

Algoritmo GCR para Unidades Consumidoras de Smart Grids de Baja Tensión

José R. Sicchar*, Carlos T. Da Costa Jr**, José R. Silva***
Rodrigo C. de Freitas*

*Universidade do Estado do Amazonas, Escola Superior de Tecnologia, Av. Darcy Vargas, 1200, Parque Dez, CEP 69050-020, Manaus-AM, Brasil; (e-mail: jvilchez@uea.edu.br/rchoji@yahoo.com.br).

**ITEC, Depto. Eng. Elétrica, UFPA, Av. Augusto Corrêa, 01, CEP 66075-900, Belém, Brasil (e-mail: cartav@ufpa.br)

*** Design Lab, Depto. Eng. Mecatrônica, USP, Av. Prof. Melo Moraes, 223, CEP 05508-900, SP, Brasil, (email: reinaldo@usp.br)

Abstract: This paper presents the results of low voltage smart grid intelligence to energy managing consumption in the final consumers. Which is developing based on specific processing macro-agents with embedded algorithms. This is called *Final Management Consumption* intelligence and it shows the energy consumption forecast during a future year, based on the history of discrete states energy use, and also the equilibrium power diagnosis between residential feeders. The first Macro-agent is formed by a modeling process based on jump Markov chain to energy forecasting; and the second Macro-Agent by a Mamdani Fuzzy inference for equilibrium phase's diagnosis. The benefits generated by this model among others are: the equilibrium into residential feeders and the power losses decrease on low voltage distributed grid and consequently reducing the risk of burning transformers. Therefore establishes an intelligent automation process for low voltage smart grids.

Keywords: Smart Grids, EMS Intelligence, Macro-agents, Markov Chains, Fuzzy Systems.

1. INTRODUCCIÓN

Dentro del proceso de concepción y evolución de modelos y arquitecturas de Redes Eléctricas Inteligentes o Smart Grids (SG), las inteligencias de Gerenciamiento de Consumo de Energía (GCE) están comenzando a jugar un papel importante, no solamente como algoritmos o *frames* que automatizan, el flujo de operaciones de las SG presentes en los sectores de Generación, Transmisión, Distribución y recientemente también en la red secundaria de distribución de Baja Tensión (BT), donde están la mayor parte de las unidades consumidoras finales (UCFs), e.g. Nguyen (2013).

Así puede observarse que en la red de distribución de BT, las inteligencias de GCE a parte de su papel principal de automatización de operaciones internas de la SG, también ofrecen un abanico de servicios específicos destinados al consumidor final como: la supervisión *online* del consumo actual de energía; el monitoreo del perfil futuro de consumo; el gerenciamiento virtual de compra y venta (acceso a planes de consumo personalizados y a paquetes pre-pagos, venta de producción independiente de energía), e.g. Leão et al (2011).

Dentro de esas opciones de gran importancia, una incidencia problemática presente en la red secundaria de BT, se registra constantemente: el desequilibrio de carga entre las fases del transformador de la red, y también en las fases de las UCFs e.g. Shahnia et al (2014). Notándose que la sobre de carga entre las fases de los consumidores finales, puede causar consecuentemente, el desequilibrio de las fases del transformador, e.g. Siti et al (2011). Los efectos causados son grandes y algunas veces nocivos, y pueden ser sentidos en la red secundaria de BT y también en cada UCF que se

encuentre en estado de desequilibrio de carga, entre sus fases. Algunos de esos efectos son por ejemplo: el aumento de pérdidas de energía, la disminución de la calidad de la energía suministrada, y en casos extremos la quema de los transformadores de BT, e.g. Bina et al (2011).

En ese sentido el estado del arte indica algunas iniciativas recientes que buscan encontrar, a través de metodologías y procedimientos inteligentes, la mejor combinación de conmutación, para el proceso de Reconfiguración Automática de Fases (RAF) a ser ejecutada por la Unidad de Gerenciamiento Inteligente de la SG, cuyo flujo de operaciones y procedimientos relacionados, son desarrollados bajo el *design* de inteligencias o *frames* internos. Los resultados de ese *workflow* visan la recuperación del estado de equilibrio de carga y tensión entre las fases de la red secundaria de BT y de las respectivas fases de las UCFs e.g. Sharma et al (2014).

