA 3.1.3: Estimación de parámetro beta en codo final de descarga.....	36
FIGURA 3.1.4: Identificación de zonas de operación en celda de Ión-Litio para prueba controlada	37
FIGURA 3.2.1: Diagrama general de AEP offline.....	39
FIGURA 3.2.2: Diagrama modular de flujo de etapa de estimación del AEP	40
FIGURA 3.2.3: Efecto del Remuestreo sistemático aplicado a una población de partículas.....	42
FIGURA 3.2.4: a) Filtrado de voltaje observado con 500 datos proyectados. b) Filtrado de voltaje observado con 100 datos proyectados	43
FIGURA 3.2.5: Primera parte de la obtención de parámetros de la CM (Intervalos y estados por intervalo).....	46
FIGURA 3.2.6: Segunda parte de la obtención de parámetros de la CM (Discretización por intervalo y EWMA).....	46
FIGURA 3.2.7: Caracterización estadística del perfil de uso mediante CM de primer orden y dos estados [1].....	47
FIGURA 3.2.8: Generación de distintos perfiles de uso para 3 instantes consecutivos.....	47
FIGURA 3.2.9: Diagrama modular de flujo de etapa de pronóstico del AEP	49
FIGURA 4.1.1: Datos medidos de Ruta 4 (Velocidad variable).....	54
FIGURA 4.1.2: Datos medidos de Ruta 5 (Velocidad constante).....	54
FIGURA 4.1.3: Datos medidos de Ruta 9 (Torque exigido en plano inclinado)	55
FIGURA 4.1.4: Potencia DC medida de ruta 9 (Sobredemanda de energía)	55
FIGURA 4.1.5: JITP del 5% de una distribución de probabilidad de falla [1]	57
FIGURA 4.1.6: Perfil de uso futuro asociada a una CM en ruta 4.....	59
FIGURA 4.1.7: Perfil de uso futuro asociada a una CM en ruta 5.....	59
FIGURA 4.1.8: Resultado AEP - voltaje de batería en ruta 4.....	61
FIGURA 4.1.9: Resultado AEP - SOC de batería en ruta 4.....	61
FIGURA 4.1.10: Resultado AEP - resistencia interna de batería en ruta 4.....	62
FIGURA 4.1.11: Resultado AEP - potencia utilizada de la batería en ruta 4	62
FIGURA 4.1.12: Resultado AEP - distribución de probabilidad final del EOD en ruta 4.....	63
FIGURA 4.1.13: Resultado AEP - peor y mejor realización del EOD según referencia en ruta 4.....	63
FIGURA 4.1.14: Resultado AEP – PDF EOD final para 2 enfoques de pronóstico en ruta 4.....	65
FIGURA 4.1.15: Resultado AEP - voltaje de batería en ruta 5.....	65
FIGURA 4.1.16: Resultado AEP - SOC de batería en ruta 5.....	66

FIGURA 4.1.17: Resultado AEP - resistencia interna de batería en ruta 5.....	66
FIGURA 4.1.18: Resultado AEP - potencia utilizada de la batería en ruta 5	67
FIGURA 4.1.19: Resultado AEP - distribución de probabilidad final del EOD en ruta 5.....	67
FIGURA 4.1.20: Resultado AEP - peor y mejor realización del EOD según referencia en ruta 5	68
FIGURA 4.1.21: Resultado AEP – PDF EOD final para 2 enfoques de pronóstico en ruta 5.....	69
FIGURA 4.1.22: Resultado AEP - potencia máxima disponible estimada en ruta 9.....	72
FIGURA 4.1.23: Evolución del error de predicción EOD en diferentes inicios de predicción	73
FIGURA 4.1.24: Evolución del intervalo de confianza en diferentes inicios de predicción	73
FIGURA 4.1.25: Evolución de parámetros de cadena de markov en diferentes inicios de predicción	75
FIGURA 4.1.26: Efecto del ancho de banda en la forma del Kernel de Epanechnikov	76
FIGURA 4.2.1: Rendimiento del tiempo de procesamiento del AEP en entorno matlab	79
FIGURA 4.2.2: Vista de usuario en aplicación móvil propuesta	80
FIGURA 4.2.3: Ejemplo vista de interfaz de pruebas online.....	80

ÍNDICE DE TABLAS

Tabla 2.6.1: Especificaciones técnicas de la celda de Ión-Litio en estudio.....	26
Tabla 3.1.1: Especificaciones de prueba de descarga.....	34
Tabla 3.1.2: Resultados finales prueba de descarga controlada	37
Tabla 3.1.3: Parámetros finales del modelo de observación	38
Tabla 3.1.4: Error cuadrático medio mínimo en la estimación de parámetros específicos	38
Tabla 4.1.1: Desempeño final modulo de estimación en ruta 4	64
Tabla 4.1.2: Desempeño final modulo de pronóstico en ruta 4 con 40 partículas.....	64
Tabla 4.1.3: Desempeño final modulo de pronóstico en ruta 4 con 3 partículas.....	64
Tabla 4.1.4: Desempeño final modulo de estimación en ruta 5	68
Tabla 4.1.5: Desempeño final modulo de pronóstico en ruta 5 con 40 partículas.....	69
Tabla 4.1.6: Desempeño final modulo de pronóstico en ruta 5 con 3 partículas.....	69
Tabla 4.1.7: Resumen de parámetros ajustados fuera de línea.....	77

LISTA DE ACRÓNIMOS

AEP	Algoritmo de Estimación y Pronóstico
BMS	Sistema de Administración de Baterías (<i>Battery Management System</i>)
CIL	Centro de Innovación del Litio
CM	Cadena de Markov (<i>Markov Chain</i>)
EKF	Filtro de Kalman Extendido (<i>Extended Kalman Filter</i>)
EOD	Fin de la Descarga (<i>End of Discharge</i>)
ESD	Dispositivo de Almacenamiento de Energía (<i>Energy Storage Device</i>)
EWMA	Media Móvil con Ponderación Exponencial (<i>Exponentially Weighted Moving Average</i>)
FP	Filtro de Partículas (<i>Particle Filter</i>)
HMI	Interfaz Usuario Máquina (<i>Human-Machine Interface</i>)
HZ	Zona de Peligro (<i>Hazard Zone</i>)
JITP	Valor Justo a Tiempo (<i>Just-in-Time Point</i>)
KMC	Método de Agrupamiento K-Means (<i>K-Means Clustering</i>)
LR	Regresión Lineal (<i>Linear Regression</i>)
OCV	Voltaje en Circuito Abierto (<i>Open Circuit Voltage</i>)
PCM	Módulo Circuitual de Protección (<i>Protection Circuit Module</i>)
PDF	Función Densidad de Probabilidad (<i>Probability Density Function</i>)
RMSE	Raíz Cuadrada del Error Cuadrático Medio (<i>Root Mean Square Error</i>)
SIR	Remuestreo Secuencial de Importancia (<i>Sequential Importance Resampling</i>)
SIS	Muestreo Secuencial de Importancia (<i>Sequential Importance Sampling</i>)
SMC	Métodos Secuenciales de Monte Carlo (<i>Sequential Monte Carlo Methods</i>)
SOC	Estado de Carga (<i>State of Charge</i>)
SOH	Estado de Salud (<i>State of Health</i>)
TOF	Tiempo de Falla (<i>Time of Failure</i>)
UKF	Filtro de Kalman Unscented (<i>Unscented Kalman Filter</i>)

CAPITULO 1

INTRODUCCIÓN

1.1. MOTIVACIÓN

En la actualidad, los dispositivos de almacenamiento de energía (ESD, por sus siglas en inglés) representan una función elemental en los sistemas electrónicos modernos (equipos de tracción, computadores/servidores de datos, equipos de radiocomunicación, robots, equipos médicos, entre otros) como fuente principal de energía, o bien como sistema de respaldo. Los ESDs requieren de una gran autonomía con el fin de proveer un nivel de carga sostenida en el tiempo para las diversas aplicaciones industriales en las que se utiliza, en particular en el uso de sistemas eléctricos de transporte, teleoperados o autónomos, mediante baterías de Litio donde Chile posee una de las mayores reservas a nivel mundial, por lo cual se debe impulsar el desarrollo e innovación dentro de esta industria y generar valor agregado para un mercado que despierte el interés de inversionistas. Con respecto a la utilidad de este tipo de baterías, uno de los dos problemas actuales corresponde a altos costos de fabricación, peso empleado, tiempo de recarga con baja vida útil y baja autonomía por ciclo, es decir, una baja densidad de energía acumulada, los cuales son desafíos a mejorar, sin embargo siguen siendo una alternativa eficiente con respecto al cuidado del medio ambiente. El segundo problema o desafío hace referencia a los sistemas de control asociados a la operación de baterías Li-Ion, donde no existe un sistema de supervisión y control que permita informar sobre el Estado de Carga (SOC, por sus siglas en inglés) de forma estandarizada, y más aún en tiempo real, en consecuencia, esta ineficiencia en la acumulación y extracción de energía produce costos para las compañías, principalmente OPEX, que pueden ser reducidos optimizando la gestión de la potencia que entrega y recibe el banco de baterías a través de uno o más módulos predictivos del comportamiento en carga y/o descarga con tal de generar algún tipo de control sobre su uso.

Considerando lo anterior, el trabajo desarrollado en el presente informe corresponde a la aplicación en parte de variados trabajos de postgrado enfocados en la estimación y pronóstico del SOC en baterías de iones de Litio o Li-Ion, en el cual se desarrolla un sistema computacional de consumo de energía inteligente para baterías tomando diferentes metodologías para cada uno de los objetivos a cumplir y finalmente ser aplicadas en bicicletas eléctricas o E-bikes bajo el control de un usuario, las cuales son propiedad del Centro de Innovación del Litio (CIL). En este sentido, el trabajo representa un proyecto comercial de electromovilidad sustentable a cargo del CIL llamado ELIBATT con el apoyo de investigadores del Laboratorio Avanzado de Sistemas establecidos en las dependencias del Departamento de Ingeniería Eléctrica (DIE) de la Universidad de Chile.

En lo que respecta a la solución propuesta, también llamado AEP (Algoritmo de Estimación y Pronóstico) como su nombre lo dice, posee una etapa de estimación o filtrado del SOC y otra de pronóstico del término o fin del proceso de descarga (EOD, por sus siglas en inglés), donde en un escenario de falla también es llamado tiempo de falla (TOF, por sus siglas en inglés). El módulo

de estimación requiere de un modelo característico para el tipo de baterías a monitorear, por lo cual se realizan pruebas de descarga a corriente constante con el objeto de estimar los parámetros necesarios para modelar eficientemente el pack de baterías. El algoritmo de filtrado propuesto es adaptado en entorno *Matlab* acorde a la infraestructura de hardware disponible en la E-bike. Posteriormente el módulo de pronóstico utiliza el resultado de la etapa de estimación para generar predicciones del valor de la corriente de descarga y a su vez, un modelo de observación ante la inexistencia de mediciones de voltaje del ESD durante un periodo de tiempo definido. Paralelamente, a través de una Interfaz Humano-Máquina (HMI, por sus siglas en inglés) desarrollada bajo entorno Android se informa al operador de la E-bike sobre el estado del SOC, EOD, entre otras variables de interés asociadas al ESD, donde la comunicación se logra mediante protocolo Bluetooth implementado sobre un Smartphone de memoria y nivel de procesamiento suficientes para implementar el AEP en tiempo real. Por su parte, para que el estado de operación de cada celda de Li-Ion se mantenga dentro de los rangos aceptables, se dispone de un sistema de administración de baterías (BMS, por sus siglas en inglés) donde la principal dificultad contempla la descarga sin previo aviso del ESD, sin lograr que el usuario llegue a su destino. Sin embargo, este sistema no altera la dinámica del banco o pack de baterías ni ejecuta acciones de control, sino que consiste en un monitoreo en tiempo real del nivel de carga presente en las baterías mientras está proporcionando energía al motor eléctrico de la E-bike, acorde a las demandas del usuario principalmente reflejadas en la velocidad deseada. Por lo cual existe una toma de decisiones con el objeto de aumentar la autonomía del ESD [1] [2].

1.2.

ALCANCES

Como el presente trabajo considera una implementación práctica y comercial, se definen alcances que dan paso a los objetivos específicos planteados más adelante. Entre estos alcances se menciona la no inclusión de variables de terreno dentro del modelo de descarga a causa de la complejidad paramétrica que se evita presentar como una primera aproximación aplicada, sumado a esto, cada ciclo de carga/descarga es tratado como un ciclo independiente idéntico al anterior sin estudiar su degradación en el tiempo ni su vida útil remanente, los cuales sí son significativos si se toma en cuenta el Estado de Salud (SOH, por sus siglas en inglés) del ESD, pero no para los objetivos del trabajo presente. Por consiguiente, se propone únicamente un modelo de descarga asociado al SOC sin medir la temperatura interna de la batería y sus efectos sobre la vida útil remanente de éste, ni fenómenos de regeneración o cargas parciales, aunque si se emplea informar de manera cuantitativa la potencia que está siendo utilizada en todo momento, considerando la potencia máxima disponible que el ESD puede entregar en ese instante [3].

En términos de metodología de estimación y predicción, se destacan los métodos de inferencia Bayesiana o estocástica como se sugieren en gran parte de la literatura para temáticas ligadas al SOC durante eventos de descarga por motivos de simplicidad y exactitud. Entre estos métodos se trabaja primordialmente con simulaciones de Monte Carlo secuencial (SMC, por sus siglas en inglés) o también llamado filtro de partículas (FP), en el cual se modela la dinámica del SOC incluyendo toda la incertidumbre que se posee bajo ciertos modelos preexistentes en la literatura

para un banco de baterías de parámetros conocidos. Para lograr aquello, la solución recoge algoritmos de filtros de partícula genéricos para posteriormente ser adaptados y/o simplificados antes de ser implementados en un Smartphone con las características ya mencionadas; del mismo modo ante escenarios de pronóstico, se requiere modelar eventos aleatorios que evolucionan en tiempo discreto donde se define la metodología basada en Cadenas de Markov (CM, por sus siglas en inglés) como una primera aproximación a la realización de perfiles de uso o perfiles de descarga que evolucionan aleatoriamente entre 2 o más estados predefinidos [1] [2] [4].

1.3. OBJETIVOS

El objetivo general del trabajo comprende en responder el cómo introducir inteligencia en tiempo real o en línea al sistema de monitoreo de baterías Li-Ión, con el fin de conocer la cantidad de energía disponible del ESD para su utilización y por tanto, maximizar su autonomía durante una ruta determinada de la E-bike. La optimización de esta autonomía se basa en la toma de decisiones del operador que recibe aquella información del SOC, entre otros parámetros relevantes. Referente a aquello, esta autonomía puede presentarse en kilómetros, tiempo o porcentaje, sin embargo, para nuestro caso el tiempo es una variable de interés en la modelación del proceso de descarga, mientras que una autonomía en kilómetros requiere un modelo orientado a variables de terreno y posición.

Por otro lado, los objetivos específicos constan en (i) estimar el SOC mediante la metodología de inferencia Bayesiana llamada Filtro de Partículas bajo un modelo no lineal y estocástico propuesto, logrando un nivel de aprendizaje de los estados definidos con suficiente exactitud, precisión y convergencia para su aplicación en línea (ii) generar un perfil de uso futuro del ESD (Corriente de descarga o salida) a través de la caracterización estadística de datos históricos medidos en ruta para su uso en el pronóstico del EOD, específicamente para caracterizar la función de densidad de probabilidad (PDF, por sus siglas en inglés) del EOD hasta su punto de corte o *cutoff* (iii) Estimar dentro de un marco “en línea” la potencia máxima disponible que puede extraerse de la batería hasta su punto de corte (iv) proveer flexibilidad tanto en el AEP ante cambios de configuración y/o capacidad del ESD como también en el modelo de descarga empleado (v) definir los parámetros óptimos del AEP en términos de desempeño *offline* y establecer a su vez las condiciones para su posterior implementación en un dispositivo móvil que permita recibir, procesar y desplegar la información del ESD en todo momento.

1.4. ESTRUCTURA DEL INFORME

La estructura del informe comprende en el CAPITULO 2 los antecedentes sobre la estimación y pronóstico del SOC, los métodos y herramientas matemáticas que se requieren en el desarrollo de la solución o AEP, el modelo de descarga propuesto y sus características; y por último, la infraestructura electrónica pre-existente en la E-bike de estudio. En el CAPITULO 3 se expone la metodología desarrollada de forma modular en entorno *Matlab* y estableciendo todas las consideraciones de diseño de la solución. En el CAPITULO 4 se presentan las métricas de desempeño y se analizan los resultados obtenidos con tal de validar la solución con datos reales de ruta. Finalmente, en el CAPITULO 5 se generan las conclusiones del trabajo realizado, en conjunto con los focos a seguir o considerar en trabajos futuros.

CAPITULO 2

REVISIÓN BIBLIOGRÁFICA

El presente capítulo tiene por objetivo ubicar al lector en el entorno en el cual se desarrolla este trabajo de título, entregando los antecedentes previos y necesarios para su contextualización y comprensión.

En primer lugar, en la sección 2.1, se indican las características generales del estado de carga en baterías de litio-ion y por qué es un parámetro relevante, además de sus propiedades de estimación y predicción en un entorno en línea. En el apartado 2.2 se señala el método de inferencia bayesiana a implementar comparando diferentes enfoques con sus ventajas y desventajas para luego describir cada etapa del algoritmo de estimación seleccionado, además de un enfoque de pronóstico a considerar. En el apartado 2.3 y 2.4 se describen de forma general las herramientas matemáticas K-Means clustering (KMC, por sus siglas en inglés) y CM respectivamente para la fase de caracterización estadística de perfiles de uso futuro, los cuales son necesarios en el pronóstico del estado de carga. Luego en la sección 2.5 se describe el modelo de descarga propuesto del ESD a implementar en los módulos de estimación y pronóstico a desarrollar. Finalmente, en la sección 2.6 se señala el contexto en el cual se desarrolla el trabajo y las características principales de la infraestructura tecnológica utilizada en el monitoreo del ESD en estudio.

2.1. ANTECEDENTES GENERALES DEL ESTADO DE CARGA EN DISPOSITIVOS ACUMULADORES DE ENERGÍA

Dentro de las baterías de Li-ion existen varios factores dinámicos que son relevantes para un monitoreo y control eficiente de cada ciclo de carga/descarga del mismo. Uno de estos factores es el estado de carga o SOC, el cual se presenta como un porcentaje del nivel de carga del banco de baterías en un instante de tiempo determinado con respecto a la máxima energía disponible presente en el banco para ser extraída. El SOC tiene la característica de no ser una variable observable o directamente medible por instrumento, por lo cual, se calcula en base a métodos de estimación conformados por modelos de descarga, en el cual existe un *pool* de alternativas para el caso de baterías de Ión-Litio donde más adelante se propone una de ellas acorde a la metodología de estimación utilizada en este trabajo.

Las baterías de Ión-Litio son un tipo de acumulador que se agrupa de manera más general en lo que se conoce como un ESD. Un ESD corresponde tanto a una unidad básica de acumulación o celda (electrolítica o galvánica) como a una batería conformada por un conjunto de celdas interconectadas entre sí. Las ventajas de un ESD de Ión-Litio en comparación con los acumuladores de Plomo Ácido corresponden principalmente a la densidad de energía que puede acumularse por unidad de peso, es decir medido en Wh/kg, las cuales requieren un ínfimo mantenimiento, mayor vida útil, operación con amplio rango de temperatura, capacidad de carga rápida, ínfimo efecto memoria y baja tasa de auto-descarga. Sin embargo, las desventajas

principales a considerar de los ESD de Ión-Litio son la degradación a altas temperaturas, lo cual es posible observar con el AEP más adelante descrito en detalle, además la necesidad de un sistema BMS, su alto costo de adquisición y otras dos desventajas directamente relacionadas con el objetivo general de este trabajo; una consta de la pérdida de capacidad de acumulación ante sobrecargas y la otra ligada al daño irreversible ante eventos de descarga que superen el límite de corte específico de cada celda.

En comparación con baterías NiCd o NiMh, el fenómeno de efecto memoria o de pérdida de capacidad por cargas incompletas en baterías Ión-Litio, PbO₂ y polímero de litio (LiPo) no afecta de manera significativa su capacidad por ciclo de carga, sin embargo, en estas últimas se recomienda no traspasar el umbral de corte o seguridad de **2.7 a 3[V]** para no ver afectada su operación en recargas futuras, puesto que al traspasar este límite la celda queda prácticamente inutilizada.

En lo que respecta a baterías de Ciclo Profundo (Por lo general de Plomo-Ácido), presentan un menor costo adquisitivo en el mercado, además permite mediante el cálculo de la fuerza del ácido sobre el plomo o densidad del electrolito una estimación confiable del SOC de la batería como también una capacidad de recuperación ante degradaciones, lo que las convierte en alternativas eficaces en sistemas móviles de alta autonomía, sin embargo, presentan la falencia de una descarga más lenta que las de Ión-Litio o Polímero de Litio, las cuales están desarrolladas para operar de forma continua para alcanzar largas duraciones, por lo tanto, ante exigencias altas de energía o variaciones significativas de energía (caso de arranque de motores) en el sistema, no es recomendable este tipo de baterías [4] [5].

2.1.1. ESTIMACIÓN Y PREDICCIÓN DEL ESTADO DE CARGA

El SOC es un valor que puede estimarse mediante la inclusión de parámetros característicos de los acumuladores de energía como la corriente de salida, Voltaje de circuito abierto (OCV, por sus siglas en inglés), densidad de electrolito, temperatura interna, resistencia interna total, entre otras. En aplicaciones dinámicas, muchas de estas magnitudes descritas comprenden mediciones bastante complejas, por lo cual, se hace necesario estimar en base a características o parámetros de mayor facilidad en su medición, como por ejemplo, tensión, corriente e incluso temperatura. Por esta razón para lograr estimaciones con un esfuerzo computacional reducido y una precisión alta, se modela la dinámica del banco de baterías a caracterizar en base principalmente a parámetros eléctricos o circuitales (Incluso electroquímicos o heurísticos) donde el voltaje de salida y la corriente de descarga predominan en un modelo de estados para la evolución del SOC porcentual, el cual un 100% corresponde a una batería completamente cargada, y una vez comienza a descargarse, éste porcentaje se reduce hasta un nivel proporcional al voltaje actual en bornes. El grado de estimación en base a modelos dinámicos principalmente de naturaleza no lineal suele apreciarse mediante índices de desempeño como intervalos de confianza, JITP (*Just-In-Time-Point*), RMSE, entre otros [1] [4].

En la literatura, existen diversos tipos de enfoques para la modelación de ESD tales como modelos electroquímicos, circuitales en el dominio continuo o alterno, tipo caja negra en base a datos de entrada-salida, heurísticos, estocásticos, fenomenológicos y una combinación de aquellas. Dichos modelos pueden ser desarrollados en el dominio del tiempo o en frecuencia, también pueden ser de tipo unidimensional o multidimensional, con ruidos aditivos o no aditivos

de naturaleza Gaussiana o no, de comportamiento lineal o no lineal, en base a sistemas de aprendizaje como redes neuronales o lógica difusa, entre otros factores que dependiendo de la metodología de estimación a aplicar, se atribuyen de mayor o menor grado a la estructura del modelo a proponer. Por ejemplo, los modelos dinámicos no lineales multidimensionales con ruidos aditivos de proceso y observación de naturaleza no necesariamente Gaussiana determinan el uso de técnicas de estimación y predicción avanzadas para un desempeño robusto, donde permiten una visión directa de la incertidumbre envuelta en la dinámica del proceso de descarga de una batería de Ión-Litio. Estos modelos estocásticos conducen a veces a comportamientos artificiales de sus estados como sucede con algunos parámetros internos de la batería de Litio-Ion en la literatura [1] [5].

Hoy en día se implementan variados métodos de estimación del SOC como lo son estrategias fundamentadas en modelos difusos, redes neuronales, modelos lineales empíricos e inferencia Bayesiana. Éste último enfoque en particular, considera la evolución de las densidades de probabilidad de los estados a través del tiempo bajo ciertos supuestos, las cuales dependen del tipo de modelación que se aborda sobre un problema, además de la naturaleza de los ruidos de proceso y observación, entre otros. El Filtro de Kalman Extendido (EKF, por sus siglas en inglés), el Filtro de Kalman “Unscented” (UKF, por sus siglas en inglés) y el Filtro de Partículas (FP) son los más reconocidos dentro de este enfoque Bayesiano de carácter no lineal como lo es el proceso de descarga de una batería Ión-Litio [1] [5] [6].

La predicción del SOC bajo una metodología Bayesiana posee por su parte, una etapa previa de estimación como periodo de aprendizaje o entrenamiento de esta misma variable con tal de generar un pronóstico lo más exacto posible con un horizonte de tiempo definido, ya que en ese instante de término de las estimaciones del vector estado, los resultados de la última iteración con la distribución *a posteriori* del vector estado se asignan como parámetros iniciales de predicción, la cual requiere un horizonte de predicción mayor o menor dependiendo la aplicación donde se implemente, sin embargo, esta etapa considera realizaciones de muestras medidas para el modelo de observación que se considere, puesto que no existen medidas reales para ello, y así lograr una evolución del estado dependiente del tiempo con un grado de exactitud y precisión medibles en probabilidad. Con el objetivo de caracterizar la incertidumbre asociada a las mediciones desconocidas durante la etapa de pronóstico, se suelen aplicar herramientas matemáticas de naturaleza aleatoria para un procesamiento estadístico de mediciones históricas, si éstas existen, que generen perfiles de comportamiento futuro en el sistema estudiado, por ejemplo la descarga o carga de un ESD en el tiempo, donde la corriente cumple un rol fundamental [1] [4].

2.2. INFERENCIA BAYESIANA Y FILTRO DE PARTÍCULAS

La inferencia Bayesiana consiste principalmente a una estrategia de estimación mediante la inferencia de las distribuciones de probabilidad del vector de estado para cada instante de tiempo, tomando en cuenta la observación de estados pasados y mediciones hasta ese instante de estimación. Aquellos métodos como filtro de Kalman, EKF, UKF y FP presentan distintos enfoques de estimación y predicción, pero utilizando los mismos fundamentos de inferencia Bayesiana en las distribuciones de probabilidad condicional que se desean encontrar como se explica a continuación:

En base a una formulación en el espacio-estado de un sistema dinámico, se puede representar la evolución del vector de estados y el vector de observaciones de un sistema como sigue:

$$\mathbf{x}_k = \mathbf{f}_k(\mathbf{x}_{k-1}, \mathbf{v}_{k-1}) \quad (2.1)$$

$$\mathbf{y}_k = \mathbf{h}_k(\mathbf{x}_k, \mathbf{n}_k) \quad (2.2)$$

En donde la ecuación (2.1) representa la evolución del vector de estados y en la ecuación (2.2) el vector de observaciones en el tiempo; ambas funciones no lineales con \mathbf{v}_{k-1} y \mathbf{n}_k secuencias aleatorias independientes e idénticamente distribuidas (i.i.d.) definidas como ruido de proceso y medición respectivamente. Sea $\mathbf{y}_{1:k} = \{\mathbf{y}_i\}_{i=1}^k$ el conjunto de observaciones disponibles y $\mathbf{x}_{0:k} = \{\mathbf{x}_i\}_{i=0}^k$ la trayectoria del vector de estados hasta el instante k con \mathbf{x}_0 el vector de estado inicial, entonces el filtrado Bayesiano u óptimo consiste en conocer sobre el estado \mathbf{x}_k de forma recursiva con la información entregada por el conjunto $\mathbf{y}_{1:k}$, en otras palabras, se desea obtener la PDF de $\rho(\mathbf{x}_k | \mathbf{y}_{1:k})$ de forma recursiva, también llamada distribución *a posteriori* del vector de estados para lograr estimaciones de ella, como la media o varianza.

Una primera etapa para la obtención de esta PDF *a posteriori* corresponde a la etapa de predicción del estado mediante el uso de la ecuación de transición de estados caracterizada en modo general por (2.1). Para ello, se calcula la PDF *a priori* del vector de estados en el instante k según la ecuación de Chapman-Kolmogorov, la cual comprende la siguiente integral:

$$\rho(\mathbf{x}_k | \mathbf{y}_{1:k-1}) = \int \rho(\mathbf{x}_k | \mathbf{x}_{k-1})\rho(\mathbf{x}_{k-1} | \mathbf{y}_{1:k-1}) d\mathbf{x}_{k-1} \quad (2.3)$$

Luego existe una última etapa de actualización donde ante la llegada de una nueva observación en el instante k , la distribución *a priori* de (2.3) se modifica con tal de obtener la PDF *a posteriori* mediante el Teorema de Bayes como sigue:

$$\rho(\mathbf{x}_k | \mathbf{y}_{1:k}) = \frac{\rho(\mathbf{y}_{1:k} | \mathbf{x}_k)\rho(\mathbf{x}_k)}{\rho(\mathbf{y}_{1:k})} \quad (2.4)$$

$$= \frac{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1}, \mathbf{x}_k)\rho(\mathbf{y}_{1:k-1} | \mathbf{x}_k)\rho(\mathbf{x}_k)}{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})\rho(\mathbf{y}_{1:k-1})} \quad (2.5)$$

$$= \frac{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1}, \mathbf{x}_k)\rho(\mathbf{x}_k | \mathbf{y}_{1:k-1})\rho(\mathbf{y}_{1:k-1})\rho(\mathbf{x}_k)}{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})\rho(\mathbf{y}_{1:k-1})\rho(\mathbf{x}_k)} \quad (2.6)$$

$$= \frac{\rho(\mathbf{y}_k | \mathbf{x}_k)\rho(\mathbf{x}_k | \mathbf{y}_{1:k-1})}{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})} \quad (2.7)$$

En donde la ecuación (2.7) exhibe una relación recursiva con $\rho(\mathbf{y}_k | \mathbf{x}_k)$ la función de verosimilitud, la cual depende de la ecuación de observación del modelo. Además se genera la relación entre la distribución *a priori* $\rho(\mathbf{x}_k | \mathbf{y}_{1:k-1})$, formulada en (2.3), y la *a posteriori*. En

esta ecuación recursiva encontramos de igual forma la función de normalización $\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})$ basada en evidencia observable, por lo tanto es una magnitud conocida. Así, la recursión (2.7) para calcular la distribución *a posteriori* se puede resolver en determinados casos como en el filtro de Kalman o EKF para un modelo lineal y Gaussiano, pero no en un caso general.

Se puede deducir que la PDF *a posteriori* es proporcional al producto entre la probabilidad *a priori* y la función de verosimilitud basado en el teorema de Bayes. El teorema de Bayes nos dice como se relacionan las distribuciones de probabilidad condicionadas por las observaciones obtenidas hasta el instante actual y la función de verosimilitud tomando todas las observaciones pasadas [1] [7] [8].

Como previamente mencionamos, la metodología del filtro de Kalman tiene su aplicación en sistemas lineales donde se estima el estado oculto no medible a partir de mediciones de entradas y salidas, además de un modelo en variables de estado que representa la dinámica del sistema, sumado a esto, considera perturbaciones gaussianas en estados conocidos como ruido de proceso y también en mediciones como ruido de observación. Debido a que los procesos de descarga en acumuladores son no-lineales y sujetos a incertidumbre es natural implementar una técnica de estimación sub-óptima Bayesiana como lo es el EKF, el cual se aplica por ejemplo a baterías de Ión-Litio, donde se mantiene la condición de ruidos aditivos y gaussianos, pero el sistema se linealiza mediante aproximación de Taylor de primer orden, es decir, se aproxima la densidad *a posteriori* a una distribución Gaussiana. El EKF representa una extensión del filtro de Kalman en este caso, sin embargo, una de las ventajas del filtro de Kalman consta de encontrar un óptimo en la estimación del estado bajo los ruidos no multiplicativos previamente descritos. En el caso de que el modelo no lineal de transición de estados y de observación fuesen no derivables se decae la representatividad de la densidad *a posteriori* del estado a estimar, por lo cual, se aplica una variante del EKF conocida como UKF, donde la transformada “Unscented” realiza una aproximación más eficiente de los modelos no lineales involucrados, en el sentido de mantener la media y covarianza de las variables aleatorias durante la transformación no lineal [5] [8] [9].

Un enfoque similar es encontrando en el método SMC con el objetivo de actualizar los parámetros de un modelo empírico, y así representar la predicción de un proceso de descarga mediante la obtención de una PDF *a posteriori* por ejemplo. Las deficiencias de métodos como EKF y UKF están relacionados con el hecho que los modelos puros empíricos no pueden combinar la información que es proporcionada por el conocimiento acerca del proceso fenomenológico y las mediciones de los datos en tiempo real, bajo los supuestos de fuentes de incertidumbre no-Gaussianas y considerando la existencia de fenómenos no-lineales. Sin embargo, esos objetivos pueden ser alcanzados si se utilizan modelos de espacio-estado estocásticos no-lineales. Dada la no-linealidad y que no es posible asumir ruidos Gaussianos independientes en algunos modelos propuestos, el filtro de Kalman no puede asegurar optimalidad del estimador. Por esta razón, se considera en este trabajo la implementación de una variante específica de algoritmos Bayesianos denominada SMC o FP. La metodología de FP cuenta con una población de muestras o partículas aleatorias que junto a pesos ponderados en cada una de ellas, se calculan estimadores para representar la PDF *a posteriori*. A medida que crece esta población, la caracterización se asemeja más a la solución Bayesiana óptima. Sumado a ello, presenta una gran habilidad para adaptarse a distintos tipos de modelos dinámicos, en particular sistemas no-lineales (que incluso pueden considerar modelos difusos y redes neuronales), y sistemas no-Gaussianos (esto descarta una gran cantidad de métodos sub-óptimos

alternativos) lo que permite usar la estructura del modelo empírico-fenomenológico e internalizar la evolución empírica de sus parámetros, capturando características propias. Esto se logra gracias a la capacidad de estimación en línea del FP, lo que permite una corrección y a su vez, una actualización constante de los parámetros del modelo, viéndose reflejado en un aumento en la exactitud y precisión de las estimaciones del vector de estado, obteniendo así un aprendizaje del sistema [1] [10] [11].

La estimación recursiva como es en el caso del Filtro de Partículas, establece una aproximación de las distribuciones *a posteriori* en cada iteración del tiempo discreto. Esta metodología no supone distribuciones Gaussianas en los ruidos estocásticos para cada modelo dinámico. A continuación se expresa la esperanza o valor esperado de la secuencia de estados en cada tiempo de iteración, para el cual se utiliza la distribución *a posteriori* en su aproximación:

$$E[\phi(\mathbf{x}_{0:k})] = \int \phi(\mathbf{x}_{0:k}) \rho(\mathbf{x}_{0:k} | \mathbf{y}_{1:k}) d\mathbf{x}_{0:k}; \quad \phi: \mathbf{X}^{k+1} \rightarrow \mathbb{R}^n \quad (2.8)$$

Se detalla el método de FP con estimación recursiva a un paso de la distribución de PDF *a posteriori*, la cual nos interesa aproximar con su valor esperado y varianza asociada. Esta técnica de filtrado Bayesiano presenta un esquema de estimación de estados en base a la inferencia de la distribución de probabilidad *a posteriori* de cada partícula o muestra aleatoria seleccionada [1] [8] [10].

$$\boldsymbol{\pi}_k(\mathbf{x}_{0:k}); \quad \forall k \geq 1 \quad (2.9)$$

Sea $\{\mathbf{w}_k^{(i)}, \mathbf{x}_{0:k}^{(i)}\}_{i=1, \dots, N}$ la población de partículas que caracteriza a $\boldsymbol{\pi}_k$ donde $\mathbf{x}_{0:k}^{(i)}$ comprende la trayectoria de la muestra *i-ésima* desde el instante inicial hasta el instante k y $\mathbf{w}_k^{(i)} \geq \mathbf{0} \quad \forall i, k$ los pesos asociados a cada muestra; en relación a ello, se define la trayectoria de los estados hasta el instante k como $\mathbf{x}_{0:k} = \{\mathbf{x}_0, \dots, \mathbf{x}_k\}$. Debido a que los pesos son normalizados; la densidad *a posteriori* en el instante k puede ser aproximado como:

$$\boldsymbol{\pi}_k^N(\mathbf{x}_{0:k}) \approx \sum_{i=1}^N \mathbf{w}_k^{(i)} \cdot \delta_{\mathbf{x}_{0:k}^{(i)}}(\mathbf{x}_{0:k}) \quad (2.10)$$

Entonces la distribución empírica representada por una colección de N partículas que se propagan temporalmente, donde δ corresponde a la función delta de Dirac, queda representada por la ecuación de (2.10). Por otro lado, existen varios modos de obtener muestras para las cuales propagar en el tiempo, una de ellas es la estrategia llamada Muestreo de Importancia o IS por sus siglas en inglés, la cual requiere de todas las muestras pasadas para estimar el siguiente valor, en consecuencia no es una solución fiable para una estimación recursiva de los estados, debido a la cantidad de procesamiento o costo computacional que se debe aportar al algoritmo [1] [8] [9] [12].

