

# Identificação Inteligente de Dados Críticos para a Estimação de Estado em Sistemas de Potência

Diogo L. Bragança\*, Andre A. Augusto\*  
Julio C. S. de Souza\*, Milton B. Do Coutto Filho\*\*

\*Departamento de Engenharia Elétrica, Universidade Federal Fluminense,  
Niterói, Brasil (e-mail: aaaugusto@id.uff.br).

\*\*Instituto de Computação, Universidade Federal Fluminense,  
Niterói, Brasil

---

Abstract: State estimation plays a vital role in the real-time operation of electrical systems, being responsible for obtaining the best estimate of the state of an electrical network considering measurement uncertainties and the occurrence of bad data. Critical Data groups or criticalities present in the available database constitute limitations and risks to a successful realization of state estimation. Identifying these criticalities is a problem of combinatorial nature and difficult solution, which can be built intelligent solution strategies that explore some properties exhibited by these criticalities. This work aims to investigate the application of Artificial Intelligence search algorithms to identify accurate data for state estimation in power systems. Simulations with the IEEE 30-bus system will illustrate the proposed methodology for the intelligent identification of criticalities.

Resumo: A estimação de estado desempenha papel importante na operação de sistemas elétricos em tempo real, sendo responsável por obter a melhor estimativa do estado de uma rede elétrica a partir de medições contendo incertezas e eventualmente Erros Grosseiros. Grupos de dados críticos ou criticalidades presentes na base de dados, identificados no processo de estimação, constituem limitações e riscos à realização exitosa da estimação de estado. A listagem destas criticalidades é um problema de natureza combinatória e de difícil solução, para o qual pode-se construir estratégias inteligentes de solução que explorem as propriedades que essas criticalidades exibem. Este trabalho objetiva a investigação da aplicação de algoritmos de busca, baseados em Inteligência Artificial, na identificação de dados críticos para a estimação de estado em sistemas de potência. Simulações com o sistema IEEE 30 barras ilustrarão a metodologia proposta para a identificação inteligente de criticalidades.

*Keywords:* Power System State Estimation; Observability; Criticality; Artificial Intelligence.

*Palavras-chaves:* Estimação de Estado em Sistemas de Potência; Observabilidade; Criticalidade; Inteligência Artificial.

---

## 1. INTRODUÇÃO

A operação em tempo real dos sistemas elétricos de potência baseia-se nas observações colhidas pelo sistema supervisor de controle e aquisição e de dados (*Supervisory Control And Data Acquisition - SCADA*) e enviadas ao Sistema de Gerenciamento de Energia (SGE) – constituído por um conjunto de ferramentas computacionais destinadas ao monitoramento, controle e otimização de uma rede elétrica. A Estimação de Estado (EE), uma das funções componentes de um SGE, tem a finalidade de processar os dados colhidos, através de um modelo da rede elétrica em tempo real (Monticelli 1999, Abur 2004). Esses dados geralmente contêm erros estatisticamente pequenos, inerentes à medição, ou podem estar corrompidos por Erros Grosseiros (EGs) eventuais ou intencionais oriundos de ataques cibernéticos (Kosut et. al. 2010).

As medições são obtidas em subestações instrumentadas com unidades de medição (UMs) como dispositivos eletrônicos

inteligentes (*Intelligent Electronic Devices – IEDs*) e unidades de medição fasorial (UMFs). Normalmente, os IEDs coletam magnitudes de tensão e corrente; injeções e fluxos de potência (ativa e reativa), além das posições (aberto/fechado) dos dispositivos de seccionamento. Já as UMFs fornecem os fasores de tensão e corrente (Phadke 2008). As tensões complexas (ângulos de fase e magnitudes) das barras usualmente são adotadas como componentes do estado da rede elétrica (Abur 2004). O estabelecimento da configuração atual da rede, análise de observabilidade, filtragem e processamento de EGs são as etapas constituintes da EE. Inicialmente, as medições são processadas de forma a construir-se o modelo barra-ramo utilizado pelas funções do SGE. Em seguida, a análise de observabilidade verifica se há condições para a determinação do estado a partir dos dados disponíveis. No módulo de filtragem, estima-se o estado da rede e as medidas, usualmente através do método dos Mínimos Quadrados Ponderados (MQP). A partir dessas estimativas, verifica-se a consistência dos resultados da estimação na etapa de depuração de EGs.

