

Estimador de Estado para Redes de Distribuição utilizando Inferência Bayesiana

L. B. M. Pinheiro e P. I. Ekel
Pontifícia Universidade Católica de Minas Gerais
leobmpin@hotmail.com e pekel@superig.com.br

W. Z. Guerra
Universidade Federal de Ouro Preto, UFOP
willgusch@gmail.com

Resumo—Neste trabalho aplicou-se a Inferência Bayesiana e o método de Monte Carlo para estimar o estado de uma rede de distribuição de energia elétrica, visando a magnitude de tensão. Foi considerada a existência de poucos equipamentos de medição em tempo real, os quais possuem canais de medição de tensão, de corrente e/ou de potência ativa e reativa. O baixo número de medições *online* representa um diferencial, quando comparadas com técnicas encontradas na literatura, além de sua fácil implementação e reduzido esforço computacional. Para validar a metodologia foram utilizadas uma rede de 33 e outra de 202 barras do IEEE.

Palavras-Chave— *Estimação de Estados, Inferência Bayesiana, Monte Carlo, Sistemas de distribuição*

I. INTRODUÇÃO

Nos tempos atuais, o conhecimento da operação em tempo real de um sistema de energia elétrica (SEE) é de grande necessidade, já que auxilia os operadores na tomada de decisões, visando manter a operação do SEE com índices de segurança e confiabilidade adequados.

Nas últimas décadas, o investimento em automação da operação foi voltado para os sistemas de geração e transmissão de energia elétrica (STEE), permitindo o desenvolvimento de modelos próprios de estimação de estado (EE) para esses sistemas. Na literatura pesquisada encontram-se diferentes trabalhos, sendo um dos primeiros o apresentado em [1], no qual se utiliza o método de Mínimos Quadrados Ponderados (MQP ou WLS, do inglês: *Weighted Least Square*), cuja sua aplicação, tornou-se amplamente utilizado por outros trabalhos na procura de solução do problema de EE [1, 2, 3].

Por outro lado, a recente modernização dos sistemas de distribuição de energia elétrica (SDEE) visa uma operação inteligente da rede elétrica (do inglês: *Smart Grid*), através da instalação de equipamentos de medição e automação. Isto gera o desafio de estimar a operação da rede em tempo real.

Considerando que os SDEE possuem características operacionais e físicas próprias, tais como: $R > X$, operação radial ou fracamente malhada, rede desbalanceada, número de barras bem maior, entre outros, estas características fazem com que os modelos aplicados aos STEE apresentem problemas quando aplicados aos SDEE. Além dos poucos equipamentos de medição que inviabilizam a utilização dessas técnicas.

Na literatura apresentam-se diversos trabalhos que utilizam modelos de fluxo de carga voltados para SDEE. Um dos primeiros é proposto em [4], no qual são utilizadas medições remotas em tempo real. Todas as grandezas são transformadas em medidas equivalentes de corrente. Muitas medições

são resultado de curvas de carga, além de utilizar medições angulares das correntes. Já em [5] a abordagem do SDEE é trifásica e utilizou-se MQP para resolver o sistema de equações que representam a EE. Em [6] também foi usada uma formulação trifásica e resolvida pelo método de MQP. São definidas como variáveis de estado as tensões nodais e as correntes das cargas do SDEE. Em [7] utiliza-se um fluxo de carga monofásico que modifica as equações de Newton-Raphson para aplicação em redes radiais. Em [8] é proposto um EE baseado em fluxo de carga probabilístico, onde as medições em tempo real são modeladas como restrições. Os resultados são validados através da análise de Monte Carlo. Em [9] propõe-se um estudo estocástico para estimar os níveis de tensão afetados pela conexão de geradores distribuídos no SDEE. Em [8, 10], os autores introduzem modelos estocásticos para a demanda de energia e de geração distribuída utilizando variáveis não gaussianas. Em [11], os autores comparam três técnicas baseadas no método de MQP, no Mínimo Valor Absoluto Ponderado (MVAP ou WLAV, do inglês: *Weighted Least Absolute Value*) e a combinação destas duas, sendo que o primeiro MQP apresenta melhor desempenho. Em [12] os autores utilizam a meta-heurística: Otimização por Nuvens de Partículas. Esta abordagem é baseada na utilização de Compensadores Estáticos e Geradores Distribuídos, cujas características são não-lineares e impossibilita a utilização de métodos clássicos de fluxo de carga.