Una estrategia de estimación recursiva dentro del método de Filtro de Partículas es el muestreo secuencial de importancia (SIS, por sus siglas en inglés) el cual presenta un mayor grado de representatividad que el IS. La estrategia SIS aproxima la distribución empírica (2.10) a la PDF *a posteriori* $\rho(\mathbf{x}_{0:k} | \mathbf{y}_{1:k})$ a través de la selección de pesos mediante el principio de muestreo de importancia, el cual se refiere a la extracción de muestras o partículas desde una densidad de importancia $q(\mathbf{x}_{0:k} | \mathbf{y}_{1:k})$, debido a que asumiendo que $\rho(\mathbf{x}_{0:k}) \propto \pi_k^N(\mathbf{x}_{0:k})$ es una PDF difícil de extraer muestras, se cumpla que con la PDF $q(\mathbf{x}_{0:k})$ se tomen muestras fácilmente y e $\rho(\mathbf{x}_{0:k})$ quede dada por:

$$\rho(\mathbf{x}_{0:k}) \approx \sum_{i=1}^N w_k^{(i)} \cdot \delta_{\mathbf{x}_{0:k}^{(i)}}(\mathbf{x}_{0:k}) \quad \text{con} \quad w_k^{(i)} \propto \frac{\pi(\mathbf{x}_{0:k})}{q(\mathbf{x}_{0:k})} \quad (2.11)$$

Es decir, la aproximación queda ponderada por pesos normalizados en cada partícula con respecto a esta nueva distribución discreta. En cada iteración se desea aproximar $\rho(\mathbf{x}_{0:k} | \mathbf{y}_{1:k})$ con una colección nueva de partículas y pesos asociados, entonces $\mathbf{x}_{0:k}^{(i)} \sim q(\mathbf{x}_{0:k})$ puede obtenerse expandiendo las partículas conocidas $\mathbf{x}_{0:k-1}^{(i)} \sim q(\mathbf{x}_{0:k-1})$ con un nuevo estado $\mathbf{x}_k^{(i)} \sim q(\mathbf{x}_k)$, en otras palabras, de forma secuencial. La actualización de los pesos se calcula en base al Teorema de Bayes mostrado en (2.7):

$$\rho(\mathbf{x}_{0:k} | \mathbf{y}_{1:k}) = \frac{\rho(\mathbf{y}_k | \mathbf{x}_{0:k}, \mathbf{y}_{1:k-1}) \rho(\mathbf{x}_{0:k} | \mathbf{y}_{1:k-1})}{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})} \quad (2.12)$$

$$= \frac{\rho(\mathbf{y}_k | \mathbf{x}_{0:k}, \mathbf{y}_{1:k-1}) \rho(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k-1}) \rho(\mathbf{x}_{0:k-1} | \mathbf{y}_{1:k-1})}{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})} \quad (2.13)$$

$$= \frac{\rho(\mathbf{y}_k | \mathbf{x}_k) \rho(\mathbf{x}_k | \mathbf{x}_{k-1})}{\rho(\mathbf{y}_k | \mathbf{y}_{1:k-1})} \rho(\mathbf{x}_{0:k-1} | \mathbf{y}_{1:k-1}) \quad (2.14)$$

$$\propto \rho(\mathbf{y}_k | \mathbf{x}_k) \rho(\mathbf{x}_k | \mathbf{x}_{k-1}) \rho(\mathbf{x}_{0:k-1} | \mathbf{y}_{1:k-1}) \quad (2.15)$$

En donde los pesos quedan definidos por una recursión basada en los pesos de la iteración pasada al realizar la división entre (2.12) y la descomposición de $q(\mathbf{x}_{0:k} | \mathbf{y}_{1:k})$ tal que se genere la magnitud conocida $q(\mathbf{x}_{0:k-1} | \mathbf{y}_{1:k})$:

$$w_k^{(i)} \propto \frac{\rho(\mathbf{y}_k | \mathbf{x}_k^{(i)}) \rho(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)}) \rho(\mathbf{x}_{0:k-1}^{(i)} | \mathbf{y}_{1:k-1})}{q(\mathbf{x}_k^{(i)} | \mathbf{x}_{0:k-1}^{(i)}, \mathbf{y}_{1:k}) q(\mathbf{x}_{0:k-1}^{(i)} | \mathbf{y}_{1:k})} \quad (2.15)$$

$$\propto w_{k-1}^{(i)} \frac{\rho(\mathbf{y}_k | \mathbf{x}_k^{(i)}) \rho(\mathbf{x}_k^{(i)} | \mathbf{x}_{k-1}^{(i)})}{q(\mathbf{x}_k^{(i)} | \mathbf{x}_{0:k-1}^{(i)}, \mathbf{y}_{1:k})} \quad (2.16)$$

Si se desea sólo estimar la PDF $\rho(\mathbf{x}_k | \mathbf{y}_{1:k})$ en cada instante, entonces basta simplificar la densidad $q(\mathbf{x}_k | \mathbf{x}_{0:k-1}, \mathbf{y}_{1:k})$ a $q(\mathbf{x}_k | \mathbf{x}_{k-1}, \mathbf{y}_k)$, es decir, la distribución de importancia sólo depende del estado inmediatamente anterior y la nueva observación obtenida. Esta simplificación ahorra una gran cantidad de cálculos y valores ya obtenidos en cada iteración, puesto que sólo basta con almacenar $\mathbf{x}_k^{(i)}$ para tiempos futuros, dejando de lado la historia de observaciones y la trayectoria del estado. Por lo tanto, en la ecuación (2.16) $q(\cdot)$ queda simplificada y a medida que el número de partículas aumenta, la aproximación (2.11) se asemeja más a la PDF *a posteriori* $\rho(\mathbf{x}_k | \mathbf{y}_{1:k})$.

La función de importancia es asignada de acuerdo al grado de complejidad que se le quiere dar al filtro, sin embargo, para los casos más básicos suele definirse como la distribución *a priori* del vector de estado como sigue [1] [10] [13]:

$$q(\mathbf{x}_{0:k} | \mathbf{y}_{1:k}) = \rho(\mathbf{x}_k | \mathbf{x}_{k-1}) \quad (2.17)$$

Así la actualización recursiva de los pesos se acota solamente al valor de la función de verosimilitud al obtener nuevas observaciones.

$$w_k^{(i)} \propto w_{k-1}^{(i)} \rho(\mathbf{y}_k | \mathbf{x}_k^{(i)}) \quad (2.18)$$

2.2.2. REMUESTREO SECUENCIAL DE IMPORTANCIA

Una solución al problema de degeneración de partículas o representatividad de éstas, en el cual todas las partículas excepto una tienen asociado un peso despreciable a lo largo de su propagación, es el remuestreo secuencial de importancia (SIR, por sus siglas en inglés), el cual recalcula los pesos de la colección de partículas en cada iteración consiguiendo reducir la varianza de los pesos en cada paso, sin embargo, para partículas con pesos no degenerados son sometidos a reemplazo de igual forma, por lo cual se crea un nuevo set de \mathbf{N} partículas. Además de esto, sólo requiere conservar las muestras o partículas una iteración atrás en base a las observaciones recibidas para extraer las muestras en el instante actual; y no todo el historial de muestras pasadas, la cual minimiza significativamente los cálculos como sucede análogamente con SIS. Uno de los criterios mayormente utilizados para detectar el instante conveniente para ejecutar un remuestreo es el *tamaño de muestras efectivas* N_{eff} , el cual en realidad es un estimador que mide el grado de degeneración de los pesos de las partículas como un conjunto. Este estimador se expresa como:

$$\hat{N}_{eff} = \frac{1}{\sum_{i=1}^N \bar{w}(x_{0:k}^{(i)})^2} \quad (2.19)$$

Si \hat{N}_{eff} es menor a un umbral N_{um} determinado, por lo general este valor corresponde a un porcentaje del número de partículas, entonces la varianza de los pesos aumenta desencadenando una degeneración, por lo cual a veces se selecciona un número de partículas muy grande, lo que a veces es inviable en casos reales [14].

Uno de los factores desfavorables de esta estrategia consiste en incluir muestras nuevas con distribución uniforme, es decir, $w_k^{(i)} = \frac{1}{N}$ para cada partícula, en consecuencia, se genera una representatividad sesgada de la nueva colección de partículas donde predominan las partículas con mayor peso asignado (pérdida de diversidad estadística) en la etapa de actualización con pesos normalizados de importancia.

En resumen, el método de FP es un filtro Bayesiano sub-óptimo recursivo, principalmente descrito por los siguientes pasos en su enfoque SIR:

- 1) Inicialización aleatoria de partículas en el espacio-estado con respecto a la distribución de probabilidad inicial propuesta, muchas veces Gaussiana.
- 2) Predicción del estado siguiente mediante la ecuación de transición de estados, el cual recurre a un modelo de observación previamente generado y evaluado. Este proceso ajusta la posición de cada partícula en el espacio que representa con el fin de estimar el mismo estado en un instante siguiente.
- 3) Actualización de pesos de cada partícula propagada en el tiempo, asignando estos pesos o grados de importancia una vez se conoce la observación de la salida del sistema.
- 4) Remuestreo de partículas por degeneración o falta de representatividad, mediante el umbral de remuestreo N_{um} definido por el tamaño de muestras efectivas como se expresa en (2.19) y el uso de estrategias como el multinomial o sistemático.
- 5) Se itera nuevamente hasta que dejen de haber observaciones o se determine un número finito de iteraciones.

El número de iteraciones, las condiciones de borde a definir y la cantidad de partículas para la etapa de estimación del Filtro de Partículas son esenciales para la convergencia del algoritmo si se desea un grado alto de desempeño con mayor diversidad y mayor representatividad [1] [7] [15].

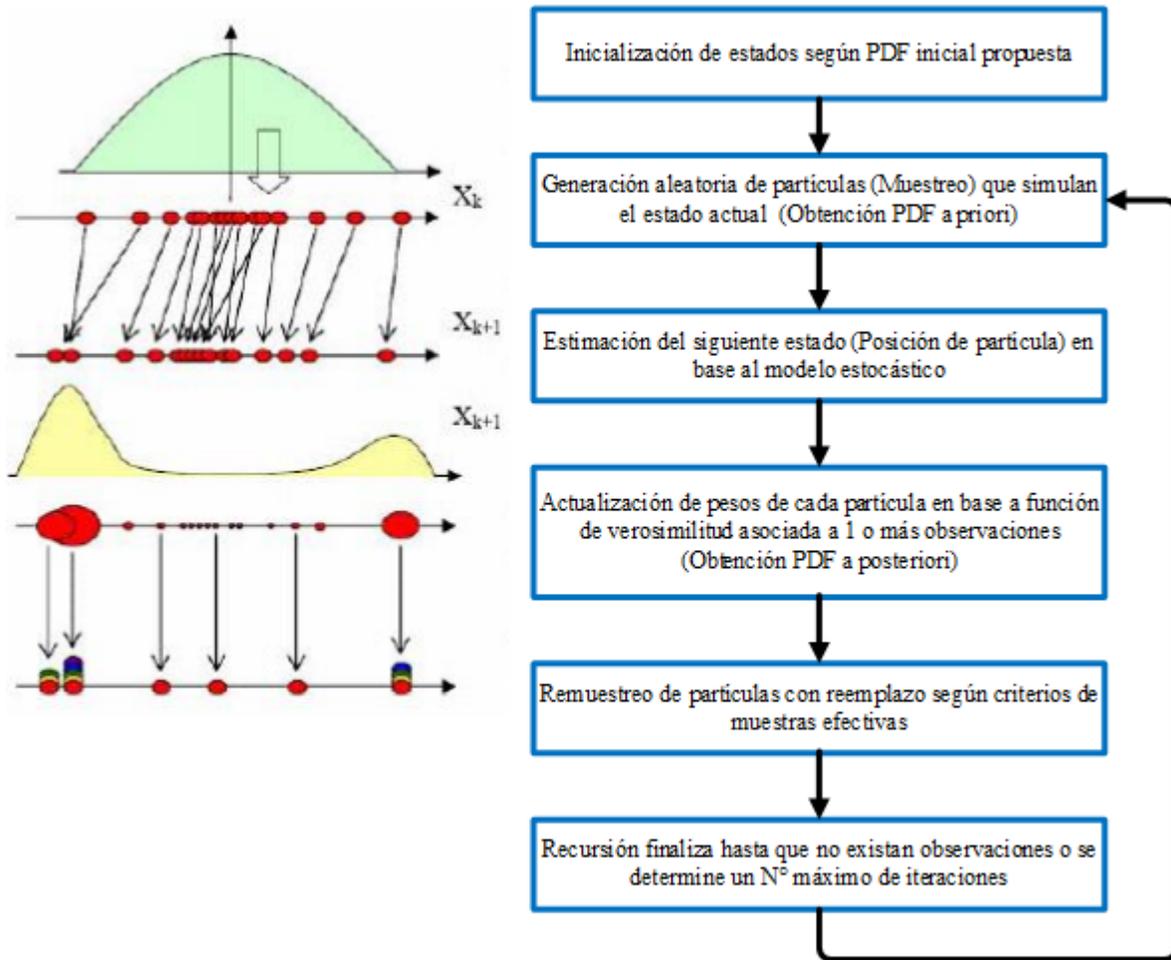


FIGURA 2.2.1: ESQUEMA GENERAL DEL FILTRO DE PARTICULAS CON REMUESTREO DE IMPORTANCIA

2.2.3. PRONÓSTICO DE EVENTOS BASADO EN FILTRO DE PARTÍCULAS

Un esquema de pronóstico mediante FP relacionado con el proceso de descarga de un ESD consiste, por ejemplo, en la estimación del tiempo remanente de descarga de la batería o EOD mediante un valor umbral crítico para el sistema, el cual refleja el evento catastrófico durante un ciclo de descarga. Este umbral puede o no coincidir con el nivel de descarga cero, ya que puede estar condicionado a un nivel de carga específico.

Un punto importante es que esta etapa considera condiciones iniciales entregadas por la etapa de estimación o filtrado principalmente en aplicaciones en línea. La predicción condicional de la distribución en el tiempo $k + \tau$ se aproxima de la siguiente forma utilizando las distribuciones predichas de cada partícula en ese instante, la cual se traduce en la ley de probabilidades totales ponderada por el peso de cada partícula en el instante anterior:

$$\hat{p}(x_{k+\tau} | \hat{x}_{0:k+\tau-1}) \approx \sum_{i=1}^N w_{k+\tau-1}^{(i)} \cdot \hat{p}(x_{k+\tau}^{(i)} | \hat{x}_{k+\tau-1}^{(i)}); \quad \tau = 1, \dots, N_h \quad (2.20)$$

Donde N_h corresponde al horizonte de predicción en la etapa de pronóstico y la ausencia de observaciones en este horizonte fuerza la actualización de los pesos, los cuales pueden ser invariantes en el tiempo como un primer enfoque, estimando el valor esperado del estado asociado a la contribución de cada partícula. Un segundo enfoque pretende regularizar las fuentes de incertidumbre que afectan el comportamiento futuro del sistema mediante un remuestreo de las PDF de los estados predichos. Así sólo dependerá de la posición de cada partícula propagada y no de sus pesos asociados [1] [7] [10].

El enfoque regularizado de predicción mediante un esquema de FP en pronóstico implementa una aproximación discreta para la PDF predicha de los estados con una función de distribución K_H que simula el ruido de proceso, también llamada *Kernels* de Epanechnikov. La generación de estas fuentes artificiales de incertidumbre mediante los núcleos o *Kernels* de Epanechnikov corresponde a funciones parabólicas como se describe a continuación:

$$\hat{\rho}(x_{k+\tau} | \hat{x}_{0:k+\tau-1}) \approx \sum_{i=1}^N w_{k+\tau-1}^{(i)} \cdot K_H \left(x_{k+\tau} - \mathbb{E} \{ x_{k+\tau-1}^{(i)} | \hat{x}_{k+\tau-1}^{(i)} \} \right); \quad \tau = 1, \dots, N_h \quad (2.22)$$

$$K_H = \frac{1}{H^{n_x}} \cdot \left(\frac{x}{H} \right); \quad H_{opt} = A \cdot N^{-\frac{1}{n_x+4}}; \quad A = \left(8C_{n_x}^{-1} \cdot (n_x + 4) \cdot (2\sqrt{\pi})^{n_x} \right)^{\frac{1}{n_x+4}} \quad (2.22)$$

$$K(x) = \begin{cases} \frac{n_x + 4}{2C_{n_x}} \cdot (1 - \|x\|) & \text{Si } \|x\| < 1 \\ 0 & \text{En otro caso} \end{cases} \quad (2.23)$$

Donde $\hat{\rho}(x_{k+\tau}^{(i)} | \hat{x}_{k+\tau-1}^{(i)})$ corresponde a la distribución de Epanechnikov con la diferencia entre el estado y el valor esperado de cada trayectoria de las partículas propagadas, así se desea caracterizar el sesgo en cada instante de predicción. Este enfoque es similar al remuestreo de la etapa de estimación/filtrado, sin embargo se contrastan en el hecho de que la regularización tiene como propósito caracterizar el perfil de uso desconocido del ESD o una falta de aprendizaje en la etapa de filtrado/estimación; no caracterizarlo bien, provoca mucha dispersión o varianza en la propagación de las partículas. La colección de partículas se propaga en el tiempo actualizando la posición de cada partícula, mientras sus pesos se mantienen constantes debido a la inexistencia de medidas observadas durante la ventana de predicción [16].

En términos de hasta cuándo predecir, se presenta la probabilidad de falla, por ejemplo en el caso del proceso de descarga de un ESD, la probabilidad de desconexión del ESD o EOD bajo el mismo esquema de N partículas en el FP regularizado.

$$P\{EOD = eod\} = \sum_{i=1}^N P\{ \text{Evento de Falla} | x = \hat{x}_{eod}^{(i)} \} \cdot w_{eod}^{(i)} \quad (2.24)$$

Las ventajas principales del FP comprenden un mayor desempeño ante un aumento de los recursos computacionales, debido a la cantidad de partículas que pueden ser representadas. Sumado a ello, la no necesidad de un nivel de confianza caracterizada por una distribución Gaussiana representa una aproximación global y posee gran facilidad de implementación en código o algún lenguaje de programación, facilitando el análisis de índices de desempeño como el error de exactitud y el ancho de los intervalos de confianza de la PDF *a posteriori* del vector de estados [17].

2.3. K-MEANS CLUSTERING

K-Means Clustering o KMC corresponde a un método iterativo de agrupamiento de datos comúnmente utilizado en minería de datos que se centra en realizar una asignación de k grupos o *clusters* dentro de un set de n puntos multidimensionales, por lo general vectores de observación, donde cada observación es asignada a un *cluster* determinado según la distancia mínima entre la media del *cluster* y el dato.

Sea $\mathbf{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ el conjunto de datos observados y $\mathbf{S} = \{\mathbf{S}_1, \dots, \mathbf{S}_k\}$ con $|\mathbf{S}| \geq 2$ un set de conjuntos, donde cada conjunto S_i corresponde a una partición disjunta de \mathbf{X} , $\forall i \in \{1, \dots, k\}$. Se definen 2 etapas en cada iteración del método; una etapa de asignación y una de actualización.

En el primer paso se generan aleatoriamente k particiones \mathbf{S}_i dentro del conjunto de datos \mathbf{X} y luego se le asigna a cada dato \mathbf{x}_j el conjunto o *cluster* \mathbf{S}_i con la media más cercana. Este problema puede ser formulado mediante el siguiente problema de optimización sujeto a restricciones:

$$\begin{aligned} \underset{\mathbf{W}, \mathbf{S}}{\text{Minimizar}} &= \sum_{i=1}^k \sum_{\mathbf{x}_j \in \mathbf{S}_i} \omega_{ji} \cdot \|\mathbf{x}_j - \boldsymbol{\mu}_i\|^2 & (2.25) \\ \text{Sujeto a} & \sum_{i=1}^k \omega_{ji} = \mathbf{1}, \quad (\forall j \in \{1, \dots, n\}) \\ & \omega_{ji} \in \{0, 1\}, \quad (\forall j \in \{1, \dots, n\}, \forall i \in \{1, \dots, k\}) \end{aligned}$$

En donde \mathbf{S} representa el conjunto de particiones o *clusters* y $\mathbf{W}[j, i] = \omega_{ji}$ la ponderación porcentual de asignar el dato j -ésimo al *cluster* i -ésimo basado en la métrica de distancia.

Por lo tanto, se minimiza la suma de los cuadrados entre cada dato perteneciente a \mathbf{S}_i y $\boldsymbol{\mu}_i$, el cual corresponde a la media muestral o centroide de todos los puntos dentro de \mathbf{S}_i . Además por defecto la distancia entre los puntos \mathbf{x}_j y $\boldsymbol{\mu}_i$ corresponde a la distancia Euclidiana, $\forall j \leq n$.

Luego en el segundo paso se recalculan los nuevos centroides $\boldsymbol{\mu}_i$ de cada partición \mathbf{S}_i como el centroide de los puntos dentro de la partición actual. Una vez calculados, se inicia la próxima iteración del algoritmo repitiendo los 2 pasos previos ya mencionados hasta que las asignaciones ya no cambian, es decir, cuando no se encuentre un mejor agrupamiento de los datos.

El algoritmo KMC tiene como principales ventajas poseer un bajo costo computacional, una facilidad de ser programado y permitir trabajar con grandes conjuntos de datos multidimensionales; donde por lo general se suele utilizar en problemas de predicción no lineal, agrupamiento por similitud, entre otras aplicaciones. Sin embargo, al corresponder a un algoritmo heurístico, no se garantiza su convergencia a un óptimo global, el cual depende categóricamente del conjunto de particiones iniciales, tanto en el número de estas particiones como en la distribución espacial de los datos [7] [18].

2.4. CADENAS DE MARKOV

En teoría de probabilidad, uno de los modelos matemáticos más simples para modelar eventos aleatorios que evolucionan en el tiempo son las cadenas de Markov o CM, las cuales pueden emplearse en diversos procesos estocásticos de tiempo discreto como por ejemplo, la gestión de inventarios de un proceso productivo, el pronóstico del consumo energético de una localidad e incluso la caracterización del perfil de uso de un ESD, la cual se aplica en este trabajo.

La estructura básica de la CM consiste en un estado o vector de estados del sistema asociado a un proceso estocástico, el cual corresponde a una variable aleatoria definida en algún conjunto finito y numerable, en particular, una variable aleatoria de tiempo discreto, es decir, donde los instantes de observación del estado cumplen con $\mathbf{k} \in \mathbb{N}$, ya que durante este trabajo se realiza un enfoque a las propiedades discretas de la CM.

Sea \mathbf{X}_k una variable aleatoria definida en algún conjunto finito $\mathbf{S} = \{\mathbf{S}_1, \dots, \mathbf{S}_r\}$ con $r \in \mathbb{N}$, la evolución temporal del sistema queda representada por la secuencia discreta de variables aleatorias $\{\mathbf{X}_k\}_{k \in \mathbb{N}}$, las cuales quedan determinadas por uno de los r -estados posibles en cada instante de tiempo.

El comportamiento temporal del sistema mediante una secuencia de variables aleatorias no necesariamente correlacionadas entre sí, se compone de una probabilidad *a priori* de que el estado del sistema tome cierto valor de \mathbf{S} en un instante determinado. Sea $\pi_i(\mathbf{k}) = \mathbf{P}\{\mathbf{X}_k = \mathbf{S}_i\}$ la probabilidad asociada de que \mathbf{X}_k represente el estado \mathbf{S}_i con $i \in \{1, \dots, r\}$, la dimensión del vector de probabilidad $\boldsymbol{\pi}(\mathbf{k})$ es equivalente al del conjunto finito \mathbf{S} y por lo tanto, $\boldsymbol{\pi}(\mathbf{k})$ corresponde a la distribución de probabilidad de \mathbf{X}_k como se muestra a continuación:

$$\begin{aligned} \boldsymbol{\pi}(\mathbf{k}) &= [\mathbf{P}\{\mathbf{X}_k = \mathbf{S}_1\}, \mathbf{P}\{\mathbf{X}_k = \mathbf{S}_2\}, \dots, \mathbf{P}\{\mathbf{X}_k = \mathbf{S}_{r-1}\}, \mathbf{P}\{\mathbf{X}_k = \mathbf{S}_r\}] & (2.26) \\ &= [\pi_1(\mathbf{k}), \pi_2(\mathbf{k}), \dots, \pi_{r-1}(\mathbf{k}), \pi_r(\mathbf{k})] \quad \forall \mathbf{k} \in \mathbb{N} \end{aligned}$$

Un proceso estocástico queda descrito principalmente bajo el conocimiento de su vector de probabilidad inicial $\boldsymbol{\pi}(\mathbf{0}) = [\pi_1(\mathbf{0}), \dots, \pi_r(\mathbf{0})]$, el cual corresponde a la distribución de probabilidad de \mathbf{X}_0 y también por medio de la ley de probabilidad condicional de \mathbf{X}_k con respecto a los estados del sistema en instantes pasados. En consecuencia, la distribución de probabilidad de \mathbf{X}_k describe una recursión condicionada a los estados pasados a medida que evoluciona el sistema. Aquello se expresa como sigue:

$$\mathbf{P}\{X_k = S_{i_k} \mid X_0 = S_{i_0}, X_1 = S_{i_1}, \dots, X_{k-1} = S_{i_{k-1}}\} \quad \forall (i_0, \dots, i_k) \in \{1, \dots, r\}^{k+1} \quad (2.27)$$

Dentro de los procesos estocásticos de tiempo discreto definidos en un conjunto finito, se encuentran las CM homogéneas, las cuales poseen una amplia variedad de aplicaciones por su simplicidad de uso. Las CM homogéneas se caracterizan por cumplir la propiedad de Markov que establece una dependencia directa entre la distribución de probabilidad de X_{k+1} y su último estado conocido X_k , donde el estado siguiente X_{k+1} es independiente de la trayectoria de los estados previos en un instante de tiempo k determinado:

$$\mathbf{P}\{X_{k+1} = S_{k+1} \mid X_0 = S_{i_0}, X_1 = S_{i_1}, \dots, X_k = S_{i_k}\} = \mathbf{P}\{X_{k+1} = S_{k+1} \mid X_k = S_{i_k}\} \quad (2.28)$$

Formalmente, un proceso estocástico discreto que satisface la propiedad de Markov se conoce como una CM discreta de primer orden como se muestra en (2.28) debido a la cantidad de estados sucesivos alcanzados por el sistema que influyen en el estado siguiente. De esta forma, se puede generalizar el orden de la CM a un orden superior $n \in \mathbb{N}$, presentándose la posibilidad de un orden nulo que refleja la independencia absoluta de la trayectoria de los estados previos.

Cada CM de tiempo discreto compuesto de un vector de probabilidad inicial $\boldsymbol{\pi}(\mathbf{0})$ y una distribución de probabilidad de X_k condicional a la información dada por el estado X_{k-1} , presenta una matriz de probabilidades de transición que caracteriza la evolución del sistema en un periodo específico de tiempo. Se denota por $p_{ij}^{(0:k)} = \mathbf{P}\{X_k = S_j \mid X_0 = S_i\}$ la probabilidad de transición *a priori* del estado X de saltar a un estado S_j siendo que el estado en el tiempo inicial era S_i durante un periodo de tiempo $(k - \mathbf{0})$. Por esta razón $p_{ij}^{(0:k)}$ también se le conoce como probabilidad de transición a k -pasos:

$$\mathbf{P}_0^k [i, j] = p_{ij}^{(0:k)} = \mathbf{P}\{X_k = S_j \mid X_0 = S_i\} \quad \forall k \in \mathbb{N}, \quad \forall (i, j) \in \{1, \dots, r\}^2 \quad (2.29)$$

Sin embargo, existe una variante que emplea transiciones a 1-paso omitiendo el periodo de tiempo y estableciendo únicamente el instante de transición:

$$p_{ij}^{(k)} = \mathbf{P}_{k-1}^k [i, j] = \mathbf{P}\{X_k = S_j \mid X_{k-1} = S_i\} \quad \forall k \in \mathbb{N}, \quad \forall (i, j) \in \{1, \dots, r\}^2 \quad (2.30)$$

Como se puede apreciar, cada vector columna o fila de la matriz de probabilidades de transición posee dimensión equivalente al conjunto finito \mathcal{S} . Sumado a ello, la matriz a 1-paso se define para cada instante de tiempo, por lo cual puede ser variable o constante en el tiempo. Para el caso general donde se conoce el vector de probabilidad inicial del sistema, la distribución de probabilidad *a priori* del estado en un instante determinado es una función de la matriz \mathbf{P} a 1-paso:

$$\boldsymbol{\pi}(\mathbf{k}) = \boldsymbol{\pi}(\mathbf{0}) \cdot \prod_{i=1}^{\mathbf{k}} \mathbf{P}_{i-1}^i, \quad \forall \mathbf{k} \in \mathbb{N} \quad (2.31)$$

En un caso particular, se dice que la CM es homogénea cuando la probabilidad de transición entre estados no depende del tiempo en que se encuentre la cadena, formalmente es una matriz de probabilidad constante en el tiempo, en donde todo vector de probabilidades del sistema se reduce al producto determinado por su valor inicial y la potencia de orden \mathbf{k} de la matriz de transición constante \mathbf{P} :

$$\boldsymbol{\pi}(\mathbf{k}) = \boldsymbol{\pi}(\mathbf{0}) \cdot \mathbf{P}^{\mathbf{k}}, \quad \forall \mathbf{k} \in \mathbb{N} \quad (2.32)$$

Una propiedad adicional que es útil en la modelación de procesos estocásticos de tiempo discreto y que simplifica su comprensión, es cuando la matriz de transición \mathbf{P} es simétrica, lo que se interpreta como una matriz que en cada uno de sus componentes posee una probabilidad de transición $\mathbf{p}_{ij}^{(\mathbf{k})} = \mathbf{p}_{ji}^{(\mathbf{k})}$, $\forall \mathbf{k} \in \mathbb{N}$, es decir, la probabilidad de saltar de un estado \mathbf{S}_i a un estado \mathbf{S}_j es equivalente en sentido contrario.

Con el fin de estudiar el comportamiento a largo plazo en la evolución del sistema para una CM finita y homogénea, sobresale el hecho de exhibir un vector de probabilidades estacionario o invariante en el tiempo que es independiente de su condición inicial. Por ende, la existencia de un vector $\boldsymbol{\pi}(\mathbf{k})$ que converge en límite temporal a un valor constante, se traduce en la convergencia de la matriz potencia $\mathbf{P}^{\mathbf{k}}$ para ese tiempo largo:

$$\lim_{\mathbf{k} \rightarrow +\infty} \boldsymbol{\pi}(\mathbf{k}) = \boldsymbol{\pi}(\mathbf{0}) \cdot \lim_{\mathbf{k} \rightarrow +\infty} \mathbf{P}^{\mathbf{k}} = \boldsymbol{\pi}$$

Por lo tanto, luego de un tiempo largo de evolución del sistema, la probabilidad de encontrarlo en un estado \mathbf{S}_i es independiente de la cantidad de transiciones que se han generado hasta ese momento, obteniendo un valor constante $\boldsymbol{\pi}_i$ para todas las componentes del vector $\boldsymbol{\pi}$ [1] [7].

2.5. MODELO ESTOCÁSTICO EN ECUACIONES DE ESTADO PARA LA ESTIMACIÓN DEL SOC EN EL PROCESO DE DESCARGA

Una de las mayores dificultades asociadas al control y seguimiento de baterías, a pesar de su gran versatilidad en diversas aplicaciones de baja y alta potencia, corresponde a la alta complejidad de los procesos electroquímicos en su interior, los cuales dejan en evidencia la necesidad de modelar mediante métodos alternativos, en nuestro caso particular de estudio, el proceso de descarga de un ESD, con un nivel de precisión deseado. Este hecho es crítico en la predicción del comportamiento que adquiere una batería a lo largo del tiempo, en donde se hace primordial conocer sus características propias de funcionamiento y como ellas se ven afectadas por las condiciones de operación para la cual se aplica.

Dentro de la diversa gama de métodos ligados a la estimación del SOC, se conoce el método de medición de electrolito, el cual es solo aplicable a baterías Plomo-Ácido de tipo VRLA, donde se relaciona linealmente la densidad del electrolito y el SOC, presentando la ventaja de fácil aplicación, pero de ser muy costoso para ser implementado en tiempo real. Un segundo método

es utilizando la impedancia espectroscópica, brindando información del SOC, SOH, temperatura, ciclos de vida, entre otros, mediante espectroscopia de impedancia electroquímica, sin embargo, las curvas son muy dependientes de la temperatura y se basa en la respuesta en frecuencia del acumulador. Otra metodología corresponde al cálculo de la resistencia interna del ESD utilizando la resistencia óhmica de la estructura de la celda, y no de la resistencia de polarización o fuga que depende de la concentración del electrolito, sin embargo, la relación entre la resistencia óhmica y el SOC es de algunos mili-Ohms entre su nivel máximo de carga y su mínimo, por lo cual se calcula experimentalmente bajo un tren de pulsos controlado sólo para efectos de modelación en escenarios de pronóstico o en la determinación del SOH. Por otro lado, existe el método que relaciona linealmente el OCV y SOC en el caso de acumuladores del tipo Plomo-Acido, y de naturaleza no lineal para el caso de Ión-Litio, sin embargo, aplica en procesos dinámicos combinado con el método de la integral de corriente, permitiendo la estimación continua del SOC donde en tiempo real no es posible aplicarlo debido a los efectos de la temperatura, histéresis e historia del ESD. Como se mencionó previamente, el método de integral de corriente, relaciona la corriente que entra y sale del acumulador e integrarla en el tiempo para estimar la capacidad extraída con respecto a la nominal, observando un porcentaje asociado al SOC o nivel de carga extraída del ESD. Tal cálculo aplica a un ESD donde se tiene una operación permanente, ya que posee la ventaja de poder ser implementado en línea combinado con el método OCV con el fin de reducir los errores de medición de los sensores de corriente, puesto que este método por sí solo, es muy sensible ante errores de medición. Por último, existen modelos estocásticos como el descrito en esta sección, bajo la combinación de los métodos de OCV, integración de corriente en descarga y de resistencia interna, de este modo se extiende la visión de los sistemas determinísticos como los ya mencionados [5] [10].

Se propone un modelo circuital simplificado en corriente continua basados en la fenomenología fisicoquímica del ESD en estudio, principalmente enfocado en la relación OCV – SOC en todo instante de tiempo para el proceso de descarga del ESD como se muestra en Figura 2.5.1, en la cual la impedancia interna y la corriente de descarga cumplen un rol fundamental en términos de cómo el modelo representa la pérdida de energía en cada instante. Esta relación de naturaleza no lineal, modela la caída de tensión en los bornes de un circuito DC en base al máximo voltaje posible, correspondiente al OCV y comprende a una simplificación del proceso de descarga, debido a que se modela un ciclo de carga/descarga arbitrario sin considerar la posible degradación o vida útil remanente del ESD, sin embargo, existen formas de detectar una potencial degradación del acumulador mediante la misma metodología desarrollada en este trabajo y la cual se explica en la sección 4.1.2.

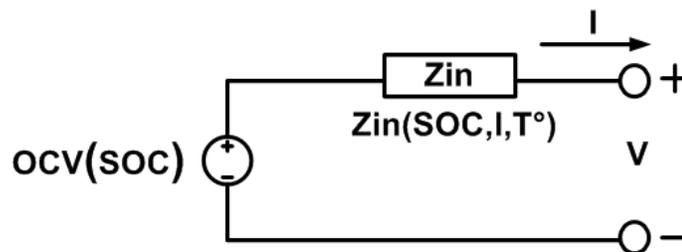


FIGURA 2.5.1: MODELO DE BATERÍA LITIO-ION MEDIANTE CIRCUITO ELÉCTRICO DC EQUIVALENTE [5]

El voltaje de circuito abierto OCV indica la tensión en **Volts** medido en los bornes del acumulador cuando no circula corriente durante la descarga. De esta manera, **OCV(SOC, k)**

representa el máximo voltaje esperado para un instante k , independiente del perfil de uso o consumo que se esté utilizando en ese momento. El SOC no es directamente medible, por lo que se infiere de los demás parámetros de modelación como se describe a continuación.

En base al modelo circuital descrito, se plantea un modelo dinámico en el espacio-estado de naturaleza estocástica y no lineal, en el que se incluye una combinación de métodos asociados al voltaje en circuito abierto, ley de conservación de energía, integración de corriente de descarga en el tiempo y resistencia óhmica interna de una celda de Ión-Litio. Una de las ventajas de este enfoque de modelación recae en el requerimiento de mediciones de voltaje y corriente en línea, lo que permite un trabajo en tiempo real directo. Otra ventaja está relacionada a la inclusión de elementos de incertidumbre ligados al uso de mediciones imprecisas, perfiles desconocidos de uso futuro, falta de diversidad en procesos de remuestreo, entre otras fuentes, las cuales se desean reducir.

Se define a la resistencia interna como un estado x_1 y al SOC como un estado x_2 según se muestra en (2.33), en el caso de x_1 , al ser un parámetro desconocido asociado a la resistencia interna óhmica del ESD, se plantea una evolución artificial de los estados pasados en base a un ruido de proceso aditivo w_1 determinado mediante criterios de diseño donde su valor depende del ruido aditivo Gaussiano de media nula y varianza a determinar. El estado x_2 comprende un valor entre 0 ó 0% y 1 ó 100% según sea el caso y corresponde de la energía remanente en la batería normalizada por el total de energía que puede entregar la batería en condiciones de máxima carga y sin degradación (cercano al valor de placa), es decir, el SOC porcentual. Por lo tanto se tiene un modelo en espacio-estado que considera un vector de estados que evoluciona en el tiempo de dimensión 2.

$$|Z_{IN}(k)| = x_1(k), \quad SOC(k) = x_2(k) \quad (2.33)$$

Para un ESD la información relevante para lograr un modelamiento apropiado son las magnitudes físicas medibles, características propias de las celdas obtenidas mediante pruebas experimentales y ciertos indicadores que sólo pueden ser estimados en base a las primeras 2 formas mencionadas como es el caso del porcentaje de energía extraída del ESD por unidad de tiempo.

El modelo estocástico se compone de ruidos aditivos asociados no necesariamente de origen Gaussiano, los cuales representan las perturbaciones en los datos medidos por los sensores de voltaje y corriente del microcontrolador del *hardware* operado en la E-bike descrita más adelante. Dichos ruidos de proceso y observación se asumen Gaussianas de media nula y varianza conocida “inicialmente” para la estimación del SOC, visto desde los bornes de una batería que puede ser un arreglo de celdas Ión-Litio de igual o diferente capacidad.

- **Modelo de Transición de Estados**

$$x_1(k+1) = x_1(k) + w_1 \quad (2.34)$$

$$x_2(k+1) = x_2(k) - V_{MEDIDO}(k) \cdot I_{MEDIDO}(k) \cdot \Delta t / E_{Crítica} + w_2 \quad (2.35)$$

El parámetro Δt corresponde al tiempo de muestreo de las mediciones en segundos, mientras I_{MEDIDO} supone una corriente positiva vista desde los bornes del ESD en **Amperes**. Por otro lado, $E_{Crítica}$ representa la energía total medida en **Watts · seg** que puede entregar el ESD, la cual puede inferirse tanto de pruebas empíricas como de la capacidad nominal indicada por el fabricante del ESD. Este último parámetro se utiliza como factor de normalización para obtener un valor porcentual de la energía extraída del acumulador en ese instante de tiempo.

- **Modelo de Observación**

$$V_{MEDIDO}(k) = OCV(SOC, k) - I_{MEDIDA}(k) \cdot |Z_{IN}(k)| + \eta \quad (2.36)$$

$$OCV(SOC, k) = V_L + (V_0 - V_L) \cdot e^{\gamma \cdot (SOC(k) - 1)} + \alpha \cdot V_L \cdot (SOC(k) - 1) + (1 - \alpha) \cdot V_L \cdot (e^{-\beta} - e^{-\beta \cdot (\sqrt{SOC(k)})}) \quad (2.37)$$

Donde η se asocia a un ruido Gaussiano de media nula y varianza a ser estimada. El término del voltaje de circuito abierto en función del SOC se propone a continuación [19].

