

# Aplicação de Sistema Imunológico Artificial para Alocação Ótima de Medidores com Suporte de Rede Neural Artificial

1º Thales Schuabb de Almeida  
*Faculdade de Engenharia Elétrica*  
*Universidade Federal de Juiz de Fora*  
Juiz de Fora, MG, Brasil  
thales.schuabb@engenharia.ufjf.br

2º Lucas Eduardo Silva Braga  
*Faculdade de Engenharia Elétrica*  
*Universidade Federal de Juiz de Fora*  
Juiz de Fora, MG, Brasil  
braga.lucas@engenharia.ufjf.br

3º Pedro Caruso Fracetti  
*Faculdade de Engenharia Elétrica*  
*Universidade Federal de Juiz de Fora*  
Juiz de Fora, MG, Brasil  
caruso.fracetti@engenharia.ufjf.br

4º Leonardo Willer de Oliveira  
*Faculdade de Engenharia Elétrica*  
*Universidade Federal de Juiz de Fora*  
Juiz de Fora, MG, Brasil  
leonardo.willer@ufjf.edu.br

5º Edimar José de Oliveira  
*Faculdade de Engenharia Elétrica*  
*Universidade Federal de Juiz de Fora*  
Juiz de Fora, MG, Brasil  
edimar.oliveira@ufjf.edu.br

6º Jerson dos Santos Carvalho  
*Faculdade de Engenharia Elétrica*  
*Universidade Federal de Juiz de Fora*  
Juiz de Fora, MG, Brasil  
jerson.carvalho@engenharia.ufjf.br

**Abstract**—The strategical allocation of meters, such as the Phasor Measurement Unit (PMU), at Power Distribution Systems (PDS), represents an optimization of the use of monitoring resources. This optimization can contribute to the State Estimation (SE) process, which consists of obtaining an estimated electrical network state without full monitoring. Meta-heuristics are potential methods for application to optimal allocation problems, such as meters in PDS. Still, computational intelligence techniques, such as Artificial Neural Networks (ANN), can be applied to SE, due to its agility in processing available measures. Therefore, this work aims to investigate the potential of associating a meta-heuristic technique, Artificial Immunological System (AIS) to allocate meters with the processing agility of ANN to evaluate different allocation options. A case study using a well-known test system in the area of knowledge demonstrates the applicability of the proposed hybrid method.

**Index Terms**—Meta-heuristic. Artificial Immune System. Artificial Neural Network. Distribution Network. State Estimation.

## I. INTRODUÇÃO

Os Sistemas Elétricos de Potência (SEP) têm se tornando cada vez mais complexos devido à expansão e ao aumento de diversidade das cargas. Para garantir confiabilidade ao sistema, é necessário conhecer os estados da rede e, para isso, técnicas de Estimção de Estados (EE) são utilizadas. Através da EE, é possível estimar tensões e fluxo de potência de uma rede elétrica, utilizando um conjunto limitado de medidas disponíveis. O estudo de estimção de estados para Sistemas de Distribuição de Energia Elétrica (SDEE) vem ganhando destaque, devido à baixa disponibilidade de equipamentos nessas redes.

Os autores deste artigo agradecem ao apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq, FAPEMIG, CAPES, INERGE, e aos grupos SMART4GRIDS e GOHB - Grupo de Otimização Heurística e Bioinspirada.

O processo de EE pode ser feito de diversas formas; um método bastante utilizado é o dos mínimos quadrados (WLS), baseado em um algoritmo que utiliza processos numéricos iterativos para realizar a estimção. Um fluxo de potência ótimo estendido é proposto em [1] para a EE, utilizando modelo de programação matemática capaz de prover estimativas a partir de dados históricos imprecisos e poucas medidas disponíveis, em relação ao porte da rede elétrica em estudo. Além dos métodos anteriores, técnicas baseadas em Redes Neurais Artificiais (RNA), como em [2], vêm ganhando destaque, por serem eficientes no processo de estimção, além de reduzir o esforço computacional, agilizando o processo para aplicações em tempo real.