O objetivo deste trabalho é a aplicação da Inferência Bayesiana e o método de Monte Carlo, para resolver o problema de EE visando o módulo de tensão, o qual é um índice de qualidade de energia elétrica [13]. São apresentados os resultados (eficiência, robustez, esforço computacional e análise de sensibilidade) para uma rede de 33 e outra de 202 barras do IEEE.

II. INFERÊNCIA BAYESIANA

A Inferência Bayesiana é baseada na utilização de um operador estatístico que descreve as incertezas ocultas de forma probabilística. Sua utilização permite levar em consideração as modificações de incertezas no tempo após observação de novos dados. Em outras palavras, a Inferência Bayesiana calcula a probabilidade posterior de acordo com a regra de Bayes, que é a seguinte [14]:

$$P(\Theta/x) = \frac{P(\Theta \cap x)}{P(x)} = P(\Theta) \frac{P(x/\Theta)}{P(x)} \quad (1)$$

onde Θ é qualquer hipótese; x é a evidência de novos dados que não foram utilizados no cálculo da probabilidade anterior;

$P(\Theta)$ é a probabilidade *a priori* de Θ antes de x ser observado (isso é uma estimativa *a priori*); $P(\Theta/x)$ é a estimativa ou probabilidade *a posteriori* de Θ dado x ; $P(x/\Theta)$ é a estimativa ou probabilidade de observar x dado Θ ; $P(x)$ é chamado de probabilidade marginal.

A regra de Bayes permite combinar novas evidências (informações) sobre os dados anteriores. A Fig. 1 ilustra três distribuições de probabilidade, sendo a cor azul os dados esperados, a cor verde os dados *a priori* e a cor vermelha os dados *a posteriori* aplicando a inferência Bayesiana.




Fig. 1: Funções de distribuição de probabilidade aplicando Inferência Bayesiana.

Nota-se em 1, que a probabilidade *a posteriori* não depende de Θ , e funciona como uma constante normalizadora de $P(\Theta/x)$. Para um valor fixo de x , a função fornece a plausibilidade ou verossimilhança de cada uma dos possíveis valores de Θ enquanto $P(\Theta)$ é chamada de distribuição *a priori* de Θ .

Estas duas fontes de informação, *priori* e verossimilhança, são combinadas levando à distribuição *a posteriori* de Θ , $P(\Theta/x)$. Assim, uma forma equivalente de 1 é $P(\Theta/x) \propto P(\Theta; x)P(\Theta)$, a qual é entendida como “*Dist. Posteriori a Verossimilhança x Dist. Priori*”. O que evidencia que a distribuição *a posteriori* de um parâmetro contém toda a informação probabilística a respeito do mesmo. Dessa forma, toda a inferência com respeito ao parâmetro é realizada por meio desta distribuição, pois a partir de seus valores centrais, se tem as estimativas de interesse.

Ao se tratar de parâmetros que são representados por curvas de distribuição normal [15] para *a priori* e para as observações, teremos $\Theta \sim N(\mu, \sigma^2)$ e $(Y/\Theta) \sim N(\Theta, r^2)$, onde a distribuição *a posteriori* de Θ é também normal, ou seja, $(\Theta/Y = y) \sim N(\mu_{ajustado}, r_{ajustado})$ é ajustada através das seguintes expressões:

$$\mu_{ajustado} = \frac{\sigma^{-2}\mu + r^{-2}Y}{\sigma^{-2} + r^{-2}} \quad (2)$$

$$(r_{ajustado})^{-2} = \sigma^{-2} + r^{-2} \quad (3)$$

Assim, verifica-se que a precisão ou inverso da variância conota informação, ou seja, a relação, mede a informação contida na *priori* em relação à informação total (*priori* e verossimilhança). Dessa forma, pode-se escrever, que a média da *posteriori* equivale à média ponderada pela certeza na *priori* e na verossimilhança. Verifica-se também que a precisão ($r_{ajustado}$) da *posteriori* equivale à soma das precisões da *priori* e da verossimilhança.

