

INTELIGÊNCIA HCR PARA AUTOMAÇÃO DE SERVIÇOS EM SMART GRIDS DE BAIXA TENSÃO

JOSE R. SICCHAR¹, RODRIGO C. DE FREITAS¹, JOSÉ R. SILVA², CARLOS C. TAVARES JR.³, IDALINA M. CAVALCANTE¹, RAIMUNDO C. GOMES¹.

1. *Escola Superior de Tecnologia, Universidade do Estado do Amazonas, Av. Darcy Vargas, 1200, Parque Dez, CEP 69050-020, Manaus-AM, Brasil*
jvilchez@uea.edu.br rchoji@yahoo.com.br iamc.lina@gmail.com
rclaudio.gomes@gmail.com

2. *Design Lab, Depto. de Eng. Mecatrônica, Universidade de São Paulo Av. Prof. Melo Morais, 2231, CEP 05508-900 Butantã, São Paulo, SP, Brasil*
reinaldo@usp.br

3. *ITEC, Depto. de Eng. Elétrica, Universidade Federal do Pará Av. Augusto Corrêa, 01, CEP 66075-900 Guamá, Belém, PA, Brasil*
cartav@ufpa.br

Abstract— This paper presents the results of the Hybrid Residential Consumption (HRC) intelligence to services automation in residential smart grids. Which is implemented using embedded intelligent agents (EIA) aiming the energy managing consumption (EMC). The same has a forecast process based on jump Markov chain to the future energy consumption, and also by a Mamdani Fuzzy inference machine to equilibrium residential feeder's diagnosis. The results show the energy consumption forecasting during twelve months from history data base, and also an inference for allowed values of electrical current levels in each feeder. Thereby forming an intelligent automation process for low voltage smart grid that allow the applications of news services for residential consumers: the energy programming consumption, the costumed energy use, and the equilibrium state of residential feeders, as well as the losses reduction on electric energy distribution grid.

Keywords— Smart Grid, EMC, Embedded Intelligent Agents, Markov Chains, Fuzzy Systems.

Resumo— Este artigo apresenta, os resultados da inteligência Híbrida de Consumo Residencial (HCR) para automação de serviços de smart grids residenciais. A mesma é implementada com agentes inteligentes embarcados (AIE) e, focada no gerenciamento de consumo de energia (GCE). Conta com um processo de previsão baseado em cadeias de salto de *Markov* para o consumo futuro de energia, e com uma máquina de inferência *Fuzzy Mamdani* para o diagnóstico de equilíbrio dos alimentadores residenciais. Os resultados mostram a previsão de consumo de energia num período de doze meses a partir de um banco de dados de consumo de quatro anos, e também a inferência para valores permitidos dos níveis de corrente em cada alimentador. Formando assim um processo de automação inteligente em smart grids de baixa tensão, que permite a aplicação de novos serviços para o consumidor residencial: a programação de consumo de energia, o consumo de energia sobremedida, o estado de equilíbrio dos alimentadores residenciais, bem como a diminuição das perdas na rede de distribuição de energia elétrica.

Palavras-chave— Smart Grid, GCE, Agentes Inteligentes Embarcados, Cadeias de Markov, Sistemas Fuzzy.

1 Introdução

Atualmente a literatura científica indica, que em função da evolução de modelos e implementação de aplicações no cenário mundial, o estado da arte de smart grids (SG) aponta, para um processo de modernização e de reestruturação da integração funcional e operacional de todos os setores do sistema elétrico como um todo Nguyen (2013).

De acordo com essa observação, as especificações e requisitos técnicos indicados pelo *National Institute of Standard and Technologies*, NIST (2012) sugerem as bases para o desenvolvimento de modelos e arquiteturas e o fluxo de operações e serviços de SG. Em função dessas diretrizes, muitos modelos e arquiteturas aplicadas e em desenvolvimento, seguem as bases esboçadas e sugeridas por essas três importantes iniciativas, que a pesar da adoção de um padrão internacional, formam a linha de padronização de design de SG de geração, transmissão, distribuição

e, comercialização, adotada nos sistemas elétricos e, concessionárias de vários países. No caso particular da baixa tensão (BT), em especial no setor de consumo residencial, apreciam-se várias aplicações interessantes, destacando-se o caso, do desenvolvimento de inteligências ou *frameworks* focados no gerenciamento de *consumo de energia elétrica* (GCE), como uma validação do conceito base de “*inteligências*” de automação de processos do design moderno de SG residenciais e prediais, indicada por Corno (2012).