Siti et al (2011) muestra una solución interesante aplicado en la red secundaria de BT, vía una metodología híbrida formada por una etapa de identificación de desequilibrio entre las fases por medio de un supervisor *Fuzzy*, y por un proceso de minimización del valor actual de corrientes de cada fase, neutro y secuencias negativas vía el algoritmo *Newton-Raphson*. Con la selección del vector de menor valor de corrientes, se obtiene el vector de conmutación de fases.

La secuencia obtenida para el proceso de RAF produce, una disminución significativa del desequilibrio de carga entre las fases del transformador. Sin embargo el proceso denota apenas un análisis determinístico de las variables (potencia y corriente). Desconsiderando la proyección futura de consumo

de estas. Parámetro que puede pesar en la robustez, eficiencia y durabilidad del estado de equilibrio entre las fases.

Análogamente, Shahnia et al (2014) también en la red secundaria de BT con apenas UCFs monofásicas, presenta una solución interesante para la obtención del vector de conmutación de fases, una metodología basada en un algoritmo genético de optimización que obtiene la menor variación de tensión y potencia. El proceso también considera sólo un análisis determinístico de las variables (potencia y tensión). Dejando de lado la previsión de su consumo futuro.

Por otro lado, los autores desarrollaron una inteligencia EMS para el problema de desequilibrio en las fases de conexión, de una UCF trifásica, e.g. Sicchar et al (2013) basado en la integración de dos *Agentes de Procesamiento Específico* (APES): *Agente Markoviano Empotrado* (AME) para la previsión de consumo de energía en un horizonte de doce meses, *Agente Difuso Emporado* (ADE) para la selección de las reglas generales del diagnóstico de conmutación, en las fases en función de los meses de previsión de consumo del AME. Obteniéndose resultados de validación aceptables para el proceso de RAF de UCF de BT. Sin embargo, no se considera en el ADE, el valor preciso de variación de carga para cada mes de análisis.

Proponemos continuar con el desarrollo de la inteligencia EMS para el problema de desequilibrio de fases en UCFs, implementando como coeficiente de discretización de estados de consumo, a la variancia aleatoria objetivando la mejoría de los resultados de la etapa de previsión de consumo; y la introducción del valor preciso de variación de carga de los meses de validación para la mejoría de la precisión del diagnóstico del estado de equilibrio de las fases de la UCF.

La validación de esos objetivos establecerá un flujo inteligente de automatización de los procesos operacionales y de los servicios de GCE en las UCFs de SG de BT, especialmente en el proceso RAF cuando detectado el desequilibrio de carga entre las fases de los consumidores finales de BT. Garantizándose así la disminución de las pérdidas de energía, el estado de equilibrio de las fases de las UCFs y de la red secundaria, la calidad de la energía suministrada y la disminución de la quema de los transformadores de BT.

El artículo sigue en su segunda sección, el abordaje de la concepción del modelo de SG de BT direccionado a UCFs; en la tercera sección se trata el contexto de los algoritmos de GCE en SG de BT; la cuarta sección aborda el modelo de la inteligencia GCR describiendo sus Macro-Agentes integrados; la quinta sección muestra la validación de los resultados, y en su parte final la conclusión e indicación para trabajos futuros.

2. SMART GRID DE BAJA TENSIÓN FOCADA EN UNIDADES CONSUMIDORAS FINALES

El contexto de SG se ha extendido recientemente al nivel de distribución de BT, precisamente en la red secundaria, en razón de no apenas ofrecer los servicios de GCE a los consumidores finales, pero especialmente porque se identifican varias incidencias como son: **el aumento de los**

desbalances producto de los consumos domiciliarios de cada Unidad Consumidora (UC) del circuito, **el crecimiento rápido de consumidores, la diversidad de perfiles, horarios y hábitos de consumo**, y la presencia de **conexiones clandestinas**.