III. MÉTODO DE MONTE CARLO

O método de simulação de Monte Carlo tem sido aplicado em todos os campos do conhecimento. Consiste em um processo de geração de números aleatórios (designado pela letra U) empregando qualquer distribuição de probabilidade, permitindo estimar o comportamento de um sistema ou de um processo que envolve variáveis estocásticas [16]. U deve cumprir as propriedades de uniformidade e independência. Uma vez determinado U , pode-se gerar uma observação da variável aleatória de interesse. Em particular, qualquer função de distribuição de probabilidade avaliada em qualquer valor x é igual a um número entre 0-1, representado da seguinte forma:

$$F(x)=U \quad (4)$$

Desta forma, obtém-se uma observação da variável x encontrada a função inversa da distribuição de probabilidade:

$$x=F^{-1}(U) \quad (5)$$

Para o caso do problema neste trabalho, U , representa as potências ativas e reativas conectadas às barras. Para o critério de parada escolhido foi aplicado um coeficiente de variação estatístico [17] através da seguinte expressão:

$$C_V = \frac{\sigma}{\mu} \quad (6)$$

onde, σ = Desvio Padrão e μ = Valor Médio. O valor de C_V deve estar na faixa de 5% a 6%.

IV. MÁXIMA VEROSSIMILHANÇA

De acordo com [18], o princípio da estimativa da Máxima Verossimilhança (MLE, do inglês: *Maximum-Likelihood Estimation*) é um método para estimar os parâmetros de um modelo estatístico, ou seja, dado um conjunto de dados (módulos de tensões nas barras) e um modelo estatístico, o MLE estima os valores dos diferentes parâmetros do modelo estatístico de maneira a maximizar a probabilidade dos dados observados (isto é, busca parâmetros que maximizem a função de verossimilhança). O MLE apresenta-se como um método geral para estimação de parâmetros, principalmente no caso de distribuições normais, que serão utilizadas neste trabalho.

V. METODOLOGIA

A. Algoritmo de fluxo de potência probabilístico

Aplicando o método de simulação de Monte Carlo (descrito no item III) é gerada uma observação de P e Q nas barras (U). Com os dados desta observação é realizado um fluxo de carga determinístico. O fluxo de carga determinístico utilizado é o *backward/forward sweep* [19], sendo amplamente utilizado na análise de sistemas de redes de distribuição de energia elétrica. Uma vez calculados os módulos de tensão ($|V|$) em todas as barras, estes resultados são guardados. Com os resultados guardados do fluxo determinístico e utilizando a MLE descrito no item IV, são determinados os módulos das tensões e seus respectivos desvios. A Fig. 2 ilustra o algoritmo de fluxo de carga probabilístico (as equações utilizadas estão em [20]).