Tendo-se recentemente um forte avanço no referente ao gerenciamento de consumo residencial de energia, na forma de algoritmos que supervisionam e controlam o processo de consumo e previsão de energia, e o melhor horário de consumo Pippattanasamporn (2012) bem como a estabilidade em cada fase de conexão residencial Constanzo (2012). Todavia Nguyen (2013) ressalva a importância do desenvolvimento de inteligências para GCE em residências e prédios, por deixar bem definida, a integração entre essas inteligências e toda a arquitetura da SG, permitindo-se o gerenciamento ótimo das funcionalidades

des que conformam a mesma. Sendo um marco de melhoria no design de aplicações de modelos de SG de BT onde há apenas, supervisão e ativação automática de cargas, mas sem presença de alguma inteligência de GCE que otimize o processo Lo (2013).

Na concepção da ciência de serviços nota-se que é possível formular e modelar, o fluxo de operações e rotinas em uma SG de BT, Oliveira (2012) num modelo híbrido *Unified Modeling Language- Petri Nets* (UML-PN) das funcionalidades da SG, como serviços específicos, definindo um processo de automação inteligente para o *workflow* da mesma. Um serviço específico chama assim nossa atenção, o GCE das unidades consumidoras residenciais (UCRs) por: i) a aleatoriedade do consumo das mesmas e, ii) o fluxo de análise para previsão de demanda de energia no circuito de distribuição. Nesse sentido, os autores apresentaram uma proposta de inteligência de GCE em SG de BT, também como resultado de uma modelagem híbrida UML-PN. Porém focando-se na implementação da *inteligência* Sicchar (2012).

Propomos seguir o desenvolvimento dessa inteligência *Híbrida de Consumo Residencial* (HCR). Cujas implementações seguem o modelo proposto pelos autores na forma de dois *agentes inteligentes embarcados* (AIE): o *agente embarcado Markoviano* (AEM), para a previsão de consumo de energia e, o *agente embarcado Difuso* (AED), para o diagnóstico de sobrecorrente nas fases de conexão residencial.

Neste artigo focamos a previsão de consumo de energia, num período de doze meses, bem como a formulação de uma inferência eficiente de diagnóstico de nível de corrente, nas fases de conexão residencial baseada no histórico de consumo.

Objetivando com isso, a identificação eficiente, do perfil de consumo futuro, bem como a definição precisa dos níveis de corrente permitidos nas fases de conexão para o estado de equilíbrio das mesmas. Esses objetivos estabelecem um fluxo inteligente de automação dos serviços da SG de BT, em especial, no consumo futuro de energia, consumo de energia sobremedida, programação de uso de energia e, a análise do estado de equilíbrio das fases de conexão da residência, garantindo, um consumo ótimo de energia, customizado e com qualidade e segurança.

O artigo segue na sua segunda seção, o estudo do comportamento aleatório no consumo residencial; na terceira seção mostra um modelo alternativo de SG com foco em serviços para aplicação da proposta; na quarta seção aborda-se, a arquitetura HRC sobre o conceito de AIE; na quinta seção, se têm a discussão dos resultados de validação; finalmente apresenta-se a conclusão e indicação de trabalhos futuros.

2 Estudo do comportamento aleatório no consumo residencial de energia

Baseados na definição de Morettin (2006) quem indica que o desempenho das trajetórias das variáveis aleatórias (v.a) de um processo estocástico de um sistema real qualquer, num determinado espaço de tempo periódico comum, formam uma dita série temporal, neste artigo adotamos este critério para justificar, a aplicação da inteligência proposta, demonstrando a *estocacidade* do consumo de energia, na BT, isto é, nas residências. Assim a Figura 1 mostra os perfis de consumo num circuito de BT da rede local de distribuição de Manaus. Neste estudo consideramos apenas, o perfil, de 3 UCRs, com tipos diferentes de conexão: monofásica, bifásica e trifásica respectivamente.

