PREDITORES APLICADOS NA INICIALIZAÇÃO INTELIGENTE DO MÉTODO DA SOMA DE POTÊNCIAS EM SÉRIE TEMPORAL

Jéssica M. M. Henriques^{*}, Pedro H. M. de Andrade[†], Helon D. M. Braz[‡]

* Departamento de Engenharia Elétrica, UFPB, João Pessoa/Brasil Cidade Universitária, João Pessoa-PB, CEP:58.051-900

[†]Departamento de Engenharia Elétrica, UFPB, João Pessoa/Brasil Cidade Universitária, João Pessoa-PB, CEP:58.051-900

[‡]Departamento de Engenharia Elétrica, UFPB, João Pessoa/Brasil Cidade Universitária, João Pessoa-PB, CEP:58.051-900

Emails: jessica.henriques@cear.ufpb.br, pedro.andrade@cear.ufpb.br, helon@cear.ufpb.br

Abstract— The conventional analysis of the steady state power systems starts from the execution of the load flow, so we can analyze the behavior of the system. However, with the insertion of distributed generation, for example, the nature of the system becomes more intermittent. As a result of problems like this and also because of a greater availability of computational processing and memory that allows to perform actions that were previously unfeasible, the idea arises to execute a Load Flow in the Time Series, which opens the possibility of radyzing how the system varies daytime. In this paper, an algorithm was developed with the purpose of reducing the total number of iterations required for the load flow. So a analysis and implementation of predictors that make an intelligent initialization of the tensions in the network bars were carried out before running the load flow. The number of iterations required for convergence was then compared with the reference value, obtained without intelligent initialization of the load flow. For this analysis, data from a real system of 63 bars with real loading was used. The results presented proved the efficacy of the predictors with intelligent initialization.

Keywords— Time series power flow, power flow analysis, predictors with intelligent initialization.

Resumo— A análise convencional dos sistemas de potência em regime permanente é feita a partir da execução do fluxo de carga, onde podemos analisar o comportamento do sistema. Contudo, com a inserção da geração distribuída, por exemplo, a natureza do sistema passa a ser mais intermitente. A partir de problemas como esse e também de uma maior disponibilidade de processamento e memória que permitem realizar ações que antes eram inviáveis, surge a ideia de executar um Fluxo de Carga na Série Temporal, que abre a possibilidade de analisar como o estudo do sistema varia durante o dia. Neste trabalho, foi desenvolvido um algoritmo com o intuito de reduzir o número total de iterações necessárias no fluxo de carga. Para isso, foi feita a análise e implementação de preditores que fazem uma inicialização inteligente das tensões nas barras da rede antes de executar o fluxo de carga. O número de iterações necessárias para convergência foi então comparado com o valor de referência, obtido sem inicialização inteligente do fluxo de carga. Para essa análise, foram utilizados dados de um sistema real de 63 barras com carregamento real. Os resultados apresentados comprovaram a eficácia dos preditores com a inicialização inteligente.

Palavras-chave— Fluxo de carga temporal, análise de fluxo, preditores com inicialização inteligente.

1 Introdução

Um Sistema Elétrico de Potência (SEP) é formado basicamente pelos sistemas de geração, transmissão, distribuição e suas subestações de energia elétrica. O SEP é constituído por usinas geradoras, as quais transmitem a energia gerada através do sistema de transmissão em alta tensão, atingindo então os consumidores nos sistemas de distribuição de média e baixa tensão (Stevenson, 1978).

Atualmente, o SEP está evoluindo para redes elétricas inteligentes, conhecidas na literatura como *Smart Grids*. Isto é, uma rede estruturada em tecnologias digitais e de automação com o intuito de melhorar a eficiência operacional de todo o sistema (Sarno et al., 2014).

As redes elétricas inteligentes utilizam algoritmos de fluxo de potência ótimo para calcular o estado de operação do sistema de modo a reduzir as perdas, ajustar em tempo hábil as fontes de ativos e reativos na rede visando melhorar a qualidade da energia, promovendo assim, respostas imediatas às variações de carga (Bruno et al., 2011).

A análise do fluxo de carga fornece como resultado o estado operativo da rede em determinado momento e é possível avaliar se a mesma está operando de forma adequada. Em caso negativo, são estabelecidas as ações corretivas para solucionar os problemas. De fato, a análise de fluxo de potência é relevante em vários tipos de estudos de operação e planejamento por parte das concessionárias (Kagan et al., 2010).