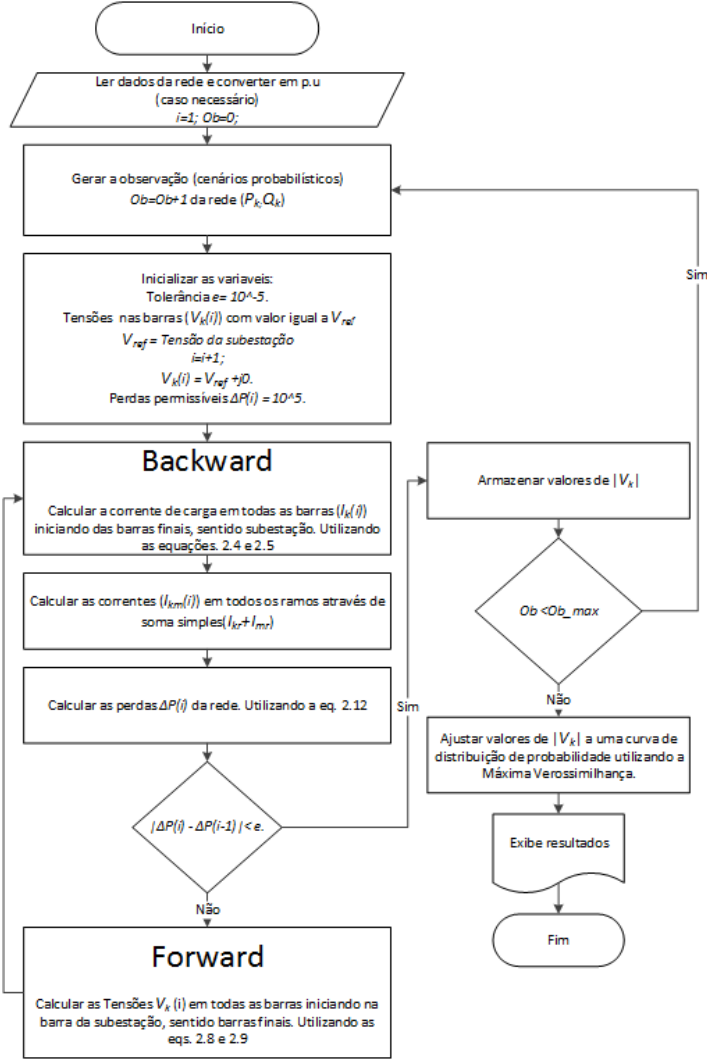


Fig. 2: Algoritmo Fluxo de Carga Probabilístico

VI. ESTIMAÇÃO DE ESTADOS

Com a existência de equipamentos de medição em alguns pontos da rede elétrica, é possível reduzir a incerteza dos resultados no cálculo do fluxo de potência probabilístico, para o qual, são utilizados os conceitos da Inferência Bayesiana acima descritos. Naqueles locais onde estão instalados medidores, é feito um ajuste dos parâmetros calculados no fluxo probabilístico com os parâmetros medidos, detalhados a seguir.

A. Ajuste da tensão

Na etapa *forward* do fluxograma da Fig. 2 são calculados (atualizados) os valores das tensões nas barras. Naquelas barras onde existem medidores de tensão é feito o ajuste proposto neste trabalho.




Fig. 3: Trecho de uma rede elétrica

Considerando na Fig. 3 a existência de um medidor de tensão na barra m , o ajuste é feito utilizando 2 e 3, da seguinte forma:

$$\sigma_{\text{corrigido}}^m = \frac{(\sigma_{\text{calculado}}^m)^{-2}}{(\sigma_{\text{calculado}}^m)^{-2} + (\sigma_{\text{medidor}}^m)^{-2}} \quad (7)$$

$$X_{\text{corrigido}}^m = X_{\text{calculado}}^m + \sigma_{\text{corrigido}}^m (X_{\text{medidor}}^m - X_{\text{calculado}}^m) \quad (8)$$

onde, σ = Desvio Padrão e X = Tensão (V).

É considerado um valor elevado para $\sigma_{\text{calculado}}^m$. Uma vez obtido $V_{\text{corrigido}}^m$, este passa a ser $V_{\text{calculado}}^m$ e o processo de fluxo de carga probabilístico continua.

B. Ajuste da Corrente

Na etapa *backward* do fluxograma da Fig. 2 são calculados (atualizados) os valores das correntes nos trechos. Naqueles trechos onde existem medidores de corrente são feitos os ajustes de correntes utilizando as mesmas expressões do ajuste de tensão. Considerando na Fig. 3 a existência de um medidor (I_{km}) no trecho km , são utilizadas 7 e 8 para o ajuste, onde $X = I_{km}$. Considera-se também um valor de $\sigma_{\text{calculado}}^m$ elevado. Uma vez obtido $I_{\text{corrigido}}^{km}$, este passa a ser $I_{\text{calculado}}^{km}$ e o processo de fluxo de carga probabilístico continua.