A EE confere transparência às informações disponibilizadas ao SGE. Essa clareza, entretanto, depende da criticalidade dos dados supridos a EE. Entende-se por criticalidade dos dados a essencialidade desses – individual ou conjunta – ao processo de estimação (Braga Flôr et. al. 2021, Coimbra et. al. 2021). Uma forma de criticalidade com grande importância para a EE é a  $k$ -tupla crítica. Em termos gerais, uma  $k$ -tupla crítica ( $C_k$ -tupla, ou  $C_k$ ) é caracterizada como o grupo de  $k$  elementos que, quando indisponíveis (em sua totalidade), tornam o sistema inobservável. Porém, a indisponibilidade de  $j$  deles (para qualquer  $j < k$ ), não afeta a observabilidade (Augusto 2016). Assim, as  $C_k$ s são grupos de dados críticos essenciais ao processo de estimação, sendo considerados vulnerabilidades da EE (Augusto 2019).

Uma avaliação qualitativa da capacidade da EE em gerar dados transparentes consiste em identificar as  $k$ -tuplas críticas presentes nos dados. Esta, todavia, é uma tarefa de enumeração difícil e complexa. Até o presente momento, tem-se investigado a identificação destes dados críticos utilizando-se programação inteira-mista (Sou 2012) ou otimização discreta (Augusto 2019, London 2007, Do Coutto Filho 2007). Em ambas as abordagens, trata-se a identificação das criticalidades como um problema de busca. Com os avanços tecnológicos e disponibilidade de dados verificada nos últimos anos, métodos de Inteligência Artificial (IA) têm se tornado cada vez mais atrativos e vêm ganhando destaque. Problemas de busca também podem ser solucionados de maneira eficiente por meio de IA. Assim sendo, este trabalho busca investigar o uso de IA para solucionar o problema de identificação de dados críticos em EE. Agentes inteligentes baseados em técnicas clássicas de busca informada e não informada serão propostos. Testes com a rede de referência IEEE 30 barras ilustrarão os resultados. O resto do trabalho está organizado na seguinte forma: a Seção 2 apresenta os fundamentos da estimação de estado e criticalidades de dados, uma breve revisão da solução de problemas de busca é realizada na Seção 3, a metodologia proposta constitui a Seção 4, os resultados obtidos serão apresentados na Seção 5 e, por fim as conclusões do trabalho serão discutidas na Seção 6.

## 2. ESTIMAÇÃO E CRITICALIDADE DOS DADOS

Esta seção apresenta aspectos fundamentais da estimação de estado, notadamente aqueles referentes à análise de observabilidade, e o processamento de EGs. Noções de criticalidades dos dados, suas principais características e seu impacto na EE também serão discutidos.

### 2.1 Análise de Observabilidade

A observabilidade de uma rede elétrica está intrinsecamente associada à interdependência entre as medições, o estado e a configuração da rede. Os métodos adotados na análise de observabilidade tipicamente assumem as medições em pares (ativo/reactivo ou real/imaginário) e utilizam o modelo linearizado (Monticelli 1999, Abur 2004):

$$\mathbf{z}_a = \mathbf{H}_a \boldsymbol{\theta} + \mathbf{v}_a \quad (1)$$

onde:  $\boldsymbol{\theta}$  – vetor contendo os ângulos de fase das tensões das barras;  $\mathbf{z}_a$  – vetor de medidas ativas;  $\mathbf{v}_a$  – vetor de erros de medição;  $\mathbf{H}_a$  – matriz Jacobiano de medidas ativas.