Para realizar a estimção de estados, é necessário um conjunto de medidas, que podem ser provenientes de medidores inteligentes ou Unidades de Medição Fasorial (UMF). Como o custo desses equipamentos é elevado, principalmente de UMF, diversos estudos na literatura buscam determinar os melhores locais para a instalação. Em [3], é proposta uma abordagem multiobjetivo associada à meta-heurística Modified Monkey Search. A referência [4] utiliza algoritmo genético de chave aleatória para alocar medidores considerando critérios técnicos e econômico. Já em [5], tem-se um algoritmo que visa posicionar medidores em SDEE, aumentando a eficiência de EE, considerando três fatores: múltiplos níveis de carga, medidas correlacionadas e avaliação da precisão da EE sem o uso de Simulação de Monte Carlo.

Com o objetivo de aliar as vantagens das técnicas meta-heurísticas para problemas de alocação ótima de equipamentos com a agilidade de ação das redes neurais artificiais, o presente trabalho propõe a associação da técnica Sistema Imunológico Artificial (SIA) com RNA para a alocação de medidores do tipo UMF em SDEE. Como contribuição, tem-se a viabilidade

do processo de EE para a avaliação de soluções candidatas ao problema de otimização durante a execução da meta-heurística, que reduz o tempo computacional de execução em relação aos métodos conhecidos. A RNA embutida na meta-heurística SIA para a avaliação rápida de soluções candidatas é previamente treinada. Pseudo-medidas são utilizadas para garantir a observabilidade da rede elétrica mesmo com um número reduzido de medidas. Um estudo de caso envolvendo um sistema teste de 33 barras conhecido na literatura para o problema de EE é apresentado, a partir do qual se pode comprovar a aplicabilidade do método híbrido SIA/RNA proposto.

Além desta seção introdutória, o presente artigo tem outras quatro seções. A seção 2 apresenta uma breve fundamentação teórica sobre SIA e EE. A metodologia proposta é apresentada na seção 3, enquanto que os resultados são descritos na seção 4. Por fim, a seção 5 discorre sobre as principais conclusões.

## II. FUNDAMENTAÇÃO TEÓRICA

### A. O Sistema Imunológico Artificial

Para minimizar o erro do processo de estimação de estados, a alocação estratégica de medidores do tipo UMF é proposta através da técnica meta-heurística sistema imunológico artificial, mais precisamente, do algoritmo de seleção clonal para problemas de otimização combinatória, denominado CLO-NALG, utilizado em [6] e [7].

O SIA [8] é baseado no sistema imune natural adaptativo, inspirado em mecanismos avançados de identificação de agentes infecciosos. Em um problema de otimização, como o presente trabalho, o SIA utiliza mecanismos evolutivos descritos na seção III-C para identificar o ponto de mínimo ou de máximo de uma função objetivo.

Uma característica importante dessa técnica, que motivou sua aplicação no presente trabalho, é a sua capacidade para combinar processos de busca global e local, através de mecanismos como edição de receptores e maturação de afinidade, respectivamente [8]. Essa capacidade é de interesse para problemas de otimização combinatória na tentativa de tentar evitar a convergência prematura em subespaços com soluções subótimas de baixa qualidade.

### B. Índices de Estimação de Estados

Para avaliação da EE, são utilizadas algumas métricas conhecidas na literatura. A métrica *EEE* (Erro de Estimação de Estados), descrita em (1), é a mais difundida [9]. Adicionalmente, o presente trabalho também considera outras três métricas, propostas por [1]:

- *EMT* (Erro de Módulo de Tensão), formulado em (2);
- *EAF* (Erro de Ângulo de Fase), conforme (3);
- *IGE* (Índice Geral de Estimação), dado pelo somatório das métricas *EEE*, *EMT* e *EAF*, conforme (4).