Estas incidencias causan en conjunto los principales problemas en las fases del transformador: **las pérdidas de energía en la red**, el estado de desequilibrio o **fases desbalanceadas**, y en casos extremos **la quema de transformadores**, e.g. Leão et al (2011). A seguir es mostrado un modelo de SG de BT integrada que considera el flujo de consumo de energía, a partir de las cargas internas en las UCFs de la red secundaria de BT, y que también explica la integración de las inteligencias GCE en el proceso automatización de procesos y servicios en la BT.

2.1 Modelo GCR para SG de BT

La literatura científica, registra un gran número de iniciativas de modelos e implementaciones de arquitecturas de SG de BT (edificios y residencias) a lo largo del mundo, e.g. Nguyen et al (2013). Habiendo ventajas importantes, aunque pocos con la aplicación de algoritmos de GCE que integran el flujo de consumo entre las UCFs y la red secundaria de BT.

Así la Fig. 2 muestra, el modelo de **Gerenciamiento de Consumo Residencial** (GCR) con aplicación de procedimientos operacionales automatizados o servicios que obedecen al Gerenciamiento Interno Operacional (GIO) de SG de BT dirigidos a sus consumidores finales.

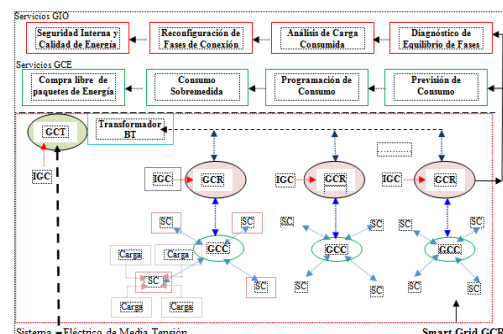


Fig. 1. Modelo GCR de SG de BT.

Los servicios GIO permiten la medición y tratamiento de consumo además de garantizar y realizar: la “*seguridad interna y calidad de energía*” en la infra-estructura interna de las UCFs, la “*reconfiguración de fases de conexión*” de los consumidores finales, el “*análisis de carga consumida*” en cada fase de las UCFs; y el “*diagnóstico de equilibrio de fases de los consumidores finales*”.

Por otro lado los servicios de GCE garantizan y realizan: la “*previsión de consumo*”; la “*programación de consumo*” con mejores horas de uso de energía; el “*consumo sobre-medida*”; la “*compra libre o suelta de paquetes de energía*”, todos en función del perfil futuro de consumo.

El flujo interno operacional del modelo GCR se inicia, con la adquisición del consumo de cada carga interna, a través del *Scanner de Carga* (SC) localizado en los terminales internos

de corriente de la UCF; transmitiendo ese consumo al dispositivo *Gerente Central de Carga* (GCC), que transfiere vía comunicación *wireless*, la lectura de consumo de las cargas al *Gerente de Consumo Residencial* (GCR), ubicado en el medidor de cada UCF. Dentro de este son realizados los servicios de la inteligencia GCR propuesta, ejecutando entre otras aplicaciones: la *supervisión en tiempo real del consumo interno* de cada consumidor, el *tratamiento para previsión de consumo de energía*, y el *diagnóstico de concentración de carga* en cada fase de conexión. El GCR transmite la información de las aplicaciones de consumo de cada UCF al *Gerente de Consumo del Transformador* (GCT) dispositivo que concentra la medición, tratamiento, previsión y diagnóstico de fases del circuito de BT. Este puede transferir en tiempo real el perfil de consumo del circuito de forma precisa al sistema de distribución de Media Tensión.

3. ALGORITMOS DE RECONFIGURACIÓN AUTOMÁTICA DE FASES EN SG DE BT

Las inteligencias de GCE pueden tener diversas aplicaciones según el tipo de ejecución, de las rutinas y servicios GIO y GCE deseados. Sin embargo en función de las investigaciones desarrolladas en la infra-estructura de SG de BT. Estas pueden ser agrupadas en cuatro clasificaciones importantes, e.g Nguyen et al, (2013): “Inteligencias de Activación de Carga (IAC)”, “Inteligencias de Supervisión de Consumo (ISC)”, “Inteligencias de Previsión de Consumo (IPC)” e, “Inteligencias de Reconfiguración de Fases (IRF)”.