A análise clássica dos sistemas de potência é feita a partir da execução de um número reduzido de fluxos de carga durante o dia, gerando "fotografias" do estado do sistema em momentos como carregamento máximo, mínimo e contingências principais. Analisando o sistema atual, diante da inserção crescente da Geração Distribuída (GD), essa metodologia poderia fornecer apenas o impacto momentâneo daquela fonte em dados instantes. Esse tipo de análise pode não ser mais suficiente, visto que as energias provenientes de fontes renováveis, tais como a energia solar e eólica, por exemplo, possuem uma natureza intermitente. De fato, a intermitência da GD acarreta intermitência no ponto de conexão da rede de distribuição em que quanto maior for a parcela de GD, maior será esse efeito.

Em virtude desse aumento na variação das características do sistema durante o dia, pode-se observar que a necessidade de avaliar os estados operativos do sistema de distribuição em intervalos menores de tempo torna-se cada vez maior, visto que será necessária uma regulação mais efetiva sobre a rede quanto à tensão nas barras, correntes nos equipamentos e continuidade de serviço, por exemplo.

Assim, a execução de um fluxo de carga em redes de distribuição na série temporal é uma estratégia de simulação que pode fornecer perfis de tensão, de acordo com o fornecimento de dados disponíveis da companhia de energia, permitindo uma melhor análise do sistema, pois irá considerar as variações na rede durante todo o período estabelecido e não apenas em situações pontuais.Além de que, outra vantagem inerente à análise temporal ocorre ao avaliar se determinado equipamento precisa ser substituído e até mesmo, avaliar a ordem de prioridade dessa substituição.

Diante do cenário exposto, o presente trabalho propõe a implementação de um fluxo de carga na série temporal utilizando o Método da Soma de Potência (MSP). Inicialmente, o algoritmo é usado sem uma inicialização inteligente e posteriormente, seis estratégias para inicialização inteligente da rede visando diminuir as iterações do algoritmo do MSP são implementadas e testadas. A proposta da inicialização inteligente é mitigar a carga computacional em cada execução do MSP e melhorar o tempo total de máquina.

2 Estado da Arte

Uma técnica de previsão, denominada Preditor PQ, baseada no Método de Lagrange é desenvolvida em (Selim et al., 2016), em que a magnitude da tensão é predita através das variações da potência reativa e os ângulos da fase são previstos a partir das variações da potência ativa.

A análise da série temporal em (Zeng et al., 2016) é feita através do algoritmo ARIMA que é muito utilizado para previsões de séries temporais ao criar um modelo que relaciona a variável de saída com seus valores anteriores.

Um estudo feito em (Boehme et al., 2007) analisa o impacto da inserção de turbinas eólicas em uma rede de distribuição radial sob diversas condições, através dos dados históricos da carga e da geração.

Em (Buragohain and Boruah, 2017) é utilizada a Lógica *Fuzzy* para desenvolver um modelo simples para a análise do fluxo de carga com uma solução mais rápida que o Método de Newton-Rapshon. Uma solução dos problemas de fluxo de carga utilizada em (Romero-Ramos et al., 2017) é a modificação do multiplicador ideal para o Método Rapshon com o intuito de melhorar as propriedades de convergência da metodologia. Uma nova distribuição de probabilidade do fluxo de carga é apresentada em (Ahmed et al., 2013) para estudar os efeitos da conexão de uma turbina eólica ao sistema de distribuição.

Em (Aly, 2015) são desenvolvidos três preditores baseados nos polinômios de Lagrange que são implementados neste trabalho com o objetivo de fazer um comparativo com outros três novos preditores propostos que são uma variação deles.

3 Método da Soma das Potências na Série Temporal

O Método da Soma de Potências (MSP) é um dos métodos de varredura mais comuns na literatura para sistemas elétricos com topologia radial. Esse método é reconhecidamente robusto, convergindo mesmo em redes extremamente carregadas; possui convergência rápida; e permite considerar com certa facilidade equipamentos como reatores, bancos de capacitores e reguladores de tensão, bem como modelar com maior precisão as cargas usando o modelo ZIP (Braz, 2010).

O MSP clássico é iterativo e parte da premissa de que todos os ramos têm perdas nulas e todas as barras têm tensão igual a da subestação 1 pu). Em cada iteração, o fluxo de potência é atualizado em uma varredura reversa e as tensões nas barras e perdas nos ramos são calculadas em uma varredura direta (Cespedes, 1990).