A utilização dessas métricas é necessária para que os resultados obtidos possam ser diretamente comparados com os resultados de [1].

$$EEE = \sqrt{\sum_{i=1}^{Nb} (V_i^* - \widehat{V}_i)^2 + \sum_{i=1}^{Nb} (\theta_i^* - \widehat{\theta}_i)^2} * 100 \quad (1)$$

$$EMT = \max_k \left| \frac{|V_k^*| - |\widehat{V}_k|}{|V_k^*|} \right| * 100 \quad (2)$$

$$EAF = \max_k \left| |\theta_k^*| - |\widehat{\theta}_k| \right| * 100 \quad (3)$$

$$IGE = EEE + EMT + EAF \quad (4)$$

Em que:

- $V_i^*$  é o valor real do módulo de tensão da barra  $i$ ;
- $\widehat{V}_i$  é o valor estimado do módulo de tensão da barra  $i$ ;
- $\theta_i^*$  é o valor real do ângulo de fase da tensão da barra  $i$ ;
- $\widehat{\theta}_i$  é o valor estimado do ângulo de fase da tensão da barra  $i$ ;
- $Nb$  é o número total de barras do sistema.

O índice *IGE* será utilizado para comparação direta com os resultados de [1]. As métricas *EMT* e *EAF* dão uma maior sensibilidade ao resultado sobre os erros individuais de cada estado, uma vez que indica a magnitude do maior erro, algo que a métrica *EEE* não é capaz de detectar, pois computa todos os desvios entre valores reais e estimados, conforme (1).

## III. METODOLOGIA PROPOSTA

### A. Codificação da solução candidata no SIA

O SIA requer um conjunto de soluções candidatas e estas soluções são representadas através de códigos. No problema em questão, uma solução refere-se às barras em que há alocação de medição e, portanto, a codificação deve ser feita em função dessas barras. A Figura 1 mostra um sistema fictício e ilustrativo de 5 barras, utilizado para exemplificar a codificação de uma solução, que consiste na alocação de medidores (M) nas barras 2 e 5. O algoritmo SIA foi desenvolvido na linguagem de programação *Python*.




Figura 1. Sistema Exemplo de 5 Barras e a Codificação da Solução Candidata




Figura 2. Rede *MultiLayer Perceptron* Utilizada

### B. Método Híbrido SIA/RNA Proposto

O estudo utiliza uma Rede Neural com topologia denominada *MultiLayer Perceptron* (MLP), atuando com aprendizado supervisionado pelo método *ADAM*. O processo de aprendizagem é realizado utilizando como dados de entrada vetores que incluem os valores dos módulos de tensão ( $V$ ) e de ângulo de fase ( $\theta$ ), e as saídas são as estimativas de módulos de tensão ( $\hat{V}_i$ ) e ângulo de fase ( $\hat{\theta}_i$ ) em todas as barras  $i$  do sistema. A arquitetura da RNA proposta é representada pela Figura 2, presente em pacote da linguagem de programação *Python*, mais precisamente, o pacote *Scikit-Learn*.

A sigla NNCO, apresentada na Figura 2, é o número de neurônios da camada oculta. Os dados de tensão são pseudo-medidas obtidas através da variação da carga de cada barra em  $\pm 40\%$ , o que representa um registro histórico de baixa precisão. Para cada cenário deste registro, é executado um fluxo de potência, do qual se obtém todas as tensões em módulo e fase. Para a execução junto ao SIA, o treinamento da RNA é realizado utilizando medidas em todas as barras, uma vez que a localização dos medidores é variável durante o processo de convergência da meta-heurística.

Durante a execução do SIA, para que uma solução candidata seja avaliada, são realizados testes com 1250 cenários de carga, a fim de representar a aleatoriedade da carga. Em cada teste, as entradas para as barras indicadas pela solução candidata do SIA correspondem às medições das UMFs alocadas, considerando seu erro máximo de  $0,4\%$ , conforme classe de precisão desse tipo de equipamento. Já nas demais barras, são utilizadas pseudomedidas  $V_{pi}$  e  $\theta_{pi}$ , que consistem nos módulos e ângulos de tensões das barras não monitoradas para um cenário com as cargas ajustadas nos respectivos valores médios do histórico do SDEE.