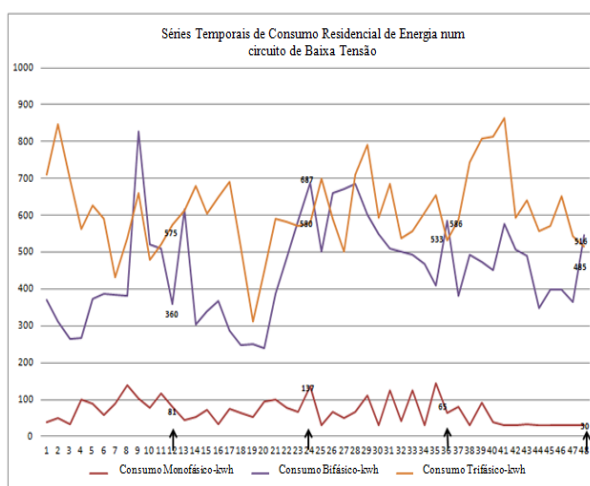


Figura 1. Perfis de Consumo num circuito de distribuição de BT

Os perfis de consumo apresentam trajetórias diferenciadas, por ano. Observando-se uma provável repetição de comportamento no tempo. Num horizonte, de 48 meses em cada UCR notam-se trajetórias de consumo com picos máximos e descidas, num período de 12 meses. No primeiro ano identifica-se um decréscimo de consumo nas UCRs monofásica e bifásica respectivamente com acréscimo de consumo, na UCR trifásica. No segundo ano, há acréscimo de consumo de energia nas UCRs monofásica e bifásica, mas com queda de consumo na UCR trifásica. No terceiro ano, se têm queda de consumo na UCR trifásica, porém com aumento de consumo nas UCRs monofásica e bifásica. Finalmente no quarto ano, identifica-se acréscimo de consumo apenas na UCR bifásica, com queda de consumo na UCR trifásica e *estacionariedade* de consumo na UCR monofásica.

Evidenciando-se uma periodicidade bem demarcada entre o segundo, e terceiro ano; trajetória de tendência de repetição do período anterior, entre o terceiro e quarto ano. Ou seja, para esse processo de consumo a partir do segundo ano, identifica-se periodicidade de repetência de trajetórias ao longo do tempo, isto é, séries temporais de consumo residencial, que podem ser representadas por “(1)”. O vetor

“ C_{Res} ” a partir de um conjunto de dados “ T ”, em função do tempo “ t_i ” denota, os perfis de consumo periódicos a partir do segundo ano, das trajetórias de cada perfil nas “UCR-M” monofásica, “UCR-B” bifásica e, “UCR-T” trifásica respectivamente, através de uma variável aleatória própria “ $C_{URC-j}(t)$ ”.

$$[c_{Res}, t_i = [C_{UCR-M}(t_i), C_{UCR-B}(t_i), C_{UCR-T}(t_i)]$$

$$\text{onde: } C_{Res} = \{C_{URC-j}(t), t \in T / t \in T, C_{URC-j}(t)\} \quad (1)$$

A *estocacidade* do processo pode ser analisada com o diagrama *boxplot* de consumo das três UCRs, Figura 2, via a observação do grau de variância de consumo, em cada residência.

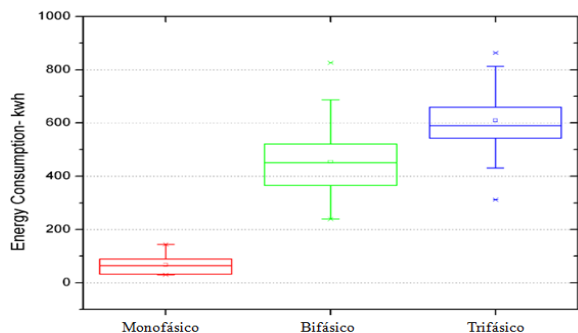


Figura 2. Variância de Consumo em UCRs de um circuito de BT

Há maior grau de variância no perfil das UCRs trifásica e bifásica respectivamente, e na UCR monofásica, grau de variância bastante pequeno. Tal comportamento pode ser causado por várias razões: uso de energia por horários, ocupação de espaços, temperatura do dia, estação do ano, etc. Com essa observação, temos um indicio interessante do comportamento *estocástico* do consumo residencial de energia, concentrado fortemente, nas UCRs trifásica e bifásica, o que conduz a estabelecer, que o processo tem *estocacidade* moderadamente acentuada. Sendo possível aplicar a teoria de cadeias de *Markov*, para a modelagem do processo, e sua previsão de consumo de energia.