3.1 Inteligencias de Reconfiguración de Fases

Las Inteligencias de Reconfiguración de Fases (IRF) visan garantizar, el estado de equilibrio de las fases de conexión y de las fases del transformador. Las IRF de un modo general tienen una arquitectura conforme es indicada en la Fig.2.

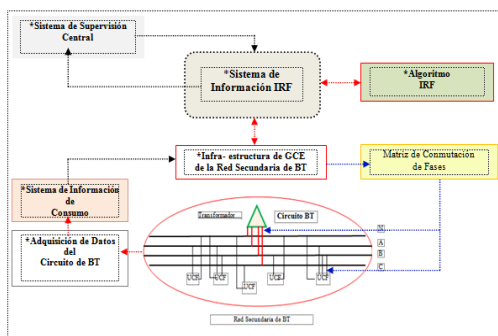


Fig. 2. Arquitectura de Inteligencias IRF.

El algoritmo IRF se aloja como componente del sistema de información IRF, que recibe los datos de consumo de carga o energía, a través del sistema de información de consumo; este recibe las informaciones provenientes del sistema de adquisición de datos del circuito de BT, que adquiere de hecho los datos de consumo de la red secundaria de BT (transformador y UCFs).

Después del procesamiento de la inteligencia IRF, esta retorna al sistema de información IRF (como servicio

interno), realizando el diagnóstico del estado de equilibrio de las fases, con su respectiva instrucción de conmutación para la RAF (transformador y/o UCFs). Repasando esa información a la infra-estructura del circuito de BT, bajo la forma de matriz de conmutación de fases, que será aplicada respectivamente, en las fases del transformador y/o de las fases de las UCFs.

4. INTELIGENCIA GCR

La inteligencia de Gerenciamiento de Consumo Residencial (GCR) es modelada con dos *Macro-agentes de Procesamiento Específico* (MAPEs) con algoritmos empotrados, cuya implementación se hace con ambientes computacionales distintos. Cada MAPE atiende servicios GIO y GCE relacionados con la previsión de consumo y la reconfiguración de fases, e.g. Sicchar et al (2013).

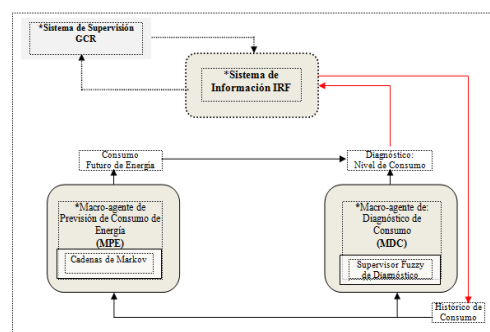


Fig. 3. Arquitectura de la Inteligencia GCR.

4.1 Macro-agente de Previsión de Consumo de Energía

La Fig. 4 presenta, el modelo de concepción del Macro-agente de Previsión de Energía (MPE) aplicado para UCFs. El MPE es basado en el modelado de transición de estados de cadenas de salto de *Markov*.

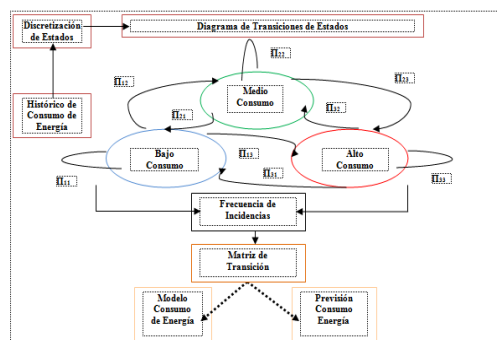


Fig. 4. Modelo del MPE.

Se parte de un histórico de consumo de energía como memoria del proceso, contando con un proceso de discretización de estados de consumo, para el registro de incidencias probabilísticas, o sea, la dinámica del proceso es denotada por la transición probabilística en los estados de consumo discretos. Son considerados tres posibles “ π ” estados de consumo en cada fase “ $CF\pi$ ”: bajo consumo “ BC ”, consumo medio “ CM ” y alto consumo “ AC ”. Con “ π_{ij} ” combinaciones de transición de estados probabilísticos.