El voltaje de circuito abierto se expresa tomando en cuenta las curvas de decaimiento, también llamados codos y la zona lineal de la batería, en donde existe una relación aproximadamente constante entre el voltaje y el SOC:

Donde se cumple que:

$$SOC(OCV = V_0) = 1$$

$$SOC(OCV = 0) = 0$$

En este caso los ruidos de observación η y de proceso w_2 están correlacionados, es decir, existe una dependencia directa en la evolución del estado x_2 o SOC a causa del voltaje de observación V_{MEDIDO} del modelo de salida.

El modelo de observación propuesto en (2.36) y (2.37) corresponde al voltaje de salida en bornes del ESD considerando la caída de tensión, producto de la resistencia interna total y el OCV característico del ESD en estudio durante el proceso de descarga. Sumado a ello, la temperatura interna del ESD afecta directamente la impedancia interna como se muestra en Figura 2.5.1 provocando alteraciones en el voltaje observado y por consiguiente en el SOC. Una causa común del aumento de la temperatura se debe a la presencia de al menos una celda de Ión-Litio degradada que provee una cantidad de energía eléctrica insuficiente comparado al resto de las celdas conectadas. Sin embargo, la temperatura se toma como una constante durante el proceso de descarga, tanto en las pruebas de descarga realizadas como en las rutas registradas de la E-bike, por lo cual se omite como una variable de entrada al AEP o solución al problema de estimación y pronóstico; a su vez, simplifica la dimensionalidad del modelo propuesto.

Cabe destacar que como el vector de estados no es medible, en consecuencia su valor no puede ser determinado mediante la medición u observación de la salida del sistema, el cual corresponde al voltaje DC en bornes. Por lo tanto, al presentar un sistema discreto no observable, se deben proponer diferentes metodologías empíricas o teóricas para inferir el vector de estados durante el

desarrollo de este trabajo. Dentro de otras características, el modelo representa un sistema dinámico variante en el tiempo y de naturaleza no-lineal. Una de las principales ventajas del modelo no lineal de observación propuesto es la facilidad en el ajuste de los parámetros en la identificación de una gran gama de procesos de descarga, la escalabilidad de sus parámetros ante apilamientos en serie/paralelo de las celdas que componen el ESD y el efecto del ruido aditivo que permite. Los parámetros desconocidos se determinan en base a pruebas experimentales de descarga suficientemente controladas para garantizar una identificación precisa del ESD en estudio [1] [20] [21].

2.6. CONTEXTUALIZACIÓN Y ESPECIFICACIONES DEL ESD OPERADO EN LA E-BIKE

Con el objetivo de especificar el ESD en estudio para su correcta supervisión y control, se describen las características generales y técnicas del sistema de monitoreo del ESD, en este caso, un pack de baterías instalado en una E-bike estándar desarrollada por el CIL bajo su proyecto ELIBATT y en la cual se implementará el AEP como una alternativa más eficiente frente al desconocimiento *a priori* de la energía disponible en el ESD.

En primer lugar se presenta un esquema general de los sistemas operados en la E-bike asociados directamente con el pack de baterías, luego se describen las especificaciones técnicas del *hardware* implementado para el monitoreo en línea del ESD incluyendo la topología de celdas de Ión-Litio utilizadas en el pack y finalmente se presenta el concepto de acumulación de energía a implementarse dentro del proyecto ELIBATT para su nueva versión donde se incluirá el AEP optimizado en línea y al mismo tiempo un nuevo modo de procesamiento.

El esquema de conexión general entre los diferentes dispositivos físicos que integran el sistema de control y supervisión en la E-bike es presentado en la FIGURA 2.6.1.

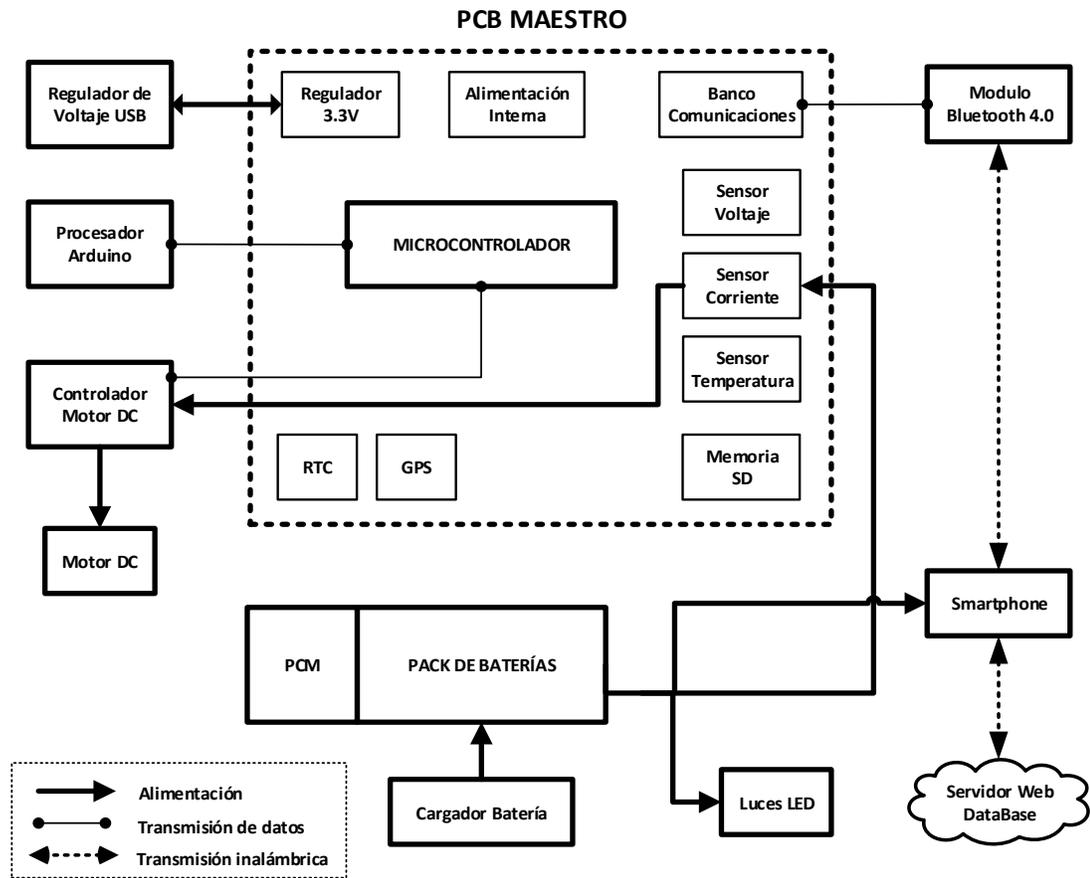


FIGURA 2.6.1: ESQUEMA GENERAL DE CONEXIÓN DEL HARDWARE E-BIKE

Cada bloque o dispositivo es descrito a continuación junto a las especificaciones técnicas más relevantes con respecto a la función que cumplen dentro del sistema:

- Pack de baterías

El módulo de baterías comprende un arreglo de celdas de Ión-Litio idénticas bajo una configuración específica de conexión como se muestra en FIGURA 2.6.2, con el propósito de lograr un nivel de tensión, capacidad eléctrica y por tanto, de energía almacenada conveniente durante el proceso de descarga, en el cual existen limitantes directas para su dimensionamiento como ocurre con el peso y espacio utilizado del pack en la E-bike para su correcto funcionamiento en diferentes tipos de terreno.

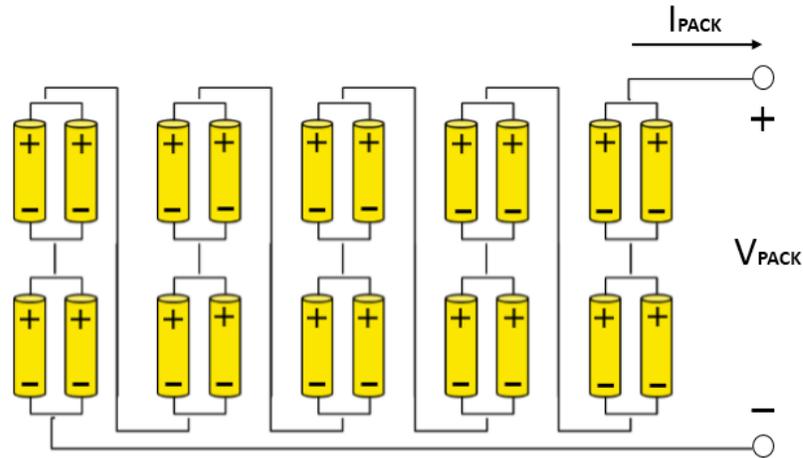


FIGURA 2.6.2: CONFIGURACIÓN DE CELDAS DE IÓN-LITIO EN PACK DE BATERÍAS

El voltaje visto desde los bornes del pack de baterías y la corriente asociada son las 2 principales variables medidas por los sensores. Ambas variables asumen pérdidas inexistentes de potencia activa, lo que se refleja en los valores máximos registrados de potencia que se han extraído del pack. Este hecho facilita la extrapolación de los valores nominales de cada celda de Ión-Litio tales como su voltaje, capacidad, resistencia interna y potencia a magnitudes determinadas por su configuración, las cuales son de real importancia para el modelo de estimación propuesto en la sección 2.5. Conforme a lo dicho sobre el uso de celdas equivalentes y extrapolación, en conjunto con el trabajo descrito en este documento, cabe mencionar que el desarrollo y análisis del AEP considera la topología de conexión de celdas adaptándose a cualquier reconfiguración en serie-paralelo o a un cambio en el número de éstas.

Con respecto a la función del ESD o pack de baterías utilizado, se tiene como función primaria alimentar el motor DC para la tracción de la E-bike y como función secundaria entregar energía a los sistemas de iluminación LED y Smartphone. Toda alimentación por parte del acumulador es protegido mediante el circuito de protección (PCM, por sus siglas en inglés) configurado ante anomalías en los niveles de tensión y corriente, sumado a esto, se incluyen un fusible de protección y un interruptor principal de desconexión en los bornes.

Examinando la celda de Ión-Litio en detalle, el pack de baterías estándar que opera en el sistema contiene **20** celdas King Kong modelo ICR26650 idénticas donde cada una posee **3.7[V]** nominales de voltaje y **4000[mAh]** de capacidad nominal. La configuración ilustrada en FIGURA 2.6.2 considera 1 arreglo de 10 módulos en serie donde cada módulo se compone de 2 celdas en paralelo. En consecuencia, el pack estándar origina **37[V]** nominales y **8000[mAh]** de capacidad, el cual permite entregar aproximadamente **296[Wh]** de energía total con un valor máximo de corriente de **12.75[A]** aproximados en descarga. La topología estándar propuesta se adopta con la razón de alimentar un motor DC de **36[V]** y **250[W]** de potencia nominal prevaleciendo la búsqueda de una capacidad en Ámpere-Hora mayor tal que la autonomía del acumulador aumente. Cabe decir que por la conexión establecida, la resistencia interna del pack debiese tomar valores cercanos a 5 veces la resistencia interna de cada celda, por lo que se asume una magnitud equivalente en cada una de ellas de **50[mΩ]**, es decir, cada celda exhibe aproximadamente la misma vida útil remanente. En resumen:

Propiedad	Valor	Propiedad	Valor
Capacidad	4000 mAh	Corriente nominal de descarga	4 A
Voltaje nominal	3,7 Volt	Masa	95 gramos
Voltaje máximo	4,2 Volt	Resistencia interna	50 miliOhm
Corriente de corte (carga)	20 mA	Vida útil	800+ ciclos
Voltaje de corte (descarga)	2,75 Volt	Densidad energética (Masa)	155,78 Wh/kg
Corriente nominal de carga	2 A	Densidad Energética (Vol)	429,07 Wh/L

TABLA 2.6.1: ESPECIFICACIONES TÉCNICAS DE LA CELDA DE IÓN-LITIO EN ESTUDIO

A continuación se describen las curvas características de la celda ICR26650 en base al *datasheet* del fabricante, en particular su dinámica de descarga según la capacidad experimental y el tiempo transcurrido respectivamente. Ambos gráficos se presentan con respecto a distintos perfiles de corriente o utilización constante donde es posible inferir el comportamiento en descarga para la corriente nominal de **4[A]**, el cual es relevante para el cálculo de parámetros en el AEP.

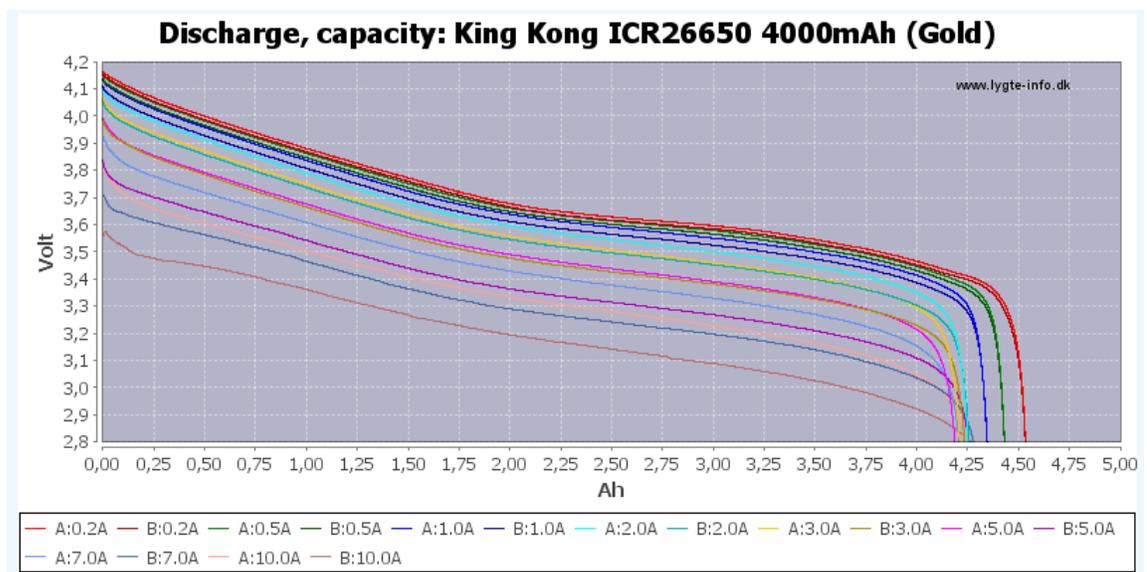


FIGURA 2.6.3: CURVA CARACTERÍSTICA DE DESCARGA DE CELDA ICR26650 POR CAPACIDAD (DATASHEET)

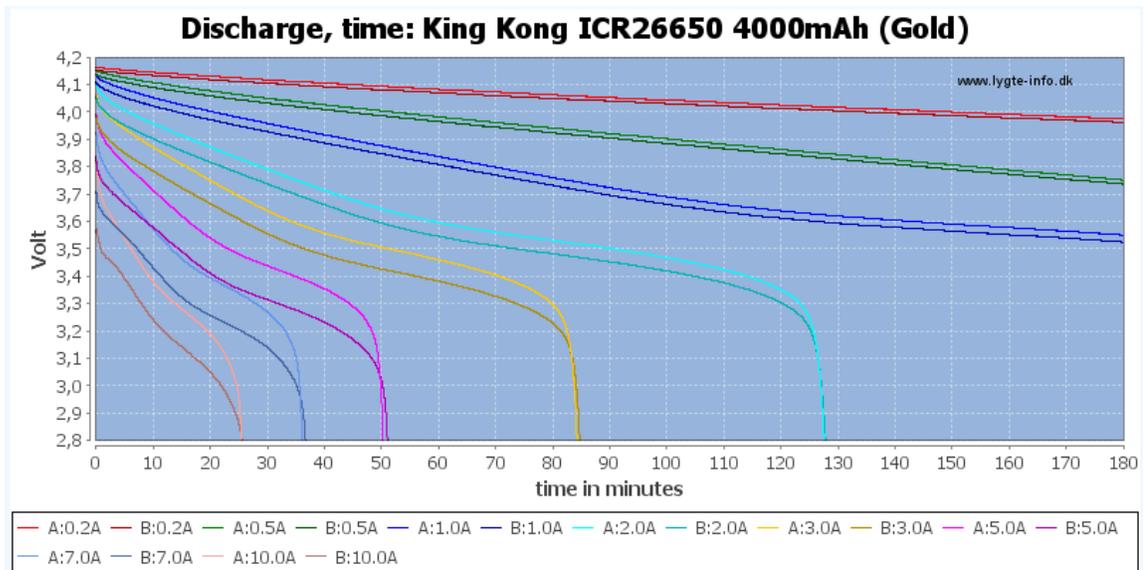


FIGURA 2.6.4: CURVA CARACTERÍSTICA DE DESCARGA DE CELDA ICR26650 POR TIEMPO (DATASHEET)

- PCM

El dispositivo de protección de baterías, también llamado controlador de carga de baterías o BMS corresponde a un módulo diseñado para actuar en situaciones anómalas de carga con el fin de proteger la normal operación del pack de baterías mediante la detección y control de los niveles de tensión durante un proceso de carga o descarga como también la desconexión de la batería en casos de sobrecorriente o cortocircuito en tiempos de respuesta cercanos a los **10[ms]**. La principal importancia de este dispositivo consiste en el valor de corte o *cut-off* del voltaje en bornes que permite ser ajustado según los requerimientos deseados del sistema, el cual puede ir desde los **28[V]** (valor mínimo extrapolado de la configuración del pack) hasta su valor nominal.

- Procesador Arduino

El procesador Arduino instalado representa un módulo de monitoreo básico del SOC previo a la implementación del AEP donde se detectan 4 niveles de SOC (25% - 50% - 75% - 100%) utilizando una función lineal establecida y programada para finalmente informar mediante una luz LED de 3 segundos de duración el porcentaje de carga disponible. Este dispositivo es parte de las modificaciones a considerar del *hardware*, la cual será reemplazada por un terminal móvil o Smartphone en entorno Android con el objetivo de visualizar las variables primarias y secundarias del monitoreo en línea del ESD y al mismo tiempo ser un módulo de procesamiento con suficientes recursos de memoria para los resultados generados por el AEP.

- Sensores

Se tienen 3 tipos de sensores para cada una de las variables a medir. Primero se describe el sensor de temperatura que para fines de este trabajo tiene un objetivo de seguridad importante en lo que respecta al posible aumento de la temperatura interna del pack de baterías como un síntoma de la degradación de una o más celdas de Ión-Litio durante su operación. Este sensor posee una

precisión de **0.25[°C]** entre **-40[°C]** y **125[°C]** donde se han registrado rangos normales de operación del pack entre **20[°C]** y **30[°C]**.

En segundo lugar se tiene un divisor de tensión simple para medir el voltaje en los bornes conectados al PCB Master mediante 2 resistencias en serie de valor bajo y conocido, de este modo el cálculo es preciso.

Finalmente para medir la corriente que circula entre los polos del pack se posee un sensor de efecto hall bidireccional modelo ACS711 de **3.3-5[V]** de alimentación como se muestra en FIGURA 2.6.5, el cual logra medir hasta una magnitud de **15.5[A]** en cualquier sentido, lo cual es adecuado para los **12.75[A]** que pueden alcanzar los picos de corriente del acumulador estándar bajo condiciones normales de operación.

Estos sensores son la base del desempeño del AEP en términos de confiabilidad en la estimación y posterior predicción del SOC, puesto que el modelo depende directamente de estas magnitudes y cualquier ruido asociado genera variaciones en su comportamiento.



FIGURA 2.6.5: SENSOR DE CORRIENTE DE EFECTO HALL

- GPS

Corresponde al dispositivo de posicionamiento global para el registro en tiempo real de las coordenadas geográficas de la E-bike, su altura, entre otras características.

- RTC

Es un reloj digital en tiempo real para el conteo del tiempo transcurrido para una ruta determinada de la E-bike.

- Almacenamiento de datos

El sistema de almacenamiento consiste en una tarjeta microSD clase **10** de **32[GB]** de capacidad y con una velocidad mínima de transferencia de **10[MB/seg]** en lo que respecta a escritura/lectura de datos con una determinada estructura, los cuales son posteriormente procesados.

- Módulo Bluetooth

Corresponde a una antena que opera mediante protocolo Bluetooth 4.0 para la transmisión inalámbrica de información entre el microcontrolador principal (PCB Master) que adquiere las mediciones de los sensores y el terminal móvil (Smartphone) donde se encuentra la HMI, el cual visualiza la información de monitoreo en pantalla.

- Regulador USB

Dispositivo que transforma, en particular reduce el voltaje de entrada **5[V]** con un **96%** de eficiencia en la conversión y una frecuencia de conmutación de **340[KHz]** con el fin de alimentar el microcontrolador principal PCB Master y transferir datos de manera externa desde o hacia él mediante una conexión USB.

- PCB Maestro

Como se aprecia en FIGURA 2.6.1 el PCB Master corresponde al módulo principal de control diseñado como parte del proyecto ELIBATT y compuesto de todos los elementos de medición, adquisición, procesamiento y transmisión de datos previamente descritos. Este dispositivo opera a **3.3[V]** y es el responsable de generar la información de interés para el usuario tanto para el control de aceleración y frenado del motor como para las variables eléctricas de los bornes del pack de baterías, las cuales se conectan a este módulo como se ilustra en la FIGURA 2.6.6.



FIGURA 2.6.6: CIRCUITO MAESTRO DE ADQUISICIÓN Y TRANSMISIÓN DE DATOS

- Smartphone

El terminal móvil corresponde a un dispositivo con sistema operativo Android o IOS donde se presenta la información medida y procesada en el PCB Maestro, en particular para el voltaje observado, el SOC del pack de baterías y la potencia extraída. Esto se logra mediante una conexión bluetooth y un HMI amigable para el usuario de la E-bike, el cual se pretende modificar en sus funciones y representar el módulo principal de procesamiento para el AEP en línea, además de seguir siendo un terminal con un HMI más compacto y robusto de información, sin embargo, esta modificación sólo está enfocada para un entorno Android y en un Smartphone de gama media con 2 núcleos de procesamiento.

- Motor DC y controlador

El motor eléctrico corresponde a un motor DC *brushless* de imanes permanentes Bafang modelo SWXK5 de **36[V]** y **250[W]** de tipo *hub* o de acoplamiento a rueda, el que a su vez, posee un controlador de 6 transistores Mosfet para la conversión de potencia DC al mismo nivel de voltaje. El flujo de potencia entre el motor y el pack de baterías se controla mediante un acelerador de mano de partida suave y un freno manual de tal modo que el motor demande una corriente de salida del pack suficiente para lograr el torque requerido y alcanzar la velocidad establecida por el usuario. En relación al flujo de potencia cabe señalar que no se cuenta con una estrategia de regeneración de ningún tipo, lo que simplifica la estimación de la energía almacenada disponible.

Una de las modificaciones en la operación del monitoreo del ESD es escalar la capacidad energética del ESD y su topología, por lo cual se pretenden utilizar packs esclavos o secundarios conectados en paralelo o serie dependiendo de qué parámetro se desee maximizar. Por un lado se desea maximizar el voltaje nominal y/o su capacidad nominal según el dispositivo o máquina que se desea alimentar. El pack de baterías maestro considera voltajes de salida desde los **12[V]** para la alimentación de equipos de campaña hasta equipos de alta potencia de más de **48[V]** con diferentes niveles de corriente según la conexión entre los packs esclavos y el maestro. Este nuevo concepto se resume en la siguiente figura:

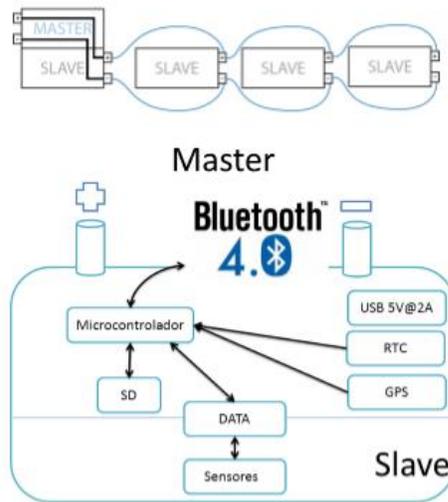


FIGURA 2.6.7: NUEVO CONCEPTO DE ACUMULADORES ELIBATT

CAPITULO 3

DESARROLLO METODOLÓGICO

En este capítulo se expondrán los métodos utilizados para estimar los parámetros desconocidos del modelo y ser adaptados a una celda de Ión-Litio descrita en 2.6, luego la descripción de las etapas de desarrollo del AEP en fases modulares para un mejor entendimiento de su funcionamiento, las cuales constan de una primera etapa de estimación, seguida de una tapa de pronóstico, en donde se realiza una caracterización estadística del perfil de uso futuro del ESD para finalizar con una etapa de estimación de la potencia máxima disponible. En primer lugar se debe mencionar la importancia que significa adaptar un algoritmo a distintos valores de corte programados en un PCM y BMS; ambos instalados dentro del pack de baterías, debido a la zona de la curva de descarga, según la curva OCV – SOC característica en que se encuentra el voltaje de corte programado.

Actualmente una de las aplicaciones asociadas al control óptimo de baterías consiste en la estimación y predicción en línea del SOC, con el fin de emplear decisiones en periodos cortos de tiempo manteniendo un nivel significativo de exactitud y precisión. La exactitud es reflejada principalmente mediante la diferencia entre el valor esperado del estado y el valor observado, mientras la precisión involucra la varianza estadística que presenta el estado en cada instante de tiempo apreciados de forma directa en las colas de la PDF resultante del AEP.

A continuación se presenta el diagrama general del proyecto de monitoreo en tiempo real del ESD. Tal proyecto consiste principalmente en la supervisión del SOC presente en el ESD, donde se remarca en “celestes” las etapas desarrolladas en este trabajo, es decir, el desarrollo del AEP incluyendo los parámetros y condiciones iniciales requeridos para la implementación en línea de la solución, además de presentar una estructura que permita evolucionar el sistema a un grado mayor de complejidad o tamaño ante desafíos futuros.

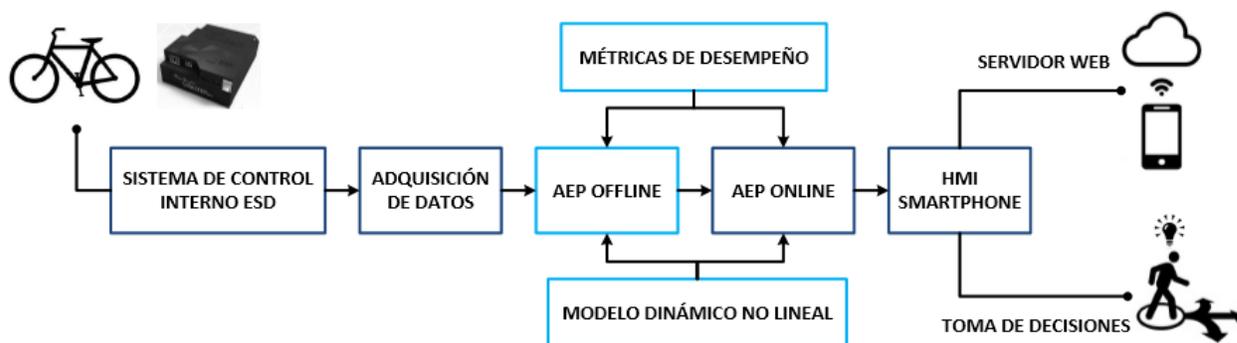


FIGURA 3.1: DIAGRAMA GENERAL DE PROYECTO DE SUPERVISIÓN DE BATERÍA

En este sentido, la solución que se dispone es un algoritmo de estimación y pronóstico desarrollado en plataforma *Matlab* mediante un método de inferencia Bayesiana como es la simulación de Monte Carlo secuencial o también llamado Filtro de Partículas. Este algoritmo

posee varias etapas modulares con objetivos específicos. Primero se modela el proceso de descarga de la batería de modo fuera de línea basado en pruebas de descarga controlada, con el cual se estiman los parámetros asociados al modelo estocástico que se propone para 2 estados, la impedancia interna de la batería y el SOC porcentual. Luego se estiman los estados mediante el FP utilizando como observación el voltaje medido por los sensores, ya que el SOC es una variable no observable directamente. El voltaje medido representa una entrada del sistema al igual que la corriente medida en los bornes del ESD y el voltaje de corte de este. Después de ello, se da paso a la etapa de predicción bajo un horizonte previamente definido y donde al no tener mediciones disponibles se utiliza la información histórica de la batería para predecir el perfil de uso futuro basado en una caracterización estadística de eventos aleatorios mediante CM. En esta etapa se le da mayor importancia a los últimos registros de medición. Una vez realizado esto, se toman variadas realizaciones del perfil de uso futuro y se generan distribuciones de probabilidad para el SOC predicho con un **95%** de nivel de confianza. Finalmente en base al SOC predicho a medida que transcurre el tiempo y al voltaje de corte que representa el umbral de falla, se generan las distribuciones de probabilidad del EOD con el fin de obtener el tiempo de falla o TOF de la batería, destacando la tendencia a sub-estimar ese valor respecto a la sobre-estimación encontrada en los métodos presentes en la literatura. Puesto que es preferible dar una alerta antes que ocurra el corte en la realidad [1] [10] [19].

Se considera de forma independiente cada ciclo de descarga del acumulador sin incluir el SOH de éste, por lo que la vida útil remanente no es una variable analizada en este trabajo. Se asume que el perfil de descarga que se caracteriza es invariante en el tiempo, lo cual simplifica considerablemente la etapa de pronóstico para el enfoque de FP regularizado que se propone.

3.1. ESTIMACIÓN OFFLINE DE PARÁMETROS PARA MODELO DE DESCARGA DEL SOC

Con el fin de caracterizar el proceso de descarga del pack de baterías el modelo en tiempo discreto Prueba con 3 set de datos diferentes sobre una celda de Ión-Litio ICR26650. Un set destinado a la estimación de parámetros del modelo propuesto, un set con pulsos en la corriente manipulada con el fin de estimar la impedancia interna óhmica de la celda y finalmente un set de datos para validar el modelo obtenido.

Para el modelo descrito en (2.37), los parámetros V_0 , V_L , α , β y γ corresponden a constantes propias de cada batería o celda. Estos valores son calculados en línea, mediante un procedimiento cuyo objetivo es disminuir el error cuadrático medio entre la curva de voltaje obtenida al descargar la batería (completamente cargada) a corriente nominal y la ecuación de observación presentada en (2.37). La Tabla 4.1 presenta los parámetros obtenidos para las baterías asociadas a los conjuntos de datos presentados en el Capítulo 3. El valor $|Z_{IN}|$ presentado en la corresponde a una aproximación del valor absoluto de la impedancia interna de la batería o celda. Para determinar dicha aproximación; en la prueba de descarga a corriente constante, realizada para determinar los parámetros de la ecuación de observación, se agregan dos pulsos en la corriente de descarga. De esta forma, es posible estimar el valor, al menos, inicial de dicho parámetro mediante $|Z_{IN}|$ expresado en (3.1). En donde, ΔI_{medido} representa la diferencia de corriente empleada para realizar el pulso en la prueba. Mientras que ΔV_{medido} corresponde a la diferencia de voltaje en bornes de la batería producida al aplicar dicho pulso de corriente.

Esta prueba de descarga también es utilizada para obtener una estimación *a priori* del comportamiento del SOC, mediante la utilización de la ley de conservación de energía. Esta estimación es utilizada para calcular el ancho de los intervalos temporales, con los que se segmenta el perfil de corriente, mencionados en el Capítulo 3. En este trabajo se ha escogido un ancho para cada intervalo dado por el ancho de los intervalos donde el SOC disminuye **10%** en la estimación mencionada.

El modelo propuesto tiene la capacidad de realizar la estimación de parámetros cuyo valor exacto es desconocido. Este es el caso del valor absoluto instantáneo de la impedancia interna de la batería, representada por el estado x_1 . La ecuación corresponde a la realización de un proceso de evolución artificial, con el objetivo de realizar una correcta estimación de este estado. La realización de este proceso ayuda a compensar errores debidos a una inadecuada elección de la condición inicial para el estado, dada por $|Z_{IN}|$. Por otro lado, esta estrategia de estimación tiene la ventaja de poder incorporar la incidencia de factores externos, cuyo efecto no está contemplado en la formulación del modelo de espacio-estado. Un ejemplo de tales factores es la temperatura ambiental, ya que el valor de la impedancia interna se ve afectada directamente por ella.

Algunas desventajas radican en que el OCV es dependiente de la temperatura, de la historia de la batería, y además presenta efectos de histéresis. Lo que afecta el mapeo de la curva SOC - OCV y evidentemente el desempeño del método [10] [19] [22].

3.1.1.

PRUEBA DE DESCARGA CONTROLADA

Se realiza una prueba de descarga controlada para una celda de Ión-Litio nueva ICR26650 con el fin de obtener los parámetros desconocidos del modelo de observación y del modelo de transición de estados presentados en (2.34), comparando los resultados experimentales obtenidos con diferentes pruebas de descarga de celdas idénticas, y así validar dichos parámetros. En esta sección se presentará el procedimiento de experimental en un entorno controlado.

En primer lugar se utiliza una carga electrónica programable de corriente continua que tolera hasta **7[A]** de descarga del pack de baterías donde se establece una corriente constante de **4[A]**, es decir, se descarga a una tasa **1C**. Sin embargo, para determinar su resistencia interna, el cual se pretende definir como valor inicial del estado x_1 , se aplicó un escalón de corriente de **2[A]** de **30** segundos de duración en la zona de tensión constante de la batería o zona lineal ubicado en el tramo medio de la descarga. La Tabla 3.1.1: Especificaciones de prueba de descarga Tabla 3.1.1 ilustra los valores tomados, mientras la FIGURA 3.1.2 expone los pulsos de corriente constante manipulados para la prueba de descarga. Cabe destacar que la corriente manipulada para controlar el voltaje de salida o descarga de la celda en prueba posee un número muy reducido de ciclos de carga/descarga, por lo cual no esta afecta a algún tipo de degradación. El comportamiento dinámico sin considerar degradación de la batería es apreciada en la FIGURA 3.1.2, en el cual se manifiesta la reacción del voltaje en bornes ante un cambio abrupto de la corriente de descarga sin considerar corrientes de fuga en el cálculo de la resistencia interna. Así, se toma como la diferencia entre el valor de la tensión justo antes de aplicar el escalón y el último valor del escalón de tensión, todo esto dividido por **2[A]** que es la diferencia de corriente aplicada, en otras palabras lo que se tiene es:

$$|Z_{IN}| = \frac{\Delta V_{medido}}{\Delta I_{medido}} \quad (3.1)$$

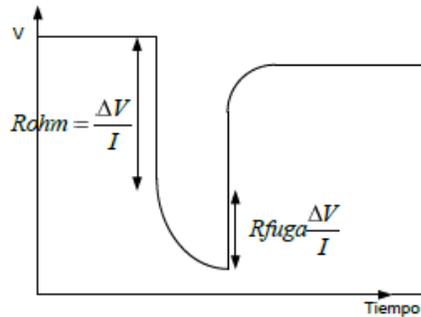


FIGURA 3.1.1: IDENTIFICACIÓN DE LA RESISTENCIA ÓHMICA EN PULSOS CONTROLADOS DE VOLTAJE [5]

La corriente manipulada para controlar la salida de voltaje de la celda. A continuación se presentan las especificaciones consideradas para la prueba de descarga controlada:

Propiedad	Valor
Corriente de prueba (Nominal)	4 A
Variación de corriente	± 2 A
Voltaje de corte	2.7 V
Tiempo de muestreo Δt	1 seg
Instante de activación pulso 1	Segundo 889
Instante de activación pulso 2	Segundo 1865
Instante de activación pulso 3	Segundo 2842
Duración de pulsos	30 seg

TABLA 3.1.1: ESPECIFICACIONES DE PRUEBA DE DESCARGA

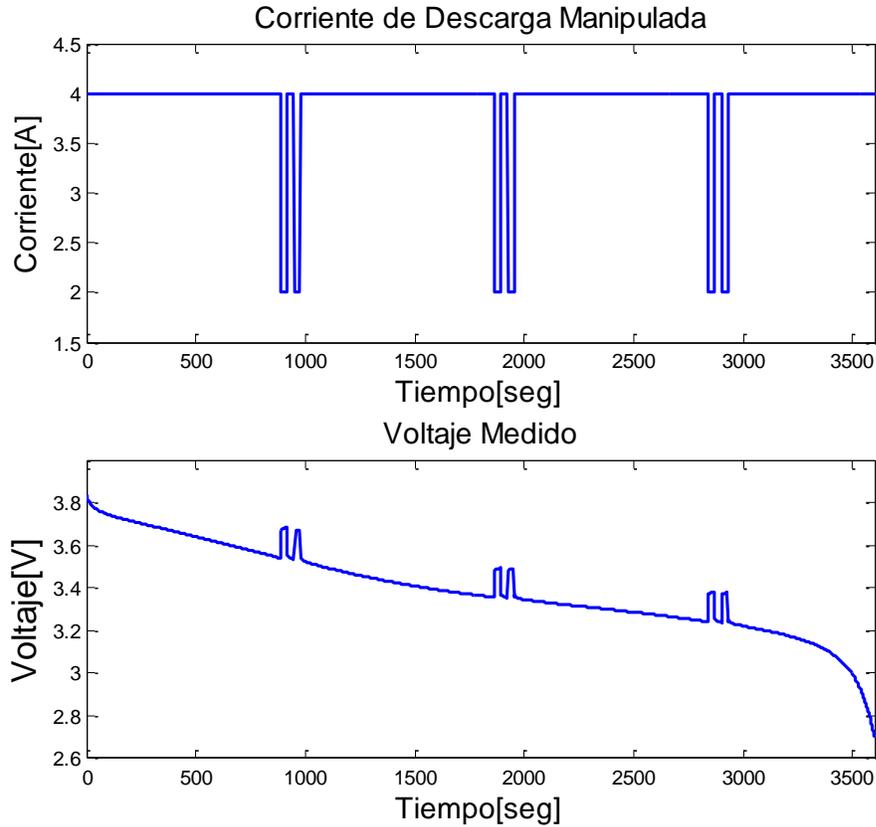


FIGURA 3.1.2: CORRIENTE Y VOLTAJE DE PRUEBA CONTROLADA DE CELDA IÓN-LITIO

El SOC real final de la prueba de descarga comprende la razón porcentual entre la capacidad real final en [Ah] de la prueba hasta el momento en que se llegue al valor de corte programado o Voltaje *cut-off* y la capacidad nominal de 4[Ah]. La siguiente expresión resume el cálculo:

$$SOC_{Final Normalizado} = \frac{\sum I(t) \cdot \Delta t}{4} \quad (3.2)$$

Luego para obtener la energía crítica real del pack de baterías, se suman los productos de voltaje y corriente en cada instante y durante toda la prueba, con el objeto de calcular la energía almacenada, luego se divide por el SOC real final obtenido. Éste parámetro es relevante para el modelo de SOC, debido a que rige el nivel de decrecimiento del SOC a medida que se extrae energía almacenada:

$$E_{critica}[W \cdot seg] = \frac{\sum V(t) \cdot I(t) \cdot \Delta t}{SOC_{Final Normalizado}} \quad (3.3)$$

Dentro del modelo de observación en el cual deseamos estimar sus parámetros conocidos, la zona 2 o zona lineal es caracterizada por la expresión que se muestra a continuación y en la FIGURA 3.1.2, la cual corresponde a una componente del modelo de observación:

$$V_L + \alpha \cdot V_L \cdot (SOC(k) - 1) \quad (3.4)$$

La zona 1 y 2 corresponden al codo inicial de descarga y zona lineal respectivamente, las cuales se pueden representar juntas en base a la siguiente expresión mostrada en la FIGURA 3.1.2:

$$(V_0 - V_L) \cdot e^{\gamma \cdot (SOC(k)-1)} + V_L + \alpha \cdot V_L \cdot (SOC(k) - 1) \quad (3.5)$$

En las pruebas #2 y #3 se apreciaron celdas con degradación dejando como consecuencia directa la caída de voltaje abrupto en el tiempo y una elevada temperatura del pack de baterías como los 2 síntomas principales. Todo esto bajo una demanda constante de corriente. Este fenómeno provocó la disminución de voltaje hasta su punto de corte en menos de **40 minutos**, lo cual, difiere mucho en comparación con el tiempo esperado de aproximadamente **1 hora y 20 minutos** apreciado en FIGURA 3.1.2, obteniendo set de datos insuficientes para validar la prueba #1. Por esta razón, se consideran ambas pruebas como fallidas.