Os sistemas de distribuição operam, em sua grande maioria, na topologia radial. Neste trabalho, serão considerados apenas sistemas com essa topologia para as soluções do fluxo de carga. Para a análise de sistemas fracamente malhados podem ser usadas variações do MSP como em (Souza and Braz, 2016); e para sistemas fortemente malhados, usa-se algoritmos clássicos como Gauss-Seidel (GS) (Stagg and El-Abiad, 1968), Newton-Raphson (NR) (Tinney and Hart, 1967) e Desacoplado Rápido (DR) (Stott and Alsac, 1974).



Figura 1: Modelo de trecho da distribuição primária.



Figura 2: Fluxograma do Método da Soma de Potências.

Redes de distribuição radiais conexas podem ser modeladas exclusivamente por subestações e *trechos*. Um trecho é formado por uma barra e o ramo através do qual a barra é alimentada, como ilustrado na Figura 1. A solução proposta pelo MSP é resolver em cada ramo as seguintes equações:

$$V_i^4 + A_i V_i^2 + C_i = 0 (1)$$

em que V_i é a tensão da linha desejada,

$$A_i = P_i R_i + Q_i X_i - \frac{V_{i-1}^2}{2}$$
(2)

e

$$C_i = (P_i^2 + Q_i^2)(R_i^2 + X_i^2)$$
(3)

sendo $S_i = P_i + jQ_i$ o fluxo de potência que chega na barra de destino do trecho, a impedância do trecho: $Z_i = R_i + jX_i$ e V_{i-1} a tensão da barra de origem. O ângulo de fase das tensões é calculado, após a convergência, por:

$$\delta_i = \delta_{i-1} - \arccos(\frac{P_i X_i - Q_i R_i}{V_i V_{i-1}}) \tag{4}$$

Por fim, as perdas complexas são dadas por:

$$\widehat{DS}_i = \hat{Z}_i \frac{|\hat{S}_i|^2}{V_i^2} \tag{5}$$

Na Figura 2, o algoritmo executado todas as vezes que o fluxo de carga for solicitado no programa é apresentado. Quando aplicado numa série temporal com n carregamentos da rede, é plausível usar de alguma maneira os resultados obtidos pelo fluxo de carga nas n - 1 execuções anteriores para obter estimativas melhores para as tensões iniciais de *n*. Isto é, em vez de inicializar todas vezes o MSP da maneira clássica, com todas as barras em 1 pu, busca-se algoritmos que utilizam execuções anteriores para estimar melhores tensões de partida. Tais algoritmos são denominados de preditores e sua eficiência pode ser medida precisamente pela redução observada no número de iterações do MSP.

Os preditores proporcionam uma Inicialização Inteligente em que o algoritmo de solução de fluxo de carga converge de maneira mais rápida. Portanto, ocorre uma economia de processamento, principalmente quando se trata de problemas de fluxo de carga em redes de grande porte ou em séries temporais longas.

A rede de distribuição é monitorada pelo sistema supervisório SCADA (*Supervisory Control* and Data Acquisition) que coleta os dados da subestação de maneira sequencial a cada 15 minutos. Sendo assim, geralmente, o fluxo de carga é calculado 96 vezes por dia. As grandezas de interesse são tensão, corrente, fator de potência, potência ativa e potência reativa.

4 Preditores

Seis preditores foram estudados neste trabalho, três preditores propostos por (Aly, 2015): N0, N1 e N2; e outros três novos preditores: X1S, X1P e X1Q, que utilizam a potência medida na saída do alimentador como variável independente em substituição ao tempo.

A ideia de se escolher a potência como variável independente foi pensada visto que sua relação com a tensão é frequentemente linear para cargas com fator de potência (FP) constante. Assim, considerando que, em sistemas reais, a variação do FP é pequena durante o dia, implementou-se o algoritmo onde temos a relação Tensão x Potência aproximada por uma reta.

Todos os preditores são avaliados entre si e também com relação a configuração de referência, na qual nenhuma inicialização inteligente foi adotada.