Para la formulación de los estados de consumo es considerada, la aproximación sugerida por de Oliveira (2010). Que denota un coeficiente de dispersión aleatorio “ ρ ” para estados discretos *Markovianos*.

Este es obtenido, a partir de la definición de la variancia aleatoria “ σ_x ” que es determinada por el producto de la incidencia de “ nX_i ” del mayor desvío, con el cuadrado de la diferencia de la medida con mayor desvío (módulo) “ X_i ” con su media “ m_x ”, dividido por las “ N ” mediciones de consumo en un determinado espacio de tiempo como indicado en “(1)”.

$$\sigma^2_x = \lim_{n \rightarrow \infty} \frac{(X_i - m_x)^2 n X_i}{N} \quad (1)$$

Luego, el coeficiente de dispersión de los estados discretos de consumo “ ρ ” es definido por

$$\rho \cong \frac{\sqrt{\sigma_x}}{100} \quad (2)$$

A partir de la media de consumo que forma el estado “*Medio Consumo*” (MC) y “ ρ ” se forman los demás estados discretos.

Para “*Bajo Consumo*” (BC) se tiene

$$BC = M_c - (M_c \cdot \rho) \quad (3)$$

Por analogía para “*Alto Consumo*” (AC) se tiene

$$AC = M_c + (M_c \cdot \rho) \quad (4)$$

Luego es posible obtener el modelo de previsión de consumo “ $CF\pi(n+m)$ ” indicado en “(5)”, para cada fase de UCF.

Esta es definida por la probabilidad de salto “ j ”, en función de la probabilidad de un estado anterior “ i ” y del nivel de consumo también anterior “ $CF\pi(k)$ ”.

$$\begin{aligned} (C_{F\pi})_{ij}^{(n+m)} &= \sum_{k=0}^{\infty} (C_{F\pi})_{ik}^{(n)} (C_{F\pi})_{kj}^{(m)} \\ \forall (n, m) &\geq 0 \end{aligned} \quad (5)$$

La previsión de consumo de energía es realizada con la “*estacionariedad*” del proceso visando obtener las mejores probabilidades de “*concatenación*” de las cadenas de *Markov*, durante el proceso de previsión, como indica “(6)”.

$$(C_{F\pi})_{ij}^{(n)} = \sum_{k=0}^{\infty} (C_{F\pi})_{ik}^{(n)} (C_{F\pi})_{kj}^{(n-1)} = \{C_{F\pi n} = k\} \quad (6)$$

donde:

$$(C_{F\pi})_{ij}^{(n)} = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases}$$

La *estacionariedad* del proceso es conseguida con “ n ” pasos de iteraciones sucesivas, como se indica en “(7)”.

$$(C_{F\pi})_{ij}^{(n)} = \underbrace{(C_{F\pi})_{ij} \cdot (C_{F\pi})_{ij} \cdot (C_{F\pi})_{ij} \cdot \dots \cdot (C_{F\pi})_{ij}}_{\text{"n" pasos}} = (C_{F\pi})_{ij}^n \quad (7)$$

En la “*expresión (8)*” se indican las probabilidades de transición de paso “ n ” de “ i ” hasta “ M ” futuros estados, o sea, un modelo *Markoviano* para el consumo residencial de energía eléctrica de “ F ” fases para UCFs.

$$(C_{F\pi})_{ij}^{(n)} = \begin{bmatrix} (C_F)_{00}^{(n)} & (C_F)_{01}^{(n)} & (C_F)_{02}^{(n)} & \dots & (C_F)_{0M}^{(n)} \\ (C_F)_{10}^{(n)} & (C_F)_{11}^{(n)} & (C_F)_{12}^{(n)} & \dots & (C_F)_{1M}^{(n)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ (C_F)_{M0}^{(n)} & (C_F)_{M1}^{(n)} & (C_F)_{M2}^{(n)} & \dots & (C_F)_{MM}^{(n)} \end{bmatrix} \quad (8)$$