C. Ajuste do Fluxo de Potência

É necessário relacionar os parâmetros P_{km} e Q_{km} (lidos nos medidores) com os parâmetros utilizados no Fluxo de Carga de Varredura. Para isso, são calculadas as potências (P_{km} e Q_{km}) naqueles trechos onde existem medidores de fluxo de potência, através das seguintes expressões:


$$S_{km} = P_{km} + jQ_{km} = V_k I_{km}^* \quad (9)$$

Considerando na Fig. 3 a existência de um medidor de fluxo de potência P_{km} e/ou Q_{km} , o ajuste é feito utilizando 7 e 8, onde X assume valores de P_{km} e/ou Q_{km} . Também são considerados desvios elevados para P_{km} e Q_{km} calculado.

Após obtidos os valores de $P_{\text{corrigido}}^{km}$ e/ou $Q_{\text{corrigido}}^{km}$, estes passam a ser $P_{\text{calculado}}^{km}$ e/ou $Q_{\text{calculado}}^{km}$. Com estes valores é obtida a tensão na barra m utilizando a expressão [21]:

$$V_m^4 + [2(r_{km}P + x_{km}Q) - V_k^2]V_m^2 + (P^2 + Q^2)(r_{km}^2 + x_{km}^2) = 0 \quad (10)$$

Onde existem medidores, o bloco *forward* do fluxograma da Fig. 2 deverá ser substituído pelo da Fig. 4.

Fig. 4: Bloco *forward* modificado

VII. APLICAÇÃO DA METODOLOGIA

A implementação computacional da metodologia foi desenvolvida na linguagem de programação *Matlab* e testada em duas redes, de 33 barras e 202 barras. Foi considerada nas redes, a existência de medidores com canais de medição de tensão, corrente e/ou fluxo de potência, nos quais os desvios padrões considerados foram 2%. São mostrados os dados das redes na Tabela I.

TABELA I: DADOS DAS REDES DE DISTRIBUIÇÃO

Dados das redes de distribuição			
Rede	33 barras	202 barras	
Nº de barras	33	202	
V operação (kV)	12,6	13,8	
Tipo de Consumidores	Industrial, Comercial e Residencial	Industrial, Comercial e Residencial	
Modelo das cargas	Potência Constante	Potência Constante	
Desvio padrão P	40%	40%	
Desvio padrão Q	20%	20%	

A. Rede de 33 Barras

Nesta rede [22] ilustrada na Fig. 5 foi considerada a existência de 4 medidores de tensão, (barras 1, 3, 6 e 8) alocados na saída da subestação, nos ramos e no tronco da rede (as bolas pretas são medidores de |V|).




Fig. 5: Rede de 33 Barras

A rede foi analisada operando com carregamento pesado ($|V|_{\text{subestação}} = 0,95$ p.u.), ou seja, as cargas foram alteradas para 2,0 e 1,3 vezes os valores iniciais de P e Q respectivamente.

Na Tabela II se apresenta resultados do desempenho da metodologia. Já na Tabela III se mostra os resultados em cada barra, aplicando fluxo probabilístico e Inferência Bayesiana. Na última coluna desta tabela se indica a queda de tensão real.

TABELA II: RESULTADOS - REDE DE 33 BARRAS

Desempenho da Metodologia - Rede de 33 barras	
Carregamento	Pesado
Nº de barras com V na faixa crítica (Cargas reais)	21
Barras com medidores	1,3,6,8
Nº de fluxo determinísticos	20
Tempo de convergência[s]	2,657
Nº de barras ajustadas nas seguintes curvas:	
Distribuição Normal	25
Distribuição Lognormal	0
Distribuição Weibull	7

