

Análise sobre às técnicas aplicadas à estimação de parâmetros de sistemas de transmissão

Ronaldo F. R. Pereira * Felipe P. Albuquerque **
Luísa H. B. Liboni *** Eduardo C. M. Costa **
Maurício C. de Oliveira ****

* *Centro de Ciências Exatas e Tecnológicas - CCET, Universidade Federal do Acre - UFAC. Rio Branco, AC, Brasil, (ronaldo.pereira@ufac.br).*

** *Departamento de Engenharia de Sistemas Eletrônicos - PSI, Universidade de São Paulo - USP. São Paulo, SP, Brasil, (felipe.proenca.albuquerque@usp.br, educosta@usp.br).*

*** *Instituto Federal de Educação, Ciência e Tecnologia de São Paulo - IFSP, Sertãozinho, SP, Brasil, (luisa.liboni@ifsp.edu.br).*

**** *Departamento de Engenharia Mecânica e Aeroespacial, Universidade da Califórnia, San Diego, EUA, (mauricio@ucsd.edu).*

Abstract: This paper shows an Extended Kalman filter-based method to estimate the parameters of transmission lines. Unlike common-place practices, in which parameters are estimated by using Least Squares methods or linear methods, the Extended Kalman filter algorithm is used. We represent the transmission line by using a steady-state model in which the voltage and current phasors are considered complex values in the $d - q$ domain. Thereafter, it is analyzed the estimation performance of the filter-based estimator by means of a numerical simulation, considering a medium-length transmission line, and compared to other well-established methods based on two different Least Mean Square Setups. The results show that the filter is highly efficient and encourage further researches on estimation methods with optimal initialization terms. In addition, results show that the filter-based estimation method could be used jointly in phasor measurement devices for improved monitoring and control capabilities of electrical systems by estimating phasors and parameters.

Resumo: Este artigo propõe um método baseado em filtro de Kalman estendido para estimar os parâmetros de linhas de transmissão. Ao contrário das práticas comuns, nas quais os parâmetros são estimados usando métodos de mínimos quadrados ou métodos lineares, propõe-se a utilização do algoritmo de filtro de Kalman estendido. Representamos a linha de transmissão usando um modelo de estado estacionário no qual os fasores de tensão e corrente são considerados no domínio $d - q$ complexo. Em seguida, mostramos o desempenho da estimativa baseada em filtro de Kalman estendido por meio de simulação numérica de uma linha de transmissão de comprimento médio e comparamos o método proposto a um método de estimação baseado em duas diferentes configurações do método dos mínimos quadrados. Os resultados mostram que o filtro é altamente eficiente e possibilita pesquisas futuras na estimativa da inicialização ótima do método para linhas de transmissão. Concluímos o artigo argumentando que o método de estimação por filtro pode ser usado em conjunto com dispositivos de medição fasorial para melhorar a capacidade de monitoramento e controle de sistemas elétricos por meio da estimativa de fasores e parâmetros.

Keywords: Covariance; Estimation; Extended Kalman Filter; Parameters; Transmission Systems.

Palavras-chaves: Covariância; Estimação; Filtro de Kalman Estendido; Parâmetros; Sistemas de Transmissão.

1. INTRODUÇÃO

Com o advento das redes inteligentes e o crescimento da geração distribuída, seja por fontes de energia intermitentes ou não, novas tecnologias são desenvolvidas no que tange o aperfeiçoamento dos inversores eletrônicos e os métodos de extração de informações, medição e processamento de sinais (Asprou and Kyriakides, 2015). A inserção de fontes de energia renováveis intermitentes e novas cargas na rede, resultam em alterações significativas no sistema elétrico como um todo, levando à necessidade de métodos de monitoramento, bem como a estimação de estados e parâmetros, mais precisos e confiáveis. A partir do conhecimento de tais dados, análises importantes podem ser realizadas, tais como: estabilidade de tensão, fluxo de carga e possíveis contingências.