3 Modelo GCR de SG para serviços de GCE

A revisão literária indica varias iniciativas de modelos e implementação de arquiteturas de SG de BT (prédios e residências) no mundo inteiro Lo (2013) mostrando interessantes vantagens, mas poucas delas com a aplicação de algoritmos de GCE. Nesse sentido apresentamos uma sugestão na Figura 3, o modelo de Gerenciamento de Consumo Residencial (GCR) com aplicação de rotinas operacionais automatizadas para a medição e tratamento de consumo, focando a realização de dois serviços GCE importantes: a “previsão de consumo” e o “diagnóstico de equilíbrio nas fases” de conexão nas UCRs. A partir dos mesmos, são gerados os serviços funcionais ao consumidor. Tendo-se a partir da “Previsão de Consumo”: a *programação de consumo* por melhores horas de uso de energia, o *consumo sobre-*

medida, a compra avulsa de pacotes de energia, ambos em função do perfil futuro de uso de energia e; a partir do “Diagnóstico de Equilíbrio nas Fases”: a *análise de carga consumida* em função da sobrecorrente presente em cada fase de conexão, o *balanceamento de fases* quando necessário uma vez diagnosticado desequilíbrio nas mesmas e, a *segurança e qualidade interna* nas instalações dos circuitos elétricos internos de cada UCR, em função da supervisão e diagnóstico periódico de equilíbrio das fases de conexão.

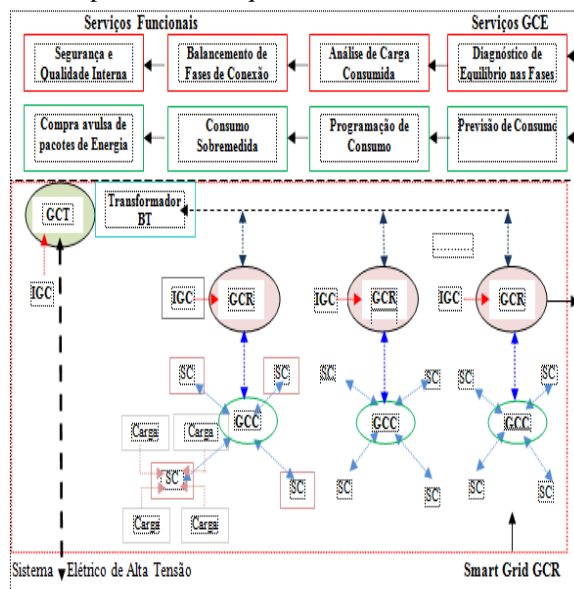


Figura 3. Modelo GCR de SG de BT focado nos serviços de GCE

O fluxo interno de operação das aplicações dos serviços de GCE inicia-se com a aquisição de consumo de cada carga, através de um dispositivo denominado *scanner de carga* (SC) alocado nas tomadas internas de corrente da UCR, os mesmos transmitem o consumo ao dispositivo *gerenciador central de carga* (GCC), que transfere via comunicação *wireless*, a leitura de consumo das cargas ao *gerenciador de consumo residencial* (GCR), alocado no medidor de cada UCR. É nele que são aplicados os serviços da inteligência HCR proposta, realizando entre outras aplicações: a supervisão em tempo real do consumo interno de cada UCR, o tratamento para previsão de consumo de energia, e o diagnóstico de concentração de carga em cada fase de conexão, podendo fazer entre outras aplicações automatizadas, a comutação eletrônica de balanceamento de fases. O GCR transfere a informação das aplicações e de consumo de cada UCR ao *gerenciador de consumo do transformador* (GCT) dispositivo que concentra a medição, tratamento, previsão e diagnóstico de fases de distribuição do circuito de BT. O mesmo pode transferir em tempo real o perfil de consumo do circuito de forma precisa ao sistema de distribuição de alta tensão (AT).

4 Arquitetura HCR implementada com AIE

A inteligência HCR têm 2 agentes de processamento inteligente para atingir os objetivos de GCE. Os agentes são ambientes supervisórios que contêm algoritmos de processamento específico Sicchar (2012) tendo ambientes diferenciados de processamento computacional para cada um dos objetivos propostos. A Figura 4 mostra a arquitetura HCR com o agente *Markoviano embarcado* (AME) que modela o comportamento dinâmico e faz a previsão do consumo residencial com as probabilidades de incidência de cada estado discreto de consumo, via cadeias de salto de Markov e; o agente *Difuso embarcado* (ADE) que implementa na previsão de consumo do AME (em função do histórico de consumo) os níveis permitidos de corrente em cada fase, via a matriz de diagnóstico de fases. A inteligência HCR é implementada na forma de IGC do modelo GCR.