Dessa forma, as barras indicadas pela solução são providas de medições apuradas, enquanto as barras sem medição são representadas por pseudo-medidas considerando um cenário de carga médio, que não retrata com fidelidade o sistema em todos os cenários de teste. Para cada solução candidata e codificada conforme mostrado anteriormente na seção III-A, a RNA proposta já treinada é executada a fim de retornar o

índice *IGE* para cada um dos 1250 cenários. Daí, a média dos valores de *IGE* para os 1250 cenários de teste é considerada como métrica final para a solução candidata em questão.

Para comparar a solução final obtida pelo algoritmo híbrido SIA/RNA com a literatura, a solução do SIA/RNA é submetida à outra RNA que estima o estado do SDEE, porém, sem considerar todas as entradas da RNA embutida no SIA. Isso porque as barras decididas para alocação já são conhecidas após a convergência do algoritmo SIA/RNA e, portanto, a RNA de comparação pode considerar como entradas apenas as medidas de UMF para as barras monitoradas. As métricas de *IGE* também é calculada para a solução da literatura, para fins de comparação.

O conjunto de cenários obtidos a partir do cálculo de fluxo de potência é dividido em três grupos:  $50\%$  dos cenários para conjunto de treinamento (2500 amostras);  $25\%$  para o conjunto de validação (1250 amostras);  $25\%$  para o conjunto de teste (1250 amostras). O critério de validação cruzada é, portanto, utilizado no presente trabalho, considerando  $N_{vc}$  como limite de vezes em que a precisão da RNA, durante o treinamento, piora para o conjunto de validação.

### C. Algoritmo SIA

Conforme descrito anteriormente, o presente trabalho utiliza o algoritmo proposto em [7], em que os fundamentos da técnica SIA [10] [6] são aplicados a problemas de otimização combinatória, cujos passos são descritos a seguir e representados pelo fluxograma da Figura 3.