Métodos de estimação baseados em medição podem ser aplicados para sistemas do tipo SCADA ou unidades de medição fasorial (PMUs) ou registros de falta armazenados em relés de proteção. Um método de estimação de parâmetros que se baseia em registros de falta capturados por relés digitais e utiliza a equação da velocidade de propagação de ondas é proposto em (Wang and Xu, 2015). Em (Liao and Kezunovic, 2008), o autor apresenta um estimador ótimo que minimiza os impactos de medições não sincronizadas e erros de medição em PMUs. Em (Mousavi-Seyedi et al., 2014), um algoritmo não linear ponderado de mínimo quadrado (NWLS) é empregado combinando medições PMU e SCADA para linhas multiterminais.

O problema de estimação de parâmetros em linhas de transmissão pode ser melhor resolvido por uma técnica dinâmica de estimação de parâmetros, especialmente para as futuras redes onde informações em tempo real sobre a variação dos parâmetros de linha serão necessárias (Bian et al., 2011a,b). Um método de aumento do vetor de estados foi proposto recentemente para combinar estados do sistema e parâmetros de linha, formulando um problema não linear resolvido por NWLS (Ritzmann et al., 2017). Outra abordagem baseada em métodos de mínimos quadrados é apresentada em (Albuquerque et al., 2021). Os autores de (Bian et al., 2011a) e (Bian et al., 2011b) apresentam uma abordagem baseada em filtro de Kalman para rastrear estados e parâmetros de linha simultaneamente com termos específicos adicionados à inovação na etapa de atualização da medição. Os autores de (Ren et al., 2017) e (Ren et al., 2019) apresentam uma abordagem baseada em filtro de Kalman para rastrear estados e parâmetros de linha que processa recursivamente a estimativa de estado e de parâmetro a partir de uma única varredura de medição, de modo que quando obtém soluções convergentes do processo recursivo, o algoritmo passa para a próxima varredura de medição. Com base nisso, os problemas de estimação são muito importantes para muitos tipos de aplicações em linhas de transmissão de energia elétrica, como, e.g., localização de faltas (Bendjabeur et al., 2021).

Neste artigo, propomos uma combinação de estimativa de estado e rastreamento de parâmetro para estimar os parâmetros de sequência positiva de uma linha de transmissão em estado estacionário modelada por um circuito π (Costa and Kurokawa, 2015), tal modelo é simples e suficiente para traduzir a operação em estado estacionário de uma

linha de transmissão. Essa combinação pode ser usada para estimar fasores e parâmetros para sistemas de sequência, bem como componentes modais em alguns casos, o que é suficiente para análise de fluxo de potência e contingências e outros estudos de estado estacionário. O algoritmo proposto realiza estimação de estado e rastreamento de parâmetros simultaneamente pelo aumento do vetor de estado e o processo de linearização do Filtro de Kalman Estendido (EKF), sendo que tal processo é baseado no produto de Kronecker o que melhora a eficiência do algoritmo com relação aos cálculos matemáticos. A presente pesquisa é uma extensão do trabalho apresentado em (Pereira et al., 2021), ambos são baseados nos trabalhos de (Liboni et al., 2020; Pereira et al., 2021; Liboni et al., 2016, 2017a).

A principal contribuição deste artigo é mostrar que o método EKF pode ser usado na estimação de parâmetros de sistemas de componentes de sequência ou modais para melhor monitoramento e controle de sistemas de potência, bem como utilizar o produto de Kronecker para melhorar a eficiência do algoritmo. O artigo está estruturado da seguinte forma: a seção 2 apresenta o modelo matemático da linha de transmissão e o enunciado do problema; A seção 3 apresenta a teoria de filtragem de Kalman Estendida aplicada ao modelo do sistema; A seção 4 discute os resultados e, por fim, a seção 5 apresenta as conclusões.