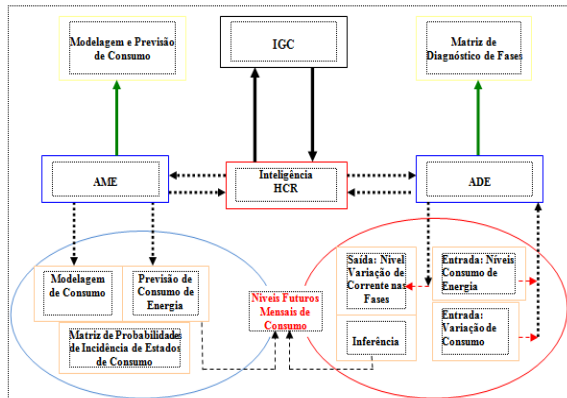


Figura 4. Arquitetura HCR para SG de BT

4.1 AME

As séries temporais de consumo de energia em UCRs são baseadas na modelagem de transição de estados de cadeias de salto de Markov mostrada na Figura 5. Partindo-se de um histórico de consumo de energia, como referencia inicial ou memória da modelagem do sistema de Oliveira (2010).

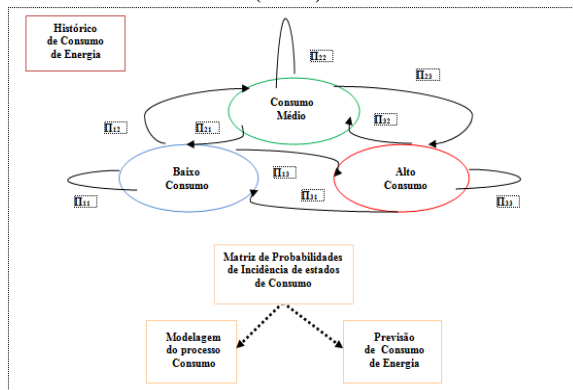


Figura 5. Diagrama de Transição de Estados do AME

Consideram-se 3 possíveis “ π ” estados de consumo em cada fase “ $C_{F\pi}$ ”: baixo consumo “ C_{BC} ”, consumo médio “ C_{CM} ” e alto consumo “ C_{AC} ” com “ π_{ij} ” combinações de transição de estados probabilís-

ticos. Obtendo-se o modelo de previsão de consumo “ $C_{F\pi}^{(n+m)}$ ” indicado em “(2)”, em cada fase de UCR, definida pela probabilidade de salto “ j ”, em função da probabilidade do estado anterior “ i ” e do nível de consumo também anterior “ $C_{F\pi}^{(k)}$ ”.

$$\left(C_{F\pi} \right)_{ij}^{(n+m)} = \sum_{k=0}^{\infty} \left(C_{ik} \right)^{(n)} \left(C_{kj} \right)^{(m)} \quad (2)$$

$$\forall (n, m) \geq 0$$

A previsão de consumo é realizada com a *estacionariedade* do processo para obter as melhores probabilidades de transição de previsão, como indica “(3)”.

$$\left(C_F \right)_{ij}^{(n)} = \sum_{k=0}^{\infty} \left(C_{ik} \right)^{(n)} \left(C_{kj} \right)^{(n-1)} = \left\{ C_n = k \right\} \quad (3)$$

onde:

$$\left(C_F \right)_{ij}^{(n)} = \begin{cases} 1 & \text{se } i = j \\ 0 & \text{se } i \neq j \end{cases}$$

A *estacionariedade* é obtida com “ n ” passos de iterações sucessivas, como indica “(4)”.

$$\left(C_F \right)_{ij}^{(n)} = \underbrace{\left(C_{ij} \right)^x \left(C_{ij} \right)^x \left(C_{ij} \right)^x \dots \left(C_{ij} \right)^x}_{\text{"n" passos}} = \left(C_{ij} \right)^n \quad (4)$$

Em “(5)” se mostram as probabilidades de transição de passo “ n ” de “ i ” até “ M ” futuros estados, isto é, um modelo *Markoviano* para o consumo residencial de energia elétrica de “ F ” fases para UCRs.

$$\left(C_F \right)_{\pi_{ij}}^{(n)} = \begin{bmatrix} \left(C_F \right)_{00}^{(n)} & \left(C_F \right)_{01}^{(n)} & \left(C_F \right)_{02}^{(n)} & \dots & \left(C_F \right)_{0M}^{(n)} \\ \left(C_F \right)_{10}^{(n)} & \left(C_F \right)_{11}^{(n)} & \left(C_F \right)_{12}^{(n)} & \dots & \left(C_F \right)_{1M}^{(n)} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \left(C_F \right)_{M0}^{(n)} & \left(C_F \right)_{M1}^{(n)} & \left(C_F \right)_{M2}^{(n)} & \dots & \left(C_F \right)_{MM}^{(n)} \end{bmatrix} \quad (5)$$

O mesmo é o ponto de partida, para o processo de previsão indicado na Figura 6. O fluxo é iniciado pela matriz de incidência de estados, antes de gerar a matriz estacionária.