La gráfica que aprecia el rango y sensibilidad del parámetro Beta en las pruebas se muestra a continuación:

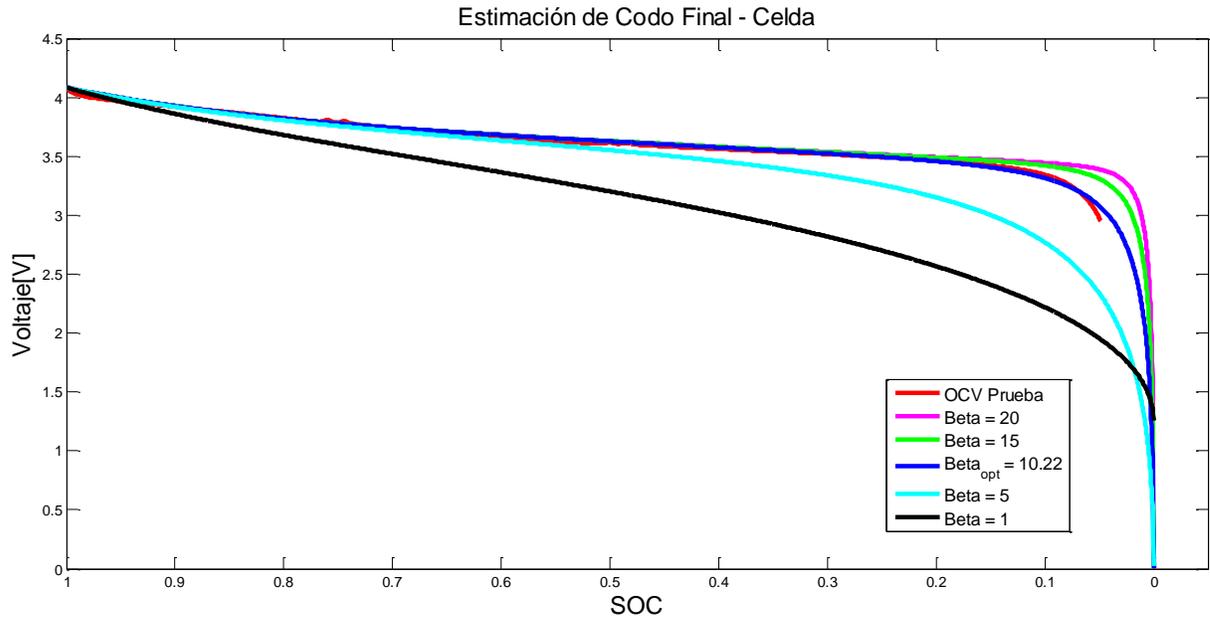


FIGURA 3.1.3: ESTIMACIÓN DE PARÁMETRO BETA EN CODO FINAL DE DESCARGA

Por su parte la zona 3 comprende el codo final de descarga hasta un punto de corte o SOC nulo, donde su comportamiento es caracterizado bajo la siguiente componente del modelo de observación, la cual expone una dinámica exponencial decreciente:

$$(1 - \alpha) \cdot V_L \cdot (e^{-\beta} - e^{-\beta \cdot (\sqrt{SOC(k)})}) \quad (3.6)$$

Sumando el comportamiento de las 3 zonas, se tiene la curva característica del voltaje en circuito abierto asociado al SOC porcentual normalizado, la cual se expone en la FIGURA 3.1.4 con un sobreajuste relacionado con el valor mínimo de la raíz del error cuadrático medio (RMSE, por sus siglas en inglés), obtenido de los datos de prueba.

Los valores resultantes en la curva característica son las siguientes:

	$ Z_{IN} $ [Ω]	Energía Crítica [Wh]	Capacidad final [Ah]	Tiempo Final de Prueba [seg]
Prueba Celda	0.0625	93.9% Energía Nominal	3.9485	3600 hasta el corte
Prueba Pack	0.3125	93.9% Energía Nominal	7.897	3600 hasta el corte

TABLA 3.1.2: RESULTADOS FINALES PRUEBA DE DESCARGA CONTROLADA

3.1.2. ESTIMACIÓN DE PARÁMETROS Y CURVA CARACTERÍSTICA OCV- SOC

En primera instancia se extrapolan los parámetros estimados empíricamente en el modelo de observación con respecto a cada celda. De esta forma, se obtiene un modelo de observación escalado para el arreglo de celdas en su totalidad.

Los parámetros α , V_L se determinan según el comportamiento dinámico del voltaje observado en la zona lineal de descarga, mientras los parámetros γ , β quedan bien definidos respecto al comportamiento del voltaje en el codo inicial y final de descarga respectivamente. Se calcula el error entre la curva de descarga OCV y la regresión lineal (LR, por sus siglas en inglés) de la zona lineal más apreciable gráficamente, para luego calcular su RMSE [23]. Después de aquello, se ajusta la función lineal obtenida tal que el RMSE del error de voltaje se reduzca aún más. Esto se logra acotando el ancho de la zona lineal hasta un rango donde el error deja de variar significativamente. En consecuencia, la Zona 2 de la curva OCV está representada entre los datos **1800** y **2900** como se muestra en FIGURA 3.1.4.

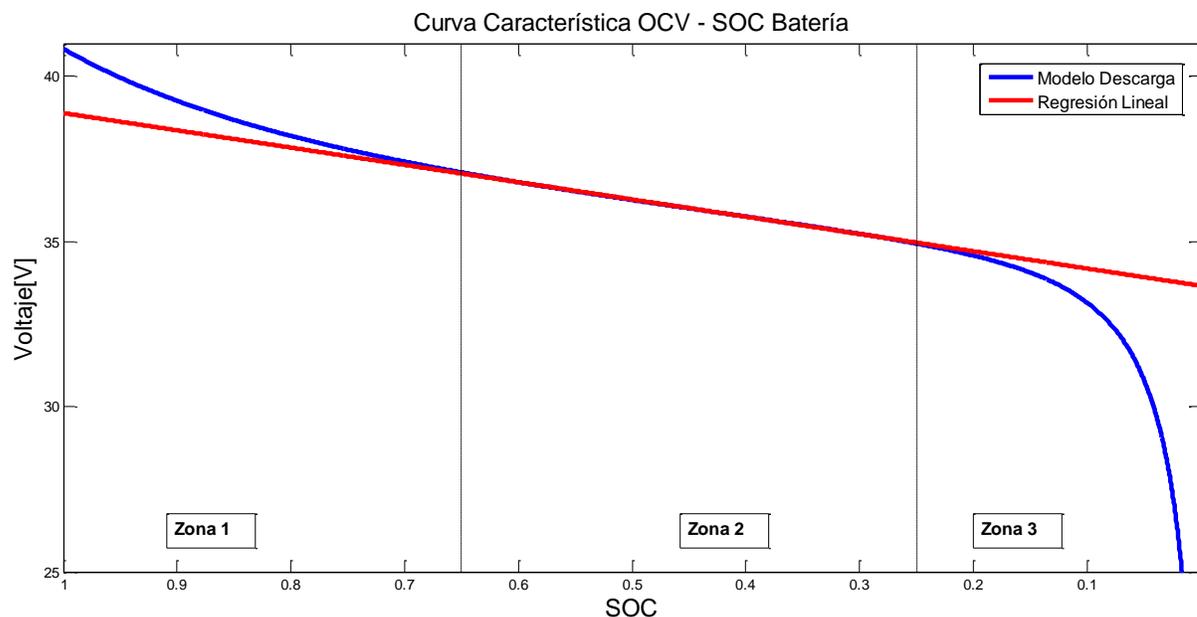


FIGURA 3.1.4: IDENTIFICACIÓN DE ZONAS DE OPERACIÓN EN CELDA DE IÓN-LITIO PARA PRUEBA CONTROLADA

De este modo, la curva OCV-SOC obtenido de las pruebas experimentales de una celda Ión-Litio extrapolada a un arreglo en serie-paralelo, es la siguiente:

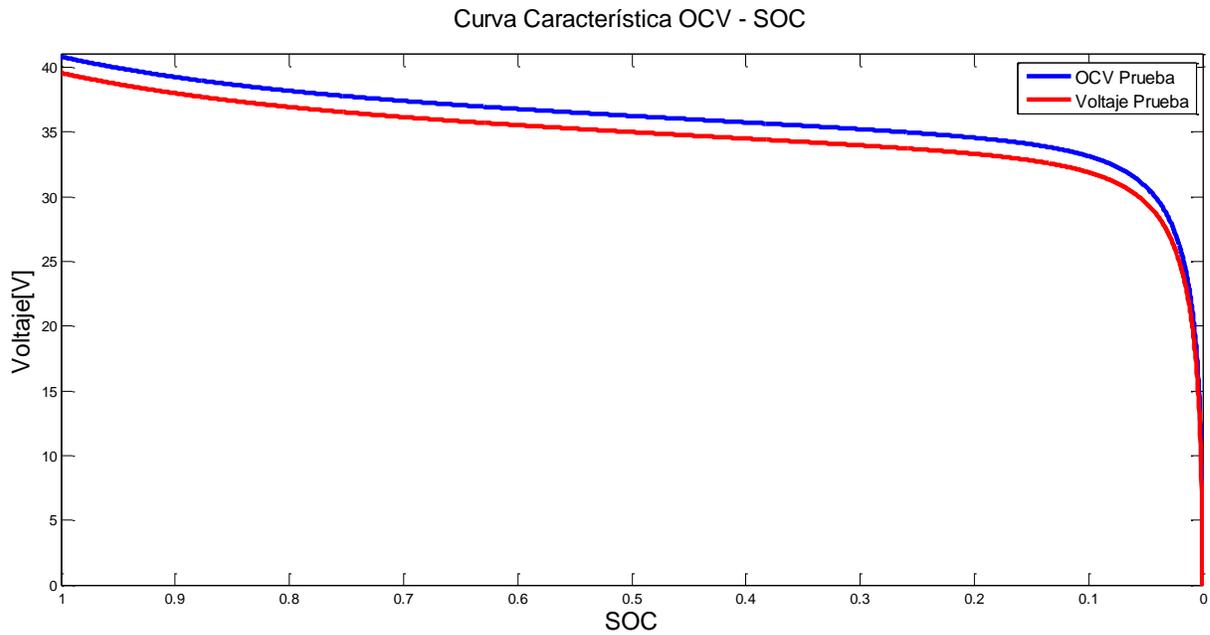


FIGURA 3.1.5: CURVA CARACTERÍSTICA OCV-SOC DE PRUEBA DE DESCARGA CONTROLADA

El voltaje en bornes observado se redefine sin el efecto de los 3 pulsos generados con el fin de apreciar la distancia entre ambas curvas, la cual demuestra la magnitud de la caída de tensión a causa de la resistencia óhmica interna del pack de baterías.

Los parámetros estimados para el modelo de observación para ambas pruebas son:

	V_0	V_L	α	β	γ
Prueba Celda	4.084	3.82	0.108	10.22	5.8056
Prueba Pack	40.84	38.2	0.108	10.22	5.8056

TABLA 3.1.3: PARÁMETROS FINALES DEL MODELO DE OBSERVACIÓN

	RMSE γ	RMSE β	RMSE Tiempo Final [seg]
Prueba	0.0135	0.0597	0.0202

TABLA 3.1.4: ERROR CUADRÁTICO MEDIO MÍNIMO EN LA ESTIMACIÓN DE PARÁMETROS ESPECÍFICOS

Cabe destacar que los parámetros del modelo de observación para el voltaje en bornes son similares entre una celda de Ión-Litio y un pack de baterías con la configuración propuesta en FIGURA 2.6.2.

3.2. DESARROLLO Y ADAPTACIÓN MODULAR DEL AEP

Dada la no linealidad del modelo de espacio-estado presentado, no se cuenta con una herramienta que permita calcular la solución al problema de estado óptimo. Es por esto que se considera la utilización de una solución sub-óptima, la cual permita trabajar en línea ante aproximaciones discretas. Particularmente se decide trabajar con el algoritmo de Filtro de Partículas, tanto para desarrollar la etapa de estimación y su posterior etapa de pronóstico. Esta herramienta posee la capacidad de ser utilizada en sistemas no lineales y no Gaussianos, siendo atractiva para el modelo fenomenológico utilizado.

En primera instancia, como un factor de seguridad a considerar en las estimaciones resultantes, se procede a establecer un valor de **0.5[V]** que se suman al SOC de corte programado en el microcontrolador, con el fin de minimizar el riesgo ante sobre-estimaciones indeseables en la predicción del EOD, en particular, en pronósticos a largo plazo cuando la capacidad del ESD sea mayor al estudiado en este trabajo, reduciendo la probabilidad de alcanzar el valor de corte mientras el AEP opera en línea.

En

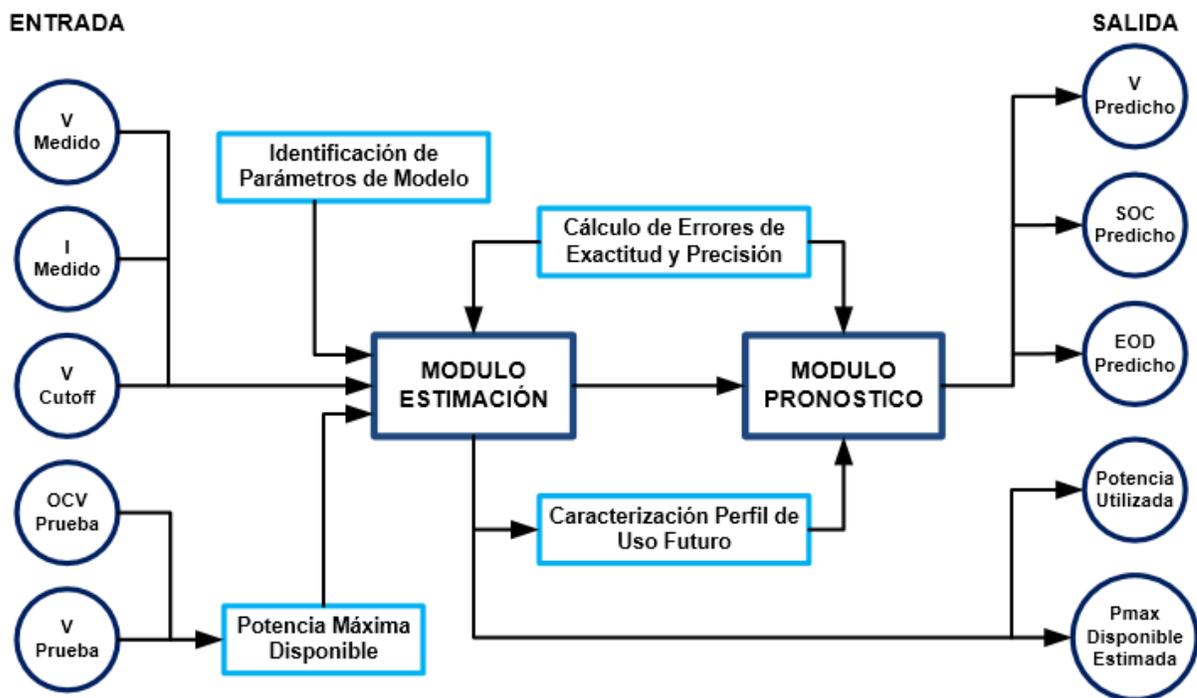


FIGURA 3.2.1: DIAGRAMA GENERAL DE AEP OFFLINE

3.2.1. MÓDULO DE ESTIMACIÓN BASADO EN FILTRO DE PARTÍCULAS

Hoy en día, una de las aplicaciones asociadas al control óptimo de baterías consiste en la estimación y predicción en línea del SOC, con el fin de emplear decisiones en periodos cortos de tiempo manteniendo un nivel significativo de exactitud y precisión. La exactitud es reflejada principalmente mediante la diferencia entre el valor esperado del estado y el valor observado, mientras la precisión involucra la varianza estadística que presenta el estado en el instante de análisis.

A continuación se presenta el diagrama de flujo modular de la etapa de estimación o filtrado del AEP en un marco offline, donde se incluyen conceptos de compensación del SOC estimado ante mediciones pequeñas de corriente y la suma de un ruido adaptativo del modelo con el fin de acelerar la convergencia del vector de estados con respecto a su valor de referencia:

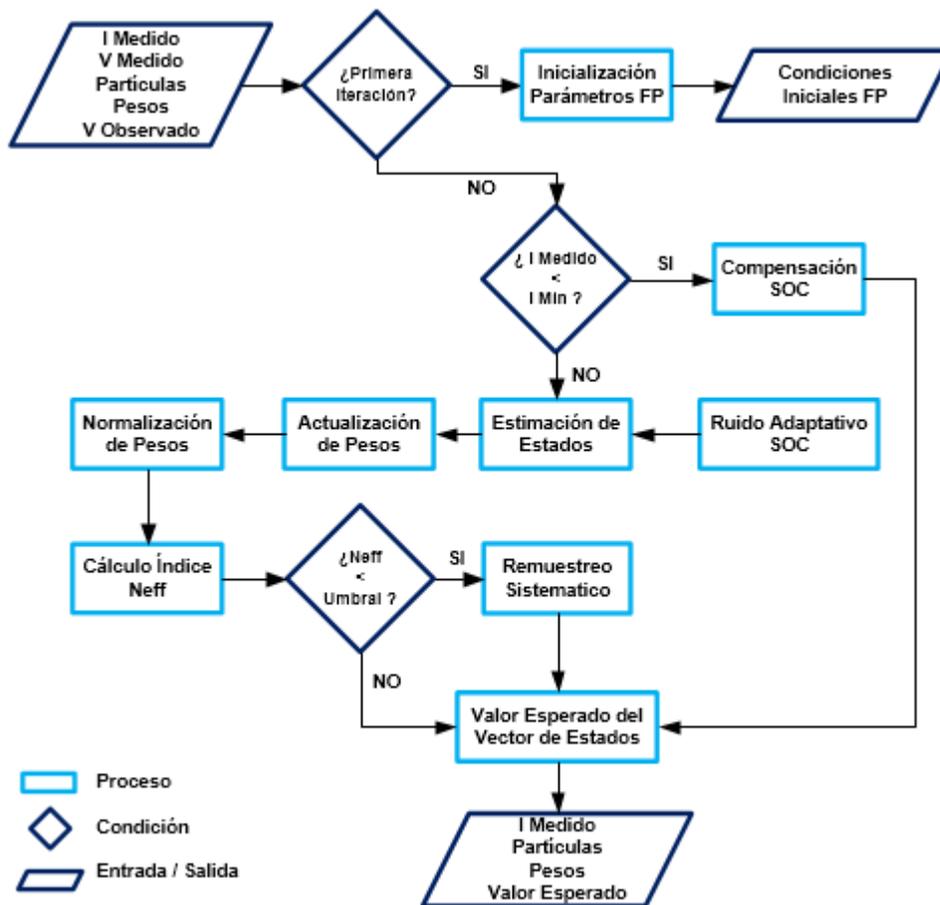


FIGURA 3.2.2: DIAGRAMA MODULAR DE FLUJO DE ETAPA DE ESTIMACION DEL AEP

Como se muestra en el diagrama FIGURA 3.2.2, la etapa de filtrado o estimación Bayesiana comprende varias iteraciones de FP con remuestreo o SIR, en las cuales necesita un modelo de transición de estados y observación con sus parámetros identificados, además de las correspondientes condiciones iniciales del filtro y dos bloques interesantes a describir; un bloque empleado para compensar o tratar la estimación del SOC (no afecta al estado x_1) ante una adaptación abrupta del estado y los parámetros del filtro, debido a una función de verosimilitud de bajo valor en el paso de actualización de los pesos; un segundo bloque consta de un ruido

adaptativo con el fin de acelerar la convergencia de los estados disminuyendo el sesgo de estimación con respecto al SOC referencial que se explica más adelante, es decir, acelerar el proceso de aprendizaje del FP y en consecuencia determinar un inicio del módulo de pronóstico en un tiempo menor. Esto afecta directamente la adaptabilidad del FP con respecto a las condiciones aleatorias iniciales que se establecen en el AEP.

En lo que respecta al estado \mathbf{x}_1 , se modela bajo una evolución artificial por lo que su comportamiento dinámico depende directamente del ruido asociado \mathbf{w}_1 , la cual se define de tipo Gaussiana y de media nula.

Durante esta etapa se requiere de un valor referencial del SOC en base a datos legibles del ESD en estudio para comparar el nivel y calidad de las estimaciones del SOC. Por esto, se define la energía extraída del pack de baterías correspondiente al SOC referencial o *Ground Truth* en base a datos reales, debido a que en un enfoque offline es posible comparar el resultado estimado, incluso predicho del SOC con tal curva referencial de descarga, de este modo se puede medir el comportamiento dinámico del AEP bajo un entorno simulado. La curva de extracción de energía porcentual para la referencia se fundamenta en la ecuación (2.35), donde se utilizan los datos medidos de voltaje y corriente de descarga hasta el dato *k-ésimo* o iteración *k-ésima* con el fin de calcular el total de energía que se ha utilizado hasta ese instante desde la carga total, equivalente a $E_{Crítica}$ como ya es sabido. A continuación se muestra la ecuación descrita para la referencia offline normalizada por el parámetro $E_{Crítica}$, con tal de representar valores porcentuales y compararlos con el SOC estimado de cada iteración.

$$SOC_{Ground\ Truth}(k) = 1 - \frac{\sum_1^k V_{MEDIDO}(1:k) \cdot I_{MEDIDO}(1:k) \cdot \Delta k}{E_{Crítica}} \quad (3.7)$$

Las condiciones iniciales del FP con remuestreo se componen de las siguientes características:

- Estados iniciales (variable aleatoria que mide la adaptabilidad inmediata del filtro), **0.3125**[Ω] para \mathbf{x}_1 . La impedancia de placa extrapolada correspondería a **0.25**.
- Tiempos de muestreo entre **1[seg]** y **1.5[seg]** debido a la capacidad de lectura y procesamiento del dispositivo de adquisición de datos, la cual no es constante y está asociada al ruido de observación.

Un punto importante dentro de esta etapa como se hizo mención, es la compensación ante mediciones negativas de corriente y a cambios abruptos de ésta que son un problema para la adaptación del FP durante la estimación del vector de estados, principalmente en el comienzo del proceso de descarga. El valor $I_{Umbral} = 0.1[A]$ se define empíricamente como el umbral para diferenciar una estimación compensada de una clásica del FP (condición crítica en esta etapa de filtrado), la cual podría generar un conjunto de pesos degenerados y sin representatividad. Si la corriente medida sobrepasa tal valor, la función de verosimilitud no será significativamente pequeña para indeterminar los pesos de actualización en cada una de las partículas durante su normalización. Una forma de evitar este hecho, consiste en compensar los pesos utilizando el voltaje de salida en el instante o iteración anterior para estimar los estados, un tipo de imputación con mediciones conocidas. Luego de realizar el paso de compensación se remuestrea el set de partículas con tal de evitar nuevas degeneraciones posibles que afecten el valor esperado de la PDF del estado SOC.

Se define una estrategia de remuestreo sistemático, el cual a diferencia del remuestreo multinomial, incorpora menos procesamiento y costo computacional. El índice de eficiencia o tamaño efectivo de muestras N_{eff} se compara con el umbral de remuestreo que consiste en el producto entre el número de partículas o muestras N y el porcentaje establecido de remuestreo (en nuestro caso **0.85**), el cual genera un tamaño de muestras que debe ser mayor a N_{eff} para remuestrear y así representar de mejor manera la población de partículas asociadas a cada estado. El remuestreo sistemático posee un tiempo de procesamiento mucho menor en comparación a otras alternativas, a medida que el largo de estimación crece. Sumado a ello, no requiere la inversión de una función característica de las partículas, ya que presentan pesos uniformes como se muestra en FIGURA 3.2.3.

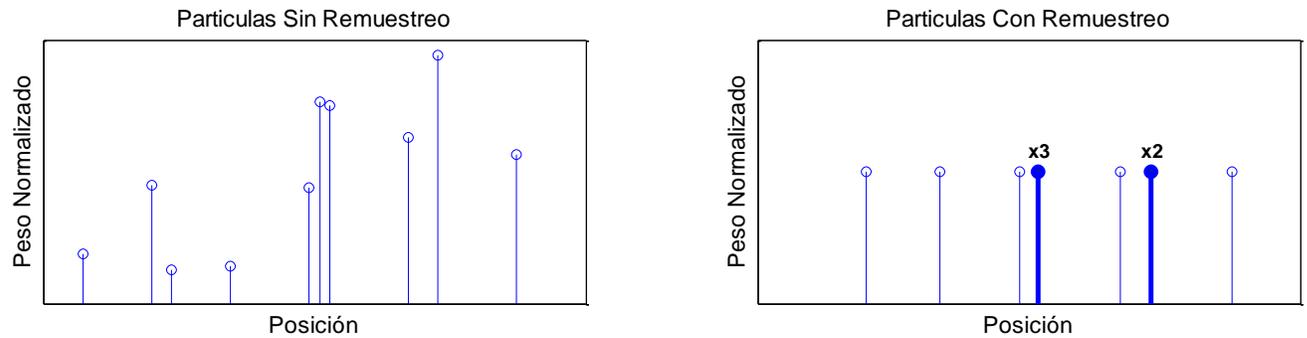


FIGURA 3.2.3: EFECTO DEL REMUESTREO SISTEMATICO APLICADO A UNA POBLACIÓN DE PARTÍCULAS

En el caso con remuestreo de la FIGURA 3.2.3 se aprecian 2 partículas que sobresalen en color azul con un multiplicador “por 3” y “por 2”, las cuales representan 3 y 2 partículas respectivamente en la misma posición. Este hecho se traduce en una mayor ponderación o importancia de esas posiciones en la PDF descrita por el set de partículas, es decir, en una mayor probabilidad de encontrar el estado de interés en esa posición. El enfoque sistemático tiene la ventaja de remuestrear con un costo computacional menor que el multinomial, debido a que no invierte la matriz característica de ponderación asociada al set de partículas [24].

La etapa de filtrado conlleva una pieza importante dentro de la estimación del vector de estados. Esta pieza corresponde al ruido de observación η del modelo que comprende un enfoque empírico aproximado a partir de 2 criterios; uno consta en estimar la variación real del voltaje observado por unidad de tiempo, por otro lado, calcular la tendencia del voltaje en datos históricos mediante un filtro pasa bajos de tipo Haar de primer orden con el propósito de separar la señal de su ruido asociado. Éste filtro pertenece a la familia de filtros *wavelet* discretos y se aplica a una gran gama de señales por su simpleza de implementación, en particular cuando existen transiciones abruptas. En la FIGURA 3.2.4 se presenta el segundo enfoque descrito mediante un filtro pasa bajos Haar [25].

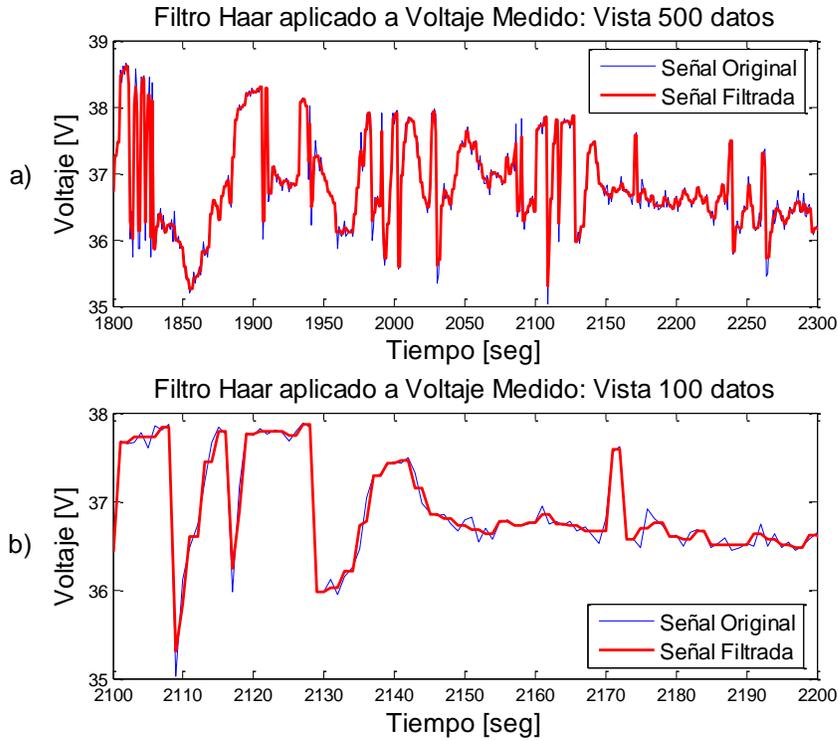


FIGURA 3.2.4: a) FILTRADO DE VOLTAJE OBSERVADO CON 500 DATOS PROYECTADOS. b) FILTRADO DE VOLTAJE OBSERVADO CON 100 DATOS PROYECTADOS

La varianza del ruido de observación se determinó mediante un procesamiento estadístico en línea, el cual consiste en aplicar un filtro pasa bajo a la señal de voltaje medido, y posteriormente calcular el valor absoluto de la diferencia entre la señal original y la entrada. La varianza empírica de dicha diferencia se utilizó como la varianza de este ruido, ya corresponde a un estimador de ella. Por otra parte, la varianza de \mathbf{w}_2 (ruido de proceso del estado \mathbf{x}_2) fue determinada mediante ajustes empíricos a través de un análisis de sensibilidad realizada a la adaptabilidad del filtro en la etapa de estimación, incorporando el efecto del ruido de observación. De forma análoga se determinó la varianza de \mathbf{w}_1 (ruido de proceso asociado al estado \mathbf{x}_1) [26]. Con esto, se logra el siguiente valor promedio con respecto al error de filtrado en voltaje o equivalentemente el ruido de observación:

$$\sigma_{\eta} = 0.25[V] \quad (3.8)$$

Una vez determinado el ruido σ_{η} se procede a estimar σ_{w2} , el cual está correlacionado con σ_{η} como se describió anteriormente.

$$\sigma_{w1} = 0.001[\Omega], \quad \sigma_{w2} = 0.001 \quad (3.9)$$

El ruido de la impedancia interna se establece en $1[m\Omega]$ y el ruido asociado al SOC se fija en 0.001 ó 0.1% , sin embargo, este valor puede variar dentro de un rango $\sigma_{w2} \in [0.1\%, 0.5\%]$ para el σ_{w1} previamente mencionado sin alterar la convergencia deseada del SOC.

Un punto a destacar es que el valor del SOC de corte o V_{cutoff} deben estar fuera del largo de estimación idealmente, ya que si está dentro, no existirá tiempo suficiente para una toma de decisión, el cual representa un objetivo del trabajo realizado. La detección de un tiempo razonable de aprendizaje o adaptación del modelo al proceso medido en tiempo real genera caracterizaciones deseables del perfil de uso y por tanto, de un módulo de pronóstico con menor sesgo en horizontes de largo plazo.

3.2.2. CARACTERIZACIÓN ESTADÍSTICA DEL PERFIL DE USO FUTURO DEL ESD

El paso previo para la etapa de pronóstico en el AEP corresponde al procesamiento estadístico de la corriente demandada en gran parte por el motor durante la etapa de estimación, con el propósito de generar un perfil de uso futuro del pack de baterías lo más confiable y ajustado posible a cada ruta que se presente, permitiendo tener una noción del uso del pack de baterías como consecuencia de las medidas inexistentes de corriente descargada durante la etapa de pronóstico.

Los perfiles de uso del pack de baterías pueden variar según las condiciones de terreno por donde la E-bike se desplaza, las cuales no se consideran para efectos de modelación. Por ejemplo, una pendiente mayor implica una demanda de corriente mayor para mantener una velocidad constante. Por lo que deben ser caracterizados de manera efectiva durante la etapa de estimación donde se poseen mediciones directas de la corriente de salida, ya que durante el pronóstico no se conoce el perfil de uso al cual operará el acumulador, por lo que se requiere caracterizar este consumo futuro para predecir tanto el SOC como el EOD del pack, ya que una buena caracterización de estos perfiles reducen directamente la incertidumbre durante el pronóstico.

La caracterización estadística involucra el uso de CM con 2 estados de consumo, “Alto” y “Bajo”, y de primer orden, lo que permite representar variados perfiles en conjunto con las tasas de transición entre ambos estados en términos de probabilidad, de acuerdo a la información medida hasta el instante en que inicia la predicción. Cabe destacar que el rango de corriente demandada para el perfil comprende valores entre $0[A]$ y $12.75[A]$ para un estado bajo y alto de consumo respectivamente.

El procedimiento de caracterización estadística desde los datos crudos de corriente recolectados hasta el perfil de uso resultante para un largo de predicción determinado, el cual se traduce en la determinación de los parámetros de la CM, se describe como sigue:

- 1) Elección de un inicio de predicción, el cual da inicio a la etapa de pronóstico y acota los datos de corriente medida a ser caracterizados. Luego se dividen estos datos en intervalos equidistantes o de igual ancho como se muestra en la FIGURA 3.2.5 a). Cabe destacar que el tiempo de muestreo como se ha mencionado anteriormente, es generalmente mayor a 1 [seg] y diferente para set de datos, por lo que se considera directamente el número de datos adquiridos hasta el inicio de predicción.
- 2) Se determinan los valores de los estados “Alto” y “Bajo” de cada intervalo mediante KMC como se aprecia en FIGURA 3.2.5 b), en consecuencia, el estado “Alto” y “Bajo” corresponden al centroide mayor y menor de ese intervalo respectivamente. Respecto a KMC, existe la posibilidad de que algún *cluster* pierda todos sus puntos asignados, en el

cual, se genera como respuesta un nuevo *cluster* en base al dato más lejano de su respectivo centroide. Esto suele ocurrir en las primeras iteraciones debido al número de grupos designados inicialmente.

- 3) Se discretizan los datos de corriente en cada intervalo asignando cada dato con el estado más cercano en términos de magnitud como se exhibe en FIGURA 3.2.6 a).
- 4) Se calculan las probabilidades de transición en cada intervalo entre ambos estados, lo que genera una matriz de transición de 2x2 para cada intervalo; donde cada componente de la matriz se calcula según el siguiente estimador:

$$p_{ij}^{(m)} = \frac{\sum_{k=2}^{N^{(m)}} [I(k) = j \mid I(k-1) = i]}{N^{(m)} - 1} \quad \forall i, j \in \{I_{Bajo}^{(m)}, I_{Alto}^{(m)}\} \quad (3.10)$$

$p_{ij}^{(m)}$ determina la probabilidad de que la transición del estado i al estado j ocurra. Para calcularlo se cuenta el número de transiciones entre ambos estados i y j , los cuales pueden corresponder a $I_{Bajo}^{(m)}$ o $I_{Alto}^{(m)}$ según sea el caso dentro de cada intervalo m ; luego se normaliza con respecto al número de datos de tal intervalo representado por $N^{(m)}$.

- 5) Se aplica el método de ponderación exponencial de media móvil (EWMA, por sus siglas en inglés), con el fin de entregar mayor importancia a los últimos intervalos caracterizados y de esta forma, obtener nuevos valores tanto de la matriz de probabilidades de transición como del valor de los 2 estados para el instante en que se inicia la predicción tal como se muestra en FIGURA 3.2.6 b), los cuales representan las condiciones iniciales para generar una realización del perfil de uso futuro en la etapa de pronóstico. Los nuevos estados y probabilidades de transición en cada intervalo consideran la información del perfil de uso de los intervalos previos como se muestra a continuación [27]:

$$\tilde{I}_{Bajo}^{(m)} = (1 - \lambda) \cdot I_{Bajo}^{(m)} + \lambda \cdot \tilde{I}_{Bajo}^{(m-1)} \quad \forall m \quad (3.11)$$

$$\tilde{I}_{Alto}^{(m)} = (1 - \lambda) \cdot I_{Alto}^{(m)} + \lambda \cdot \tilde{I}_{Alto}^{(m-1)} \quad \forall m \quad (3.12)$$

$$\tilde{p}_{ij}^{(m)} = (1 - \lambda) \cdot p_{ij}^{(m)} + \lambda \cdot \tilde{p}_{ij}^{(m-1)} \quad \forall m \quad (3.13)$$

Los parámetros $\tilde{I}_{Bajo}^{(m)}$ y $\tilde{I}_{Alto}^{(m)}$ corresponden a los valores ponderados de ambos estados en el intervalo m ; $\tilde{p}_{ij}^{(m)}$ corresponde a la probabilidad ponderada de que la transición desde el estado i al estado j ocurra en el intervalo m . Por último, el parámetro λ representa el factor de olvido dentro del método EWMA, en el que se considera con un valor fijo de $\lambda = 0.7$, el cual conlleva a una ponderación bastante significativa de los intervalos finales.

- 6) Se genera una realización de la CM caracterizada, es decir, un perfil de uso futuro independiente a ser utilizado en el modelo propuesto de descarga dentro del enfoque de FP en pronóstico, donde las condicionales iniciales determinan la evolución aleatoria que se aprecia en cada realización; desde el inicio de predicción hasta su horizonte asociado. Por lo tanto, en cada instante de predicción existen dos escenarios posibles según la probabilidad de permanecer o presentar una transición entre un estado y otro, por lo que la evolución futura de la corriente puede ser descrita con un árbol de decisión binario, el cual está representado por la FIGURA 3.2.8.