2. ENUNCIADO DO PROBLEMA

Considere as seguintes equações que representam um conjunto de medições:

$$z_m(t) = z(t) + r(t), \quad z(t) = \begin{pmatrix} i_{1d}(t) \\ v_{1d}(t) \\ i_{2d}(t) \\ v_{2d}(t) \end{pmatrix}. \quad (1)$$

Esses sinais são medições de correntes e tensões nos terminais de entrada e saída de uma linha de transmissão monofásica modelada por uma rede de circuito π , como mostrado na Figura 1, para uma condição de estado estacionário. O sinal $r(t)$ representa um ruído de medição. Mais especificamente, assumimos que $r(t)$ em (1) é um ruído branco gaussiano escalar de média zero com covariância:

$$\Sigma_r = E\{r(t)r(t)^T\} > 0,$$

que podem representar ruídos de medição tanto do ambiente quanto oriundos de equipamentos de medição.




Figura 1. Modelo-II para uma linha de transmissão.

Portanto, o sinal $z_m(t)$ é uma versão ruidosa do sinal *puramente senoidal* $z(t)$. O sinal vetorial $z(t)$ representa a parte real $i_{1d}(t)$, $v_{1d}(t)$, $i_{2d}(t)$, $v_{2d}(t)$ dos fasores rotativos

das tensões e correntes para os terminais de entrada e saída, $\dot{I}_1 e^{j\omega t}$, $\dot{V}_1 e^{j\omega t}$, $\dot{I}_2 e^{j\omega t}$, e $\dot{V}_2 e^{j\omega t}$, respectivamente. Estes fasores podem ser representados em cada instante de tempo por suas partes reais e imaginárias no domínio $d-q$ complexo como mostrado na figura 2.

Dessa forma, podemos representar todos os fasores em cada instante de tempo de simulação por um vetor dependente do tempo $z_{dq}(t)$, tal qual como pode ser visto a seguir:

$$z_{dq}(t) = \begin{pmatrix} i_{1d}(t) \\ i_{1q}(t) \\ v_{1d}(t) \\ v_{1q}(t) \\ i_{2d}(t) \\ i_{2q}(t) \\ v_{2d}(t) \\ v_{2q}(t) \end{pmatrix} = \begin{pmatrix} I_1 \cos(\omega t + \phi_{i_1}) \\ I_1 \sin(\omega t + \phi_{i_1}) \\ V_1 \cos(\omega t + \phi_{v_1}) \\ V_1 \sin(\omega t + \phi_{v_1}) \\ I_2 \cos(\omega t + \phi_{i_2}) \\ I_2 \sin(\omega t + \phi_{i_2}) \\ V_2 \cos(\omega t + \phi_{v_2}) \\ V_2 \sin(\omega t + \phi_{v_2}) \end{pmatrix}, \quad (2)$$

onde $\omega = 2\pi f$ é a frequência angular do sistema, o subscrito d é para parte direta ou real e q é a parte em quadratura ou parte imaginária.




Figura 2. Representação da dinâmica de rotação fasorial.

Dado que os fasores rotativos $\dot{V}_2 e^{j\omega t}$ e $\dot{I}_2 e^{j\omega t}$ podem ser decompostos no plano $d-q$ complexo em cada instante de tempo t separando suas partes reais e imaginárias, quatro novas equações são obtidas, nas quais os componentes do terminal de saída são dados como funções das componentes do terminal de entrada. Como as medidas $z_m(t)$ apenas contabilizam as partes reais dos fasores rotativos, podemos escrever

$$z_m(t) = \begin{bmatrix} H_R \\ M_R \end{bmatrix} z(t) + r(t) \quad (3)$$

e

$$M_R = \begin{bmatrix} a & -b & c & -d \\ -R_1 & \omega L_1 & a & -b \end{bmatrix}, \quad (4)$$

onde

$$\begin{aligned} a &= \frac{1}{2}(2 + R_1 G - \omega^2 L_1 C), \\ b &= \frac{\omega}{2}(R_1 C + L_1 G), \\ c &= -\frac{1}{4}(G^2 R_1 + \omega^2 C^2 R_1) + \frac{1}{2}(\omega^2 L_1 C G) - G, \\ d &= \omega \left[-\frac{1}{2}(G C R_1) - \frac{1}{4}(L_1 G^2) + \frac{1}{4}(\omega^2 L_1 C^2) - C \right]. \end{aligned}$$