A partir de este modelo, es iniciado el proceso de previsión de consumo de energía, siguiendo las etapas del algoritmo indicado a seguir: i) Inicio del proceso. Se hacen varias iteraciones visando la estacionariedad del proceso, y la determinación de la matriz estacionaria (para seleccionar las mejores probabilidades de concatenación) durante la previsión. ii) Caso no se obtenga la estacionariedad, se procesan más iteraciones hasta encontrarla; iii) Generación de los saltos de transición para proyectar el consumo anual actual y las previsiones de consumo, a partir de la matriz estacionaria; iv) Simulación de las curvas de consumo para confronto de las trayectorias de las mediciones reales, con las trayectorias de la variable del modelo.

4.2 Macro-agente de Diagnóstico de Consumo

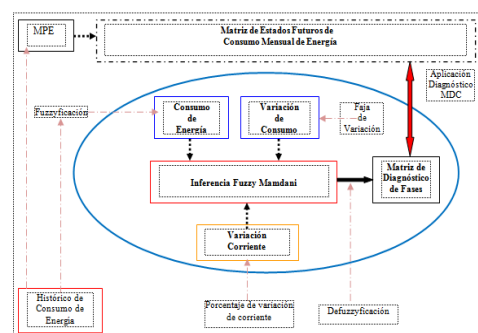


Fig. 5 Modelo del MDC.

El modelo del Macro- agente de Diagnóstico de Consumo (MDC) es mostrado en la Fig. 5. Este es formado por un supervisor *Fuzzy* “*Mamdani*”. Este es alimentado a partir del histórico de consumo, con dos variables antecedentes: “*Consumo de Energía*” y “*Variación de Consumo*”. La salida es la “*Variación de Corriente*” permitida en cada fase. El objetivo es detectar las reglas de inferencia, en función de la faja de los valores límites de corriente eléctrica. Esto forma la matriz de diagnóstico de fases, cuyo resultado es aplicado para diagnóstico en la matriz de estados futuros de energía del MPE; y apunta la conmutación cuando los niveles de corriente estén próximos del límite de corriente permitido en cada fase.

5. RESULTADOS

Los resultados del modelo GCR fueron obtenidos a través de un banco de datos de una UCF trifásica de la red de distribución de Manaus, cuyo consumo por fases corresponde al período de 2005-2008, con granularidad de colecta mensual. Fueron realizadas simulaciones de validación del modelo para 48 meses, y simulaciones de previsión de consumo de 12 meses futuros (2009), sumando al todo “60 pasos” a partir de la matriz estacionaria del MPE.

El modelado de previsión de consumo de energía basado en cadenas de *Markov* fue desarrollado en el ambiente *Mathcad* 14.0, y el supervisor de identificación de diagnóstico del nivel de corriente, a través de una máquina *Fuzzy Mamdani*, en el *toolbox* específico del ambiente *Matlab* 7.9.

5.1 Resultados de Implementación del MPE

Para los ensayos de validación experimental fueron empleados, los siguientes valores (estados discretos).

Tabla 1. Estados Discretos de Consumo

ρ	BC (kwh)	MC (kwh)	AC(kwh)
0,35	83,19	127,99	172,79

A partir de estos fueron obtenidas las matrices de transición para cada fase de la UCF conforme "(5)". En las simulaciones de previsión de energía fue aplicado el algoritmo indicado del MPE. El desempeño de los datos reales es representado por incidencias "azules", y el desempeño del modelo GCR por incidencias vacías "rojas", siendo adoptados tres valores discretos: "0" para *bajo consumo*, "1" para *consumo medio*, y "2" para *alto consumo*.

En la Fig. 6 presentamos la simulación del consumo mensual y previsión de energía, en la Fase A de la UCF evaluada. El modelo de previsión obtuvo en este caso, un patrón de eventos bastante similar a los datos de medición, evidenciándose una validación eficiente (precisión 72,92%) y, una buena margen de previsión de consumo futuro (precisión de 75%).