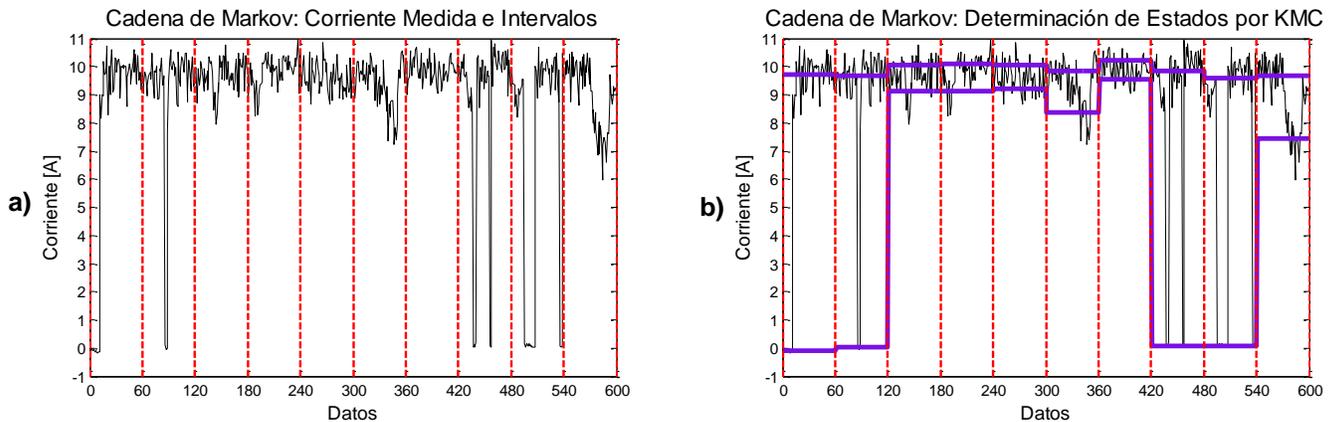


FIGURA 3.2.5: PRIMERA PARTE DE LA OBTENCIÓN DE PARÁMETROS DE LA CM (INTERVALOS Y ESTADOS POR INTERVALO)

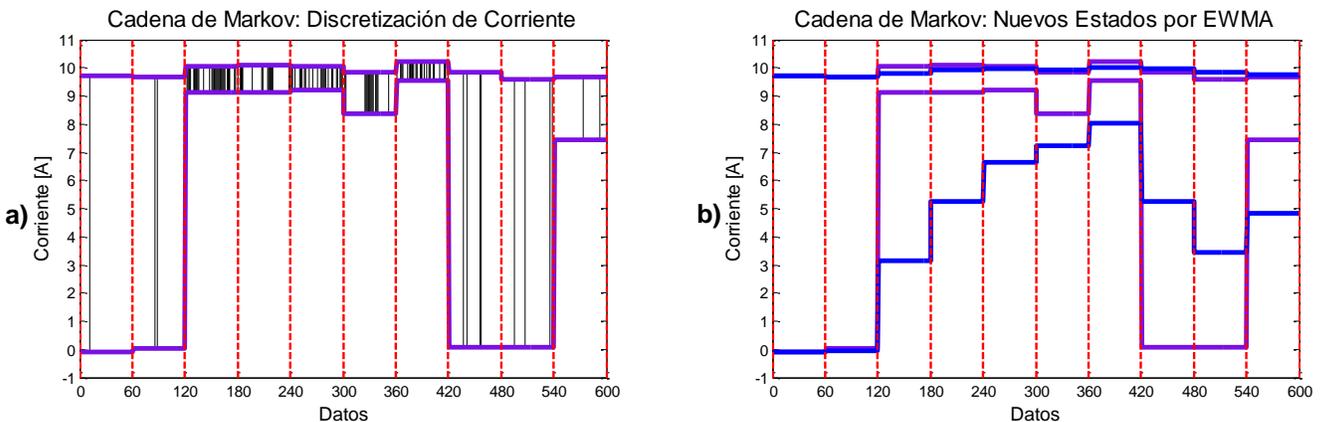


FIGURA 3.2.6: SEGUNDA PARTE DE LA OBTENCIÓN DE PARÁMETROS DE LA CM (DISCRETIZACIÓN POR INTERVALO Y EWMA)

En FIGURA 3.2.5 y FIGURA 3.2.6, las líneas punteadas rojas corresponden a la segmentación de cada intervalo, mientras las curvas de color negro corresponden a los datos crudos de corriente demandada a caracterizar; por otro lado las curvas rectas de color púrpura corresponden a los valores de ambos estados en cada intervalo, finalmente la curva recta de color azul corresponde a los nuevos estados obtenidos mediante EWMA con un factor de olvido de **0.7**.

La segmentación del perfil de corriente para los intervalos temporales (de igual ancho) se calcula según el ancho de los intervalos donde el SOC estimado decae aprox. un **10%** en la prueba de

descarga controlada, tal como se sugirió anteriormente por motivos de mejorar la caracterización en cada uno de los intervalos sin presenciar variaciones relevantes de corriente [1] [7].

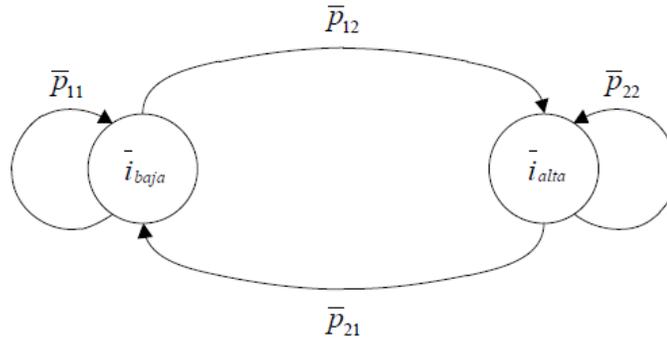


FIGURA 3.2.7: CARACTERIZACIÓN ESTADÍSTICA DEL PERFIL DE USO MEDIANTE CM DE PRIMER ORDEN Y DOS ESTADOS [1]

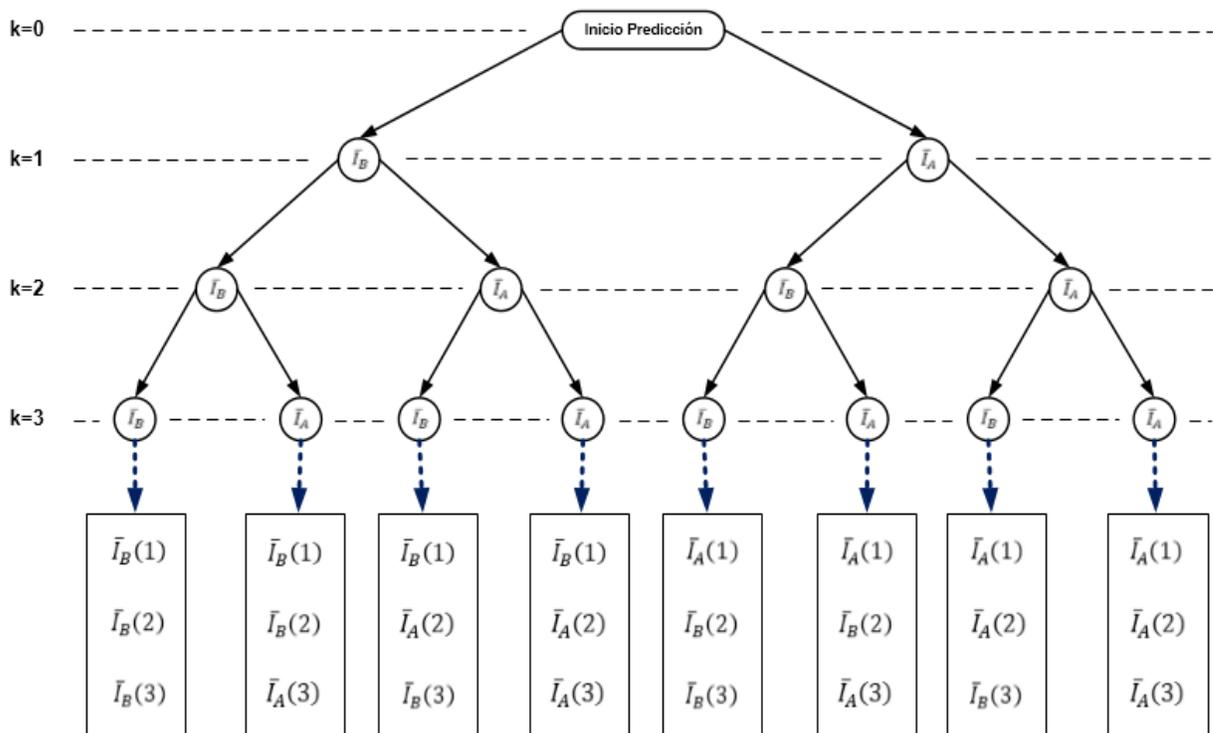


FIGURA 3.2.8: GENERACIÓN DE DISTINTOS PERFILES DE USO PARA 3 INSTANTES DE TIEMPO CONSECUTIVOS

La caracterización estadística del perfil de uso futuro $I(k), k = k_{pred} + 1, \dots, k_{EOD}$ conlleva la generación aleatoria de un perfil de descarga desde el inicio de predicción hasta un determinado horizonte, a partir de los parámetros de la CM calculados, donde en cada instante o paso temporal se asigna un estado de consumo “Bajo” o “Alto” mediante la comparación de un valor aleatorio y la probabilidad de transición de un estado a otro. Este perfil corresponde a una realización de la CM previamente obtenida, la cual es independiente de otras realizaciones generadas.

La existencia de un orden determinado en base a test de hipótesis se resuelve y analiza en la literatura, pero prevalece la idea de mantener un costo reducido del tiempo de procesamiento, por lo que se efectúa la caracterización con una CM de primer orden, donde el factor de olvido juega un rol importante en la corrección EWMA de los 2 estados definidos en el inicio de predicción. Anteriormente se explicó cómo definir los estados de la cadena mediante el uso de KMC, asumiendo un número de centroides predeterminado. La extensión para órdenes mayores es generalizable a partir del caso de primer orden. Para esto se considera que cada una de las transiciones entre estados presentes en la observación de la realización de la cadena corresponde a una variable aleatoria multinomial, cuya distribución depende del estado en el que se produjo dicha transición y corresponde a la probabilidad de transición de la CM [1] [7] [19] [27].

3.2.3. MÓDULO DE PRONÓSTICO BASADO EN FILTRO DE PARTÍCULAS

El módulo de pronóstico apunta a predecir el comportamiento dinámico del vector de estados, en particular, del SOC utilizando la corriente caracterizada hasta un horizonte de predicción definido, ya que este enfoque permite propagar las partículas actualizando la posición de cada una de ellas, pero no así sus pesos asociados, debido a la inexistencia de observaciones, generando la PDF *a posteriori* del SOC en base al modelo de observación y a su vez, la PDF *a posteriori* del EOD en base a un mapeo de la distribución acumulada del SOC en instantes futuros, con el fin de evaluar y analizar mediante índices de desempeño previamente mencionados, el desempeño del AEP. Por lo que se recalca la importancia en la exactitud del valor esperado del EOD y su dispersión.

La idea principal es modificar las posiciones en base al modelo y dada una PDF que representa la distribución *a posteriori* del estado en un tiempo inicial, se desea realizar una predicción. Entonces, fijas tres posiciones en base al análisis de la PDF (cola de 5%, valor esperado, cola de 95% por ejemplo). Todas esas posiciones ya consideran la PDF (la posición depende directamente de la forma de la PDF), por lo que tienen las tres el mismo peso. Luego se utiliza el modelo para ver cómo dichas "partículas" evolucionan en el tiempo. Obviamente, la posición cambia a medida que propagas las partículas en el futuro usando el modelo, pero los pesos son constantes porque en predicción no hay nuevas observaciones que puedas usar para ajustar los pesos.

El diagrama de flujo modular de la etapa de pronóstico del AEP tiene la siguiente estructura:

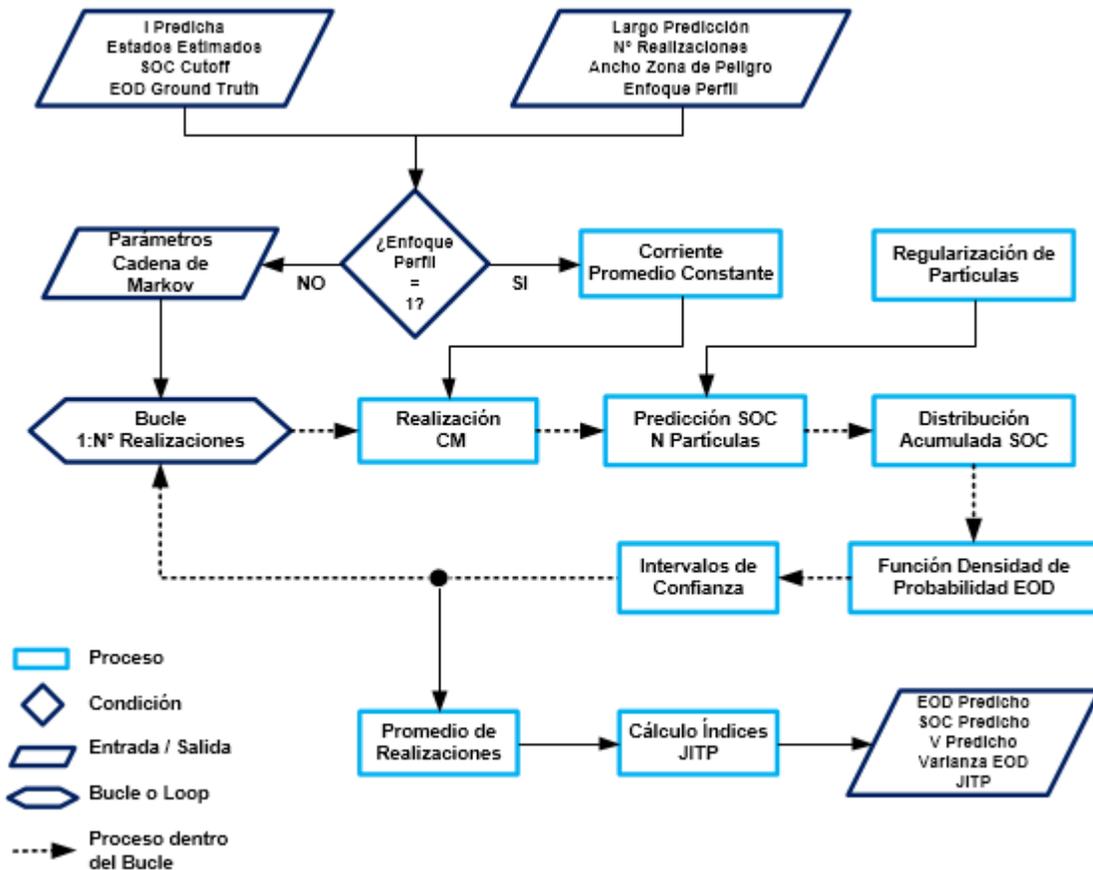


FIGURA 3.2.9: DIAGRAMA MODULAR DE FLUJO DE ETAPA DE PRONÓSTICO DEL AEP

Se presenta un marco de pronóstico de eventos basado en FP, en el cual se consideran inicialmente la PDF *a posteriori* del estado x_2 o SOC condicionada a las mediciones y una caracterización estadística de perfiles de uso en el pack de baterías, con el fin de estimar la PDF del tiempo remanente que le queda al acumulador antes del corte programado o *cutoff*, si es que se alcanza. Una de las ventajas de presentar un enfoque basado en FP es su implementación en tiempo real, mediante 3 características que se describen a continuación:

- La caracterización de una serie de posibles trayectorias del estado $\hat{x}_k^{(i)}$ determinados para una colección finita de partículas, las cuales dependen directamente de las realizaciones del perfil de uso futuro del pack de baterías y los pesos $w_k^{(i)}$ que representan la probabilidad de seguir dicha trayectoria.
- La definición de una zona de peligro (HZ, por sus siglas en inglés) que está asociada a un evento crítico como un umbral de corte en el voltaje del acumulador; con el fin de calcular la PDF del EOD que le resta al pack antes de su desconexión; mediante el uso de probabilidades totales como se muestra en la ecuación (2.24)
- El uso de estadísticos que describen de manera efectiva la PDF del riesgo asociado al instante en que el evento de corte ocurre. Estos estadísticos son los intervalos de confianza de un **95%** de confiabilidad, la varianza del EOD, el valor esperado del EOD en la predicción, entre otros.

El proceso de predicción de las N partículas finaliza cuando todas ellas alcanzan el SOC de corte programado durante la ventana o largo de predicción establecido, mientras exista una partícula sin cruzar el umbral de corte no se generará la distribución acumulada del SOC con un HZ definido en **0.01** o **1%** de ancho y por tanto, no se tendrá un valor esperado del SOC en el horizonte de predicción.

Como en el proceso de descarga el voltaje del acumulador siempre decae a medida que se utilice, debido a que se alimenta principalmente un motor que requiere potencia constante; entonces el supuesto de un consumo de corriente constante o promedio en el tiempo es falso, por lo cual se busca dar un enfoque con un perfil de uso constante y otro mediante un perfil de uso representado por una CM durante la etapa de pronóstico; con el fin de comparar el desempeño de ambos enfoques en términos de exactitud del EOD predicho y sacar conclusiones asociadas, puesto también que el perfil consta de una alta resistencia en pasar de un estado alto a bajo en el enfoque basado en CM, lo cual es evidenciado del historial de corriente durante la etapa de estimación del SOC. Otra de las simplificaciones realizadas comprende un estado x_1 como un parámetro constante durante toda la etapa de pronóstico y representando su último valor inferido en la etapa de estimación, sin embargo, la estimación basada en el FP sigue procesando paralelamente, en el cual se calcula la resistencia interna del acumulador. Además de ello, se propone utilizar una realización de CM para una realización del FP en predicción y así reducir el tiempo de procesamiento en gran parte por implementarlo en un entorno en línea donde el tiempo de ejecución es una de las principales métricas. Usamos una simplificación donde se llama una vez a Pronóstico donde se tienen igual número de realizaciones de CM e iteraciones del FP en pronóstico, pero además el *paso de predicción* en cada iteración es de **1[seg]** aprox., el cual se deja estático, ya que si se aumenta el código se complejiza mucho y la predicción se podría distorsionar.

En lo que respecta al módulo de pronóstico una vez conocido el perfil de uso futuro, se presentan 2 modos de propagar la población de partículas hasta el horizonte de predicción. Una forma es propagar el mismo número de partículas N utilizado en el módulo de estimación; mientras la otra forma compacta el número a **3** partículas representativas en el inicio de predicción mediante la siguiente metodología que se describe a continuación:

1. Búsqueda de las **3** posiciones (Para ambos estados x_1 y x_2) representativas definidas como el valor esperado de las N partículas ($N > 3$), el valor JITP de un **5%** y el valor JITP de un **95%**. Esto con el fin de mantener una noción de las colas de distribución y por tanto su dispersión.
2. Calcular la distancia media entre la partícula que representa el valor esperado y el JITP **5%**, análogamente calcular la distancia media entre la partícula que representa el valor esperado y el JITP **95%**, sin embargo sólo para el estado x_2 o SOC, debido a que x_1 o la resistencia interna del pack de baterías se considera constante durante el pronóstico y por tanto no requieren propagarse en el tiempo.
3. Asignar el peso de cada una de las N partículas normalizadas a una y sólo una de las **3** partículas representativas del SOC generadas mediante el criterio de distancia mínima. De esta forma tal peso se suma al peso de la partícula más cercana manteniendo un set de **3** partículas normalizado con pesos invariantes hasta el horizonte de predicción.

4. No regularizar las 3 partículas mediante distribuciones de Epanechnikov, debido a que su acotado número para representar la distribución del SOC no se ve degenerado en ningún caso y así se evita el empobrecimiento de las partículas durante la propagación de ellas.

Dicho esto, la importancia de la regularización y los kernels de Epanechnikov en este proceso son perceptibles, debido a que se altera la dispersión o varianza del EOD mediante núcleos o fuentes artificiales de incertidumbre para una mejor adaptación del modelo de predicción a pesos constantes principalmente.

3.2.4. DETERMINACIÓN DE POTENCIA MÁXIMA DISPONIBLE DE ESD

Con el propósito de monitorear la capacidad energética del pack de baterías y por ende, informar la máxima potencia que se puede extraer del pack de baterías para cada instante de tiempo, se busca estimar la máxima potencia, medida en *Watts*, que puede entregar el acumulador en tiempo real; para lo cual, se resuelve un problema de maximización bajo ciertas restricciones de corriente máxima y voltaje en bornes mínimo basado en las estimaciones del SOC en tiempo real y de esta manera obtener una primera aproximación del cálculo de la potencia máxima disponible.

Este hecho se puede modelar como un problema de optimización bajo restricciones basado en las estimaciones del SOC y su curva característica obtenida paralelamente al desarrollo del AEP. El problema de optimización se representa como sigue:

$$\begin{aligned} & \underset{V, I}{\text{Maximizar}} \quad P_D(k) = V(\widehat{\text{SOC}}(k), I(k)) \cdot I(k) & (3.14) \\ & \text{Sujeto a} \quad V(k) > V_{Min}, \quad I(k) < I_{Max} \quad \forall k \end{aligned}$$

En los instantes en que la corriente sea nula, la potencia disponible también lo será. Esto permite informar sobre la desconexión o anomalías presentes del acumulador al usuario que opera la E-bike mediante el HMI que actualiza esta información a una tasa determinada de tiempo.

En base a la ecuación (2.36) que relaciona el OCV con el SOC y la corriente de descarga vista en los bornes del acumulador, se tiene que la potencia disponible por unidad de tiempo se puede reescribir como:

$$P_D(k) = [\text{OCV}(x_2(k)) - I(k) \cdot x_1(k)] \cdot I(k) \quad (3.15)$$

Por lo tanto, el problema de optimización también se reformula, logrando así ser definido solamente con una variable a maximizar y separando el problema en 2 casos, los cuales corresponde a los SOC estimados sobre el umbral de corte y cuando este límite se alcanza, lo que implica que la potencia máxima queda definida por una constante en este último. La nueva formulación se expresa a continuación:

$$\begin{aligned}
\text{Maximizar } P_D &= [OCV(x_2(k)) - I(k) \cdot x_1(k)] \cdot I(k) & (3.16) \\
I &= \begin{cases} [OCV(x_2(k)) - I_{MAX} \cdot x_1(k)] \cdot I_{MAX} & \text{Si } x_2(k) > SOC_{CUTOFF} \\ [OCV(x_2(k)) - I_0 \cdot x_1(k)] \cdot I_0 & \text{Si } x_2(k) < SOC_{CUTOFF} \end{cases}
\end{aligned}$$

$$\text{Sujeto a } V(k) > V_{Min}, \quad I(k) < I_{Max} \quad \forall k$$

Donde I_0 corresponde a la corriente definida cuando se alcanza la cota V_{Min} , es decir,

$$[OCV(SOC_{CUTOFF}) - I_0 \cdot x_1] = V_{Min} \quad (3.17)$$

en el cual se denota el voltaje mínimo en bornes como el voltaje de corte programado en la PCM y x_1 como la resistencia interna de placa, lo que entrega una simplificación relevante ante situaciones donde pudiese existir una degradación de celdas significativa que genere un aumento en el valor de x_1 . En consecuencia, la corriente I_0 queda expresada como:

$$I_0 = [OCV(SOC_{CUTOFF}) - V_{CUTOFF}] / x_1 \quad (3.18)$$

El cálculo de esta potencia máxima permite la creación de una tabla de consulta o *Look-up Table* entre el SOC estimado y su potencia máxima disponible asociada, tal que se utilice en cualquier ruta mientras el pack de baterías no sufra una reconfiguración o peor aún, una anomalía importante que afecte su característica OCV-SOC. Sin embargo, esta estimación sólo se realiza a medida que el SOC es estimado y no cuando es predicho, por lo que no se busca predecir la potencia máxima en el futuro en este trabajo. Sumado a esto y para efectos en tiempo real, se considera una alarma de detección del **95%** del valor de potencia máxima estimada, con el fin de informar el uso de una potencia cercana al máximo disponible en ese momento. De esta forma, el operador puede verificar algún síntoma del sistema y realizar una toma de decisión pertinente, por ejemplo, cuando se requiere de un torque eléctrico elevado en el motor de la E-bike, posiblemente a causa de cargas mecánicas inesperadas que afecten la movilidad durante un trayecto.

CAPITULO 4

ANÁLISIS DE RESULTADOS Y VALIDACIÓN

En este capítulo se presentan los resultados de la simulación en entorno *Matlab* y posterior implementación en línea del AEP. Sumado a esto, se analizan para 2 rutas reales de la E-bike los diversos resultados obtenidos mediante medidas de desempeño previamente determinadas en 3.2.3 con el fin de probar, ajustar y validar con datos reales de ruta, según corresponda el caso, los parámetros críticos, condiciones iniciales, secuencias de procesamiento e incluso los mismos enfoques utilizados en los diferentes módulos dentro de la metodología desarrollada; más aún, se analizan diferentes escenarios que logran comprender de mejor manera la concordancia y variabilidad entre los parámetros de interés contenidos en el AEP, permitiendo finalmente concluir en base a los objetivos deseados y tomar en cuenta posibles modificaciones a futuro.

En el primer apartado, en la sección 4.1, se indican los resultados observados y su respectivo análisis de rendimiento para un marco *offline* del AEP, presentando los datos de validación para ello y el mejoramiento de cada módulo desarrollado. En el segundo y último apartado, en la sección 4.2, se señalan las características y condiciones necesarias de implementación del AEP en un marco *online*, seguido de sus correspondientes restricciones de funcionamiento u operación.

4.1. ANÁLISIS DE DESEMPEÑO EN PRUEBAS FUERA DE LÍNEA

Este análisis comprende la evaluación del AEP con respecto a las medidas de desempeño consideradas más adelante, tanto para el módulo de estimación como para el módulo de pronóstico, donde se presentan los resultados ajustados u optimizados mediante un análisis de sensibilidad de los parámetros críticos del AEP, conllevando a un mejoramiento evidente de su rendimiento general. La necesidad de corregir estos parámetros se ve influenciado por el comportamiento ineficiente que se exhibe con ciertas rutas de prueba como son la ruta 1, ruta 2 y ruta 3, sin embargo, debido a la pobre calidad de estos datos adquiridos en sensores sin calibración y distintos a los mencionados en la sección 2.6, es que se utilizan las rutas 4 y 5 para efectos de ajuste y validación del AEP, los cuales se describen a continuación.

4.1.1. SET DE DATOS UTILIZADOS FUERA DE LÍNEA

Para todo trabajo realizado, se utiliza el mismo sensor descrito en FIGURA 2.6.5, es decir, los datos para la estimación de los parámetros del modelo de descarga propuesto y la obtención de los datos de ruta 4 y 5 para la simulación *offline*, son generados bajo el mismo sistema de adquisición.

A continuación se dan a conocer los 2 set de datos utilizados durante el análisis de desempeño del AEP tanto para su módulo de estimación como para su módulo de pronóstico, incluyendo la caracterización del perfil de uso futuro y la estimación de la potencia máxima disponible en el acumulador. Estos datos corresponden a mediciones de voltaje y corriente en descarga

correspondientes a un pack de baterías como el descrito en FIGURA 2.6.2 constituido de celdas relativamente nuevas, pero operadas bajo distintos perfiles de consumo.

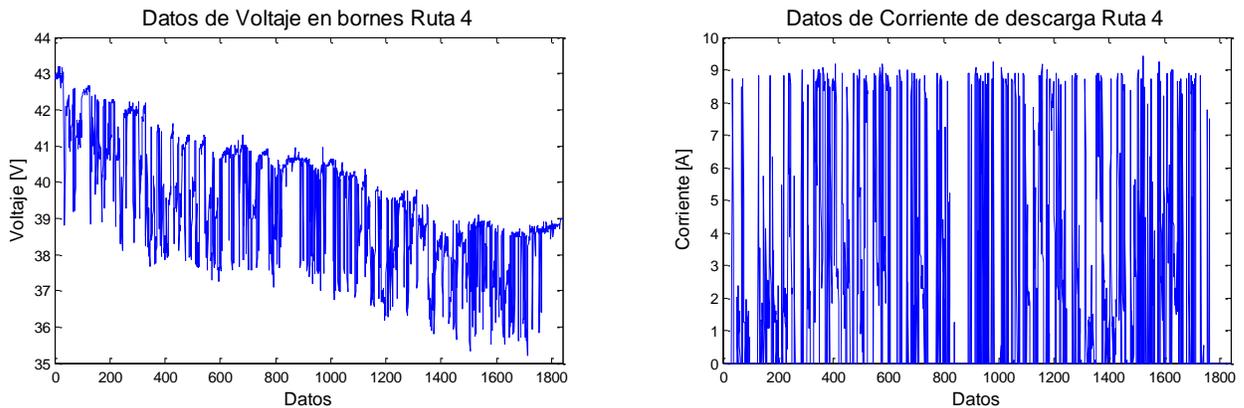


FIGURA 4.1.1: DATOS MEDIDOS DE RUTA 4 (VELOCIDAD VARIABLE)

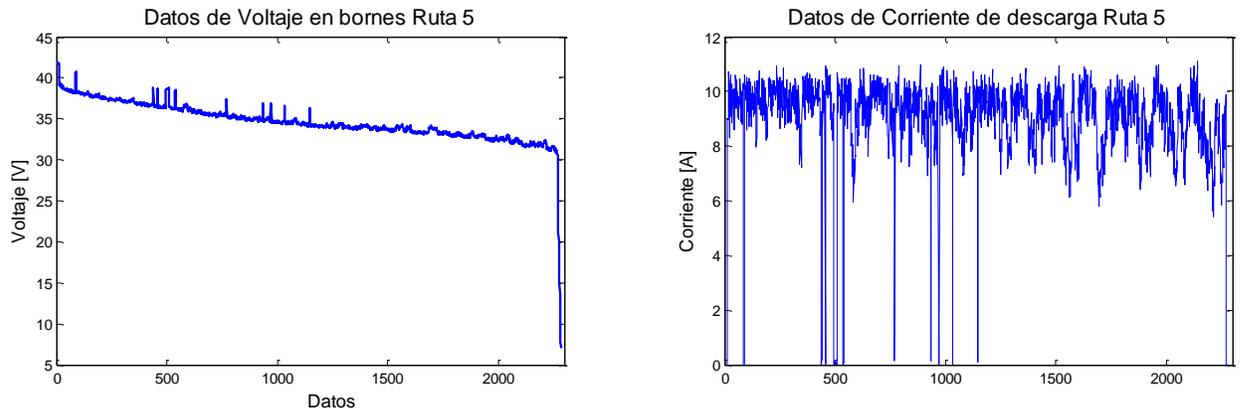


FIGURA 4.1.2: DATOS MEDIDOS DE RUTA 5 (VELOCIDAD CONSTANTE)

Ambos set de datos corresponden a rutas reales con tiempos de muestreo diferentes entre cada dato. Al tener variaciones en la velocidad de lectura/escritura de la memoria que almacena estas mediciones, se toman tiempos promedio para tal cantidad de datos. Por lo tanto el tiempo final aproximado de cada set de datos se obtiene del producto entre el número de datos y el tiempo de muestreo promedio.

La ruta 4 corresponde a una ruta con una gran presencia de aceleraciones y frenados en periodos cortos de tiempo compuesta de **1832** datos válidos con un tiempo de muestreo promedio $\overline{\Delta t_M} = 1.05[seg]$, lo que implica un tiempo total de descarga de aproximadamente **32** minutos hasta los **35[V]**, por esto mismo, se analiza para voltajes de corte mayores a **36[V]** presentes en la zona lineal de descarga, mientras la ruta 5 correspondiente a una ruta de alta velocidad y exigencia relativamente constante de corriente presenta **2285** datos válidos con $\overline{\Delta t_M} = 1.415[seg]$, lo que conlleva un tiempo total de descarga de **54** minutos hasta los **7[V]**, por el contrario de la ruta 4, se alcanza el codo final de descarga característico de las baterías de Ión-Litio. En consecuencia, se analiza sólo para voltajes de corte mayores a **30[V]** a causa de la caída abrupta de voltaje entre datos consecutivos. Con respecto a la operación y extracción del acumulador en ambas rutas se aprecian temperaturas internas de entre **20[°C]** y **32[°C]** para la ruta 4; y para la ruta 5 entre

29[°C] y **49[°C]**, lo cual refleja en este último caso una alta demanda energética por parte del sistema durante todo el trayecto.

Un aspecto a considerar dentro del análisis es la contribución de la ruta 9 representada a continuación:

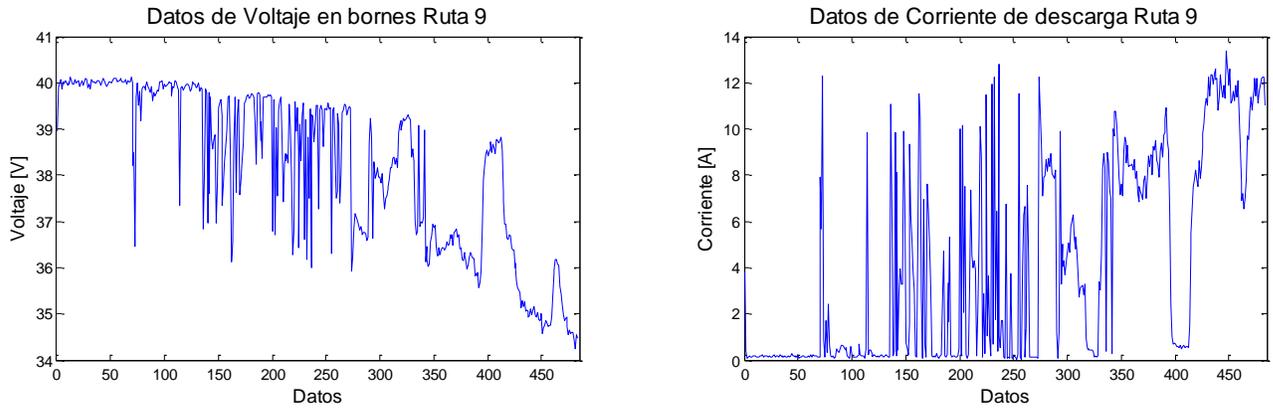


FIGURA 4.1.3: DATOS MEDIDOS DE RUTA 9 (TORQUE EXIGIDO EN PLANO INCLINADO)

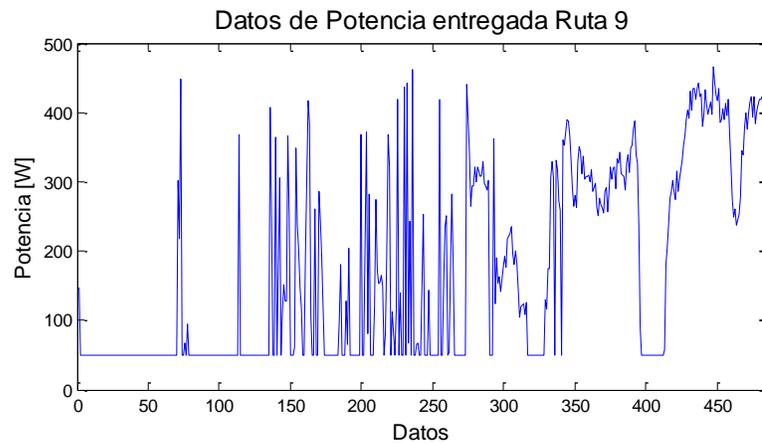


FIGURA 4.1.4: POTENCIA DC MEDIDA DE RUTA 9 (SOBREDEMANDA DE ENERGÍA)

La ruta 9 corresponde a un proceso de descarga de corto tiempo que genera un aporte en el análisis mediante un escenario interesante para la estimación de potencia máxima disponible, en particular, durante el final de su trayecto, en el que se presenta una demanda de energía que el pack de baterías no puede entregar, implicando un sobreconsumo inesperado. Por lo tanto, se calcula directamente de los datos de potencia medidos a una tasa de muestreo promedio de $\overline{\Delta t_M} = 1.77[seg]$ aproximados. Esta ruta presenta **483** datos válidos, lo que significa un tiempo aproximado de descarga de **14 minutos 15 segundos** hasta alcanzar su valor de corte de **34[V]** aproximados.

Aparte de analizar rutas con alta y baja variabilidad en sus velocidades, como también rutas con alta exigencia de potencia por múltiples causas, se pueden presentar casos de interés tales como datos con corriente en vacío, datos que se inicien sin carga completa o datos con descarga interrumpida por recarga del ESD. Los dos últimos casos son analizados más adelante, mientras las rutas con corriente en vacío comprenden mediciones de corriente muy bajas y cercanas a cero,

lo que conduce a estimaciones del SOC compensadas en su mayoría y valores de EOD muy grandes a causa de la baja demanda de potencia. Esto requiere un marco de pronóstico a largo plazo que garantice exactitud, en otras palabras, un perfil de uso futuro bien caracterizado.

4.1.2. **RESULTADOS Y OPTIMIZACIÓN OFFLINE DE AEP**

Antes de analizar los resultados obtenidos tras el ajuste u optimización de los parámetros del AEP, se detallan las medidas de desempeño utilizadas para efectos de análisis. Estas medidas se dividen entre ambos módulos del AEP, puesto que se desean analizar diferentes índices muy específicos que describen principalmente el comportamiento dinámico del FP. Para el caso del módulo de estimación se emplea el tiempo de convergencia del FP, el RMSE asociado al error de estimación del SOC y la tasa de remuestreos porcentual. Por otro lado, el módulo de pronóstico emplea el error de predicción o sesgo entre el valor esperado del EOD y el EOD *Ground Truth* calculado fuera de línea $EOD_{GT} - E\{EOD\}$, la varianza del EOD reflejada en los intervalos de confianza con un nivel de confianza de un **95%** y el índice JITP para un **5%** y un **50%**. El detalle de cada uno se presenta a continuación:

- La razón de remuestreo porcentual NR mide el porcentaje de remuestreos con respecto al total de iteraciones del FP durante la etapa de filtrado/estimación, es decir, las iteraciones donde el valor umbral de partículas supera el tamaño efectivo de muestras N_{eff} . Este índice contribuye al grado de degeneración del set de N partículas.
- El RMSE del error de estimación entre la curva SOC estimado y la curva referencial SOC *Ground Truth*, se calcula una vez se establece la convergencia de ambas curvas hasta la iteración final de la etapa de estimación, representando el sesgo de estimación para cierta ventana de tiempo. Este índice permite una apreciación del error de aprendizaje en las mismas unidades del SOC.
- El tiempo (en segundos) de convergencia o en el que la señal a estimar se estabiliza con un grado de tolerancia de un **5%** con respecto a la curva de referencia SOC *Ground Truth*, calculada *offline* mediante datos reales de ruta.
- El valor esperado del EOD corresponde a la principal métrica de desempeño en el AEP, también llamado tiempo de falla (TOF, por sus siglas en inglés) en un marco de riesgo al fin de descarga, la cual refleja la exactitud del tiempo de descarga remanente del pack de baterías hasta su SOC de corte, con respecto al EOD *Ground Truth* calculado por el AEP en base a los datos de ruta. Este índice se representa como sigue:

$$\widehat{EOD} = E\{EOD\} = E\{k \mid E\{x_2(k)\} = SOC_{cutoff}\} \quad (4.1)$$

Donde se exhibe que la probabilidad de falla, o de alcanzar el umbral de corte, antes del segundo k esperado para el EOD es de un 50%. Cabe mencionar que el valor esperado del EOD depende tanto del número de iteraciones del FP en pronóstico como del número de

realizaciones de la CM, por lo tanto, la exactitud del AEP se mide directamente con este índice.