4.1 Preditor sem inicialização inteligente (S0)

A maneira mais básica de obter resultados do fluxo de carga em redes de distribuição na série temporal é executando o fluxo em cada tempo disponível sem uma inicialização inteligente. Ou seja, no tempo t_0 , o fluxo de carga é executado sendo inicializado com a tensão em 1 pu e em seguida, num tempo t_1 , outro fluxo de carga é executado da mesma maneira ignorando o resultado encontrado na execução anterior. Este preditor básico, sem inicialização inteligente, será denominado Preditor S0. Em (Aly, 2015) são apresentados três preditores inteligentes para a análise de fluxo de carga, sendo o tempo a variável independente: N0, N1 e N2. Tais preditores são descritos nas subseções 1,2 e 3.



Figura 3: Representação gráfica do Preditor N1.

4.2.1 Preditor N0

O preditor N0 é o caso mais simples de inicialização inteligente, necessita apenas de uma execução anterior do fluxo de carga para que seja adotado. Isto é, assumindo que S0 foi utilizado no cálculo do fluxo de carga no instante t_0 , N0 é capaz de inicializar a rede para execução do MSP no instante t_1 supondo que não houve variação de carregamento e que, portanto, as tensões nas barras são simplesmente iguais àquelas obtidas em t_0 .

De forma genérica, para a inicialização da tensão na barra i no instante t_{k+1} , usando o preditor N0, temos:

$$V_i'(t_{k+1}) = V_i(t_k)$$
(6)

$$\delta_i'(t_{k+1}) = \delta_i(t_k) \tag{7}$$

Com k = 0, 1, 2, ..., 95, supondo um dia de medições com intervalo de 15 minutos e adotando aspas simples para diferenciar os valores estimados dos efetivamente calculados.

4.2.2 Preditor N1

O preditor N1, é nomeado de Preditor de Primeira Ordem. É uma aproximação linear que necessita de duas soluções consecutivas do Fluxo de Carga para estimar o próximo instante de tempo.

Assim, como pode-se ilustrar na Figura 3, considerando que nos tempos t_k e t_{k+1} as soluções do fluxo de carga são conhecidas, a previsão no instante t_{k+2} pode ser feita com o auxílio dos polinômios de Lagrange da seguinte forma:

$$V_i'(t_{k+2}) = L_0 V_i(t_k) + L_1 V_i(t_{k+1})$$
(8)

$$\delta_i'(t_{k+2}) = L_0 \delta_i(t_k) + L_1 \delta_i(t_{k+1}) \tag{9}$$

em que:

$$L_0 = \frac{(t_{k+2} - t_{k+1})}{(t_k - t_{k+1})} \tag{10}$$

$$L_1 = \frac{(t_{k+2} - t_k)}{(t_{k+1} - t_k)} \tag{11}$$

são os fatores de Lagrange, aspas diferenciam as grandezas estimadas e k = 0, 1, 2, ..., 94; supondo 1 dia de medição em intervalos de 15 minutos.



Figura 4: Representação gráfica do Preditor N2.

4.2.3 Preditor N2

O preditor N2, ou de Segunda Ordem, é uma aproximação não-linear que requer três soluções consecutivas do Fluxo de Carga para estimar o próximo instante de tempo.

Assim, como pode-se ilustrar na Figura 4, considerando que nos tempos t_k , t_{k+1} e t_{k+2} as soluções do fluxo de carga são conhecidas, a previsão no instante t_{k+3} pode ser feita com o auxílio dos polinômios de Lagrange da seguinte forma:

$$V_{i}'(t_{k+3}) = L_{0}V_{i}(t_{k}) + L_{1}V_{i}(t_{k+1}) + L_{2}V_{i}(t_{k+2})$$
(12)
$$\delta_{i}'(t_{k+3}) = L_{0}\delta_{i}(t_{k}) + L_{1}\delta_{i}(t_{k+1}) + L_{2}\delta_{i}(t_{k+2})$$
(13)

em que:

$$L_0 = \frac{(t_{k+3} - t_{k+1})(t_{k+3} - t_{k+2})}{(t_k - t_{k+1})(t_k - t_{k+2})}$$
(14)

$$L_1 = \frac{(t_{k+3} - t_k)(t_{k+3} - t_{k+2})}{(t_{k+1} - t_k)(t_{k+1} - t_{k+2})}$$
(15)

$$L_2 = \frac{(t_{k+3} - t_k)(t_{k+3} - t_{k+1})}{(t_{k+2} - t_k)(t_{k+2} - t_{k+1})}$$
(16)

são os fatores de Lagrange, aspas diferenciam as grandezas estimadas e k = 0, 1, 2, ..., 94; supondo 1 dia de medição em intervalos de 15 minutos.