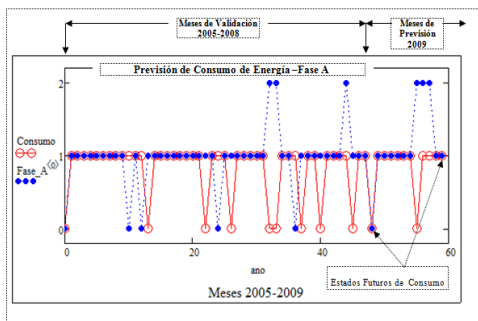


Fig. 6 Trayectoria de consumo de energía - Fase A.

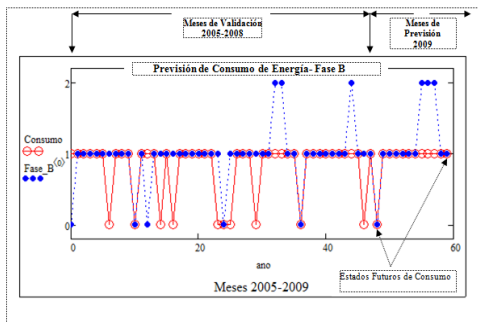


Fig. 7 Trayectoria de consumo de energía - Fase B.

La Figura 7 muestra la simulación de validación de consumo en la Fase B. Habiendo también un patrón de eventos bastante similar, con el perfil de los datos reales. Se registró una validación eficiente del modelo (precisión de 75%); también con buena margen de previsión de consumo futuro (precisión de 75%).




Fig. 8 Trayectoria de consumo de energía - Fase C.

De forma análoga, la Figura 8 muestra la simulación de validación de consumo en la Fase C. Registrándose también un patrón de eventos bastante similar, con el comportamiento de los datos reales. Verificándose una validación eficiente del modelo (precisión de 70,83%); y también una muy buena margen de previsión de consumo futuro (precisión de 83,33%).

La Tabla 2 presenta la matriz de estados de consumo futuro (año 2009) en cada fase de la UCF experimental. Habiendo sido colocados con asterisco los valores de consumo que no coincidieron con los datos reales del proceso.

Tabla 2. Matriz de Estados de Consumo para 2009

Meses	Fase A	Fase B	Fase C
Enero	BC	BC	BC
Febrero	MC	MC	BC
Marzo	MC	MC	BC
Abril	MC	MC	BC
Mayo	MC	MC	BC
Junio	MC	MC	MC
Julio	MC	MC	MC
Agosto	BC*	MC*	MC
Septiembre	MC*	MC*	MC
Octubre	MC*	MC*	MC*
Noviembre	MC	MC	MC*
Diciembre	MC	MC	BC

5.2 Resultados de Implementación del MDC

La Tabla 3 muestra las condiciones limites para conmutación de fases. Así para "BC" tiene una variación de consumo de 30%, el valor de variación de corriente es siempre menor que 30%(valor límite permitido) no habiendo conmutación; cuando "CM" tiene una variación de consumo de 32%, su valor de corriente estará próximo de 30% por lo tanto cerca del desequilibrio de carga; ya cuando "AC" tiene una variación de consumo, su valor de variación de corriente será mayor que 30%, por lo tanto indicando conmutación de fases.

Tabla 3. Condiciones límites para Conmutación

“BC”	“Var-Carga” (0,30)	“Var-Corrente” <0.30
“CM”	“Var-Carga” (0,32)	“Var-Corrente” ≈0,30
“AC”	“Var-Carga” (0,35)	“Var-Corrente” >0,30

Seguidamente con las condiciones límites para análisis de conmutación de fases y con los valores de los estados futuros de consumo en cada fase, es posible, obtener un diagnóstico de los niveles de consumo de energía para las fases; así mostramos a seguir únicamente los resultados obtenidos para la Fase A. Habiéndose sin embargo, aplicado para las fases B y C un procedimiento semejante.

La Tabla 4, muestra el Diagnóstico de los niveles de consumo de la Fase A para cada mes del año experimental de 2009. Indicándose en la mayor parte de los meses situación “Normal” de los niveles de consumo. Sin embargo, se indica la situación de “Conmutar” para los meses de agosto, septiembre y octubre. A pesar de ser los meses de no haber coincidido con la previsión de estados futuros, los estados de consumo reales para estos tres meses son de alto consumo y considerando la concentración de “Variación de Consumo”, el diagnóstico indicado se hace pertinente para los meses de septiembre y octubre. Fallando solamente para el mes de agosto, donde la situación de diagnóstico debiera ser también de “Conmutar”.