- la varianza del EOD reflejada en los intervalos de confianza con un nivel de confianza de un **95%**, representa la medida de la precisión y dispersión del cálculo del EOD final o TOF, donde la falta de representatividad de las partículas en pronóstico y la caracterización del perfil de uso futuro son una de las principales causas de una mayor varianza.
- El $JITP_{5\%}$ y $JITP_{50\%}$ corresponde a una medida que incorpora el concepto de riesgo, el cual representa el segundo de la descarga en que la probabilidad de falla alcanza un umbral predefinido, en nuestro caso, de un **5%** y **50%**. El primer umbral verifica la cota menor del intervalo de confianza como se muestra en FIGURA 4.1.5, donde los **95%** de los instantes del EOD no han ocurrido, mientras el segundo umbral verifica la medida del valor esperado del EOD para efectos de analizar la variabilidad de los resultados obtenidos en diferentes escenarios. Además de ello, este índice contribuye al reajuste del número de partículas para pronóstico, con el fin de representar la incertidumbre del sistema que aumenta con el tiempo, en particular asociada a las colas de las distribuciones. Para cualquier umbral de probabilidad, el índice se expresa como sigue:

$$JITP_{\gamma\%} = \arg \min_{eod} \{ P(EOD \leq eod) \geq \gamma\% \} \quad (4.2)$$

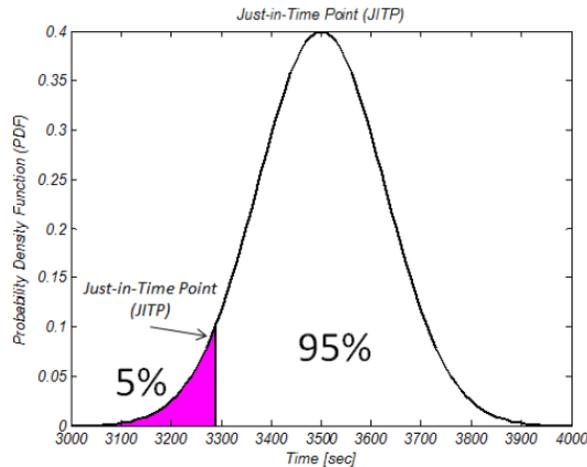


FIGURA 4.1.5: JITP DEL 5% DE UNA DISTRIBUCIÓN DE PROBABILIDAD DE FALLA [1]

Por su parte, los costos computacionales reflejados en los tiempos de lectura/escritura del AEP, su procesamiento, visualización en pantalla, recursos de memoria, entre otros; son analizados con detalle en [2]

En lo que respecta a los resultados de las pruebas y simulaciones fuera de línea del AEP, éstos se presentan en su última fase de ajustes paramétricos con respecto a las pruebas de sensibilidad mencionadas. De este modo se logra evaluar el desempeño de la solución pensando en su posterior implementación dentro de un dispositivo móvil. En primera instancia se analizan los resultados de la caracterización estadística del perfil de uso futuro para un instante inicial de

predicción predefinido, donde cada uno de estos instantes genera diferentes parámetros de la CM y por tanto de estados diferentes de consumo bajo y alto. En segunda instancia se analiza la metodología de predicción para un set de **3** partículas representativas de igual peso como una alternativa de bajo esfuerzo computacional para el módulo de pronóstico. Finalmente se analizan los resultados *offline* del AEP completo para las rutas 4 y 5, en conjunto a pruebas de desempeño enfocadas en la variabilidad de algunos parámetros de interés tales como los tiempos de inicio de predicción, número de realizaciones y método utilizado para predecir la corriente de descarga futura.

Los resultados obtenidos corresponden en primer lugar a la caracterización del perfil de uso futuro mediante una CM de primer orden y 2 estados de transición, donde se puede apreciar en un mismo plano la trayectoria asociada de la corriente de descarga histórica en la etapa de estimación y una realización de la CM en la etapa de pronóstico. Cada realización se asocia a la generación aleatoria de una trayectoria previamente descrita en la sección 3.2.2, determinada tanto por los valores de los estados “Alto” y “Bajo” de corriente en uso como de las probabilidades de transición entre ambos estados, los cuales fueron calculados para el tiempo inicial de predicción en base a la metodología explicada en 3.2.2. Debido a la independencia entre una o varias realizaciones de la CM y el inicio de predicción, se exhibe un único inicio de predicción para efectos de análisis, el cual está asociado a un valor establecido de **900[seg]** para una futura implementación en línea del AEP. En este caso, se aprecian 2 realizaciones, una para la ruta 4 como se muestra en FIGURA 4.1.6 y una para la ruta 5 mostrada en FIGURA 4.1.7, donde es de esperar que una nueva realización en cada CM indique un perfil de uso diferente en instantes futuros.

Como ya se hizo mención, cada ruta considera una fase de pronóstico iniciado a los **900[seg]** o **15** minutos con el fin de contribuir a un análisis mucho más efectivo en varios aspectos. Entre ellos, el tiempo que el FP demora en adaptar los estados con respecto a la curva referencial del SOC, obtener suficientes mediciones de corriente de descarga para su caracterización e incluir mediciones de corriente en la zona lineal de descarga del ESD para adquirir información relevante del comportamiento que debiese tener ambos estados del AEP durante esta zona, en la cual se encuentra el valor de corte programado.

La caracterización del perfil de uso en la ruta 4 y 5 comprende un ancho normalizado de **60[seg]** para cada intervalo dentro de los **15** minutos de estimación, el cual es suficientemente grande para agrupar en un mismo *cluster* varias mediciones a la vez y suficientemente pequeño para entregar una ponderación más real al momento de corregir la trayectoria de la CM mediante EWMA.

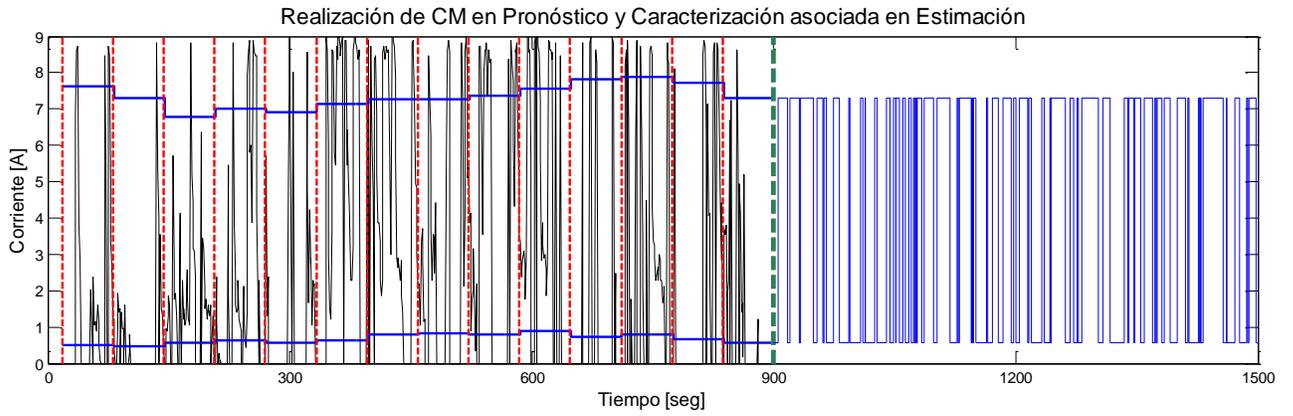


FIGURA 4.1.6: PERFIL DE USO FUTURO ASOCIADA A UNA CM EN RUTA 4

Los parámetros de la CM correspondientes a la matriz de probabilidades de transición y el vector de estados para la ruta 4 son los siguientes:

$$P(k_{Pred} = 900[s]) = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} = \begin{bmatrix} 0.8479 & 0.1521 \\ 0.1872 & 0.8128 \end{bmatrix} \quad (4.3)$$

$$S(k_{Pred} = 900[s]) = \begin{pmatrix} I_{Alto} \\ I_{Bajo} \end{pmatrix} = \begin{pmatrix} 7.3113[A] \\ 0.5686[A] \end{pmatrix} \quad (4.4)$$

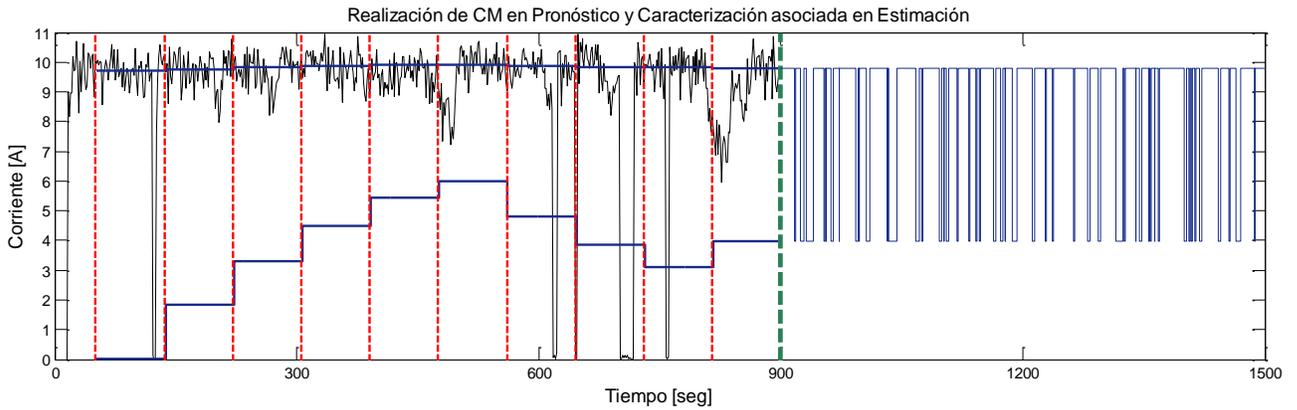


FIGURA 4.1.7: PERFIL DE USO FUTURO ASOCIADA A UNA CM EN RUTA 5

Por su lado, los parámetros de la CM correspondientes a la matriz de probabilidades de transición y el vector de estados para la ruta 5 son los siguientes:

$$P(k_{Pred} = 900[s]) = \begin{bmatrix} P_{11} & P_{12} \\ P_{21} & P_{22} \end{bmatrix} = \begin{bmatrix} 0.6126 & 0.3874 \\ 0.0908 & 0.9092 \end{bmatrix} \quad (4.5)$$

$$S(k_{Pred} = 900[s]) = \begin{pmatrix} I_{Alto} \\ I_{Bajo} \end{pmatrix} = \begin{pmatrix} 9.7758[A] \\ 3.9783[A] \end{pmatrix} \quad (4.6)$$

Una apreciación directa es la baja transitividad durante la etapa de filtrado entre un estado de consumo alto y bajo en la ruta 5, en comparación con la ruta 4, en consecuencia, las realizaciones en la ruta 5 a un horizonte de **10** minutos esperan mostrar un perfil de uso mayor en los próximos segundos, mientras la ruta 4 posee una mayor frecuencia a la transición de estados, lo cual permite simular un escenario con alta versatilidad, dinamismo en la velocidad de la E-bike y con un gran margen entre ambos estados, lo cual lo hace ideal para conocer el rendimiento de la metodología de caracterización estadística en la mayoría de las rutas donde existen demandas de corriente muy diferentes por motivos propios del terreno, por ejemplo planos inclinados o superficies muy rugosas, las cuales requieren un esfuerzo mayor de potencia.

En términos de desempeño, una observación directa ocurre mientras mayor sea el número de estados con los que se define la cadena, es de esperar que ésta represente de mejor forma el perfil de uso asociado. Sin embargo, la elección del máximo número de estados posibles no es arbitraria. Esto se debe a que a medida que se tiene un mayor número de “centroides”, la cantidad de observaciones o mediciones que pertenecen a él disminuye (para un mismo intervalo). Por consiguiente, al tener un menor número de observaciones correspondientes a cada estado de la cadena, la estimación de las probabilidades de transición entre dichos estados se ve afectado por la falta de representatividad del uso real de la batería, lo cual ocurre de modo similar al reducir el ancho de los intervalos de caracterización para un set de datos.

Cada enfoque de propagación de partículas en pronóstico presenta un nivel de desempeño distinto como se observará en los resultados obtenidos en las siguientes pruebas. Dicho esto, se presentan los resultados del AEP optimizado o con los parámetros reajustados, el impacto del cambio en el N° de realizaciones y la variabilidad de la PDF del EOD promedio ante 2 enfoques del perfil de uso futuro. Cabe destacar que los resultados de ambas rutas, tanto para el enfoque de **40** partículas como de **3** partículas, son generados en una misma iteración del módulo de estimación del AEP, por lo que ambos enfoques presentan idénticas condiciones iniciales en el inicio de predicción, idénticos parámetros de la CM y el mismo horizonte de predicción.

A continuación se presentan las gráficas obtenidas en un marco de simulación *offline* del AEP optimizado, considerando **20** realizaciones de la CM o equivalentemente del FP predictivo, **40** partículas y **900** segundos de filtrado como previamente se explicó en el análisis de la caracterización con un horizonte de predicción de **3600[seg]** para ambas rutas (desde el inicio del filtrado). Tales horizontes deben ser mayores a **2100[seg]** para la ruta 4 y **3300[seg]** para la ruta 5 con el objetivo de alcanzar el umbral de corte o falla definidos en **37[V]** y **32[V]** respectivamente. Esto implica un largo o ventana de predicción de por lo menos **20-40** minutos, el cual está sujeto a la cantidad de datos de ambas rutas. En lo que respecta a la corriente predicha, se mantiene un ancho entre intervalos de caracterización de **60[seg]** y un factor de olvido de **0.7** como se describe en la sección 3.2.2, los cuales corresponden a valores corregidos en dicha etapa.

Filtro de partículas: Voltaje de batería

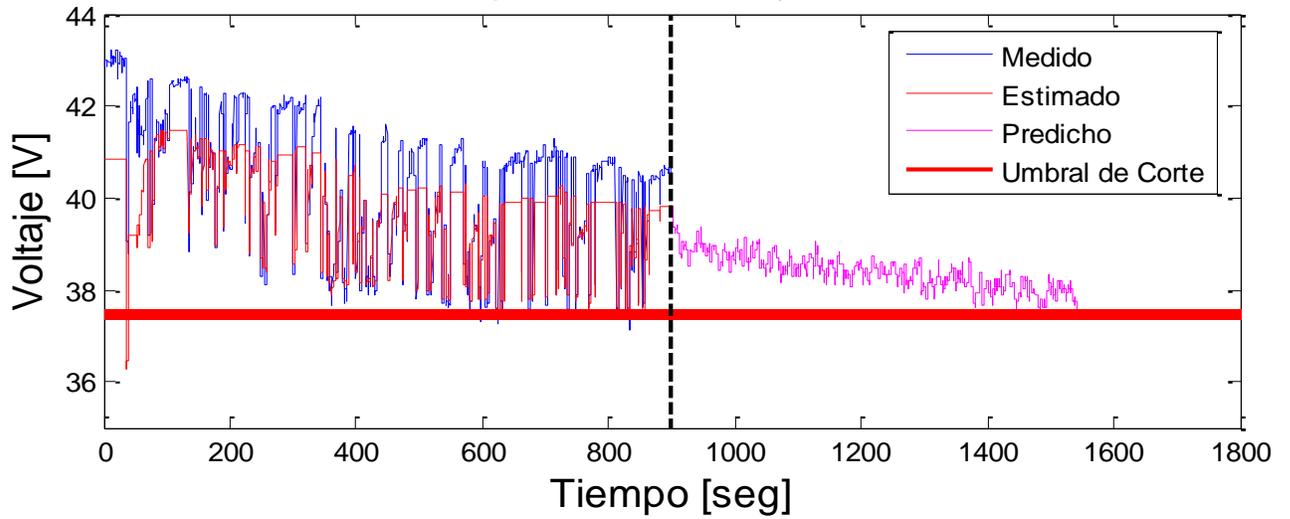


FIGURA 4.1.8: RESULTADO AEP - VOLTAJE DE BATERÍA EN RUTA 4

Filtro de partículas: SOC de batería

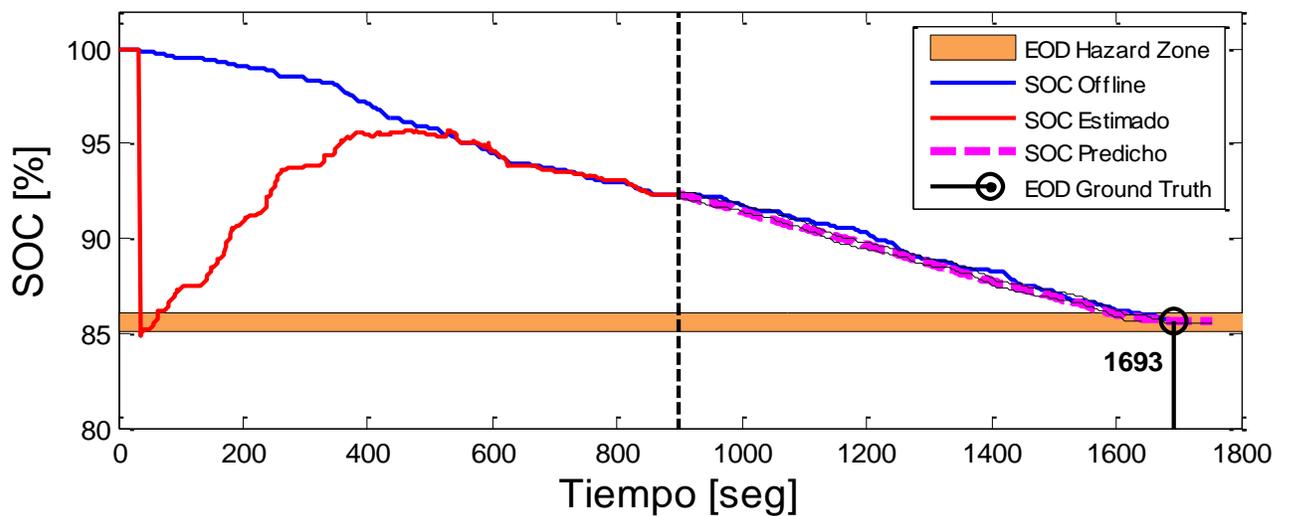


FIGURA 4.1.9: RESULTADO AEP - SOC DE BATERIA EN RUTA 4

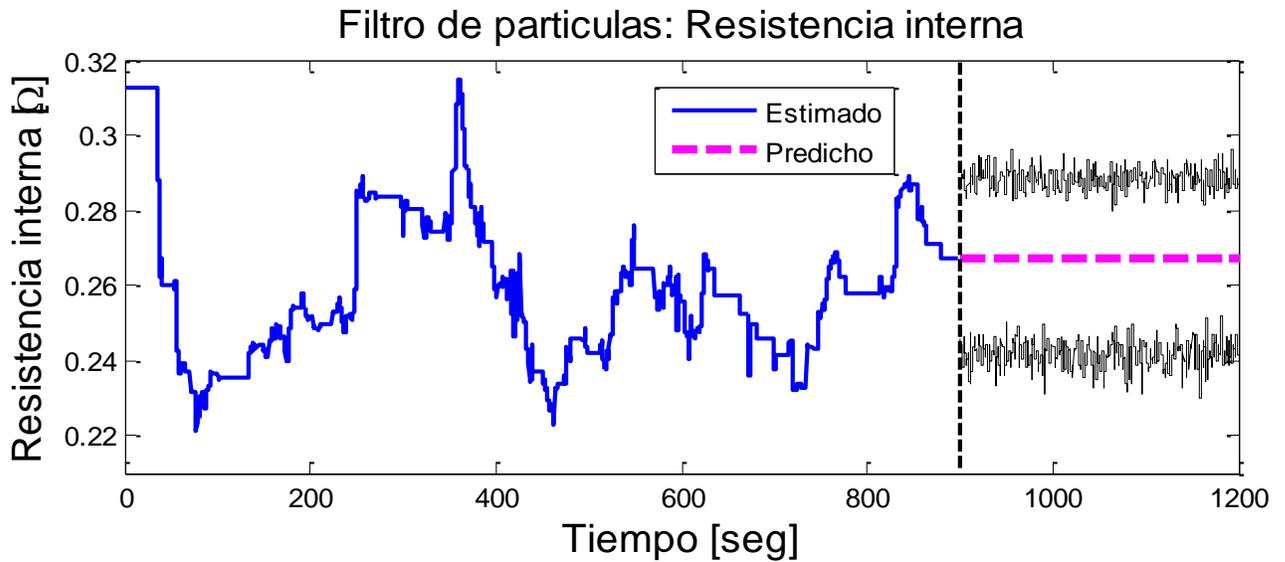


FIGURA 4.1.10: RESULTADO AEP - RESISTENCIA INTERNA DE BATERIA EN RUTA 4

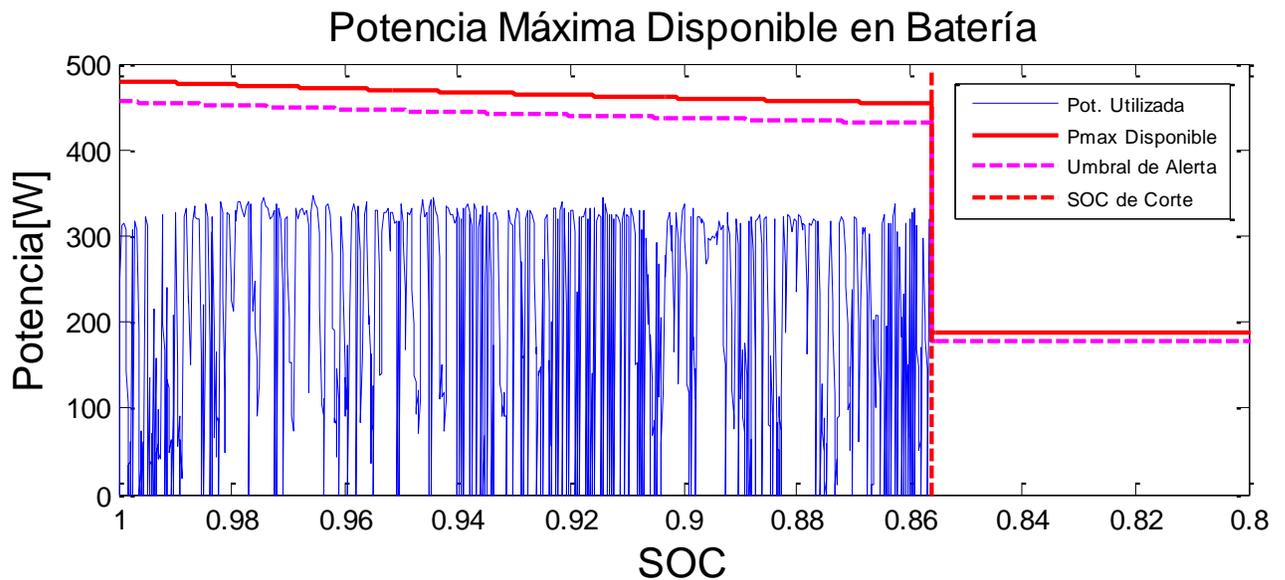


FIGURA 4.1.11: RESULTADO AEP - POTENCIA UTILIZADA DE LA BATERIA EN RUTA 4

Las distribuciones de probabilidad resultantes para la ruta 4 consideran un EOD *ground truth* de **1693[seg]**, donde la FIGURA 4.1.12 corresponde a la primera iteración en análisis mostrado en la Tabla 4.1.2, mientras en la misma iteración, la FIGURA 4.1.13 presenta la realización más cercana y lejana al EOD *Ground Truth* respectivamente dentro de las **20** realizaciones totales del FP predictivo. La realización más cercana corresponde a EOD = **1647[seg]**, es decir, con **46[seg]** de adelanto, por su parte la más lejana EOD = **1512[seg]** representa una diferencia de **181[seg]** o **3** minutos de adelanto, lo cual, se considera válido bajo el conocimiento de privilegiar una condición de falla o de descarga del ESD con una sub-estimación de un par de minutos.

Función Densidad de Probabilidad EOD Normalizado

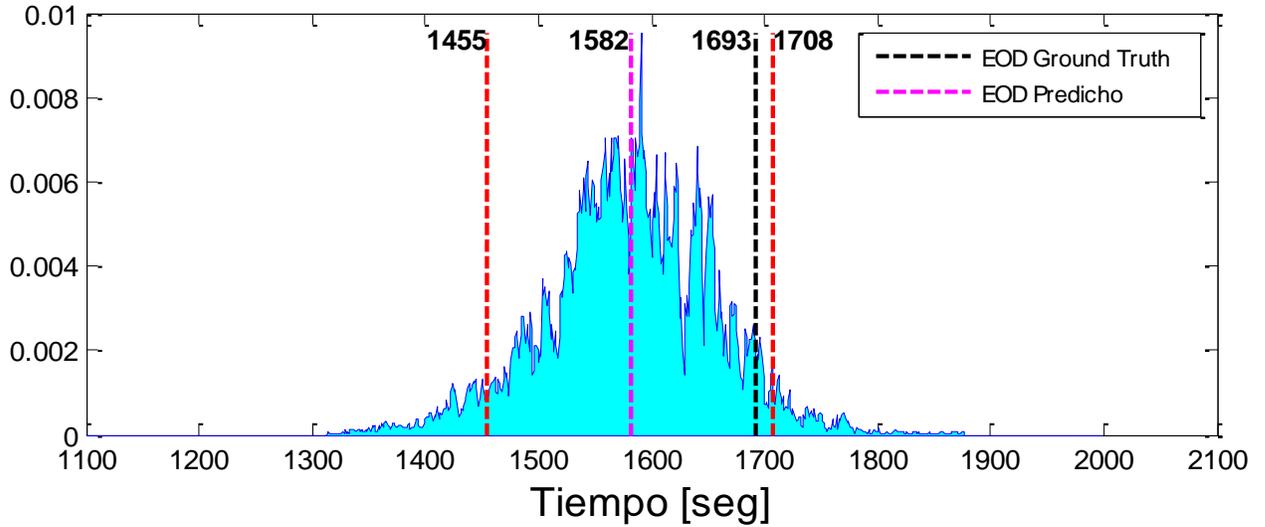
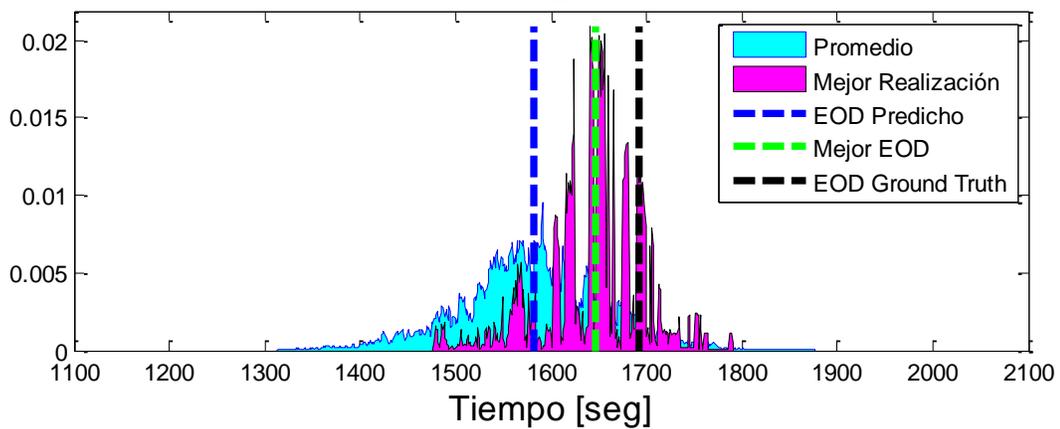


FIGURA 4.1.12: RESULTADO AEP - DISTRIBUCIÓN DE PROBABILIDAD FINAL DEL EOD EN RUTA 4

PDF End-Of-Discharge: Mejor realización



PDF End-Of-Discharge: Peor Realización

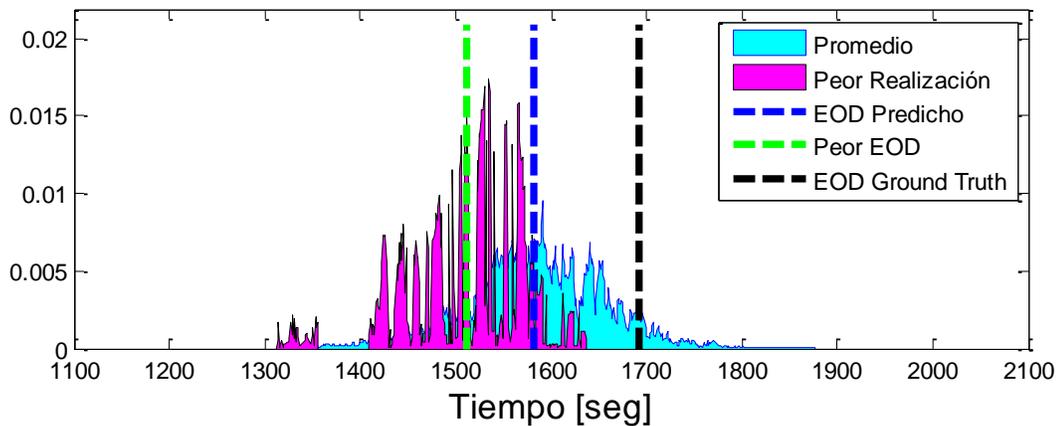


FIGURA 4.1.13: RESULTADO AEP - PEOR Y MEJOR REALIZACIÓN DEL EOD SEGÚN REFERENCIA EN RUTA 4

N° Iteración	Tiempo de estabilización t_s [seg]	RMSE de Estimación SOC [%]	Tasa de remuestreos [%]	$ Z_{IN}(t_{Pred}) [\Omega]$
1	526	0.1677	11.9	0.2484
2	592	0.1247	11.74	0.2358
3	596	0.2712	11.74	0.2370
4	540	0.2662	11.9	0.2431
5	527	0.2591	12.5	0.2466

TABLA 4.1.1: DESEMPEÑO FINAL MODULO DE ESTIMACIÓN EN RUTA 4

40 Partículas					
N° Iteración	$E\{EOD\}$ [seg]	Intervalo de Confianza 95% [seg]	$EOD_{GT} - E\{EOD\}$ [seg]	JITP 5%	JITP 50%
1	1582	[1455 ; 1708]	111	1449	1581
2	1632	[1537 ; 1726]	61	1549	1633
3	1617	[1504 ; 1730]	76	1519	1622
4	1667	[1548 ; 1787]	26	1576	1659
5	1615	[1456 ; 1773]	78	1491	1620

TABLA 4.1.2: DESEMPEÑO FINAL MODULO DE PRONOSTICO EN RUTA 4 CON 40 PARTICULAS

3 Partículas					
N° Iteración	$E\{EOD\}$ [seg]	Intervalo de Confianza 95% [seg]	$EOD_{GT} - E\{EOD\}$ [seg]	JITP 5%	JITP 50%
1	1696	[1589 ; 1803]	-3	1603	1693
2	1674	[1558 ; 1789]	19	1568	1661
3	1746	[1653 ; 1838]	-53	1668	1741
4	1676	[1550 ; 1813]	17	1596	1659
5	1583	[1461 ; 1704]	110	1471	1573

TABLA 4.1.3: DESEMPEÑO FINAL MODULO DE PRONOSTICO EN RUTA 4 CON 3 PARTICULAS

Un valor positivo de la diferencia $EOD_{GT} - E\{EOD\}$ indica una sub-estimación del módulo de pronóstico, lo cual es deseable siempre y cuando la diferencia en segundos sea lo más pequeña posible

En cuanto al error de voltaje observado, el rango obtenido es **[0.7745; 0.8624] [V]** con respecto a las pruebas previas con los parámetros reajustados del AEP.

PDF EOD Normalizado: 2 Enfoques Pronóstico

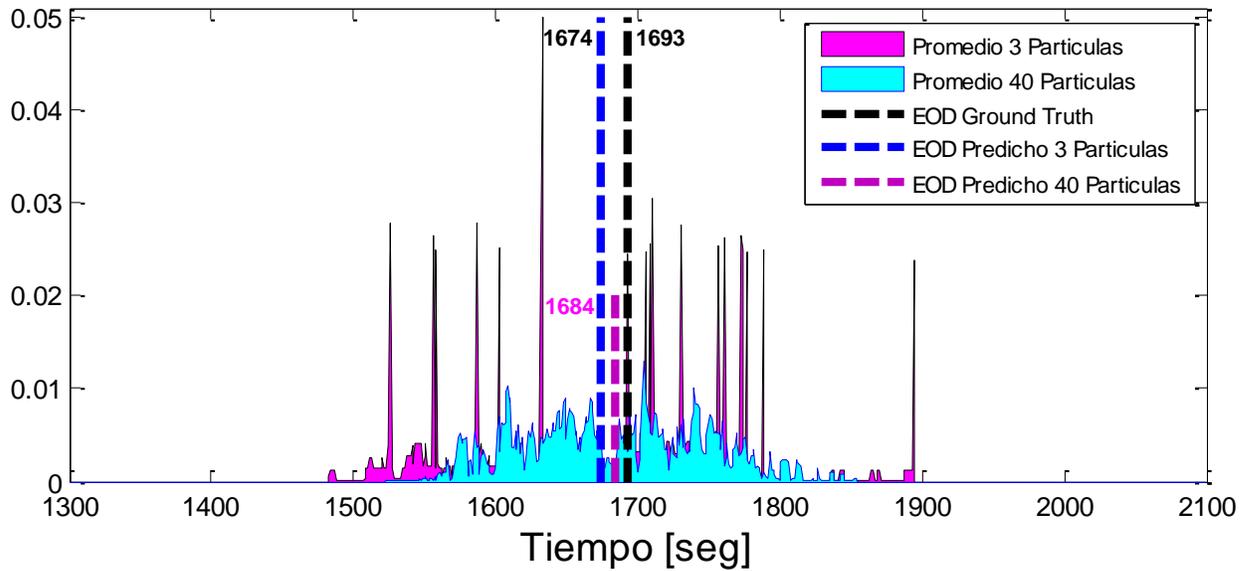


FIGURA 4.1.14: RESULTADO AEP - PDF EOD FINAL PARA 2 ENFOQUES DE PRONOSTICO EN RUTA 4

Para el caso de la ruta 5, el análisis de resultados comprende un nivel de aprendizaje de los estados del sistema mucho más rápido en términos de convergencia que en el caso de la ruta 4, principalmente debido a la naturaleza de las mediciones y sus ruidos asociados.