A matriz H_R é a matriz de ajuste que considera as partes reais das correntes e tensões do terminal de entrada.

$$H_R = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}. \quad (5)$$

O desenvolvimento detalhado dessas formulações é explicado e apresentado em (Pereira et al., 2021).

A formulação apresentada em (3) mostra a característica dinâmica do sistema e relaciona a corrente e tensão do terminal de saída com a corrente e tensão do terminal de entrada. Agora, tendo essa formulação completa da linha de transmissão, nosso principal objetivo é estimar os sinais livres de ruído e os parâmetros da linha a partir de medições ruidosas adquiridas por dados de sincrofasores.

Para alcançar nosso objetivo, usaremos um algoritmo de estimativa de parâmetros baseado em observador. Um observador de estado é um algoritmo que estima recursivamente o estado de um sistema, dado o sinal de medição. Nossa tarefa é não linear e, portanto, o método do observador do filtro de Kalman estendido é o escolhido para esta tarefa.

3. CONFIGURAÇÃO DO OBSERVADOR NÃO-LINEAR

A fim de configurar o filtro de Kalman estendido para estimar o sinal sem ruído $z(t)$, devemos representar este sinal usando uma representação em espaço de estados *discreta* e depois reorganizar as equações para o nosso problema de estimação, pois o espaço de estados é uma representação para problemas lineares. Portanto, o estado $x(k)$ do filtro de Kalman estendido deve corresponder a uma versão uniformemente amostrada dos sinais sem ruído em tempo contínuo no domínio $d-q$ complexo $z_{dq}(t)$, isto é:

$$\begin{pmatrix} x_1(k) \\ x_2(k) \\ \vdots \\ x_8(k) \end{pmatrix} = x(k) = z_{dq}(kT_s) = \begin{pmatrix} i_{1d}(kT_s) \\ i_{1q}(kT_s) \\ v_{1d}(kT_s) \\ \vdots \\ v_{2q}(kT_s) \end{pmatrix}, \quad (6)$$

onde T_s é o período de amostragem constante. Usamos o índice $k T_s$ como k para encurtar a notação.

No entanto, também pretendemos estimar os parâmetros R_1 e L_1 , portanto, o estado vetorial $x(k)$ deve ser aumentado com o vetor de parâmetro $\theta(k)$ (Liboni et al., 2017a, 2020, 2017b),

$$x_{aug}(k) = \begin{pmatrix} x(k) \\ \theta(k) \end{pmatrix}, \quad \theta(k) = \begin{pmatrix} a(k) \\ b(k) \\ c(k) \\ d(k) \\ R_1(k) \\ L_1(k) \end{pmatrix},$$

Observe que $\theta(k)$ é um vetor composto pelos elementos da matriz M_R . A equação do sistema dinâmico, ou seja, a equação do processo, deve ser representada por

$$x_{aug}(k+1) = Ax_{aug}(k) + w(k), \quad (7)$$

$$A = \begin{bmatrix} F & \cdot & \cdot & \cdot & \cdot \\ \cdot & F & \cdot & \cdot & \cdot \\ \cdot & \cdot & F & \cdot & \cdot \\ \cdot & \cdot & \cdot & F & \cdot \\ \cdot & \cdot & \cdot & \cdot & I_8 \end{bmatrix}, \quad (8)$$

onde I_8 é a matriz identidade 8x8 e F é uma matriz de rotação dada a seguir

$$F = R_\omega(\phi), \quad R_\omega(\phi) = \begin{bmatrix} \cos(\phi) & -\sin(\phi) \\ \sin(\phi) & \cos(\phi) \end{bmatrix}, \quad \phi = \omega T_s.$$