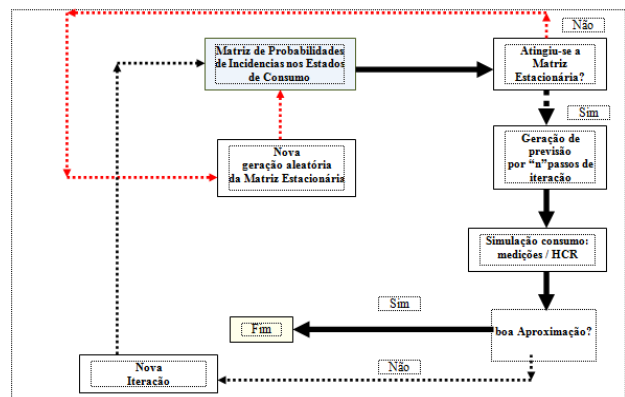


Figura 6. Algoritmo de previsão de consumo do AME

Caso não se obtenha um bom grau de *estacionariedade*, processam-se mais iterações, até encontrar o mesmo. Gerando-se os saltos de iteração *Markoviana* para obter o consumo atual e as previsões de consumo. Obtendo-se a simulação das curvas de consumo: medições reais, versus modelo HCR.

4.2 ADE

O *workflow* do ADE mostrado na Figura 7 baseia-se numa inferência *Fuzzy* “*Mamdani*”. O modelo é alimentado a partir do histórico de consumo, com duas variáveis antecedentes: “*Consumo de Energia*” e “*Variação de Consumo*”. Sendo a variável de saída a “*Variação de Corrente*” permitida em cada fase. Podendo assim detectar pelas regras de inferência, a faixa dos valores limites de corrente elétrica em cada fase formando a *matriz de diagnóstico de fases*, cujo resultado é aplicado para diagnóstico na *matriz de estados futuros de energia* do AME, apontando a comutação quando as mesmas estiverem próximas ou já tiverem ultrapassado o limite de corrente permitido em cada fase. Estabelecendo-se uma relação confiável de diagnóstico de equilíbrio de fases. Gerando a base de uma sequência robusta de fases balanceadas, para médio e longo prazo.

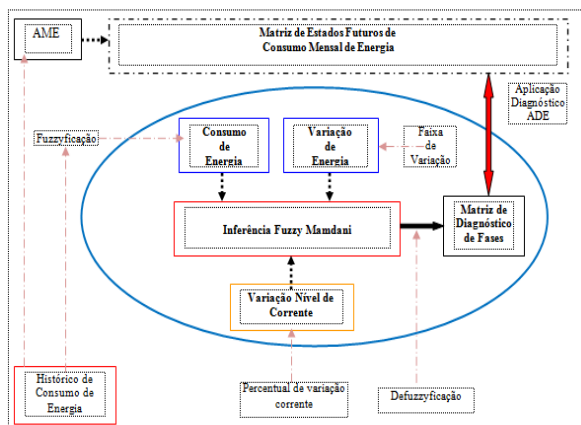


Figura 7. Algoritmo de Diagnóstico de Equilíbrio do ADE

5 Resultados

Os resultados do modelo HCR foram obtidos através de um banco de dados de uma UCR de ligação trifásica da rede de distribuição de Manaus, cujo consumo por fases corresponde ao período de 2005-2008. Tendo sido realizadas simulações de validação do modelo para os 48 meses, e simulações de previsão de consumo de 12 meses futuros (2009), somando assim “60 passos” a partir da matriz estacionária do AME. Na validação da hipótese foi aplicada a metodologia da seção 4. O sistema de modelagem e previsão de consumo de energia baseado em cadeias de *Markov* foi feito no software *Mathcad 14.0*, e a inferência de identificação de diagnóstico de faixas de corrente nas fases via uma máquina *Fuzzy Mamdani*, no toolbox específico do *Matlab 7.9*.