Por medição ativa compreendem-se as medidas de injeção e fluxo de potência ativa, ângulo do fasor de tensão nodal e a parte real das correntes nos ramos e injetadas. Representa-se o erro de medição pela distribuição normal com média  $\mathbf{0}$  e matriz de covariância  $\mathbf{R}_a = \mathbf{I}$ . A estimativa de MQP para o modelo (1) é dada por:

$$\hat{\boldsymbol{\theta}} = \mathbf{G}_a^{-1} \mathbf{H}_a^T \mathbf{z}_a \quad (2)$$

onde  $\mathbf{G}_a = \mathbf{H}_a^T \mathbf{H}_a$  é a matriz de Ganho associada às medições ativas.

Para que o estado estimado seja único, torna-se necessário que a  $\mathbf{G}_a$  seja não singular. Assim sendo, a análise de observabilidade consiste em verificar se o sistema (1) admite solução única.

### 2.2 Processamento de Dados Espúrios

Após a etapa de filtragem, busca-se identificar dados contaminados por EGs para em seguida processá-los. Uma das formas de realizar essa tarefa através dá através da análise residual, na qual o resíduo (i.e, a diferença entre os valores medidos e estimados) é normalizado e submetido a uma validação estatística (teste  $r_N$ ). De acordo com esse teste, são suspeitas as medidas que não atenderem as condições:

$$\mathbf{r} = \mathbf{z} - \hat{\mathbf{z}} \quad (3)$$

$$\mathbf{r}_N(i) = |\mathbf{r}(i)| / \sqrt{\mathbf{E}(i,i)} \leq \lambda \quad (4)$$

$$\mathbf{E} = \mathbf{I} - \mathbf{H}\mathbf{G}^{-1}\mathbf{H}^T \quad (5)$$

onde  $\mathbf{z}$  – vetor de medidas adquiridas;  $\hat{\mathbf{z}}$  – vetor de medidas estimadas;  $\mathbf{r}_N(i)$  – resíduo normalizado da medida  $i$ ;  $\mathbf{E}$  – matriz de covariância dos resíduos; e  $\lambda$  – limiar de detecção.

As matrizes  $\mathbf{G}_a$  e  $\mathbf{E}$  contém informações importantes sobre as criticalidades como será visto adiante.

### 2.3 $k$ -tuplas críticas de elementos da rede

As forças e fraquezas dos locais medidos da rede refletem os diferentes níveis de criticalidade dos dados. O conceito geral de criticalidade de um elemento no processo de estimação conduz à intensidade desta condição para o processo de EE (Augusto 2019). Assim sendo, caracteriza-se uma  $k$ -tupla crítica ( $C_k$ -tupla) como o agrupamento de  $k$  elementos, tal que a indisponibilidade de todos torna o sistema inobservável. Porém, a ausência de  $j$  deles, para qualquer  $j < k$ , não afeta a observabilidade. A cardinalidade  $k$  de uma tupla crítica quantifica suas consequências disruptivas na EE, visto que a

presença de uma  $Ck$ -tupla estabelece a capacidade de detecção e identificação de EGs (Clements 1986).

A partir do conceito de  $k$ -tupla crítica, pode-se elencar algumas propriedades dessas criticalidades:

- **Propriedade 1:** As  $k$  colunas da matriz  $E$  associadas a uma  $Ck$  constituem um conjunto linearmente dependente.
- **Propriedade 2:** Uma  $k$ -tupla crítica não contém uma  $Cj$ -tupla,  $\forall j < k$ .
- **Propriedade 3:** Se  $k-r$  elementos de um  $Ck$ -tupla ( $r < k$ ) tornam-se indisponíveis, os elementos remanescentes constituirão uma  $r$ -tupla crítica.
- **Propriedade 4:** Se uma  $\ell$ -tupla de elementos torna a rede não observável quando removida, então ela contém ao menos uma  $Ck$ -tupla,  $k \leq \ell$ .