Tabla 4. Diagnóstico de Consumo-Fase A para 2009

Mes	Consumo	Var-Consumo(%)	Situación
Enero	BC	0	Normal
Febrero	MC	0	Normal
Marzo	MC	3	Normal
Abril	MC	1	Normal
Mayo	MC	0	Normal
Junio	MC	0	Normal
Julio	MC	0	Normal
Agosto	BC*	35	Normal
Septiembre	MC*	36	Conmutar
Octubre	MC*	37	Conmutar
Noviembre	MC	22	Normal
Diciembre	MC	0	Normal

Para la Fase B se evidenciaron también tres situaciones de conmutación, en los meses de agosto, septiembre y de octubre respectivamente. Y que a pesar de ser los meses donde no se coincidió en la previsión de estados futuros de consumo (siendo de alto consumo en el perfil real), por los niveles de “Variación de Carga” bastante altos (44%,64% y 84% respectivamente en cada mes citado) el diagnóstico fue coherente. Ya en la Fase C, donde se tuvo el mejor índice de previsión de estados futuros de consumo, no se registró ninguna situación de conmutación (verificado con el perfil real de consumo).

6. CONCLUSIONES

Basados en los resultados encontrados, creemos que hemos establecido, las bases de una relación de evaluación de los límites de estado de equilibrio en las fases de conexión en UCFs. Notando especialmente que los resultados de previsión de estados de consumo del sistema propuesto tuvieron una gran mejoría, en función de la influencia de la variancia aleatoria del proceso. Esta mejoría se tornó fundamental en el diagnóstico de los niveles de consumo, habiendo en un contexto general arrojado resultados coherentes, en lo que se refiere a la necesidad de reconfiguración de fases. Siendo así validada la implementación satisfactoria de dos servicios de GCE orientados a consumidores finales de SG de BT.

Sin embargo sugerimos, la realización de más validaciones de la inteligencia presentada, en un número mayor de UCFs y en las fases del transformador de un mismo circuito de BT.

REFERENCIAS

- Bina, M.T. and Kashefi, A. (2011). Three-phase unbalance of distribution systems: Complementary analysis and experimental case study. *Electric Power and Systems*, volume (33), 817-826.
- de Oliveira, H. (2010). *Probabilidade e Processos Estocásticos*, parte 4, 380-472. UFPE, Recife, Brasil.
- Leão, R.P. S., Barroso, G.C., Sampaio, R.F., Almada, J.B., Lima, C.F.P., Rego, M.C.O., Antunes, F.L.M. (2011). The future of low voltage networks: Moving from passive to active. *Electric Power and Systems*, volume (33), 1506-1512.
- Nguyen, T.A., and Aiello M. (2013). Energy Intelligent buildings based on user activity: A survey. *Energy and Building*, volume (56), 244- 257.
- Shahnia, F., Wolfs, P.J., Ghosh, A. (2014). Voltage Unbalance Reduction in Low Voltage Feeders by Dynamic Switching of Residential Customers Among Three Phases. *IEEE Trans.on Smart Grid*, volume (5), 1318-1327.
- Sharma, I., Cañizares, C., Bhattacharya, K. (2014). Smart Charging of PEVs Penetrating Into Residential Distribution Systems. *IEEE Trans. on Smart Grid*, volume (5), 1196-1209.
- Sicchar, J., De Freitas, R., Silva, J.R., Da Costa, T.C.Jr., Cavalcante, M.I., Gomes, R.C. (2013). Inteligência HCR para Automação de Serviços em Smart Grids de Baixa Tensão. Proc. In XI SBAI 2013, 1-6, Fortaleza, Brasil.
- Siti, W.M., Jimoh, A., Nicolae, D. (2011). Distribution network phase load balancing as a combinatorial optimization problem using fuzzy logic and Newton-Rhapson. *Electric Power Systems Research*, volume (81), 1079-1087.