4.3 Preditores X

Os preditores X1S, X1P e X1Q, como ilustrado na Figura 5, são variações do Preditor N1. A diferença reside na variável independente, em que o tempo foi substituído pela carga total do alimentador: aparente, ativa, reativa.



Figura 5: Representação gráfica do Preditor proposto.

4.3.1 Preditor X1S

O Preditor X1S parte da premissa de que existe uma relação linear entre as tensões calculadas nas barras da rede e a carga total aparente do alimentador. Assim como o Preditor N1, ele necessita de duas soluções consecutivas do fluxo de carga para estimar as tensões nas barras da rede no próximo instante de tempo. O Preditor X1S requer ainda que nas duas soluções calculadas anteriormente tenha ocorrido variação de carga total aparente. Assim, considerando que nos tempos $t_k e t_{k+1}$ as soluções do fluxo de carga são conhecidas, a previsão no instante t_{k+2} pode ser feita com o auxílio do polinômio de Lagrange da seguinte forma:

$$V_i'(t_{k+2}) = L_0 V_i(t_k) + L_1 V_i(t_{k+1})$$
(17)

$$\delta_i'(t_{k+2}) = L_0 \delta_i(t_k) + L_1 \delta_i(t_{k+1})$$
 (18)

em que:

$$L_0 = \frac{S(t_{k+2}) - S(t_{k+1})}{S(t_k) - S(t_{k+1})}$$
(19)

$$L_1 = \frac{S(t_{k+2}) - S(t_k)}{S(t_{k+1}) - S(t_k)}$$
(20)

são os fatores de Lagrange, aspas diferenciam as grandezas estimadas e k = 0, 1, 2, ..., 94.

4.3.2 Preditor X1P

De forma similar a X1S, foram calculados os valores considerando a potência ativa como variável independente e assumindo duas soluções anteriores para previsão:

$$V_i'(t_{k+2}) = L_0 V_i(t_k) + L_1 V_i(t_{k+1})$$
(21)

$$\delta_i'(t_{k+2}) = L_0 \delta_i(t_k) + L_1 \delta_i(t_{k+1}) \qquad (22)$$

em que:

$$L_0 = \frac{P(t_{k+2}) - P(t_{k+1})}{P(t_k) - P(t_{k+1})}$$
(23)

$$L_1 = \frac{P(t_{k+2}) - P(t_k)}{P(t_{k+1}) - P(t_k)}$$
(24)

são os fatores de Lagrange, aspas diferenciam as grandezas estimadas e k = 0, 1, 2, ..., 94.

4.3.3 Preditor X1Q

O Preditor X1Q considerando a potência reativa como variável independente também foi implementado para comparação com os demais:

$$V_i'(t_{k+2}) = L_0 V_i(t_k) + L_1 V_i(t_{k+1})$$
(25)

$$\delta_i'(t_{k+2}) = L_0 \delta_i(t_k) + L_1 \delta_i(t_{k+1})$$
(26)

em que:

$$L_0 = \frac{Q(t_{k+2}) - Q(t_{k+1})}{Q(t_k) - Q(t_{k+1})}$$
(27)

$$L_1 = \frac{Q(t_{k+2}) - Q(t_k)}{Q(t_{k+1}) - Q(t_k)}$$
(28)

são os fatores de Lagrange, aspas diferenciam as grandezas estimadas e k = 0, 1, 2, ..., 94.

5 Resultados e Discussões

Os preditores N0, N1, N2, X1S, X1P e X1Q foram analisados em uma rede com curvas de carga reais pertencente a cidade de Campina Grande, Paraíba. O sistema engloba cargas variadas, tanto residenciais quanto comerciais. Os resultados são avaliados durante um dia, havendo 96 condições de carregamento para cada uma das 63 barras do sistema.

A carga varia de forma imprevisível, o que torna difícil avaliar qual preditor apresenta melhor desempenho. O teste comparativo consiste em executar o Fluxo de Carga na Série Temporal e verificar os números de iterações do MSP necessárias para convergência para cada preditor. O desempenho ideal seria 96 iterações, isto é, o preditor sempre acertaria na inicialização obtendo uma convergência com apenas uma iteração.

Na Figura 6 ilustram-se 7 horas do dia de estudo para a) a curva real que é tomada como referência; b) a curva do Preditor N0; c) curva do preditor N1 e d) curva do Preditor X1S.