A identificação de  $Ck$ -tuplas desempenha um papel importante na EE, uma vez que sua capacidade de processar múltiplos EGs tem limites estabelecidos pela presença de  $Ck$ -tuplas (Clements 1986, Sou 2012). Como condição geral de criticalidade de medidas, pode-se dizer que: se até  $(k - 2)$  medidas pertencentes à mesma  $k$ -tupla crítica estão contaminadas por EGs, tais erros podem ser detectados e identificados pela análise residual. Contudo, se  $(k - 1)$  ou  $(k)$  EGs estão presentes numa  $Ck$ -tupla de medidas, eles somente podem ser detectados. Outras propriedades das criticalidades podem ser encontradas em Braga Flôr et al. (2021) e Coimbra et al. (2021).

### 3. RESOLUÇÃO DE PROBLEMAS VIA BUSCA

Busca-se com a IA estudar a construção de agentes inteligentes, capazes de perceber o ambiente em que se encontram e tomar decisões sobre esse, baseadas em suas observações, e buscando sempre maximizar seu desempenho (Russel 2010). Embora venha sendo investigada por mais de seis décadas, recentemente tem se popularizado em diversas áreas, em razão da grande disponibilidade de dados e recursos computacionais. A IA tem muitos campos de estudo, sendo um deles caracterizados por problemas de busca no espaço de soluções. Esta seção versa brevemente sobre a solução de tais problemas através de estratégias de busca clássica.

#### 3.1 Agente Solucionador de Problemas

Entende-se por Agente um objeto capaz de perceber o seu ambiente através de sensores e agir – através de atuadores – nesse, modificando seu estado. Em geral, a escolha das ações que o agente toma são baseadas nas percepções observadas até o momento da ação (Russel 2010). A representação matemática de um agente (usualmente como uma função) e a sua implementação computacional, são denominadas função do agente e programa do agente, respectivamente. Quando as decisões tomadas visam maximizar o seu próprio desempenho (mensurado através de uma medida de desempenho), o agente é considerado racional.

Os agentes solucionadores de problemas são agentes racionais guiados por um objetivo onde se desconhece a estrutura dos

estados do ambiente (Russel 2010). Assim sendo, a formulação do problema a ser resolvido por tais agentes deve estabelecer um objetivo, além de ações, e estados que permitam alcançá-lo. A sequência de ações que levam ao objetivo é denominada de busca (Russel 2010). A solução de problemas por meio de busca contém em geral os seguintes elementos

- Estado inicial: representa o estado do ambiente presente no início da busca.
- Ações: conjunto de possíveis atuações no ambiente, considerando-se seu estado vigente.
- Modelo de Transição: define os resultados de cada ação.
- Teste de Objetivo: verifica se o objetivo foi alcançado.
- Custo de caminho: quantifica o custo associado a uma sequência de ações ou estados.

As ações e o modelo de transição estabelecem uma árvore de estados cuja raiz é o estado inicial. Ramos e nós da árvore correspondem aos estados e ações respectivamente. A sequência de nós *distintos* entre a raiz e um determinado nó denomina-se caminho. Diferentes estratégias de busca podem ser elaboradas para a varredura da árvore de estados. Aquelas que utilizam apenas informações indicadas na formulação do problema são denominadas cegas. Já aquelas que se aproveitam de informações adicionais são denominadas informadas.

#### 3.2 Estratégias de Busca Cega

Dentre as buscas clássicas e não informadas destacam-se as buscas em largura (*Breadth First Search* – BFS), profundidade (*Depth First Search* – DFS) e de custo uniforme (BCU). Na primeira, percorre-se a árvore de estados da seguinte forma: primeiramente visita-se e expande-se o estado inicial (i.e., listam-se os estados resultantes das possíveis ações no estado atual), em seguida, todos os seus sucessores e assim por diante, até que o (estado) objetivo seja alcançado. Na segunda estratégia, percorre-se a árvore de estados visitando-se e expandindo-se sempre o nó mais profundo (o nó de caminho mais longo a partir do nó raiz). Por fim, na busca de custo uniforme o estado expandido é aquele que apresenta o menor custo de caminho, que corresponde à soma acumulada do custo de todas as ações tomadas desde a raiz até o nó avaliado. Computacionalmente, as buscas são implementadas armazenando-se os nós gerados em uma lista LIFO, FIFO ou fila de prioridades (Russel 2010).