4.1 Resultados de implementação do AME

Após um processo de discretização dos níveis de consumo do banco de dados do período experimental (2005-2009) focando os estados de consumo do AME e a incidência probabilística de cada possível combinação gerada pelos três estados discretos (BC, CM, AC) foi obtida, a matriz de incidências de esta-

dos para cada fase conforme “(5)”. Nas simulações de previsão de energia foi aplicado o algoritmo indicado do AME indicando para cada fase, o desempenho dos dados reais pelas incidências “azuis”, e o desempenho do modelo HCR por incidências vazias “vermelhas”. Adotando três valores discretos: “0” para baixo consumo, “1” para consumo médio, e “2” para “alto consumo”.

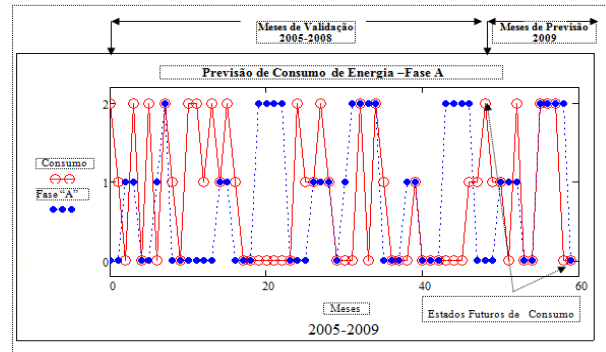


Figura 8. Trajetória de consumo de energia (2005-2009) Fase A

Na Figura 8 apresentamos a simulação de consumo mensal e previsão de energia elétrica, na Fase A da UCR experimental. O modelo *Markoviano* obteve neste caso, um padrão de eventos bastante similar aos dados de medição. Estabelecendo-se uma validação eficiente do modelo.

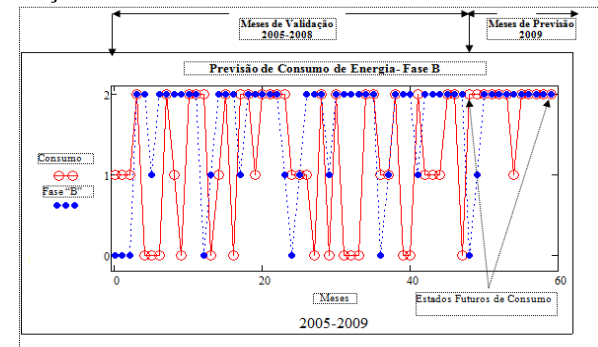


Figura 9. Trajetória de consumo de energia (2005-2009) Fase B

A Figura 9 e 10 mostram as simulações de consumo e previsão mensal de energia nas Fases B e C respectivamente, da UCR. As performances do modelo indicam também, perfil similar ao da medição. Tendo-se para este caso também validações eficientes do modelo.

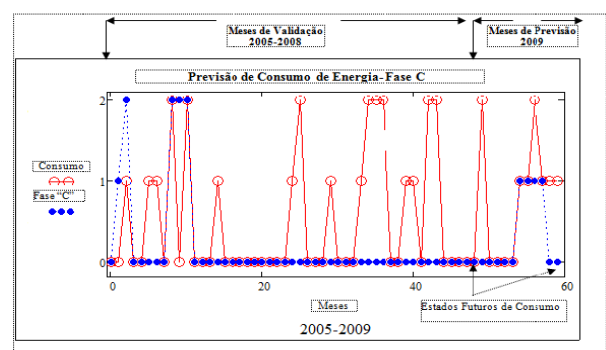


Figura 10. Trajetória de consumo de energia (2005-2009) Fase C

4.2 Resultados de implementação do ADE

O agente ADE foi implementado de acordo com o modelo da Figura 7. O resultado experimental mostra o limite de consumo de energia permitida para cada nível de consumo: *BC*, *MC*, *AC* nas fases, identificando 12% de variação de corrente permitido nos alimentadores, e limite máximo de variação de energia de 30% em todos os níveis de consumo, isto é, a regra de equilíbrio para as fases. No caso de se evidenciar variação de energia de 50%, se terá uma variação de corrente maior que 12% conforme indica a Tabela 1, isto é, fora do valor permitido tendo-se, portanto um estado de desequilíbrio nas fases, procedendo-se nesse caso ao serviço funcional de *comutação eletrônica de balanceamento de fases*.

Tabela 1. Regras de Diagnóstico de Equilíbrio de Fases em UCRs.