Na Figura 6(a) o valor real da tensão em kV na Barra 10 é mantido. Essa barra foi escolhida aleatoriamente dentro das 63 existentes no sistema de distribuição estudado. Na Figura 6(b), apresenta-se o gráfico dos valores calculados pelo preditor N0 que apresentou os melhores resultados dos preditores proposto por (Aly, 2015), enquanto que a Figura 6(c) apresenta o preditor N1 que possui um desempenho inferior. O marcador quadrado-verde indica que foi necessária apenas uma iteração para a convergência da solução, o marcador círculo-azul indica que foi preciso duas e o triângulo-vermelho indica que foram necessárias três iterações para atingir o resultado.

Analisando a Figura 6(c) observa-se que o valor inicial do chute é 13,8 kV e são necessárias três iterações até a convergência. No segundo ponto, o algoritmo converge com apenas uma iteração, representado pelo marcador quadrado-verde. Com



Figura 6: (a) Curva real de tensão na Barra 10 em um intervalo de 7 horas. (b) Curva dos valores de chute do preditor N0. (c) Curva dos valores de chute do Preditor N1. (d) Curva dos valores de chute do Preditor X1S.



Figura 7: Gráfico do Tempo (h) \times Número de Iterações Acumuladas - Comparação de S0 (sem inicialização) com os preditores propostos por citeAkher.

os dois pontos da solução, o preditor calcula o terceiro e entra em uma região de pouca eficiência com muitos cálculos necessitando de três iterações. Ao entrar em um patamar relativamente constante o Preditor N1 passa a acertar tendo 4 pontos necessitando apenas uma iteração e depois quando há uma grande variação de carregamento o Preditor N1 não responde satisfatoriamente.



Figura 8: Gráfico do Tempo (h) \times Número de Iterações Acumuladas - Comparação de N0 (melhor desempenho anterior) com os preditores propostos.

De modo similar, pode-se analisar na Figura 6(d) como foi o comportamento das iterações para o preditor X1S que pode-se ver que teve um desempenho superior, com mais amostras necessitando de apenas 1 iteração para convergir.

Tabela 1: Número de Iterações realizadas por cada preditor.

Preditor	Número de	Redução em
	Iterações	relação a SO (%)
S0	297	-
NO	186	$37,\!37$
N1	253	14,81
N2	269	$9,\!43$
X1S	148	$50,\!17$
X1P	156	47,47
X1Q	188	36,70

Pode-se perceber pela Tabela 1 que todos os preditores de Inicialização Inteligente possuem uma eficiência significativamente superior a S0 com relação a estimativa inicial dada e o valor calculado.

O Preditor N0, que utiliza sempre o valor anterior como chute, teve para esta carga um desempenho superior aos Preditores N1 e N2: 186 iterações do MSP, que representa uma redução de 37,37% em relação à referência S0. O preditor N2, que responde melhor a curvas com características mais quadráticas, apresentou o pior resultado com 269 iterações com apenas 9,43% de redução.

Dos preditores propostos, a maior redução do número de iterações ocorreu para o Preditor X1S que apresentou 148 iterações representando um decréscimo de 50,17% em relação à configuração S0. Em uma análise visual dos gráficos da Figura 6 é possível perceber quando há uma melhoria na previsão pelo aumento de marcadores quadrados-verdes que indicam convergência com uma iteração. Para o Preditor X1S, inicialmente, o valor de chute é 13,8 kV e já no segundo ponto há uma convergência com uma única iteração. O terceiro instante de tempo necessitou de três iterações, mas depois o preditor entrou em um patamar com uma sequência contínua de quadrados-verde (1 iteração) e círculos-azul (2 iterações), significativamente superior aos Preditores N0 e N1.

O gráfico da Figura 7 ilustra o número total de iterações dos preditores inteligentes propostos por (Aly, 2015) em relação ao preditor sem inicialização inteligente. É possível ver que os 3 preditores apresentam um melhor resultado em relação a S0. Já no gráfico da Figura 8, foi feita a comparação entre os novos preditores propostos neste trabalho com o preditor N0, que apresentou o melhor desempenho anteriormente. Esse comparativo indica que o preditor X1Q praticamente empatou com N0, enquanto que X1S e X1P tiveram um desempenho significativamente superior. O destaque foi X1S que reduziu 20,43% em relação ao preditor N0.