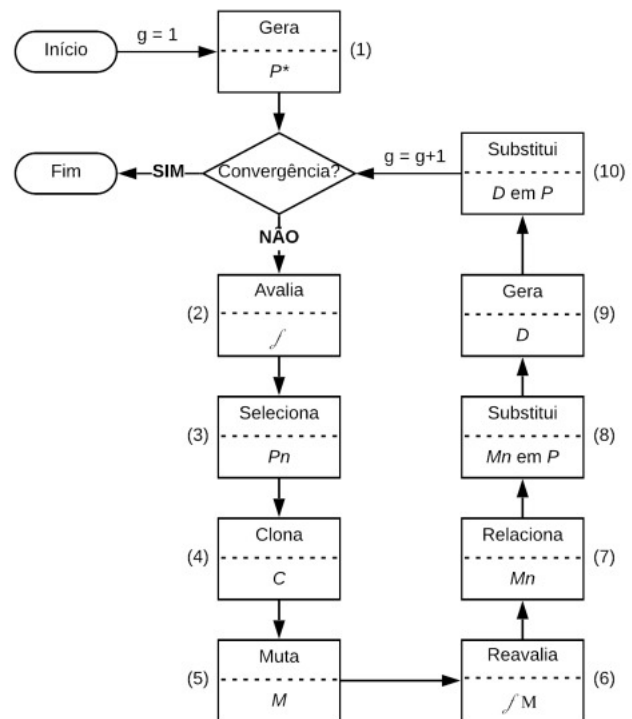


Figura 3. Fluxograma do Algoritmo SIA

- (1) **Geração inicial de Anticorpos do Repertório  $P^*$ :** O conjunto inicial de soluções candidatas é obtido por um processo aleatório. Destaca-se que  $P^*$  representa uma matriz  $[NAb \times L]$ , onde  $NAb$  é o número de anticorpos e  $L$  é o número de atributos de cada anticorpo. Ao final deste passo, a população atual  $P$  recebe  $P^*$ .
- (2) **Avaliação da afinidade de  $f$  dos anticorpos de  $P$ :** A afinidade de um anticorpo é dada pelo inverso do erro da RNA.
- (3) **Seleção dos melhores anticorpos de  $P$ :** Nesta etapa, os melhores anticorpos de  $P$  são selecionados para compor o repertório  $P_n$ .
- (4) **Clonagem dos anticorpos de  $P_n$ :** Os anticorpos que foram previamente selecionados em  $P_n$  são clonados, formando a população  $C$ .
- (5) **Hipermutação:** Nesta etapa, os anticorpos do repertório  $C$  sofrem mutação, formando o conjunto de clones maduros  $M$ .
- (6) **Avaliação da afinidade  $fM$  dos anticorpos de  $M$ .**
- (7) **Seleção dos melhores anticorpos de  $M$ :** Nesta etapa ocorre o processo descrito no Passo-3 formando a população  $M_n$ .
- (8) **Substituição dos piores anticorpos de  $P$  pelos anticorpos de  $M_n$ .**
- (9) **Edição de receptores:** Gera-se uma quantidade " $d$ " pré-definida, de anticorpos, de modo aleatório, formando o conjunto  $D$ . Estes anticorpos substituem os " $d$ " anticorpos com menor afinidade da população  $P$ .
- (10) **Substituição dos anticorpos de  $P$  pelos anticorpos de  $D$ .**

Após (10), o contador de geração ( $g$ ) é incrementado e o critério de convergência é avaliado. Este critério é satisfeito quando uma das seguintes condições é atingida:

- I) O número de gerações atinge um valor limite dado por  $gmax$ ;

Caso não ocorra convergência o algoritmo retorna ao Passo-2.

#### IV. ESTUDO DE CASOS

##### A. Descrição do Caso de Estudo

A metodologia proposta foi aplicada em um computador Intel(R) Core(TM) i3-3110M CPU @ 2.40GHz 8,00 GB RAM Windows 10, utilizando um sistema de teste conhecido na literatura, contendo 33 barras [11] conforme ilustrado na Figura 4. O número de UMFs consideradas para alocação ótima é igual a quatro, conforme o estudo presente na literatura [1]. O SIA utilizado tem suas configurações resumidas na Tabela I. O parâmetro  $\beta$  é de controle no processo de clonagem e  $\rho$  é probabilidade de mutação dos anticorpos. Já  $n$  é a porcentagem de anticorpos selecionados para clonagem.




Figura 4. Sistema de 33 Barras

Tabela I  
CONFIGURAÇÃO DO SIA

Parâmetro	$NAb$	$\beta$	$\rho$	$d$	$gmax$	$n$
Configuração	50	20	0,05%	3	50	20%

O treinamento da RNA é realizado ajustando os pesos sinápticos a uma taxa de aprendizagem  $t_a$ , em que erro médio quadrático deve atender a uma tolerância  $tol$ . Durante esse processo, são checados os seguintes critérios de convergência: número máximo de validações cruzadas  $N_{vc}$  e número máximo de iterações ou épocas  $N_{gm}$ . O treinamento é encerrado quando pelo menos um desses critérios é atendido. A configuração da RNA, conforme anteriormente descrita, é resumida na Tabela II.

O número de neurônios da camada oculta é calculado em função do número de entradas ( $NE$ ) e do número de saídas ( $NS$ ), conforme (5). Este valor de  $NNCO$  foi determinado empiricamente de modo a fornecer uma estimativa compatível com a literatura. Como a RNA considera medidas de módulo de tensão e ângulo de fase em todas as barras da rede elétrica, o número de entradas é igual ao dobro do número de barras,  $N_b$ , conforme (6). Adicionalmente, como o estimador de estados estima módulo e fase de tensão em todas as barras, o número de saídas também é dado por (6).

$$NNCO = NE + NS \quad (5)$$

$$NE = NS = 2 * N_b \quad (6)$$

Tabela II  
CONFIGURAÇÃO DA RNA INTEGRADA AO SIA

$NNCO$	$tol$	$t_a$	$N_{vc}$	$N_{gm}$
64	$1e^{-9}$	$1e^{-3}$	500	100000

Os resultados da estimação com a RNA e a alocação do SIA são comparados com o resultado obtido por [1] e sua alocação