Filtro de partículas: Voltaje de batería

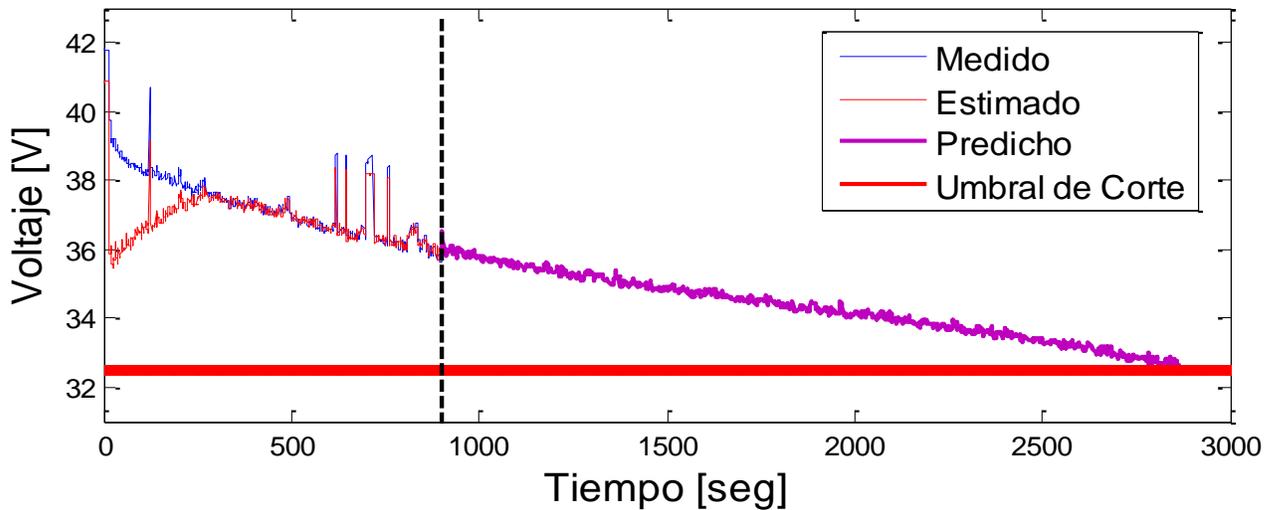


FIGURA 4.1.15: RESULTADO AEP - VOLTAJE DE BATERÍA EN RUTA 5

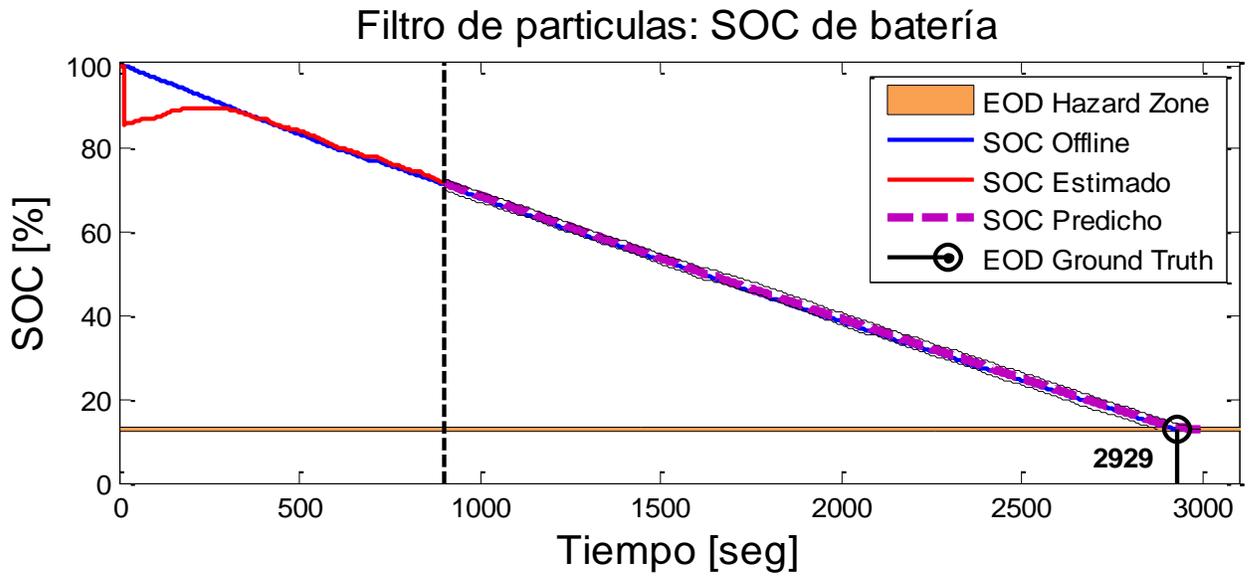


FIGURA 4.1.16: RESULTADO AEP - SOC DE BATERIA EN RUTA 5

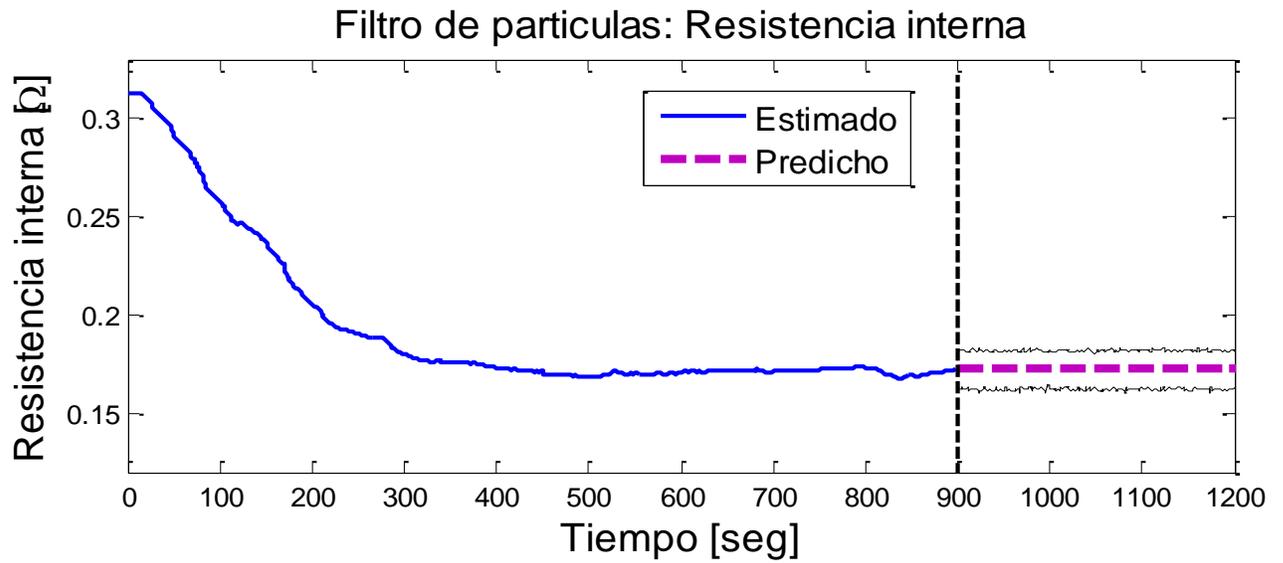


FIGURA 4.1.17: RESULTADO AEP - RESISTENCIA INTERNA DE BATERÍA EN RUTA 5

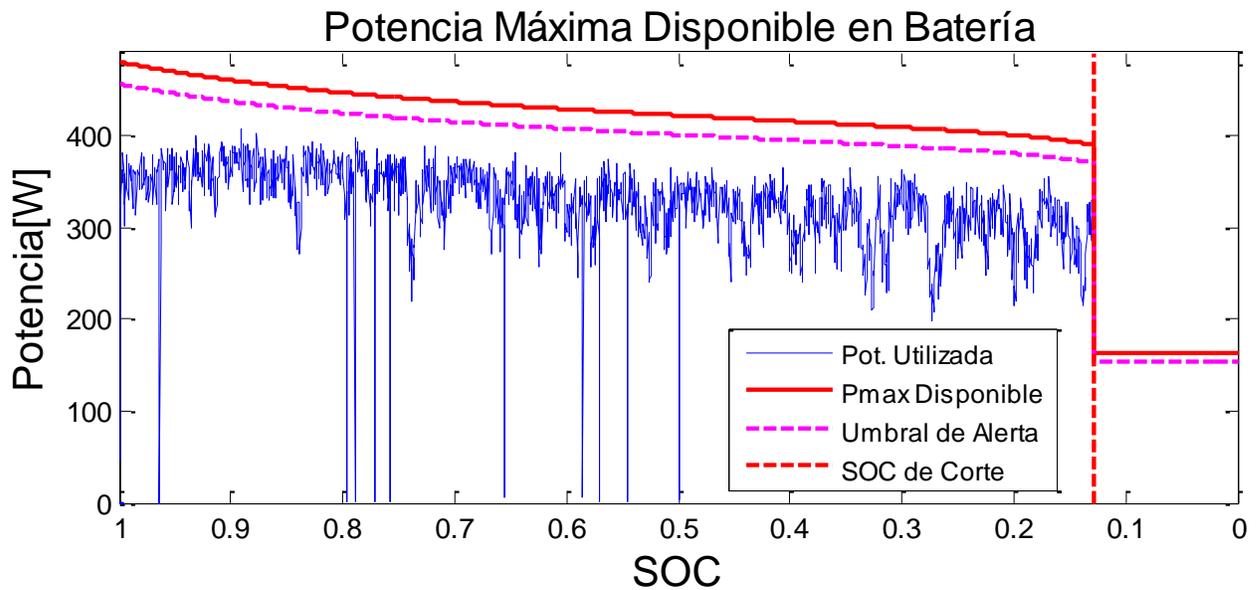


FIGURA 4.1.18: RESULTADO AEP - POTENCIA UTILIZADA DE LA BATERIA EN RUTA 5

Las distribuciones de probabilidad resultantes para la ruta 5, al igual que para la ruta 4, consideran un EOD *Ground Truth* de **2929[seg]**, donde la FIGURA 4.1.19FIGURA 4.1.12 corresponde a la primera iteración bajo análisis mostrado en la Tabla 4.1.5, mientras en la misma iteración, la FIGURA 4.1.20 presenta la realización más cercana y lejana al EOD *Ground Truth* respectivamente dentro de las 20 realizaciones totales del FP predictivo. La realización más cercana corresponde a EOD = **2928[seg]**, es decir, sólo **1[seg]** de adelanto, por su parte la más lejana EOD = **2992[seg]** representa una diferencia de **63[seg]** o **1 minuto** de retraso, lo cual, se considera bajo para la gama de pruebas realizadas, sin embargo, es un resultado indeseable al ser un retraso o sobre-estimación del EOD. Más aún si se obtiene un promedio final de realizaciones con el valor EOD sobre-estimado, lo que conllevaría a un corte sin previo aviso del pack de baterías.

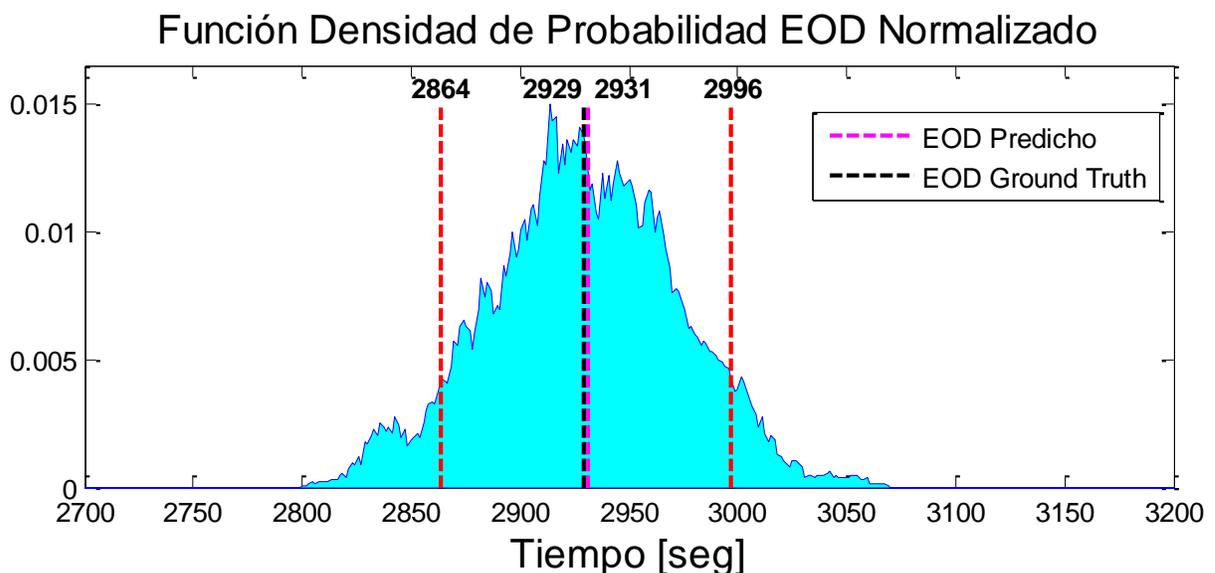


FIGURA 4.1.19: RESULTADO AEP - DISTRIBUCIÓN DE PROBABILIDAD FINAL DEL EOD EN RUTA 5

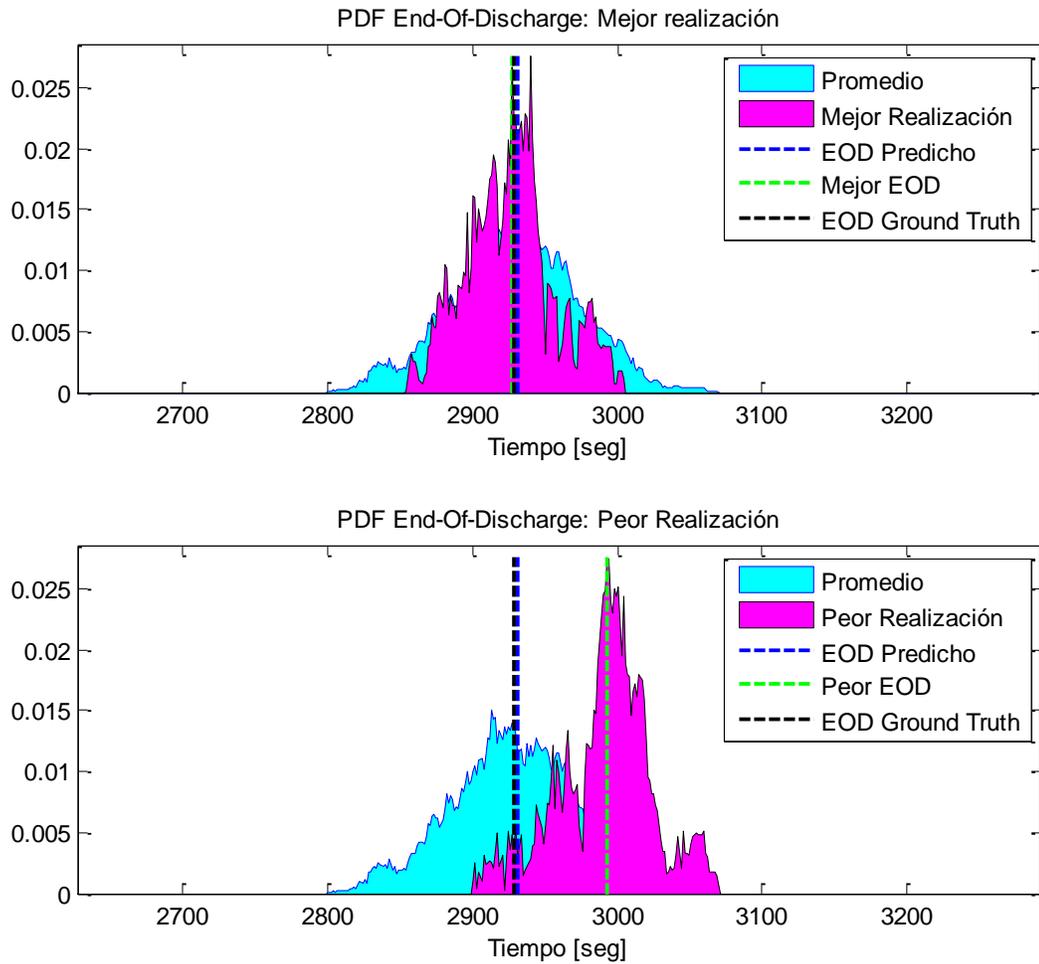


FIGURA 4.1.20: RESULTADO AEP - PEOR Y MEJOR REALIZACIÓN DEL EOD SEGÚN REFERENCIA EN RUTA 5

N° Iteración	Tiempo de estabilización t_s [seg]	RMSE de Estimación SOC [%]	Tasa de remuestreos [%]	$ Z_{IN}(t_{Pred}) $ [Ω]
1	390	0.2455	15.62	0.1860
2	406	0.2322	14.09	0.1664
3	483	0.5990	14.84	0.1666
4	408	0.3030	13.35	0.1712
5	401	0.5195	14.66	0.1667

TABLA 4.1.4: DESEMPEÑO FINAL MODULO DE ESTIMACIÓN EN RUTA 5

40 Partículas					
N° Iteración	$E\{EOD\}$ [seg]	Intervalo de Confianza 95% [seg]	$EOD_{GT} - E\{EOD\}$ [seg]	JITP 5%	JITP 50%
1	2931	[2864 ; 2996]	-2	2864	2933
2	2917	[2820 ; 3015]	12	2835	2915
3	2927	[2840 ; 3015]	2	2852	2928
4	2953	[2864 ; 3042]	-24	2875	2954
5	2916	[2831 ; 3001]	13	2835	2919

TABLA 4.1.5: DESEMPEÑO FINAL MODULO DE PRONÓSTICO EN RUTA 5 CON 40 PARTICULAS

3 Partículas					
N° Iteración	$E\{EOD\}$ [seg]	Intervalo de Confianza 95% [seg]	$EOD_{GT} - E\{EOD\}$ [seg]	JITP 5%	JITP 50%
1	2933	[2874 ; 2993]	-4	2882	2933
2	2920	[2861 ; 2980]	9	2866	2918
3	2914	[2858 ; 2969]	15	2872	2914
4	2909	[2860 ; 2959]	20	2866	2904
5	2916	[2858 ; 2974]	13	2866	2917

TABLA 4.1.6: DESEMPEÑO FINAL MODULO DE PRONÓSTICO EN RUTA 5 CON 3 PARTICULAS

En cuanto al error de voltaje observado, el rango obtenido es **[0.1819; 0.2127] [V]** con respecto a las pruebas previas con los parámetros reajustados del AEP.

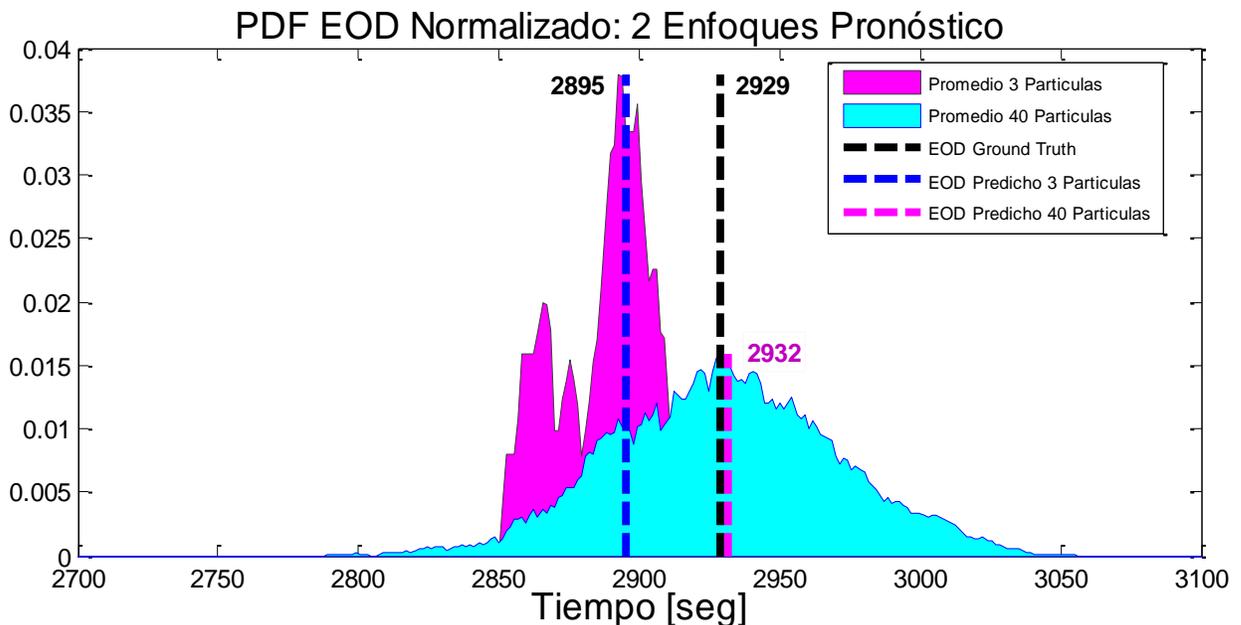


FIGURA 4.1.21: RESULTADO AEP - PDF EOD FINAL PARA 2 ENFOQUES DE PRONOSTICO EN RUTA 5

Analizando en primer lugar el proceso de filtrado, cabe destacar que el porcentaje de remuestreos toma mayor participación en los primeros **100** segundos de ejecución del módulo de estimación o

filtrado, a causa de la degeneración de las partículas durante su proceso de adaptabilidad a la referencia *Ground Truth* implementada.

Con el foco en el rendimiento del FP en la fase de estimación, se tiene que la convergencia del SOC estimado tarda entre **8-9** minutos con un voltaje observado que oscila a **2[V]** promedio en algunos instantes de tiempo para el caso de la ruta 4, por su lado, la ruta 5 muestra una convergencia que tarda entre **4-5** minutos con un voltaje observado que oscila a menos de **0.3[V]** promedio. Se puede deducir de los resultados que mientras mayor sea el ruido asociado a la evolución de la resistencia interna, el SOC produce como consecuencia una pendiente mucho más inclinada subestimando el EOD hasta su valor de corte, independiente del perfil de uso futuro que se obtenga en la CM.

Sobre los **32[V]** de corte la ruta 5 experimenta formas de PDF promedio multimodales directamente observables, lo que puede deberse a la mayor variabilidad durante el segmento final de la zona lineal del proceso de descarga, lo que permite realizaciones del FP en pronóstico más dispersos entre las mismas. También ocurre este fenómeno al obtener perfiles de uso futuro mediante un número pequeño de realizaciones, menor a 5 principalmente.

Una observación interesante consiste en identificar una degradación existente en el pack de baterías apreciando las curvas de descarga del SOC como se muestra en FIGURA 4.1.16. Tal observación comprende la diferencia entre el valor SOC estimado y el SOC de referencia utilizado para cada instante de tiempo. En términos de energía extraída del pack, esto es:

$$\left| \widehat{SOC}(k) - \left(1 - \frac{\sum_1^k V_{MEDIDO}(1:k) \cdot I_{MEDIDO}(1:k) \cdot \Delta k}{E_{Crítica}} \right) \right| \gg 0, \quad \forall k \quad (4.7)$$

El término $1 - \sum_1^k V_{MEDIDO} \cdot I_{MEDIDO} \cdot \Delta k / E_{Crítica}$ corresponde al $SOC_{Ground Truth}(k)$ como se expresa en (3.7) o a la energía porcentual disponible en el pack de baterías hasta el instante k-ésimo de descarga. La ecuación (4.7) establece que si la diferencia entre estas 2 magnitudes es muy grande, en comparación al rendimiento normal de estimación del SOC, entonces existe degradación en el sistema. En este caso, el sesgo generado en la estimación a causa del mismo desempeño del FP debe ser considerado para determinar degradaciones con un alto grado de exactitud y de este modo excluir los efectos provocados por una baja adaptabilidad de los estados por parte del FP. En relación a ello, durante el reajuste de parámetros del AEP, una de las dificultades principales era redefinir las condiciones iniciales de los ruidos asociados en el modelo estocástico con el fin de corregir el sesgo de estimación que se mantenía en el tiempo, esencialmente a causa de la baja rapidez de convergencia del FP, en consecuencia, tiempos de EOD muy sub-estimados.

En un marco en línea, si extraes cierta cantidad de energía de la batería o ESD y el SOC estimado indica que utilice más, luego la batería posiblemente se degradó como una forma indirecta de saber si una o más celdas están degradadas siempre y cuando el FP y en general el AEP presenta un funcionamiento adecuado. Esto se visualiza en el voltaje observado donde en un mismo instante la caída es mayor en uno por la impedancia interna (asumiendo un perfil de consumo similar). Si la batería parte cargada 100% *Full-Charge* y no ha degradado alguna celda, entonces el SOC *Ground Truth* puede aproximarse mediante la energía porcentual decreciente debido a la

extracción descrita por las mediciones (en etapa de pronóstico sólo es válido en simulación offline), si no, no se conoce el *Ground Truth* para comparar el desempeño. Por su parte, el aumento considerable de la impedancia interna es un efecto directo de la degradación de celdas. Lo ideal es cada cierto tiempo volver a realizar prueba de descarga completa y definir un $E_{Crítica}$ reajustado, debido a que la ciclicidad y el SOH no son considerados en cada iteración. Sumado a ello, si hay degradación de una o más celdas existirá una curva con un decrecimiento más pronunciado, incluso abrupto para un voltaje en bornes idéntico, esto se refleja con un *gap* sostenido o creciente en el tiempo entre la curva referencial de SOC y el SOC estimado con la llegada de una observación, es decir, la pérdida de su capacidad real.

Si el filtro o más generalmente el AEP funciona bien o adapta los parámetros del modelo según un buen aprendizaje, luego uno se daría cuenta de que la curva de estimación del estado decrece más rápido, entonces queda un menor tiempo de descarga y el EOD se subestima. En relación a ello, una mayor precisión implica adaptar los estados del pronóstico con un mayor número de partículas propagadas en el tiempo. Por ejemplo, el enfoque para 40 partículas como valor optimizado, al tener menos partículas, genera una mala representación de la incertidumbre en la PDF EOD promedio final, mientras un número mayor es irrelevante para conseguir una mayor exactitud y/o precisión lo cual agrega esfuerzo computacional. Por esta inquietud, se expone un marco de pronóstico con 3 partículas representativas en la predicción del SOC, para lo cual se obtienen resultados similares, pero con mayor varianza del EOD final.

Con respecto a las realización de la CM para la corriente predicha, a medida que se usen menos realizaciones de la CM o predicción basado en FP en esta etapa para generar la PDF del EOD, tal distribución no es promediada suficientemente apreciando una forma de distribución multimodal más notoria, debido a la menor cantidad de predicciones realizadas como se muestra en cada una de las gráficas resultantes para ambas rutas. Sin embargo, a medida que el valor de corte es mayor, por ende mayor probabilidad de pertenecer a la zona lineal del proceso de descarga, entonces se aprecia una PDF del EOD multimodal de igual forma, en particular bimodal por poseer realizaciones en esos instantes de mayor diversidad.

Un escenario interesante consiste en el comportamiento del pack de baterías de la ruta 9 cuando su SOC alcanza el 90% en descarga. En ese instante se observa un incremento atípico de la potencia máxima disponible para extraer. Esta variable es de suma importancia, debido a que existen situaciones donde la impedancia interna del pack de baterías aumenta en conjunto con el decrecimiento del voltaje, a medida que el proceso de descarga avanza. La suma de ambos efectos resultan en que para una exigencia específica de potencia, a rangos de voltaje limitados, la corriente de descarga aumenta desencadenando una caída de tensión en bornes mayor a la que acepta el limitador de voltaje determinado por el PCM del pack. Por lo tanto, existen casos en que, a pesar de tener energía disponible, es decir, con un SOC positivo mayor a SOC_{CUTOFF} , la energía no puede extraerse a la potencia requerida y por ende la potencia disponible presenta una cota máxima que decrece durante la descarga.

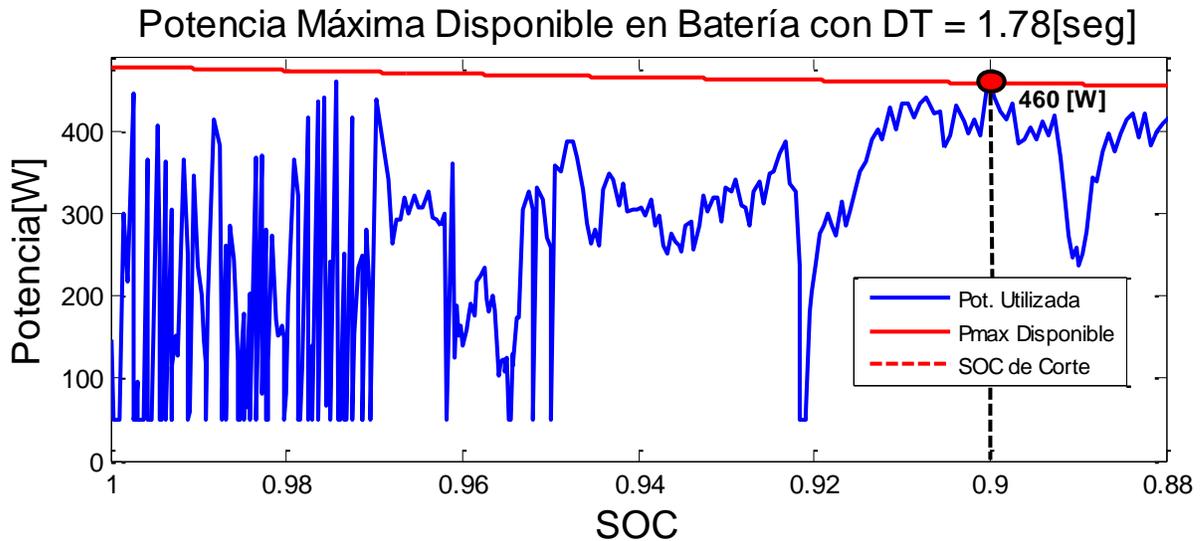


FIGURA 4.1.22: RESULTADO AEP - POTENCIA MÁXIMA DISPONIBLE ESTIMADA EN RUTA 9

Se obtuvo un $I_0 = 4.97[A]$ en la estimación de la potencia máxima disponible en la ruta 9 cuando ocurre el evento crítico o umbral de corte en nuestro caso.

Una vez extraído un **10%** del SOC en el proceso de descarga de la ruta 9 desde su máxima carga, se apreció una pendiente inclinada en la trayectoria de la E-bike según la información de altura registrada, sin embargo se concluye que la demanda de energía hacia el motor correspondió al roce mecánico entre la superficie de la rueda y el terreno inclinado, lo cual exigió mayor tracción, en otras palabras, un torque eléctrico que sobrepasara el torque resistente presente en la rueda de la E-bike en ese instante de tiempo. Por lo tanto, no se debe a una degradación parcial o absoluta de celdas de Ión-Litio.

El no conocimiento fenomenológico del proceso de descarga, tal como las fuerzas de roce involucradas en la ruta 9 por tramos inclinados que requieren mayor tracción, son una fuente de incertidumbre tratada como ruido en el modelo de estados para las mediciones de voltaje y corriente, sumado a ello, esta anomalía para el proceso de descarga es detectado mediante la potencia máxima disponible estimada.

A continuación se analiza el desempeño con una ventana de pronóstico y una ventana de filtrado variable mediante el aumento del inicio de predicción y con un horizonte de predicción siempre constante. Para este caso se estudia el comportamiento del AEP para la Ruta 5 con el objetivo de presentar una mayor apreciación gráfica, sin embargo, para la Ruta 4 y otras rutas válidas, el resultado es análogo con respecto a los parámetros que se analizarán. La prueba en que se analiza la evolución del AEP al retrasar el inicio de predicción (desde **5** hasta **45** minutos) se realizó a un paso de **10** segundos entre cada inicio evitando el esfuerzo computacional que esta prueba conllevaba, sin embargo, es un paso suficiente para observar el comportamiento del AEP en cualquiera de los enfoques considerados.

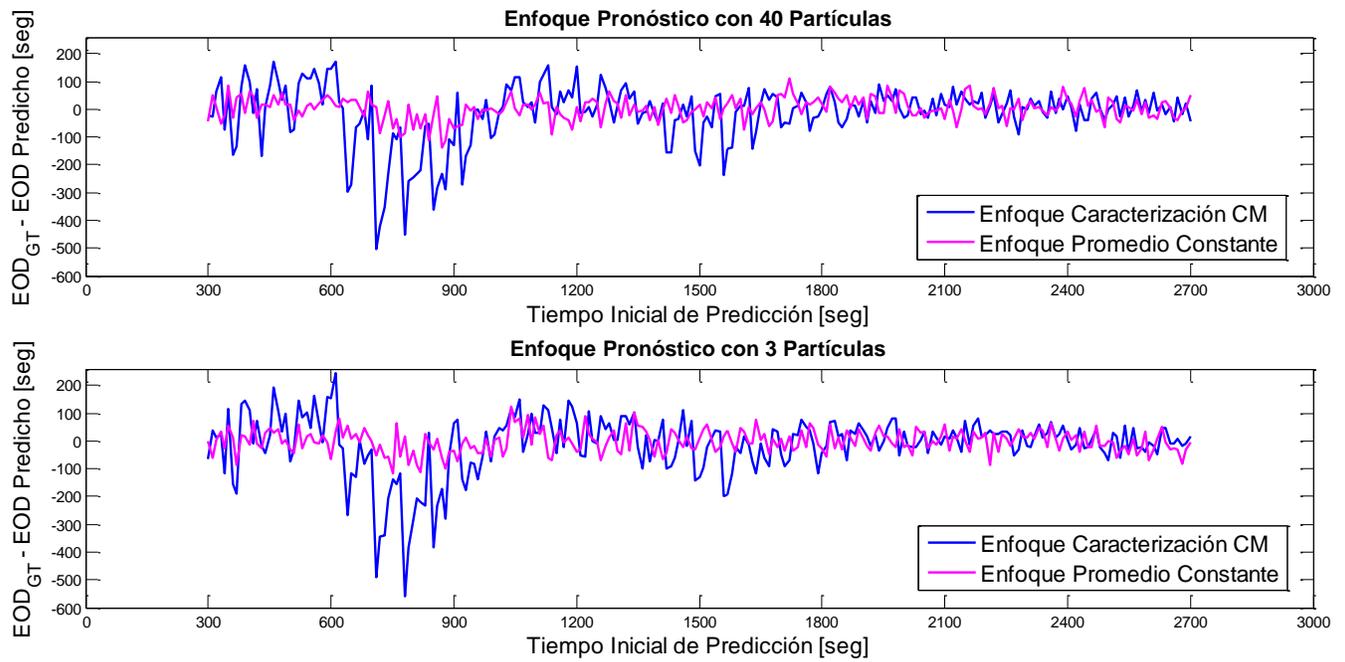


FIGURA 4.1.23: EVOLUCIÓN DEL ERROR DE PREDICCIÓN EOD EN DIFERENTES INICIOS DE PREDICCIÓN

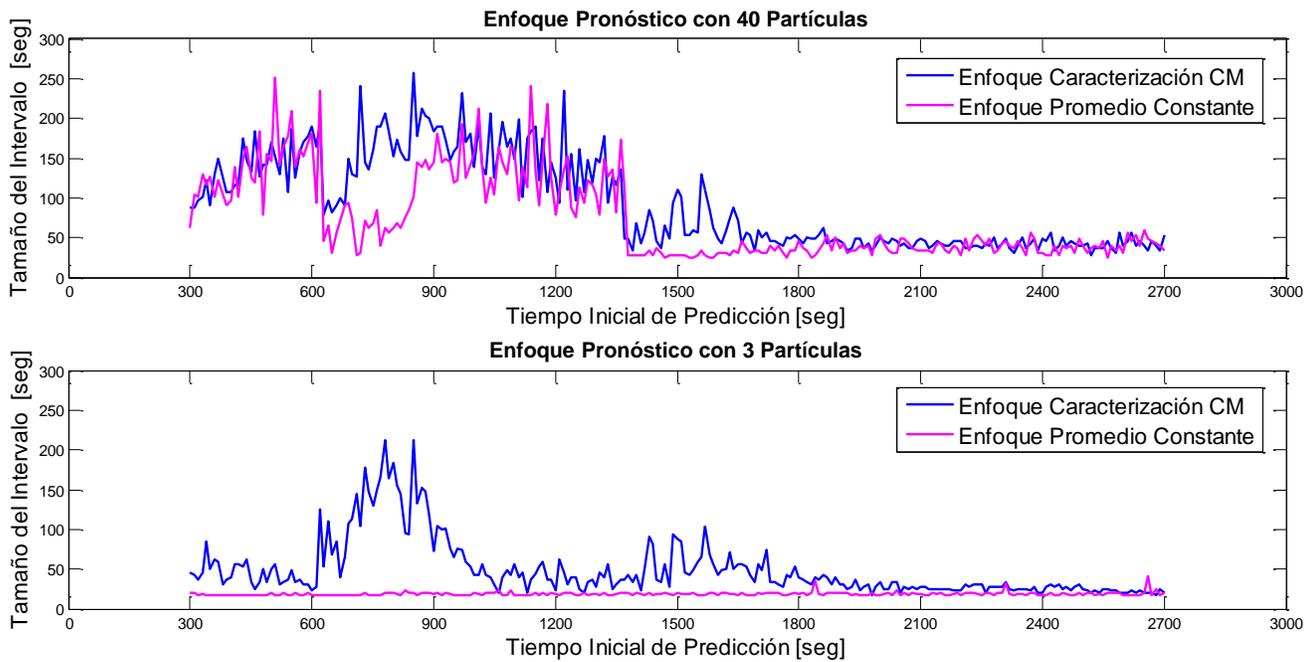


FIGURA 4.1.24: EVOLUCIÓN DEL INTERVALO DE CONFIANZA EN DIFERENTES INICIOS DE PREDICCIÓN

El enfoque de propagar **3** partículas representativas genera un relevante costo computacional menor, pero a su vez genera una dispersión o pérdida de precisión importante (más del **50%** de aumento en la varianza) por efecto de una incertidumbre no tan bien caracterizada como se desea.

Al usar un perfil constante promedio al sólo ser una realización, la PDF del EOD posee una forma menos simétrica que en el caso de las realizaciones promediadas en CM, sin embargo, un perfil constante tiene la desventaja de sobre-estimar o sub-estimar exageradamente el tiempo remanente de corte o EOD si el operario de la E-bike decide cambiar bruscamente el perfil de uso en base a la información entregada en el último pronóstico. Sin embargo, se tiene la ventaja de ver acotada la diferencia entre el EOD real y el pronosticado por **150[seg]**, independientemente del instante inicial de predicción. Sin embargo, este método cuenta con dos importantes desventajas:

- 1) Existen pruebas donde las predicciones nunca alcanzan el umbral de falla dentro del horizonte de predicción luego, no existe el instante EOD. Por lo tanto, estas pruebas tienen asociadas una diferencia entre el EOD real y el pronosticado bastante mayor que en el caso en que se considera una caracterización estadística del perfil de utilización futuro.
- 2) **I** promedio tiene la desventaja ante etapas de estimación reducidas con respecto al largo de predicción que se desea realizar, lo cual produce inexactitud en el cálculo del EOD, debido a la escasa información que entrega la corriente de descarga del ESD. Más aún si es el caso de perfiles de uso que varían al menos **1** o **2[A]** entre una medición y la siguiente.
- 3) **I** promedio tiene también la desventaja al ser una realización CTE en el tiempo, lo cual genera sobre o sub-estimaciones “considerables” del EOD al realizar un cambio en el perfil de uso o consumo de la batería, lo cual con CM se modelaría mejor a la realidad (existe mayor incertidumbre del perfil).
- 4) En términos de probabilidad, la precisión o dispersión de la PDF del EOD (varianza de las colas) con **I** promedio es muy acotada y exacta si el perfil de uso en predicción es aproximadamente constante y se tuvo una etapa de estimación eficiente (se aprendió), sin embargo, en el plano general eso ocurre en el menor de los casos, ya que en ciertas rutas la batería presentara un perfil de consumo muy variable, en el cual pudiese terminar en un EOD pronosticado muy sesgado con respecto al *Ground Truth* lo que conllevaría a una falsa alarma del tiempo de desconexión de la batería, mientras varias realizaciones de la CM minimizan la incertidumbre al considerar historia pasada y estados posibles, lo cual conlleva a pronósticos más acertados a la realidad y además subestimadas en algunos segundos o par de minutos.

Considerando lo anterior, la única desventaja que tiene el método que implementa la caracterización estadística del perfil de utilización futuro, es que en las pruebas en que se inicia la predicción antes de los **1200[seg]** se tiene una diferencia entre el EOD real y pronosticado de aproximadamente **150[seg]** mayor respecto al resultado entregado por el método que utiliza una corriente promedio y constante. Sin embargo, dado que:

(i) las desventajas del método en que se utiliza el perfil de uso constante, (ii) la diferencia entre el EOD real y el pronosticado al implementar la caracterización estadística del perfil de uso va disminuyendo progresivamente hasta alcanzar la misma diferencia que se obtiene al considerar la corriente promedio y, (iii) dicha diferencia, dentro de un horizonte de predicción de aproximadamente **2300[seg]**, tiene su máximo alrededor de los **300[seg]**, lo cual es positivo; se

considera que el método que utiliza la caracterización estadística del perfil de utilización futuro mediante una CM, tiene una importante mejora en su desempeño respecto al método comúnmente utilizado en la literatura, destacando que en sus resultados tienden a sub-estimar el EOD.