A ordem de visita e expansão dos nós resulta em diferentes complexidades de tempo e de espaço para cada uma delas. Se  $d$  é a profundidade mínima do nó objetivo, e  $b$  o fator de ramificação (média de nós gerados em cada expansão), a complexidade de tempo e espaço da busca em largura são respectivamente  $O(b^d)$  e  $O(b^d)$ . Por outro lado, a complexidade de tempo e espaço da busca em profundidade são  $O(b^m)$  e  $O(bm)$  respectivamente, sendo  $m$  a profundidade máxima da

árvore. Maiores detalhes sobre as buscas e seus algoritmos podem ser encontrados em Russel (2010).

### 3.3 Estratégias de Busca Informadas

Entre as estratégias informadas, investigou-se neste trabalho a busca  $A^*$ . Nessa busca, o nó a ser visitado e expandido é aquele que apresenta o menor custo total, composto pelo custo do caminho até o nó e pelo custo de ir desse até o nó objetivo. Em geral, estima-se a segunda parcela através de uma função heurística que deve ser admissível (nunca sobrestima o custo real) e consistente, satisfazendo a desigualdade triangular:

$$f(n) = g(n) + h(n) \leq c(n, a, n') + h(n') \quad (6)$$

onde  $n$  – novo estado;  $n'$  – estado corrente;  $f$  – custo total;  $g$  – custo do caminho;  $h$  – função heurística;  $c$  – custo de ir do nó  $n'$  até o nó  $n$ ; e  $a$  – ação em  $n'$  que resulta em  $n$ .

Nas condições expostas, a busca  $A^*$  é ótima, atingido o objetivo no menor número de passos. A implantação computacional do  $A^*$  assemelha-se à da busca de custo uniforme, sendo a diferença essencial entre elas o custo total de um nó. Maiores detalhes sobre a busca podem ser encontrados em Russel (2010).

## 4. METODOLOGIA PROPOSTA

Nesta seção será descrita de forma resumida a metodologia proposta para identificação de dados críticos utilizando busca inteligente.

### 4.1 Caracterização da Tarefa

Para caracterizar adequadamente o problema do ponto de vista da IA busca-se caracterizar o ambiente, o agente, os atuadores e os sensores. A Tabela 1 apresenta a proposição de formulação do problema. O conjunto potência engloba todas as possíveis tuplas de dados processadas pela EE. O agente proposto recolhe do ambiente tuplas de dados até encontrar uma que seja crítica ou que resulte em não observabilidade. A avaliação da criticalidade consiste em utilizar a definição de  $k$ -tupla crítica e a propriedade 2. Alternativamente, pode-se utilizar as propriedades 1 e 2, como em Braga Flôr et al. (2021).

Note que a formulação indicada na Tabela 1 tem como objetivo encontrar apenas uma única  $C_k$  ou tupla cuja remoção da rede torna-a não observável. Para encontrar todas as tuplas críticas até a criticalidade  $k$ , basta repetir a busca, tomando-se o cuidado de descartar as tuplas críticas identificadas em buscas anteriores. Para tornar a busca mais eficiente, a cada reinicialização pode-se aproveitar o último estado e a última borda.

**Tabela 1. Formulação do Problema**

Item	Descrição
Desempenho	Verificar a presença de uma $C_k$
Ambiente	Conjunto Potência dos dados da EE.
Ações	Inclusão de um dado na tupla de dados $T$ .
Sensores	Avaliação da criticalidade da tupla $T$ .