TABELA III: RESULTADOS EM CADA BARRA - REDE DE 33 BARRAS

Barra	Tensões Reais	Tensões Fluxo Probabilístico		Tensões Fluxo Probabilístico (Inferência Bayesiana)		Queda Tensão
	V [p.u.]	V [p.u.]	Desvio [p.u.]	V [p.u.]	Desvio [p.u.]	DV
1	0,9500	0,9500	0,0000	0,9500	0,0000	0,0000
2	0,9450	0,9454	0,0004	0,9450	0,0005	0,5267
3	0,9205	0,9236	0,0024	0,9205	0,0000	3,1065
4	0,9071	0,9119	0,0033	0,9084	0,0011	4,5180
5	0,8939	0,9002	0,0043	0,8963	0,0022	5,9077
6	0,8627	0,8723	0,0072	0,8631	0,0000	9,1942
7	0,8576	0,8673	0,0077	0,8583	0,0004	9,7258
8	0,8481	0,8588	0,0088	0,8480	0,0001	10,7292
9	0,8361	0,8487	0,0099	0,8381	0,0014	11,9944
10	0,8250	0,8393	0,0109	0,8288	0,0029	13,1577
11	0,8233	0,8379	0,0111	0,8274	0,0032	13,3406
12	0,8200	0,8353	0,0115	0,8249	0,0036	13,6853
13	0,8075	0,8254	0,0129	0,8154	0,0056	15,0028
14	0,8030	0,8220	0,0133	0,8119	0,0062	15,4789
15	0,7996	0,8197	0,0137	0,8097	0,0065	15,8326
16	0,7961	0,8175	0,0140	0,8074	0,0070	16,1967
17	0,7915	0,8143	0,0144	0,8041	0,0077	16,6816
18	0,7897	0,8133	0,0146	0,8031	0,0080	16,8736
19	0,9443	0,9447	0,0004	0,9442	0,0005	0,0001
20	0,9394	0,9394	0,0013	0,9388	0,0011	1,1159
21	0,9385	0,9384	0,0014	0,9378	0,0013	1,2076
22	0,9376	0,9375	0,0016	0,9370	0,0015	1,3099
23	0,9149	0,9182	0,0037	0,9149	0,0017	3,6928
24	0,9052	0,9085	0,0068	0,9043	0,0049	4,7186
25	0,8998	0,9031	0,0088	0,8990	0,0065	5,2842
26	0,8591	0,8695	0,0074	0,8600	0,0005	9,5719
27	0,8544	0,8657	0,0078	0,8558	0,0012	10,0646
28	0,8349	0,8497	0,0096	0,8382	0,0040	12,1141
29	0,8209	0,8381	0,0112	0,8257	0,0061	13,5866
30	0,8141	0,8331	0,0120	0,8200	0,0073	14,3010
31	0,8066	0,8274	0,0126	0,8131	0,0086	15,0895
32	0,8052	0,8261	0,0127	0,8116	0,0089	15,2473
33	0,8045	0,8257	0,0127	0,8112	0,0089	15,3112

A Fig. 6 ilustra o perfil de tensões da rede com dados reais, com dados com incerteza elevada (elevado desvio padrão) e com valores corrigidos.




Fig. 6: Perfil de Tensões - Rede 33 Barras

Observa-se maiores erros naquelas barras com nível de tensão na faixa crítica, nas quais os módulos de tensão corrigidos ficam mais próximos dos valores reais. Também é ilustrado na Fig. 7 o resultado da barra 33 (barra final), na qual a tensão real é 0,8045 p.u.




Fig. 7: Resultado na barra 33

B. Rede de 202 Barras

Esta rede [22] ilustrada na Fig. 8 possui 3 alimentadores, na qual foram alocados 3 medidores/alimentadores e um na subestação, totalizando 10 medidores (barras 1, 10, 25, 43, 70, 102, 122, 138, 171, e 190). Num primeiro cenário foi considerado que os medidores possuem só canais de tensão. Já num segundo cenário foram adicionados canais de corrente em 3 medidores (10, 70 e 138). As bolas pretas são medidores de $|V|$ e os quadrados são medidores de $|I|$.




Fig. 8: Rede de 202 Barras

Para os testes, foi considerado que esta rede opera com carregamento normal ($|V|_{\text{subestação}} = 1,00$ p.u.) e pesado ($|V|_{\text{subestação}} = 0,95$ p.u.), pelo qual foram multiplicadas as cargas (P e Q) vezes 2,0 e 1,3. As Tabelas IV e V mostram os resultados obtidos considerando só medidores de tensão e considerando medidores de tensão e corrente.