ótima para quatro UMFs. Um modelo não linear de fluxo de potência é utilizado para gerar o universo amostral da RNA. Os dados históricos de carga são obtidos a partir da modelagem de funções de distribuição normais de probabilidade para as potências ativas de cada barra, cuja média ou esperança é o valor obtido da literatura, denominado como caso base no presente trabalho. O desvio padrão considerado é de 13,33% em relação à média, de modo que 99,7% dos valores estejam dentro do intervalo de  $\pm 40\%$  da média, seguindo a definição de pseudo-medidas de [1]. O nível de incerteza de 40% foi escolhido para uma melhor representação do SDEE, conforme recomendado por [1].

### B. Resultados

O algoritmo híbrido SIA/RNA foi executado 100 vezes para avaliar a distribuição das soluções ótimas encontradas. A Figura 5 apresenta o gráfico de dispersão, conhecido como *boxplot*, para as soluções obtidas, sendo a métrica *IGE* representada no eixo das ordenadas. Os resultados são os seguintes:

- *IGE* Máximo: 36,9236;
- Terceiro Quartil de *IGE*: 36,1859;
- Segundo Quartil (Mediana) de *IGE*: 34,6681;
- Primeiro Quartil de *IGE*: 33,1159;
- *IGE* Mínimo: 30,5685.

Importante notar que nenhum *outlier* ou desvio grosseiro foi obtido nas 100 execuções do algoritmo híbrido proposto. A dispersão obtida demonstra que esse algoritmo é capaz de identificar a solução com pouca variação em torno da mesma, o que é um comportamento desejável para métodos probabilísticos, como as meta-heurísticas.

A Tabela III apresenta as barras monitoradas, ou seja, com alocação de UMF, pela metodologia SIA/RNA proposta e pela literatura [1]. A Tabela IV apresenta as médias dos valores obtidos para a métrica *IGE* pelo algoritmo SIA/RNA e para a solução da literatura [1], juntamente com os outros índices de estimação de estados. Por essa tabela, pode-se verificar que o índice *IGE* obtido pelo algoritmo híbrido proposto é menor do que o da literatura e, portanto, a metodologia proposta implica em uma solução de melhor qualidade no que se refere à precisão das estimativas a partir das medidas provenientes das barras decididas pelo SIA.

A Tabela V apresenta o tempo computacional gasto pelo algoritmo SIA/RNA proposto, comparado com o tempo que foi necessário para o algoritmo de [1], que foi reproduzido e incorporado à meta-heurística SIA para a alocação ótima de medidores com critério de mérito sendo a precisão da estimação. Desta tabela, pode-se verificar um tempo via SIA/RNA 89,55 % menor, comprovando a atratividade de se combinar RNA com a meta-heurística SIA. Embora o problema de planejamento seja off-line, ou seja, não tenha requisito de execução em tempo real, a redução do esforço computacional pode permitir a análise de mais opções e planos, sendo, portanto, atrativa para essa tarefa.

A Figura 6 mostra os módulos de tensão e ângulos de fase reais e estimados para a RNA com alocação de [1]. Já a Figura

Tabela III  
ALOCAÇÃO DA MEDIÇÃO

Solução	Barras Monitoradas
SIA/RNA Proposto	1-4-18-21
[1]	7-14-26-27




Figura 5. Boxplot das 100 soluções obtidas pelo algoritmo híbrido proposto

7 retrata as mesmas grandezas para a RNA com alocação de medidores sugerida pelo algoritmo SIA/RNA. É possível constatar visualmente a melhora na estimação, corroborando com a melhora nas métricas obtidas.