### 4.2 Definição do problema

Para implantar as estratégias de busca, adotou-se a seguinte definição de problema:

- Estado:  $(L, T)$  onde  $L$  é a pilha de tuplas removidas do ambiente e  $T$  a tupla no topo de  $L$ .
- Estado inicial:  $L=\{\}, T=\{\}$ .
- Ações: Dado um estado  $(L, T)$ , selecionar um dado não presente em  $T$  e inserir nessa tupla  $T$ , dando origem à  $T' \supset T$  tal que  $Card(T')=Card(T)+1$ , onde  $Card(T)$  é a cardinalidade da tupla  $T$ .
- Modelo de Transição: A ação resulta na remoção do ambiente (e inserção em  $L$ ) de uma tupla  $T'$ , dando origem ao estado  $(L', T')$ .
- Teste de Objetivo: Dado um estado  $(L, T)$ , verifica se  $T$  é crítica ou causa a não-observabilidade da rede.
- Custo de caminho:  $Card(T)$ , sendo  $T$  a última tupla inserida em  $L$ .

O custo do caminho reflete a cardinalidade da tupla a ser avaliada. Portanto, dá-se prioridade às tuplas de menor tamanho, que representam criticalidades mais severas. A busca  $A^*$  também requer a especificação da função heurística. Tendo em vista que o determinante da matriz  $\mathbf{G}$  mede indiretamente a quantidade de informação nos dados e que essa decresce conforme medidas/UMs tornam-se indisponíveis (Augusto 2014), adotou-se a seguinte função heurística e custo total:

$$h(n) = \det(\mathbf{G}_T) \quad (7)$$

$$f(n) = g(n) + h(n) = Card(n) + \det(\mathbf{G}_T) \quad (8)$$

onde  $n=(L, T)$  é um estado e  $\det(\mathbf{G}_T)$  é o determinante da matriz  $\mathbf{G}$  considerando que os dados pertencentes à tupla  $T$  estão indisponíveis.

O determinante em (7) e (8) representa a distância da tupla  $T$  da não observabilidade. De acordo com (8), a busca priorizará tuplas  $T$  de menor cardinalidade e cuja remoção torna a rede mais propensa a não-observabilidade.

## 5. TESTES E RESULTADOS

Esta seção apresenta os resultados obtidos com a metodologia proposta.

### 5.1 Descrição das Simulações

A metodologia proposta foi testada no sistema de referência IEEE 30 Barras e 41 ramos. Buscou-se somente criticalidades envolvendo unidades de medição. Os agentes inteligentes e a análise de criticalidades proposta foram desenvolvidos na linguagem C++. As simulações foram realizadas em uma máquina AMD Ryzen 5 3600X 3GHz e 16GB de RAM.