En lo que corresponde a los parámetros de la CM en la caracterización del perfil de uso futuro del ESD, se muestran los resultados de su comportamiento a medida que el inicio de predicción aumenta en cada iteración. Se toma en cuenta la evolución de los parámetros de la CM desde los 5 minutos de haber iniciado el AEP hasta los primeros 45 minutos, tal como se muestran a continuación:

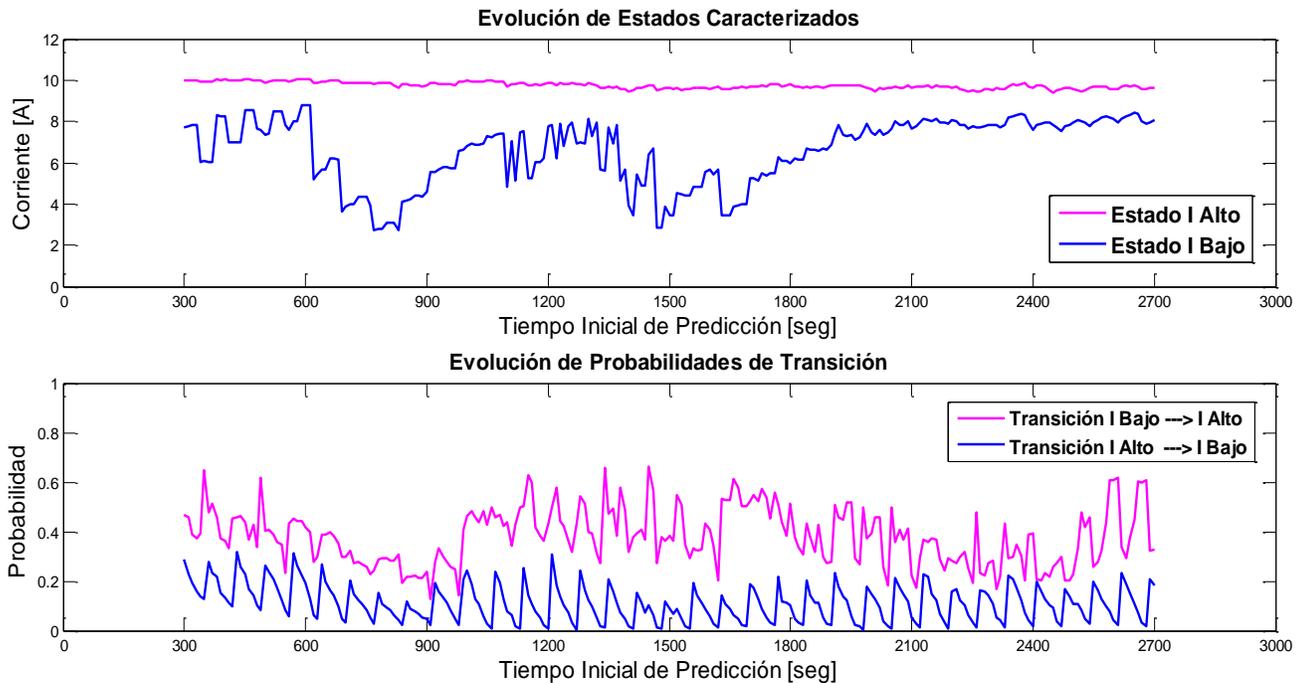


FIGURA 4.1.25: EVOLUCIÓN DE PARÁMETROS DE CADENA DE MARKOV EN DIFERENTES INICIOS DE PREDICCIÓN

Se puede observar que desde los 1800[seg] en adelante se observa que la diferencia entre el valor medido y el estimado tanto en el caso del voltaje como del SOC aumenta en relación al intervalo anterior, esto se explica a la violenta caída de tensión que se produce cuando el ESD está cerca de descargarse completamente. El efecto de esta caída de tensión también se observa en el comportamiento del estado x_1 , el cual intentar adaptar su valor a los nuevos datos observados y que por lo tanto, vuelve a tomar un rango de valores más amplios respecto a los que tenía en el intervalo anterior. Considerando esta tres etapas, en que la primera etapa corresponde a la etapa de aprendizaje con un porcentaje de carga alto y que en la tercera etapa el ESD está prácticamente descargado, es durante la segunda etapa cuando los resultados del módulo de pronóstico son más útiles al usuario, para efectos de la toma de decisiones futuras de cuánto y cuándo cargar la batería. Es también durante esta etapa cuando se tienen las mejores condiciones iniciales para el módulo de pronóstico, ya que los estados del modelo se encuentran con los valores estabilizados.

Las fuentes de incertidumbre a corregir, tales como la inexistencia de observaciones, el mismo modelamiento del perfil de utilización y el número de partículas propagadas para la etapa de pronóstico, mientras para la etapa de estimación se tiene el sesgo de filtrado o nivel de aprendizaje insuficiente de los estados, la pérdida de diversidad de las partículas por una alta tasa de remuestros, eventos de regeneración y la demanda de una potencia mayor al máximo disponible que puede entregar el ESD donde el voltaje decae rápidamente siendo insuficiente el modelo de observación propuesto para propagar las partículas.

El ancho de banda es un parámetro ajustable dentro del módulo de regularización que permite generar nuevas fuentes de incertidumbre con una distribución de partículas o dispersión de éstas cada vez mayor, a medida que el ancho de banda H óptimo aumente. Entonces como nuestro objetivo es lograr una mayor precisión del EOD, en otras palabras obtener una varianza menor de partículas en cada una de las realizaciones, se ajusta H a un valor suficientemente pequeño tal que el desconocimiento del SOC durante el pronóstico sea adecuadamente caracterizado. Para esto se divide el parámetro H por un factor de escala igual a **30**.

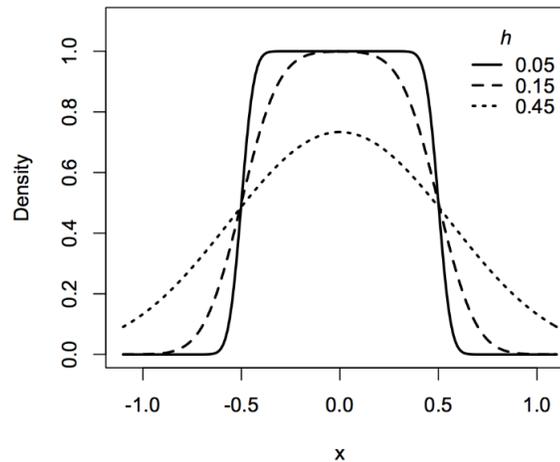


FIGURA 4.1.26: EFECTO DEL ANCHO DE BANDA EN LA FORMA DEL KERNEL DE EPANECHNIKOV

Si se regularizan N partículas, el SOC predicho sufre una variabilidad y dispersión muy apreciable en la PDF donde a menor N° de partículas, más notorio será, ya que el perfil de uso futuro afecta mucho la posición de un número corto de partículas (contribución casi absoluta de la corriente de descarga) y es independiente del número de realizaciones, sin embargo, con muchas realizaciones de CM se logra obtener una distribución más confiable sin regularización, casi el doble que con **40** partículas para llegar al mismo nivel de sub-estimación. Además con corriente promedio es similar a tener 1 realización de CM.

A continuación se presenta la tabla resumen con los valores finales ajustados del AEP offline mediante análisis de sensibilidad y qué componente de desempeño se ve afectado por cada uno de ellos, además se definen los enfoques a utilizar en la implementación en línea.

Parámetro de Ajuste	Valor de Ajuste	Localización	Índice de Desempeño - Métrica
Número de Partículas N_p	20 - 40	Parametro Inicial AEP	Precisión del TOF (Colas PDF)
Desviación Estándar σ_η	0,25 [V]	Parametro Inicial AEP	RMSE en Estimación
Desviación Estándar σ_{w1}	1-2 [mΩ]	Parametro Inicial AEP	RMSE en Estimación
Desviación Estándar σ_{w2}	0,001 – 0,005	Parametro Inicial AEP	RMSE en Estimación
Realizaciones FP-Pronóstico*	20	Parametro Inicial AEP	Exactitud del TOF (Esperanza)
Realizaciones CM*	20	Parametro Inicial AEP	Exactitud del TOF (Esperanza)
Inicio Predicción k_{pred}	900 seg	Parametro Inicial AEP	Exactitud del TOF (Esperanza)
Horizonte Predicción Offline N_h	> 3300 seg	Parametro Inicial AEP	Exactitud del TOF (Esperanza)
Delta o Ancho Medio de HZ	0,005 (0.5%)	Parametro Inicial AEP	Exactitud del TOF (Esperanza)
Umbral de Corriente Nula	0,1 [A]	Estimación	RMSE en Estimación
Umbral de Remuestreo	0,85	Estimación	RMSE en Estimación
Inicio Adaptación de Ruido w_2	SOC = 0,7 [%]	Estimación	Rapidez de Convergencia
Factor disminución w_2	0,1	Estimación	Rapidez de Convergencia
Ancho Intervalo de CM**	40 - 60 (Datos)	Caracterización Perfil	Exactitud del TOF (Esperanza)
P12 inicial CM	0,4 – 0,6	Caracterización Perfil	Exactitud del TOF (Esperanza)
P22 inicial CM	0,4 – 0,6	Caracterización Perfil	Exactitud del TOF (Esperanza)
Escala Ancho Kernel - H	20 - 30 (25)	Regularización	Precisión del TOF (Colas PDF)
Enfoque Remuestreo***	Sistemático	Estimación	Tiempo de Procesamiento
Enfoque Predicción Corriente	Perfil CM	Caracterización Perfil	Exactitud del TOF (Esperanza)
Enfoque Predicción con FP	Kernels de Epanechnikov	Pronostico	Tiempo de Procesamiento y Precisión del TOF (Colas PDF)

TABLA 4.1.7: RESUMEN DE PARÁMETROS AJUSTADOS FUERA DE LÍNEA

- * : Se escogió el menor valor dentro de los de mejor desempeño, debido al tiempo de procesamiento que emplean para un entorno en línea.
- ** : Valor muy relevante para la pendiente de la curva de SOC predicho, ya que si el ancho es muy ALTO implica una curva con pendiente baja (sobre-estima TOF o EOD).
- ***: Presenta menor tiempo de cálculo en función del N° de partículas que el Multinomial.

Se requiere un tiempo en segundos mayor a **3300** para la simulación *offline* del AEP, ya que la tasa de muestreo promedio es de **1.415[seg]** entre mediciones consecutivas, por lo que un valor menor generaría un horizonte de predicción (en número de datos) menor al largo de datos de la ruta 5 que se está analizando.

De modo general se puede decir que las corrientes muy bajas o negativas y voltajes muy bajos son las restricciones del AEP, también cargas parciales del acumulador y alcance del umbral de corte durante la estimación o antes del inicio programado de predicción, la cual no existirá una ventana de tiempo para corregir o evitar tal escenario, sino que puede inferirse de los datos mostrado en pantalla de voltaje y SOC estimado, a menos que sea instantáneo el cambio abrupto.

Una tasa de muestreo promedio muy baja entre datos produce que el tiempo de pronóstico no sea suficiente y la PDF del EOD se aprecie incompleto, mientras una tasa promedio alta genera a su vez que no se alcance a la zona de peligro o HZ establecida por el SOC de corte.

4.2. ANÁLISIS DE IMPLEMENTACIÓN EN LÍNEA

El objetivo del enfoque en línea consiste en entregar los parámetros y variables iniciales para el desarrollo del AEP online mostrado en FIGURA 3.1 donde se traspasa todo el código Matlab del AEP offline a un nuevo lenguaje con sus respectivas modificaciones. De este modo, la implementación del AEP consiste en una aplicación en entorno Android que recoge los parámetros iniciales de entrada obtenidos en el AEP offline para posteriormente ser integrado a una plataforma propia del CIL para efectos generales del proyecto. El trabajo previamente mencionado se describe en detalle en [2].

Para efectos de dar un puente de comunicación entre lo realizado en este trabajo y el desarrollo del AEP online, se analizan en una primera parte los aspectos preliminares del AEP a implementar, seguida de las limitaciones o restricciones del funcionamiento en línea que se esperan tener en base a los alcances ya mencionados del trabajo presente.

4.2.1. SET DE DATOS Y ANÁLISIS PRELIMINAR DEL AEP EN APLICACIÓN MÓVIL

Los datos utilizados para las pruebas del AEP dentro de la aplicación móvil corresponden al voltaje y corriente en bornes de la ruta 5 previamente mostrados en FIGURA 4.1.2. Sumado a ello, es posible adquirir estas mediciones en línea durante el proceso de descarga del pack de baterías vía Bluetooth 4.0 o a través de una conexión USB al pack. Una vez recibidos los datos medidos, éstos se almacenan dentro del microcontrolador de la E-bike o en la misma aplicación móvil instalada en un Smartphone. A su vez, se almacenan los datos de entrada provenientes del AEP offline, es decir, el voltaje estimado, SOC estimado, potencia máxima disponible estimada, voltaje predicho, SOC predicho y EOD predicho o también llamado TOF. Además se almacenan en la aplicación móvil los set de datos que requiere el AEP para operar tal como la tabla de correspondencia entre el SOC estimado y su respectiva potencia máxima disponible calculada, y por otra parte el valor de corte o V_{cutoff} predefinido.

Durante la recepción de datos a una tasa fija predeterminada, preliminarmente **1[seg]**, se observan datos reales fiables y datos defectuosos desde el microcontrolador del ESD. Un criterio para establecer si un dato es defectuoso o válido se define con un valor nulo del voltaje, lo cual es considerado una ventaja en el proceso de descarga, debido a que el ESD alcanza su valor de corte o *cutoff* antes. Un modo de prevenir datos defectuosos o no informados es definiendo un nuevo valor de voltaje como sigue:

$$V_k = V_{k-1} + v \quad (4.8)$$

Donde v es un ruido con distribución normal de media nula y desviación estándar equivalente al ruido de observación σ_η , ya definido en **0.25**, en consecuencia, el voltaje V_k puede tomar hasta un valor de **0.25[V]** de diferencia (en sentido positivo o negativo) con respecto a la medición válida anterior. De todos modos, durante el desarrollo de este trabajo se ha mejorado la calidad de

los sensores de voltaje y corriente utilizados, sin embargo, existen métodos de imputación estadística que pudiesen ser más eficientes en el tratamiento de datos cuando se observan pérdidas reiteradas, tales como los métodos de media muestral, NNI y “de la razón” en el caso determinístico, mientras en el caso aleatorio el más conocido y usado es el método *Random Hot Deck* [28].

En lo que respecta al procesamiento o ejecución del AEP online, se decide realizarlo en el dispositivo móvil o Smartphone, debido a las capacidades de memoria y procesamiento comparativamente mayores que el BMS o sistema de control del ESD, sumado al hecho de que no se necesita un acceso a internet para el procesamiento, el cual si se necesitaría por ejemplo en el caso de alojarlo en un servidor web, en el cual se ve afectada la cobertura de redes móviles. Realizando una comparación de los tiempos de procesamiento o ejecución entre las principales funciones del AEP en un entorno Matlab como se muestra en FIGURA 4.2.1 se puede apreciar que la regularización de partículas en la etapa de predicción es la que mayor tiempo toma independiente del número de datos analizados o equivalentemente el número de iteraciones, ya que se cuenta solamente el tiempo de ejecución sin incluir funciones anidadas o que se llamen dentro de otra como ocurre con el AEP. La función de regularización utiliza ese tiempo de ejecución a causa de los cálculos multiplicativos que realiza para generar las distribuciones de probabilidad de Epanechnikov descritos en la sección 2.2.3.

Function Name	Calls	Total Time	Self Time*	Total Time Plot (dark band = self time)
Solucion_General	1	8.163 s	0.559 s	
Pronostico_FP	1	5.218 s	0.040 s	
Distribucion_Pred	1	5.176 s	0.840 s	
Prediccion_Modelo	1	4.317 s	0.567 s	
Prediccion_Reg	2099	3.749 s	3.221 s	
Estimacion_FP	2284	1.925 s	0.854 s	

FIGURA 4.2.1: RENDIMIENTO DEL TIEMPO DE PROCESAMIENTO DEL AEP EN ENTORNO MATLAB

Este análisis ayuda a tener conocimiento del tiempo que requiere la aplicación móvil en tiempo real, en el cual se estiman resultados similares para un Smartphone de altas capacidades, aunque el tiempo total tiende a concentrarse en la lectura de datos.

Cabe mencionar que durante el desarrollo del AEP online se pretende buscar la forma más eficiente de utilizar los recursos del sistema móvil, reduciendo las redundancias de cálculos dentro de bucles o *loops* que entreguen un mismo resultado, llamar a todas las funciones y operaciones inicialmente que generen datos frecuentemente utilizados y por último mantener una secuencia lógica del proceso.

En el plano de la interfaz de usuario o HMI en la que interactúa el usuario de la E-bike y la información de salida del AEP online, la visualización de los datos relevantes como es el caso del SOC porcentual y el tiempo de descarga remanente del ESD como se muestra en FIGURA 4.2.2, deben ser actualizados automáticamente a una tasa fija para posteriormente ser subidos a un

servidor web que este siempre disponible cuando se necesite la información. Tanto el almacenamiento, control, procesamiento e interfaz de usuario son detallados en las arquitecturas de hardware y software descritos en [2].



FIGURA 4.2.2: VISTA DE USUARIO EN APLICACIÓN MÓVIL PROPUESTA

Se presenta en el AEP online una interfaz de prueba donde se exhiben los datos de salida de mayor interés como se muestra en FIGURA 4.2.3, con tal de evaluar su desempeño en la aplicación móvil de manera detallada. Estas pruebas se detallan en [2].

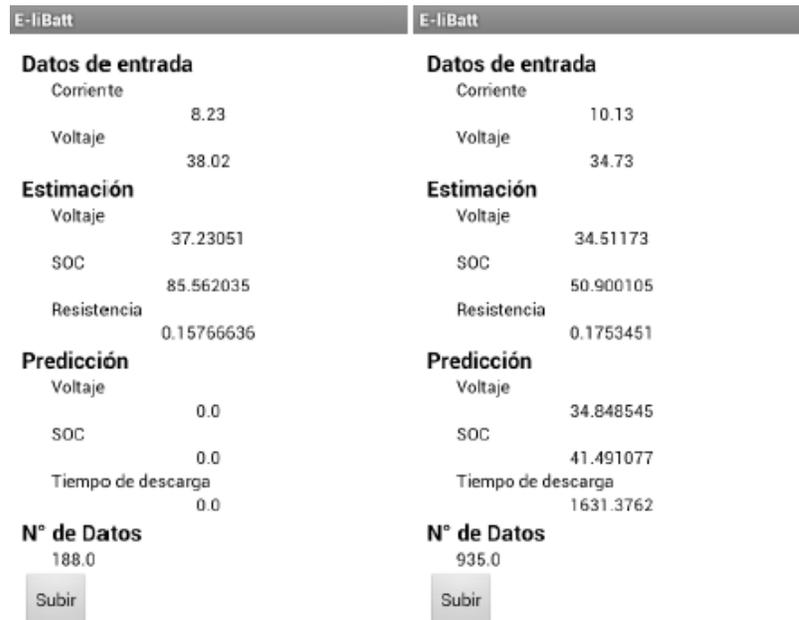


FIGURA 4.2.3: EJEMPLO VISTA DE INTERFAZ DE PRUEBAS ONLINE

Al poseer un módulo de pronóstico que consume un gran número de recursos computacionales, se requiere desplegar la información en línea con el menor tiempo posible para una toma de decisiones enfocado en la prevención de eventos críticos o de riesgo que pudiesen afectar la autonomía del ESD. Por esta razón, se ha determinado en base a los resultados analizados en el AEP offline y las consideraciones a tomar en la implementación en línea que la frecuencia de

muestreo $f_M = \frac{1}{\Delta t_M}$ debe ser establecido en **1[seg]** en la aplicación móvil, el inicio de predicción en **900[seg]** como se propone en la sección 4.1.2, el horizonte de predicción en **3600[seg]** o **1** hora a lo más con el objetivo de garantizar una estimación del valor EOD dentro de las primeras iteraciones del módulo de pronóstico en línea, y por último la frecuencia de refresco de pantalla en el HMI se pretende establecer en **1[seg]** para lograr un funcionamiento en tiempo real lo más rápido posible.

4.2.2. RESTRICCIONES Y OPERATIVIDAD EN LÍNEA

En primera instancia, se ha notado que en pruebas preliminares del AEP online se requiere un tiempo entre **10** y **20** segundos entre iniciar el pronóstico y entregar un valor EOD en pantalla, sin considerar optimización del algoritmo en entorno Android, lo cual provoca una pérdida de datos importante de corriente y voltaje que van llegando a una frecuencia mayor y que no se procesan para la etapa de estimación en ese intervalo de tiempo. Este hecho promueve evaluar tanto mejoras en el esfuerzo computacional, particularmente en esta etapa del AEP, sin sacrificar la exactitud y/o precisión de las variables de salida como también contar con una ejecución paralela en la aplicación móvil que permita utilizar esos datos entrantes para realizar la estimación de estados mientras se continúa pronosticando en otro proceso.

Para poder analizar el rendimiento de un programa existen diversos aspectos dentro de los cuales se encuentran el tiempo de inicio de un programa, el tiempo de respuesta, la cantidad de datos *throughput*, requerimientos de hardware y escalabilidad. En relación al tiempo de inicio, esto se refiere al tiempo de carga que requiere la aplicación para comenzar. El tiempo de respuesta, se refiere al tiempo que requiere el sistema para reaccionar ante una solicitud del usuario. La cantidad de datos que pueden ser procesados por el programa dentro de un tiempo dado. Los requerimientos de software se refieren a cuanto procesador y cuanto memoria RAM se requiere para ejecutar el programa. Por último, la escalabilidad es la propiedad deseable del programa, que indica su habilidad para reaccionar y adaptarse sin perder calidad, o bien manejar el crecimiento continuo de trabajo de manera fluida, o bien para estar preparado para hacerse más grande sin perder calidad en los servicios ofrecidos [2].

1. Offline el largo de predicción es fijo, si se varia el “inicio de predicción” el largo disminuye, es decir, horizonte fijo. En el caso online el largo es idealmente constante pues se llama a pronóstico periódicamente y a una frecuencia constante.
2. No existe un SOC referencial en línea con el cual se comparan los datos resultantes del AEP que se muestran en pantalla, por lo cual es crítico optimizar y corregir la solución de modo *offline* antes de implementarlo.
3. Tiempos de muestreo variables y medidos en tiempo real según la llegada de cada dato almacenado y posteriormente procesado.

Cabe destacar que el largo de predicción de la ventana de pronóstico es mayor al tiempo de espera que se tiene para ejecutar un nuevo pronóstico. Esto debido a que existen ciertos periodos de tiempo real (no de procesamiento) en los cuales pudiese no generarse una PDF del EOD donde eventualmente si se alcance el valor de corte del acumulador.

El horizonte de predicción está fijado en **3600** datos (idealmente 1 hora si la tasa de muestreo es de **1[seg]**), si por ejemplo la ruta utiliza un perfil muy bajo, es decir, una descarga casi en vacío, entonces la curva SOC de predicción debiese ser muy lenta, por lo tanto, sobrepasara ese horizonte. Para evitar esto, sabemos primero que se cumplirá TOF predicho = **0 [seg]** (el código por default asigna ese valor cuando no genera PDF EOD) luego se podría generar un visualización de pantalla afirmando que el tiempo de corte restante es mayor a **3600[seg]** por ejemplo. Como en línea se hace pronóstico reiteradamente, en donde se hacen **20-25** realizaciones de CM y FP-pronóstico en cada llamado, entonces:

- El inicio de predicción se desplaza al igual que el horizonte prefijado **3600[seg]** (por ejemplo) a medida que pasa el tiempo (idealmente a la misma tasa), entonces el largo de predicción se supone constante. Se hace pronóstico reiteradamente y en algún momento debiese el algoritmo detectar un TOF no nulo. En este caso se informa que el corte ocurrirá en ese momento.
- En el caso de alcanzar el corte antes de predecir sólo dependerá del grado de estimación, ya que en el momento de refrescar la información en pantalla se informa del SOC% que queda, entonces sería bueno informar simultáneamente el SOC% de corte para que el usuario tenga la información de que el corte es muy pronto.
- La tasa de muestreo en el algoritmo es estático y se deja como entrada al código en el caso offline, debido a la gran variación de tiempos de muestreos efectivos entre diferentes rutas. En el caso online, puede dejarse en **1[seg]** si los resultados son los esperados, en caso contrario lo ideal sería medir el tiempo entre la llegada de una muestra de voltaje y corriente, tal que con la siguiente medición se use un promedio.

En el caso de necesitar o presentar una carga parcial mientras se está ejecutando el módulo de pronóstico en la E-bike, el sistema de monitoreo no ejecutará ninguna orden para adaptar las estimaciones y predicciones a las nuevas mediciones de voltaje y corriente. Por esta razón, se implementa de forma externa al trabajo realizado, una rutina de detección de carga basado en bits de detección en los bornes del pack de baterías utilizado, con el propósito de almacenar las últimas estimaciones y/o predicciones (dependiendo si el instante de carga detectada fue anterior o posterior al inicio de predicción) del AEP para reiniciarse una vez detectada una nueva descarga; y en consecuencia, utilizar la información almacenada según el tipo de carga realizada. Existen 3 escenarios posibles:

1. La carga parcial se haya realizado hasta un valor cercano al **100%** del voltaje nominal del pack. Para este caso, el módulo de pronóstico de reinicia desde su etapa de estimación sin requerir de la información guardada en el sistema.
2. La carga parcial se haya realizado hasta un valor muy cercano al voltaje observado en la última iteración del AEP. Por lo tanto, se emplea la información de la última iteración del AEP para calcular las siguientes sin modificar ningún parámetro.
3. La carga parcial se haya realizado hasta un valor intermedio menor a una carga completa y mayor al último voltaje observado. Para este caso, se deja como trabajo futuro el reciclar la información obtenida del AEP para nuevos voltajes y corrientes de descarga medidas.

CAPITULO 5

CONCLUSIONES

En este trabajo se presenta, evalúa, valida y se establecen las condiciones de implementación de un algoritmo sub-óptimo de estimación del SOC y el pronóstico del EOD para el proceso de descarga de un ESD de Ión-Litio operado en una E-bike o bicicleta eléctrica. Esta solución es fundamentada en un modelo estocástico propuesto y en una caracterización estadística del perfil de uso del ESD mediante CM, sumado a otras alternativas paralelas con las cuales comparar niveles de desempeño y costos computacionales para su implementación en tiempo real, sumado a la combinación de conocimiento *a priori* con información en tiempo real. Dicho esto, se dan las bases y grados de inteligencia del sistema de monitoreo para su posterior aplicación en un dispositivo móvil dentro de un marco de monitoreo en línea. Con este trabajo, se dan por cumplido los objetivos señalados, como maximizar la autonomía, el impacto positivo del AEP en la toma de decisiones del usuario de la E-bike, sobre todo en rutas planificadas y la precisión de la información de monitoreo a disposición del usuario, reduciendo a su vez las fuentes de incertidumbre que obstaculizan el rendimiento general del algoritmo dejando un pie de apoyo concreto y lleno de consideraciones a tomar para las etapas siguientes que conforman el proyecto.

El considerar en el módulo de pronóstico el valor estimado del EOD en base a que todas las partículas alcancen la zona de peligro y no una primera partícula, un JITP 5% o incluso su media muestral, dan indicios de una metodología que en su diseño ya subestimaba la predicción del EOD, asumiendo una buena caracterización del perfil de uso futuro, donde la posible dispersión de partículas afectaría la precisión de la información que se visualiza en la E-Bike, evitando tanto el extremo de un desempeño del AEP imprevisto o sin lograr su objetivo de informar antes de una inminente desconexión como de un desempeño conservador en el uso real de la batería, el cual en vehículos de poca capacidad representa un problema al poseer bajos tiempos de descarga, donde el AEP debe ser aún más exacto y no muy subestimado.

Los resultados de la etapa de estimación generaron un grado de sensibilidad esperado en los niveles de ruido considerados en la modelación en espacio-estado, ya que al variar sus magnitudes, se consiguen resultados adversos, los cuales se ven muy afectados por la naturaleza de los datos de prueba y validación. Por su parte, se determina que la caracterización estadística y el orden de la CM son un elemento primordial en la estimación del EOD final y la reducción de la incertidumbre en la varianza de la predicción de la PDF de la EOD; y por tanto de la exactitud de las predicciones en pronóstico bajo las condiciones de seguridad ante sub-estimaciones que se deseaban obtener, puesto que no se llegara al umbral de falla sin informarlo de algún modo, en particular, en tiempo real. A medida que la caracterización tuviese más datos históricos, se apreciaron niveles de exactitud y precisión mayores en la ventana de pronóstico ante múltiples realizaciones, las cuales terminaron cada vez más cercanas a su valor referencial en un marco fuera de línea, del orden de segundos. Estos resultados permiten al usuario de la E-Bike tomar decisiones futuras de recarga, tales como cuando y cuanto cargar.

La integración de diversas alternativas y enfoques con la metodología propuesta ha sido aplicada bajo un escenario simplificado, pero suficiente del problema de pronóstico a considerar, en donde

las herramientas matemáticas de teoría de probabilidades y estadística, minería de datos y teoría de control avanzado contribuyeron en la cuantificación de la precisión y exactitud de la PDF del EOD en su totalidad. Sin embargo, la pérdida de diversidad del FP al remuestrear repetitivamente, requiere recursos de procesamiento más eficaces que en EKF o UKF, además de problema de estimación al aplicar modelos dinámicos de observación que no entregan el nivel de ruido para lograr un fase de adaptación eficiente.

Una de las razones del uso de métodos de estimación robustos es el impacto de representar soluciones de alto desempeño en implementaciones en línea y a su vez presentar una forma distinta de resolver problemáticas asociadas al monitoreo inteligente de baterías que no se ha utilizado con anterioridad en vehículos eléctricos de cualquier tipo. Por esta razón, se requirió una alta confiabilidad del modelo obtenido, con el cual se garantiza un conocimiento suficiente de los packs de baterías analizados donde además se adquirió una coherencia entre los resultados obtenidos y los deseados con respecto a las referencias bibliográficas aportadas. Durante esta etapa, el desempeño del trabajo se midió dependiendo tanto de los objetivos predefinidos al inicio de la práctica como de las limitaciones a los que es sujeto el problema al final de la práctica, en particular, en su implementación en un dispositivo móvil.

El presente trabajo proporciona un potencial sub-producto para el estado de arte en modelos de descarga en ESD y enfoques de pronóstico Bayesiano enfocados en otros parámetros de rendimiento. Es por esto, que como trabajo futuro se pretende incluir un mayor número de variables a considerar en la caracterización de los packs de baterías a estudiar y así lograr modelos mucho más exactos para aplicaciones de electromovilidad de mayor requerimiento energético, además de ello en lo que respecta al objetivo general del proyecto, se pretende potenciar el empleo de estos desarrollos a niveles de implementación cada vez de mayor escala como pudiesen ser algunos sistemas de transporte eléctrico que utilicen mayor potencia, con el propósito de obtener conclusiones importantes con el que se puedan adquirir enseñanzas interesantes en este rubro. Por otro lado, acercar y eventualmente incentivar el desarrollo de aplicaciones inteligentes tanto en vehículos eléctricos livianos tratados aquí como en cualquier solución que comprenda el uso de baterías de un modo innovador y no únicamente en proyectos de investigación. La incorporación de variables de terreno al modelo, el efecto de temperatura a variables como la impedancia interna de la batería, las limitaciones de un sistema de adquisición y tasas de muestreo variables, la metodología asociada a un SOC de referencia en línea, la detección de celdas degradadas o con muy baja capacidad, la predicción de la potencia máxima disponible en tiempo real, el efecto de la impedancia interna en el modelo de observación en pronóstico, entre otras consideraciones son elementos a priorizar en lo que respecta al diagnóstico y pronóstico de baterías de altas tasas de carga y descarga como lo son las de Ión-Litio.

BIBLIOGRAFÍA

- [1] M. A. Cerda, «Estimación en línea del tiempo de descarga de baterías de Ion-Litio utilizando caracterización del perfil de utilización y métodos secuenciales de Monte Carlo,» Tesis para optar al grado de Magíster en Ciencias de la Ingeniería Mención Eléctrica, Memoria para optar al título de Ingeniero Civil Electricista, Universidad de Chile, Santiago de Chile, 2012.
- [2] A. J. Díaz, «Implementación de métodos sub-óptimos de estimación y predicción del estado-de-carga de baterías de ion-litio en ambiente android,» Memoria para optar al Título de Ingeniero Civil Electricista, Universidad de Chile, Santiago de Chile, 2014.
- [3] S. J. Engel, B. J. Gilmartin, K. Bongort y A. Hess, «Prognostics, the real issues involved with predicting life remaining,» Aerospace Conference Proceedings, IEEE - Vol.6, pp.457-469, 2000.
- [4] B. E. Olivares, «Sistema de pronóstico para el estado-de-salud de acumuladores de energía basado en filtro de partículas y caracterización estadística de fenómenos de regeneración,» Tesis para optar al grado de Magíster en Ciencias de la Ingeniería mención Eléctrica, Memoria para optar al Título de Ingeniero Civil Electricista, Universidad de Chile, Santiago de Chile, 2012.
- [5] C. D. Burgos, «Estimación del estado de carga para un banco de baterías basada en modelación difusa y filtro extendido de Kalman,» Tesis para optar al grado de Magíster en Ciencias de la Ingeniería mención Eléctrica, Memoria para optar al título de Ingeniero Civil Electricista, Universidad de Chile, Santiago de Chile, 2013.
- [6] P. Abbeel, «Extended Kalman Filter and Unscented Kalman Filter,» Thrun, Burgard and Fox, Probabilistic Robotics, UC Berkeley EECS, Berkeley, CA, USA, 2012.
- [7] H. F. Navarrete, «Caracterización estadística del perfil de uso de baterías para el pronóstico del estado-de-carga,» Memoria para optar al Título de Ingeniero Civil Eléctrico, Universidad de Chile, Santiago de Chile, 2014.
- [8] F. A. Tobar, «Inferencia de la volatilidad de retornos financieros usando filtro de partículas,» Tesis para optar al grado de Magíster en Ciencias de la Ingeniería mención Eléctrica, Memoria para optar al título de Ingeniero Civil Eléctricista, Universidad de Chile, Santiago de Chile, 2010.
- [9] M. Sanjeev Arulampalam, S. Maskell, N. Gordon y T. Clapp, «A tutorial on particle filters for online nonlinear/non-gaussian bayesian tracking,» IEEE Transactions of Signal Processing - Vol. 50, No.2, 2002.
- [10] M. E. Orchard, M. A. Cerda, B. E. Olivares y J. F. Silva, «Sequential Monte Carlo methods for Discharge Time Prognosis in Lithium-Ion Batteries,» International Journal of Prognosis

and Health Management, ISSN 2153-2648, Santiago de Chile, 2012.

- [11] L. S. Zettlemoyer, H. M. Pasula y L. P. Kaelbling, «Logical particle filtering,» MIT CSAIL, Cambridge, MA, USA, 2007.
- [12] Y. Hao, Y. Yin y J. Lan, «Vehicle tracking algorithm based on observation feedback and block symmetry particle filter,» Hindawi Publishing Corporation, Journal of Electrical and Computer Engineering - Vol. 2014, Article ID 520342, Beijing, China, 2014.
- [13] Y. Huang y P. M. Djurić, «A new importance function for particle filtering and its application to blind detection in flat fading channels,» IEEE, Department of Electrical and Computer Engineering, State University of New York, Stony Brook, NY, USA, 2002.
- [14] D. J. Hol, T. B. Schon y F. Gustafsson, «On resampling algorithms for particle filters,» Division of Automatic Control - Department of Electrical Engineering - Linköping University, Linköping, Suecia, 2006.
- [15] M. E. Orchard y G. J. Vachtsevanos, «A particle-filtering approach for online fault diagnosis and failure prognosis,» Transactions of The Institute of Measurement and Control Journal, Atlanta, Georgia, USA, 2009.
- [16] L. Rodríguez Ojeda, «Construcción de kernels y funciones de densidad de probabilidad,» Escuela Superior Politécnica del Litoral (ESPOL) - Departamento de Matemáticas, Guayaquil, Ecuador, 2012.
- [17] D. Bagnell y T. Liu, «Particle filters: the good, the bad, the ugly,» Statistical Techniques in Robotics (16831, F11) Lecture#04, 2011.
- [18] S. H. Chung, K. T. Chui, K. F. Tsang y L. F. Yeung, «Appliance signature identification solution using k-means clustering,» Industrial Electronics Society IECON 2013 - 39th Annual Conference of the IEEE, pp.8420-8425, University of Hong Kong, Hong Kong, China, 2013.
- [19] D. A. Pola, H. F. Navarrete, R. S. Rabić, M. E. Orchard, J. S. Silva, M. A. Cerda y B. E. Olivares, «Particle-Filtering-Based Discharge Time Prognosis for Lithium-Ion Batteries with a Statistical Characterization of Use Profiles,» Journal of Power Sources, Santiago de Chile, 2013-2014.
- [20] S. Elizabeth y R. Jothilakshmi, «Observability and controllability of MIMO control systems via difference equations,» International Journal of Computer Applications - Vol. 62, No.1, Auxilium College, Vellore, India, 2013.
- [21] B. Saha y K. Goebel, «Modeling Li-ion Battery Capacity Depletion in a Particle Filtering Framework,» Annual Conference of the Prognosis And Health Management Society, NASA Ames Research Center, CA, USA, 2009.

- [22] P. Fearnhead, «Particle filters for mixture models with an unknown number of components,» Kluwer Academic Publishers, Statistics and Computing 14, Lancaster University, Lancaster, UK, 2003.
- [23] J. Fox, «Nonlinear Regression and Nonlinear Least Squares,» The Comprehensive R Archive Network, The R Journal, Institute for Statistics and Mathematics, Universidad de Viena, Viena, Austria, 2002.
- [24] P. V. Flores, «Modelación y predicción de focos de criminalidad basado en modelos probabilísticos,» Memoria para optar al Título de Ingeniera Civil Eléctrica, Universidad de Chile, Santiago de Chile, 2014.
- [25] R. R. Coifman y D. L. Donoho, «Translation-invariant de-noising,» Yale University and Stanford University, USA, 1995.
- [26] H. Liu, S. Shah y W. Jiang, «On-line outlier detection and data cleaning,» ELSEVIER, Computers and Chemical Engineering, Sciencedirect, University of Alberta, Edmonton, Alberta, Canada; Stevens Institute of Technology, Hoboken, NJ, USA, 2004.
- [27] J. S. Hunter, «The exponentially weighted moving average,» Journal of Quality Technology, Vol.18, 1986.
- [28] J. F. Muñoz y E. Álvarez, «Métodos de imputación para el tratamiento de datos faltantes: aplicación mediante R/Splus,» Revista de Métodos Cuantitativos para la Economía y la Empresa, ISSN: 1886-516X, Universidad de Granada, Granada, España, 2009.