6 Conclusão

Tomando como base os resultados obtidos na seção V, a resolução de problema de fluxo de carga com Inicialização Inteligente otimiza de forma considerável a carga computacional requerida.

Portanto, os preditores inteligentes são soluções interessantes para a otimização dos cálculos e os preditores propostos neste trabalho se sobressaíram significativamente. A ênfase é dada para o Preditor X1S que reduziu em mais da metade o número de iterações da solução desse fluxo de carga.

Em trabalhos futuros, serão implementados algoritmos que utilizam mais de um preditor, considerando os comportamentos da carga em que cada um responde melhor. Serão, portanto, mais efetivos na redução do número de iterações necessárias, otimizando ainda mais o método.

Referências

- Ahmed, M. H., Bhattacharya, K. and Salama, M. M. A. (2013). Probabilistic distribution load flow with different wind turbine models. IEEE Transactions on Power Systems, vol. 28, no. 2, pp. 1540-1549, Maio 2013.
- Aly, M. A. A. A. S. M. M. (2015). Initialised load-flow analysis based on lagrange polynomial approximation for efficient quasi-static time-series simulation. in IET Generation, Transmission and Distribution, vol. 9, no. 16, pp. 2768-2774, Dez 2015.
- Boehme, T., Wallace, A. R. and Harrison, G. P. (2007). Applying time series to power flow analysis in networks with high wind penetration. IEEE Transactions on Power Systems, vol. 22, no. 3, pp. 951-957, Ago. 2007.

- Braz, H. D. M. (2010). Configuração de sistemas de distribuição usando um algoritmo genético sequencial. Tese de Doutorado, Universidade Federal de Campina Grande, Campina Grande - PB - Brasil.
- Bruno, S., Lamonaca, S., G. Rotondo, U. S. and Scala, M. L. (2011). Unbalanced three-phase optimal power flow for smart grids. IEEE Transactions on Industrial Electronics, vol. 58, no. 10, pp. 4504-4513.
- Buragohain, U. and Boruah, T. (2017). Fuzzy logic based load flow analysis. 2017 International Conference on Algorithms, Methodology, Models and Applications in Emerging Technologies (ICAMMAET), Chennai, 2017.
- Cespedes, R. G. (1990). New method for the analysis of distribution networks. IEEE Transactions on Power Delivery, v. 5, n. 1, p. 391–396.
- Kagan, N., Oliveira, C. C. B. and Robba, E. J. (2010). Introdução aos sistemas de distribuição de energia elétrica. 2a. ed. São Paulo: Editora Edigard Blucher.
- Romero-Ramos, E., Tirgo-García, A. L. and Romero-Romero, J. A. (2017). Improved radial load flow for the smart distribution grid. 2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), Torino, 2017, pp. 1-6.
- Sarno, D., Murru, C. and N. Garofalo, A. Cerullo, G. G. F. C. S. (2014). Power grid outlier treatment through kalman filter. Proceedings -IEEE 25th International Symposium on Software Reliability Engineering Workshops.
- Selim, A., Akher, M. A. and Kamel, M. M. A. S. (2016). Efficient time series simulation of distribution systems with voltage regulation and pv penetration. Eighteenth International Middle East Power Systems Conference (MEPCON), Cairo, 2016, pp. 717-722.
- Souza, P. S. S. and Braz, H. D. M. (2016). Fluxo de potência para redes fracamente malhadas: Modificação do método da soma de potências. Simpósio Brasileiro de Sistemas Elétricos SBSE.
- Stagg, G. W. and El-Abiad, A. H. (1968). Computer methods in power system analysis. 1st ed., ser. McGraw-Hill series in electronic systems. Michigan University: McGraw Hill.
- Stevenson, W. D. (1978). Elementos de análise de sistemas de potencia. São Paulo: McGraw-Hill do Brasil.

- Stott, B. and Alsac, O. (1974). Fast decoupled load flow. IEEE Transactions on Power Apparatus and Systems, vol. PAS-93, no. 3, pgs. 859–869.
- Tinney, W. F. and Hart, C. E. (1967). Power flow solution by newton's method. IEEE Transactions on Power Apparatus and Systems, vol. PAS-86, no. 11, pgs. 1449–1460.
- Zeng, H., Zhu, Y. and Jin, X. (2016). Smart grid tendency warning system and its applications. 2016 IEEE International Conference on Power System Technology (POWERCON), Wollongong, NSW, 2016, pp. 1-6.