Devemos modelar a equação de medição discreta para nosso sistema, discretizando a versão de tempo contínuo da equação de medição ruidosa (9), ou seja:

$$z_m(k) = z(k) + r(k). \quad (9)$$

Fazendo $y(k) = z_m(k)$ e usando (6), podemos expressar:

$$y(k) = \begin{bmatrix} H_R & 0 \\ M_R(\theta(k)) & 0 \end{bmatrix} \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} + r(k), \quad (10)$$

que chamaremos de equação de medição. Lembre-se de que H_R é uma matriz fixa dada por (5) e M_R é dada por (4) e é dependente dos parâmetros de $\theta(k)$. Portanto, a partir de agora, como nosso estado $x(k)$ foi aumentado para $x_{aug}(k)$, indicamos explicitamente que M_R é dependente de $\theta(k)$, ou seja, usaremos a notação $M_R(\theta(k))$.

Os observadores não lineares podem processar o sistema linearizando a operação dinâmica. Isso pode ser alcançado por tratamentos matemáticos com matrizes Jacobianas ou Hessianas para as funções dinâmicas não lineares do sistema, $f(x)$ e $g(x)$, em torno de um par de pontos de operação $(x_{op}(k), y_{op}(k))$ (Haykin, 2004):

$$\tilde{A} = \left. \frac{\partial f(x)}{\partial x} \right|_{x_{op}(k)}, \quad \tilde{C} = \left. \frac{\partial g(x)}{\partial x} \right|_{x_{op}(k)},$$

E, portanto, o sistema agora pode ser escrito em termos de novas variáveis linearizadas $\tilde{x}(k)$ e $\tilde{y}(k)$:

$$\tilde{x}(k+1) = \tilde{A}\tilde{x}(k) + w(k),$$

$$\tilde{y}(k) = \tilde{C}\tilde{x}(k) + Dv(k),$$

onde $\tilde{x}(k) = (x(k) - x_{op}(k))$ e $\tilde{y}(k) = (y(k) - y_{op}(k))$.

Portanto, podemos formular o observador de Kalman estendido como uma aproximação de um filtro linear:

$$\hat{\tilde{x}}(k+1) = \tilde{A}\hat{\tilde{x}}(k) + L(k)(\tilde{y}(k) - \hat{\tilde{y}}(k)), \quad \hat{\tilde{x}}(0) = \hat{\tilde{x}}_0$$

$$\hat{\tilde{y}}(k) = \tilde{C}\hat{\tilde{x}}(k),$$

$$\tilde{e}(k) = \hat{\tilde{x}}(k) - \tilde{x}(k),$$

Este observador não linear também produz um sinal $\hat{\tilde{x}}(k)$, que é a estimativa do estado, $\tilde{x}(k)$ é o estado no instante k , e $\tilde{e}(k)$ é o erro de estimativa.

O ganho de Kalman é dado por

$$\tilde{L}(k) = \tilde{A}\tilde{\Sigma}(k)\tilde{C}^T (R + \tilde{C}\tilde{\Sigma}(k)\tilde{C}^T)^{-1},$$

$\tilde{\Sigma}(k+1) = \tilde{A}\tilde{\Sigma}(k)\tilde{A}^T + Q - L(k)(R + \tilde{C}\tilde{\Sigma}(k)\tilde{C}^T)L(k)^T$, onde R é a matriz de covariância para as medições.

Uma vez encontrada a estimativa $\hat{\tilde{x}}(k)$, é fácil encontrar a estimativa $\hat{x}(k)$:

$$\hat{x}(k) = \hat{\tilde{x}}(k) + x_{op}(k) \quad (11)$$

e $x_{op}(k)$ é o ponto de operação que é atualizado recursivamente a cada nova estimativa.