TABELA IV: RESULTADOS GERAIS - REDE DE 202 BARRAS (MEDIDORES DE $|V|$)

Desempenho da Metodologia - Rede de 202 barras - Medidores de tensão		
Carregamento	Normal $ V = 1,00$ p.u.	Pesado $ V = 0,95$ p.u.
Nº de barras com $ V $ na faixa crítica (Rede incerta)	0	189
Nº de barras com $ V $ na faixa crítica (Rede estimada)	0	189
Barras com medidores	1,10,25,43,70,102,122,138,171,190	1,10,25,43,70,102,122,138,171,190
Nº de fluxo determinísticos	22	24
Tempo de convergência[s]	14,002	28,052
Nº de barras ajustadas nas seguintes curvas:		
Distribuição Normal	114	149
Distribuição Lognormal	0	0
Distribuição Weibull	87	52

TABELA V: RESULTADOS GERAIS - REDE DE 202 BARRAS (MEDIDORES DE $|V|$ E $|I|$)

Desempenho da Metodologia - Rede de 202 barras - Medidores de tensão e corrente		
Carregamento	Normal $ V = 1,00$ p.u.	Pesado $ V = 0,95$ p.u.
Nº de barras com $ V $ na faixa crítica (Rede incerta)	0	186
Nº de barras com $ V $ na faixa crítica (Rede estimada)	0	185
Barras com medidores	1,10(I),25,43,70(I),102,122,138(I),171,190	1,10(I),25,43,70(I),102,122,138(I),171,190
Trecho com medidores de $ I $	10,70,138	10,70,138
Nº de fluxo determinísticos	25	24
Tempo de convergência[s]	16,096	21,374
Nº de barras ajustadas nas seguintes curvas:		
Distribuição Normal	172	149
Distribuição Lognormal	0	0
Distribuição Weibull	29	52

As Figs. 9 e 10 ilustram o perfil de tensões para os dois cenários. Considerou-se que a rede opera em um patamar de carga pesada.

Fig. 9: Perfil de Tensões Carregamento Pesado (medidores de $|V|$) - Rede 202 Barras

Na Fig. 10, observa-se que o impacto dos medidores de corrente nos valores corrigidos de tensão é baixo. Isso é devido a influência do parâmetro I na queda de tensão no trecho.




Fig. 10: Perfil de Tensões Carregamento Pesado (medidores de $|V|$ e $|I|$) - Rede 202 Barras

VIII. CONCLUSÃO

Neste trabalho apresentou-se a aplicação da Inferência Bayesiana no processo de cálculo de fluxo probabilístico visando a estimação do módulo de tensão nas barras de uma rede de distribuição de energia elétrica, através de um ajuste probabilístico de tensão, corrente e/ou fluxo de carga naqueles locais que possuem medidores.

A metodologia foi aplicada em duas redes elétricas (33 e 202 barras), nas quais os resultados foram satisfatórios, já que foram corrigidos valores de tensão com baixa incerteza, além de utilizar tempos computacionais razoáveis: 20 fluxos determinísticos para 33 barras e, entre 22 a 25 para 202 barras.

Uma das vantagens da técnica utilizada é a necessidade de contar com poucos medidores instalados nas redes elétricas, quando comparadas com a literatura (elevado número de medidores).

Desta forma a metodologia proposta representa uma ferramenta para estimação do módulo de tensão, auxiliando a tomada de decisões, no que se refere principalmente ao controle de reativos na rede elétrica.

Como trabalhos futuros, a metodologia deverá ser implementada em redes trifásicas, assim como o desenvolvimento de técnicas de alocação ótima de medidores.