Consumo Energia (kWh)		Varição Energia (%)	Varição Corrente (%)
BC	103	0,30	0,12
		0,50	0,36
MC	145	0,30	0,12
		0,50	0,37
AC	249	0,50	0,12
		0,50	0,61

Na Tabela 2 se mostra o diagnóstico nas três fases para 2009, caso nas mesmas se ultrapasse o valor de 50% de variação de energia.

Tabela 2. Matriz de Estados Futuros de Consumo em 2009.

Mês	Fase A	Fase B	Fase C	Var Carga%	Diagnóstico
Jan	BC	BC	BC	0,50	Comutação
Fev	BC	CM	BC	0,50	Comutação
Mar	CM	AC	BC	0,50	Comutação
Abr	CM	AC	BC	0,50	Comutação
Mai	CM	AC	BC	0,50	Comutação
Jun	BC	AC	BC	0,50	Comutação
Jul	BC	AC	CM	0,50	Comutação
Ago	AC	AC	CM	0,50	Comutação
Set	AC	AC	CM	0,50	Comutação
Out	AC	AC	CM	0,50	Comutação
Nov	AC	AC	BC	0,50	Comutação
Dez	BC	AC	BC	0,50	Comutação

5 Conclusão

Pelos resultados encontrados, acreditamos que estabelecemos as bases de uma relação de avaliação dos limites de estabilidade nas fases de conexão em UCRs, em função do seu histórico de consumo, a partir do qual também é possível prever o consumo futuro de energia num horizonte de um ano, com desempenhos bastante confiáveis. Tendo-se em sumula a implementação satisfatória de dois serviços de GCE, que podem auxiliar utilmente os serviços funcionais apresentados neste trabalho, entre eles o serviço de *previsão de carga* e de *análise de carga*, a

partir dos resultados aqui mostrados. Entretanto sugerimos, todavia a realização de mais validações da inteligência proposta, num numero maior de UCRs, com os demais tipos de conexão num mesmo circuito de BT. Reforçando a previsão com a aplicação de outros algoritmos de previsão, entre eles as redes neurais de *Kohonen* por sua refinada taxa de precisão de mineração preditiva de dados.

Agradecimentos

Agradecemos à FAPEAM, UEA, UFPA e USP por tornarem possível a realização deste trabalho.

Referências Bibliográficas

- Constanzo, G.T; Zhu G; Anjos M.F; Saward, G (2012). A System Architecture for Autonomous Demand Side Load Management in Smart Buildings. IEEE Transactions on Smart Grid, Vol.3, No 4, pp. 2157-2165.
- Corno, F; and Razzak F (2012). Intelligent Optimization for User Intelligible Goals in Smart Home Environments. IEEE Transactions on Smart Grid, Vol.3, No.42, pp. 2128- 2135.
- de Oliveira, H, 2010, Probabilidade e Processos Estocásticos, parte 4, Processos Estocásticos Específicos, pp. 380-472. PPGEE UFPE.
- Lo, C-H; and Ansari N (2013). Decentralized Controls and Communications for Autonomous Distribution Networks in Smart Grid. IEEE Transactions on Smart Grid, Vol.4, No.1, pp. 66-77.
- Morettin, P e Toloi C. (2006). Análise de Séries Temporais. 2ª ed. Ed.Blucher, São Paulo- SP.
- Nguyen, T.A, e Aiello M (2013). Energy Intelligent buildings based on user activity: A survey. Elsevier, Energy and Building Journal, Vol.56, pp. 244- 257, to be published.
- NIST, 2012, NIST Framework and Roadmap for Smart Grid Interoperability Standards, Release 2.0.NIST special publication 1108R2.
- Oliveira, V; Sicchar, J; Salmon, A; Silva J, Set 2012, "Automação e Ciência de Serviço aplicada em Smart Grid" in Proc. 2012 XIX CBA, CGC, PB, Brasil, pp. 1-6.
- Pipattanasomporn,M; Kuzlu, M; Rahman S (2012). An Algorithm for Intelligent Home Energy Management and Demand Response Analysis. IEEE Transactions on Smart Grid, Vol.3, No.4, pp. 2166-2173.
- Sicchar, J.R; Tavares, C; Silva J.R; de Freitas, R.C; Santos, J.J; Nascimento C; Rosas F, Set, 2012, "Arquitetura IGCR para Gerenciamento de Consumo Residencial de Energia," in Proc. 2012 XIX CBA, CGC, PB, Brasil, pp. 1-6.