Nesta aplicação, a equação de processo da linha de transmissão em (7) é linear, uma vez que F e I são fixos e independentes de $x_{aug}(k)$. Portanto, podemos fazer $\tilde{A} = A$ na equação de processo de Kalman e a equação de processo linearizado seria dada por

$$\tilde{x}_{aug}(k+1) = A\tilde{x}_{aug}(k) + w(k) \quad (12)$$

No entanto, a equação de medição em (10) é não linear e devemos encontrar a equação de medição linearizada.

Vamos chamar a primeira linha de (10) como $y_1(k)$

$$y_1(k) = [H_R \ 0] + r_1(k) \quad (13)$$

e dado que H_R é independente do vetor de estado, sua linearização é direta:

$$\tilde{y}_1(k) = [H_R \ 0] \tilde{x}_{aug}(k) + r_1(k) \quad (14)$$

Chamamos a função da segunda linha da equação de medição (10) como $y_2(k)$

$$y_2(k) = [M_R(\theta(k)) \ 0] x_{aug}(k) + r_2(k) \quad (15)$$

Calculando $\frac{\partial y_2(k)}{\partial x_{aug}(k)}$, nós obtemos

$$\frac{\partial y_2(k)}{\partial x_{aug}(k)} = \begin{bmatrix} \frac{\partial y_2(k)}{\partial x(k)} & \frac{\partial y_2(k)}{\partial \theta(k)} \end{bmatrix} \quad (16)$$

O primeiro termo nesta derivada é direto

$$\frac{\partial y_2(k)}{\partial x(k)} = [M_R(\theta(k)) \ 0] \quad (17)$$

Para calcular o segundo termo, usaremos o fato de que é possível construir uma relação linear entre $M_R(\theta(k))$ e $x_{aug}(k)$ por meio da vetorização

$$\text{vec} [M_R(\theta(k)) \ 0] = N x_{aug}(k) = N \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} \quad (18)$$

Agora, respondemos à pergunta sobre como aumentar o vetor de estado com os parâmetros da matriz $M_R(\theta(k))$. Então, é possível construir uma relação linear entre a matriz e o vetor aumentado que é importante durante a linearização. Também usaremos o seguinte relacionamento:

$$d \text{vec}(y_2(k)) = d \text{vec} \left([M_R(\theta(k)) \ 0] \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} \right) = d \text{vec} \left(I [M_R(\theta(k)) \ 0] \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} \right) \quad (19)$$




Figura 3. Histogramas obtidos para a solução por EKF. (a) Histograma para Resistência. (b) Histograma para Reatância.




Figura 4. Parâmetros obtidos para solução por EKF. (a) Resistência. (b) Reatância.

Agora dada a identidade, que é melhor detalhada em (Magnus and Neudecker, 2019),

$$d \operatorname{vec}(VJT) = T^T \otimes V d \operatorname{vec}(J). \quad (20)$$

o Jacobiano de uma multiplicação de matriz entre a matriz V , vetor J e a matriz T é dado pelo produto de Kronecker \otimes entre T^T e V pelo vetor J .

Nós obtemos

$$d \operatorname{vec}(y_2(k)) = \left(\begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix}^T \otimes I \right) d \operatorname{vec} [M_R(\theta(k)) \ 0] = \left(\begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix}^T \otimes I N \right) d \operatorname{vec} \begin{bmatrix} x(k) \\ \theta(k) \end{bmatrix} \quad (21)$$

Ao analisar a equação (21), concluímos que o primeiro termo nesta derivada é muito simples

$$\frac{\partial y_2(k)}{\partial \theta(k)} = (x_{aug}(k)^T \otimes I N) \quad (22)$$

Finalmente, a versão linearizada da segunda parte da equação de medição é

$$\tilde{y}(k) = \begin{bmatrix} H \\ M_R(k) \end{bmatrix} \begin{bmatrix} 0 \\ (x_{aug}^T(k) \otimes I) N \end{bmatrix} \tilde{x}_{aug}(k) + r(k), \quad (23)$$

onde N é uma matriz de ajuste dimensional para $x_{aug}(k)$, formada por elementos nulos e elementos unitários.