Figura 6. Estimação Utilizando a Alocação de [1]

Tabela IV  
COMPARAÇÃO ENTRE OS RESULTADOS

Índices de Estimação	IGE	EMT	EAF	EEE
SIA/RNA Proposto	1,545066	0,424744	0,088367	1,031955
Alocação de [1]	2,879861	0,762059	0,140257	1,977544

Tabela V  
COMPARAÇÃO ENTRE TEMPOS COMPUTACIONAIS

Algoritmo	Tempo (s)
SIA/RNA Proposto	154.800
Algoritmo de [1]	1.480.900




Figura 7. Estimação Utilizando a Alocação do Algoritmo SIA/RNA Proposto

## V. CONCLUSÃO

O presente trabalho demonstrou a potencialidade de associação de meta-heurística com técnicas de inteligência artificial, como redes neurais artificiais, para a alocação ótima de equipamentos de medição em sistemas de energia elétrica. Essa associação visa aliar a capacidade de busca por soluções ótimas para o problema combinatorial de alocação de equipamentos, com a rápida resposta das redes neurais artificiais na estimação de estados, necessária para a avaliação de soluções de alocação candidatas. Os resultados indicaram que a associação do SIA com RNA, através de um algoritmo híbrido de otimização, é capaz de analisar uma diversidade de combinações e determinar a alocação ótima de medidores sob o critério de precisão do estimador, com baixa dispersão dos resultados entre diferentes execuções. Além disso, a associação proposta permite reduzir esforços computacionais para a tarefa de alocação de medidores devido à resposta rápida das redes neurais artificiais. Espera-se que a metodologia possa abrir uma nova linha de investigação sobre estimação de estados

com suporte de otimização combinatoria associada com inteligência artificial.

## REFERÊNCIAS

- [1] F. G. Duque, L. W. de Oliveira, E. J. de Oliveira, and A. A. Augusto, "State estimator for electrical distribution systems based on an optimization model," *Electric Power Systems Research*, vol. 152, pp. 122–129, 2017.
- [2] A. F. Fiaz Ahmad, Muhammad Tariq, "A novel ann-based distribution network state estimator," *Electrical Power and Energy Systems*, vol. 107, pp. 200–212, 2019.
- [3] F. G. Duque, L. W. de Oliveira, E. J. de Oliveira, and J. C. de Souza, "A cost-benefit multiobjective approach for placement of meters in electrical distribution systems," *Electric Power Systems Research*, vol. 191, p. 106897, 2021.
- [4] A. B. Antonio A.M.Raposo and M. G. da Silva, "Robust meter placement for state estimation considering distribution network reconfiguration for annual energy loss reduction," *Electric Power Systems Research*, vol. 182, 2020.
- [5] A. A. Raposo, A. B. Rodrigues, and M. d. G. da Silva, "Optimal meter placement algorithm for state estimation in power distribution networks," *Electric power systems research*, vol. 147, pp. 22–30, 2017.
- [6] L. N. De Castro and F. J. Von Zuben, "Artificial immune systems: Part ii—a survey of applications," *FEEC/Univ. Campinas, Campinas, Brazil*, 2000.
- [7] L. W. De Oliveira, E. J. de Oliveira, F. V. Gomes, I. C. Silva Jr, A. L. Marcato, and P. V. Resende, "Artificial immune systems applied to the reconfiguration of electrical power distribution networks for energy loss minimization," *International Journal of Electrical Power & Energy Systems*, vol. 56, pp. 64–74, 2014.
- [8] P. A. D. d. Castro *et al.*, "Sinergia entre sistemas imunologicos artificiais e modelos graficos probabilisticos," 2009.
- [9] P. P. Tecchio, R. A. Benedito, and L. F. Alberto, "The behavior of wls state estimator near the maximum loadability point of power systems," in *IEEE PES General Meeting*. IEEE, 2010, pp. 1–6.
- [10] L. N. De Castro and F. J. Von Zuben, "Artificial immune systems: Part i—basic theory and applications," *Univer-sidade Estadual de Campinas, Dezembro de, Tech. Rep.*, vol. 210, no. 1, 1999.
- [11] M. E. Baran and F. F. Wu, "Network reconfiguration in distribution systems for loss reduction and load balancing," *IEEE Power Engineering Review*, vol. 9, no. 4, pp. 101–102, 1989.