IX. REFERÊNCIAS

- [1] F. C. Schweppe, "Power System Static-State Estimation, Part I, II and III", *IEEE Transactions on Power Apparatus and Systems*, New York, v. PAS-89, n. 1, p. 120-135, 1970.
- [2] A. Monticelli, "State Estimation in Electric Power Systems: A Generalized Approach", *Massachusetts: Kluwer*, 394 p., 1999.
- [3] A. Gomez-Exposito, A. Abur, A. De La Villa Jaen, and C. Gomez-Quiles, "A multilevel State Estimation Paradigm for Smart Grids", *Proceedings of the IEEE*, Seville, v. 99, n. 6, p. 952-976, June 2011.
- [4] I. Roytelman and S. M. Shahidehpour, "State Sstimation for Electric Power Distribution Systems in Quasi-Real Time Conditions", *IEEE Transactions on Power Delivery*, New York, v. 8, n. 4, p. 2009-2012, 1993.
- [5] M. Baran and A. Kelley, "A Branch-Current-Based State Estimation Method for Distribution Systems", *IEEE Transactions on Power Systems*, New York, v. 10, n. 1, p. 483-491, 1995.
- [6] A. Melipoulos, "Smart Grid Technologies for Autonomous Operation Control", *IEEE Transactions on Smart Grids*, New York, v. 2, n. 1, p. 1-10, 2011.
- [7] F. Zhang and C. S. Cheng, "A Modified Newton Method for Radial Distribution System Power Flow Analysis", *IEEE Transactions on Power Systems*, New York, v. 12, n. 1, p. 389-397, 1997.
- [8] A. K. Ghosh, D. L. Lubkeman, M. J. Downey, and R. J. Jones, "Distribution Circuit State Estimation Using A Probabilistic Approach", *IEEE Transactions on Power Systems*, New York, v. 12, n. 1, p. 45-51, 1997.
- [9] S. Chun-Lien, "Stochastic Evaluation of Voltages in Distribution Networks with Distributed Generation Using Detailed Distribution Operation Models", *IEEE Trans. Power Syst.*, vol. 25, no. 2, pp. 786-795, May 2010.
- [10] G. Valverde, T. Saric Andrija, and V. Terzija, "Stochastic Monitoring of Distribution Networks Including Correlated Input Variables", *IEEE Trans. Power Syst.*, vol. 28, no. 1, pp. 246-255, February 2013.
- [11] R. Singh, B.C. Pal, and R.A. Jabr Jabr, "Choice of Estimator for Distribution System State Estimation", *IET Generation, Transmission Distribution*, Vol. 3, Iss. 7, pp. 666-678, 2009.
- [12] S. Naka, T. Genji, T. Yura, and Y. Fukuyama, "Hybrid Particle Swarm Optimization for Distribution State Estimation", *IEEE Trans. Power Syst.*, vol. 18, no. 1, pp. 60-68, February 2003.
- [13] ANEEL, "Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional – PRODIST, Módulo 8 - Qualidade da Energia Elétrica", 2015.
- [14] M. S. Stephen, "Thomas Bayes's Bayesian Inference", *Journal of the Royal Statistical Society. Series A (General)*, Vol. 145, No. 2 (1982), pp. 250-258, Royal Statistical Society, 1982.
- [15] M. D. V. de Resende, "Inferência Bayesiana E Simulação Estocástica (Amostragem De Gibbs) Na Estimação De Componentes De Variância E De Valores Genéticos Em Plantas Perenes", *Colombo: Embrapa Florestas*, 68 p. (Embrapa Florestas. Documentos, 46), 2000.
- [16] R. Billinton and R. N. Allan, "Reliability Evaluation of Engineering Systems - Concepts and Techniques", *Plenum Press*, 1992.
- [17] A. M. Law and W. D. Kelton, "Simulation Modeling and Analysis 3. ed.", New York: *McGraw-Hill*, 745 p., 2000.
- [18] I. J. Myung, "Tutorial on Maximum Likelihood Estimation", *Journal of Mathematical Psychology* 47, 90-100, 2003.
- [19] C. S. Cheng, "A three Phase Power Flow Method for Real Time Distribution System Analysis", *IEEE Trans. on Power Systems*, New York, v.10, n.2, p.671-679, 1995.
- [20] A. C. Brandini, "Análise Crítica de Algoritmos de Fluxo de Carga Usados em Sistemas de Distribuição Radial", 2000.
- [21] R. Cespedes, "New Method for the Analysis of Distribution Networks", *IEEE Transactions on Power Delivery*, Vol. 5, No 1, pp 391-396, August 1990.
- [22] M. A. D. N. Guimarães, "Reconfiguração de Sistemas de Distribuição de Energia Elétrica utilizando Algoritmos de Busca Tabu", *Dissertação Mestrado UNICAMP*, 2005.