4. RESULTADOS

Nesta seção, apresentaremos a comparação dos resultados do EKF com dois métodos LMS, mais especificamente *Ordinary Least Square* (OLS) e *Total Least Square* (TLS), para estimativa de parâmetros de linhas de transmissão, nosso objetivo é apresentar a utilidade de uma poderosa técnica que não é comumente usada para sistemas de potência em comparação com uma técnica bem estabelecida. Para isso, utilizamos os parâmetros e sistema apresentados em (Albuquerque et al., 2021).

Para montar o estimador EKF, realizamos simulações do sistema de potência usando um ruído gaussiano branco e obtivemos as medidas. Usamos um erro de 3 % para cada

fase, covariâncias iniciais de 1 % das medidas e parâmetros nominais, valores nominais do sistema para os estados iniciais e parâmetros iniciais com valores na faixa de 70 % dos valores reais com base em (Asprou and Kyriakides, 2015).

Para a comparação dos métodos de estimação dos parâmetros, a Tabela 1 apresenta a diferença do erro relativo para os parâmetros estimados, os quais apresentaram um erro aceitável inferior a 10 % com base em (Milojević et al., 2018). Os dois LMS apresentaram melhor desempenho para o erro relativo para resistência e OLS é melhor para a reatância, porém foram necessários cerca de 100.000 realizações enquanto que para o EKF este número é cerca de 5.000 realizações em um processo recursivo, que é uma melhor característica para aplicações em tempo real. Essas afirmações podem ser vistas em (Albuquerque et al., 2021) e na Figura 3 e Figura 4.

Tabela 1. Tabela comparativa para os Parâmetros Série

Parameter	OLS $_{\Delta x}$ (%)	TLS $_{\Delta x}$ (%)	EKF $_{\Delta x}$ (%)
R	0.1019	0.3831	0.890
X	0.05970	1.484	1.421

5. CONCLUSÃO

Nesta pesquisa, analisamos o desempenho de OLS e TLS em comparação com o estimador EKF para estimação de parâmetros de linha de transmissão, verificamos que OLS e TLS apresentaram melhor desempenho, porém a principal contribuição é que o EKF pode ser utilizado para estimação de parâmetros de linha de transmissão recursivamente. Os resultados das estimativas mostram que a grande maioria dos trabalhos na literatura faz uso do LMS ou de métodos não recursivos para a obtenção desses parâmetros e que a precisão de tais técnicas de regressão depende da aquisição de múltiplos dados. Na

abordagem proposta, o filtro de Kalman estendido leva em consideração tanto a característica dinâmica do sistema quanto as medições reais recursivamente, o que é útil para aplicações em tempo real como monitoramento e análise de sistemas.

AGRADECIMENTOS

Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES, pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico-CNPq (408681/2016-0 e 402830/2021-0) e Fundação de Amparo à Pesquisa do Estado de São Paulo-FAPESP (2021/01325-7).

REFERÊNCIAS

- Albuquerque, F.P., Costa, E.C.M., Liboni, L.H., Pereira, R.F.R., and de Oliveira, M.C. (2021). Estimation of transmission line parameters by using two least-squares methods. *IET Generation, Transmission & Distribution*, 15(3), 568–575.
- Asprou, M. and Kyriakides, E. (2015). Estimation of transmission line parameters using pmu measurements. In *2015 IEEE Power & Energy Society General Meeting*, 1–5. IEEE.
- Bendjabeur, A., Kouadri, A., and Mekhilef, S. (2021). Transmission line fault location by solving line differential equations. *Electric Power Systems Research*, 192, 106912.
- Bian, X., Li, X.R., Chen, H., Gan, D., and Qiu, J. (2011a). Joint estimation of state and parameter with synchrophasors—part i: State tracking. *IEEE Transactions on Power Systems*, 26(3), 1196–1208.
- Bian, X., Li, X.R., Chen, H., Gan, D., and Qiu, J. (2011b). Joint estimation of state and parameter with synchrophasors—part ii: Parameter tracking. *IEEE Transactions on Power Systems*, 26(3), 1209–1220.
- Costa, E.C.M. and Kurokawa, S. (2015). Estimation of transmission line parameters using multiple methods. *IET Generation, Transmission & Distribution*, 9(16), 2617–2624.
- Haykin, S. (2004). *Kalman filtering and neural networks*, volume 47. John Wiley & Sons.
- Liao, Y. and Kezunovic, M. (2008). Online optimal transmission line parameter estimation for relaying applications. *IEEE Transactions on Power Delivery*, 24(1), 96–102.
- Liboni, L.H., de Oliveira, M.C., and da Silva, I.N. (2020). Optimal kalman estimation of symmetrical sequence components. *IEEE Transactions on Instrumentation and Measurement*, 69(11), 8844–8852.
- Liboni, L.H., Flauzino, R.A., da Silva, I.N., Costa, E.C.M., and Suetake, M. (2016). Efficient signal processing technique for information extraction and its applications in power systems. *Electric Power Systems Research*, 141, 538–548.
- Liboni, L.H.B., da Silva, I.N., and de Oliveira, M.C. (2017a). Best modeling practices for optimal estimation of balanced and symmetric three-phase signals. In *2017 IEEE Power & Energy Society General Meeting*, 1–5. IEEE.
- Liboni, L.H.B., de Oliveira, M.C., and da Silva, I.N. (2017b). On the problem of optimal estimation of balanced and symmetric three-phase signals. *International Journal of Electrical Power & Energy Systems*, 91, 155–165.
- Magnus, J.R. and Neudecker, H. (2019). *Matrix differential calculus with applications in statistics and econometrics*. John Wiley & Sons.
- Milojević, V., Čalića, S., Rietveld, G., Ačanski, M.V., and Colangelo, D. (2018). Utilization of pmu measurements for three-phase line parameter estimation in power systems. *IEEE Transactions on Instrumentation and Measurement*, 67(10), 2453–2462.
- Mousavi-Seyedi, S.S., Aminifar, F., and Afsharnia, S. (2014). Parameter estimation of multiterminal transmission lines using joint pmu and scada data. *IEEE Transactions on Power Delivery*, 30(3), 1077–1085.
- Pereira, R.F., Albuquerque, F.P., Liboni, L.H., Costa, E., and de Oliveira, M.C. (2021). Phasor estimation in power transmission lines by using the kalman filter. *Electrical Engineering*, 1–10.
- Ren, P., Abur, A., and Lev-Ari, H. (2019). Tracking transmission line parameters in power grids observed by pmus. In *2019 IEEE Milan PowerTech*, 1–6. IEEE.
- Ren, P., Lev-Ari, H., and Abur, A. (2017). Tracking three-phase untransposed transmission line parameters using synchronized measurements. *IEEE Transactions on Power Systems*, 33(4), 4155–4163.
- Ritzmann, D., Rens, J., Wright, P.S., Holderbaum, W., and Potter, B. (2017). A novel approach to noninvasive measurement of overhead line impedance parameters. *IEEE Transactions on Instrumentation and Measurement*, 66(6), 1155–1163.
- Wang, Y. and Xu, W. (2015). Algorithms and field experiences for estimating transmission line parameters based on fault record data. *IET Generation, Transmission & Distribution*, 9(13), 1773–1781.