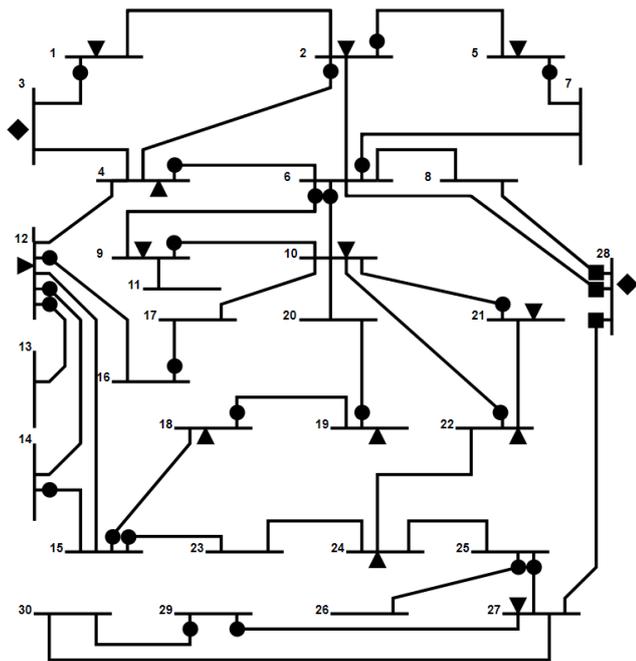


Fig. 1 Sistema IEEE 30 Barras

### 5.2 Teste com o Sistema IEEE 30 Barras

O Plano de Medição adotado, indicado na Fig. 1, contém 24 medidas de fluxo de potência (●), 13 injeções de potência (▲), 3 de fasores de corrente nos ramos (■) e 2 fasores de tensão (◆), totalizando 42 medidas coletadas por 21 UMs. As UMs podem ser identificadas na figura pelas medidas incidentes na barra onde está instalada. A UM28, por exemplo, está na barra de número 28 e coleta os fasores de correntes de ramo I28-8, I28-6, I28-27 e de tensão da barra V28. Segundo a análise de observabilidade clássica, este sistema é observável quando todas as medições estão disponíveis. Foram identificadas 153 criticidades, distribuídas como mostra a Figura 2. Os resultados obtidos estão em acordo com aqueles encontrados em Augusto (2019).

A título de ilustração, as UMs críticas identificadas encontram-se nas barras 9, 12, 15, 25, 28 e 29. Em termos práticos, isso significa que caso ocorra EGs múltiplos envolvendo todas as medidas de uma dessas UMs, a identificação de dados espúrios descrita na Seção 2.3 é inconclusiva.

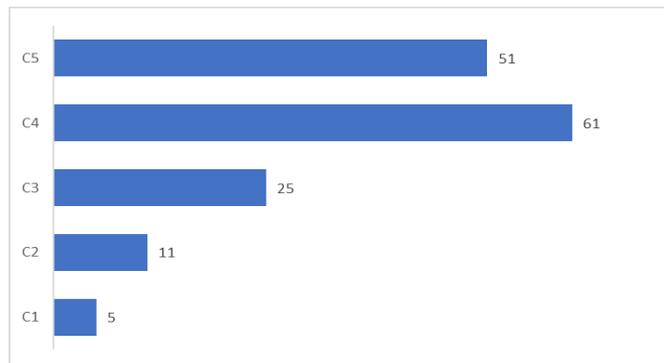


Fig. 2 Distribuição das criticidades – IEEE 30 Barras

Tabela 2. Comparativo entre as buscas

Busca	Estados visitados	Memória (MB)	Tempo (ms)		
			Min.	Máx.	Médio
DFS	2461	8,46	611	617	614
BCU	2461	11,30	1.117	1.143	1.122
BFS	2461	10,31	790	798	793
A*	2461	8,70	968	1.005	976
B&B	10673	7,60	1.000		

Além disso, se ao menos uma delas se tornar indisponível, a filtragem do estado não é possível. Assim sendo, essas UMs merecem atenção especial e seus dados devem ser considerados no processo de estimação com muita cautela.

A Tabela 2 apresenta um estudo comparativo entre as estratégias de busca propostas para 200 execuções de cada uma delas. Como se pode notar, as buscas visitam as mesmas quantidades de estados. Isso era esperado, já que a busca é realizada repetidas vezes até que todas as  $C_k$  sejam encontradas. Observa-se também que a DFS e A\* possuem médias de consumo de memória inferiores às BCU e BFS. Em relação ao de tempo, a DFS obteve o melhor desempenho, seguida da BFS e A\*. Os resultados sugerem que o cálculo do determinante em (8) pode estar impactando o tempo da busca. Já a BCU apresentou o maior consumo de memória e teve o pior tempo. Vale destacar que a cardinalidade do conjunto potência das UMs contém aproximadamente contém  $2^{21} \approx 2$  milhões de elementos. Portanto, pode-se notar que as buscas exploram inteligentemente o espaço de buscas.

Como referência, é apresentado também na Tabela 2 os resultados da busca utilizando o método *Branch-and-Bound* (B&B) proposto em Augusto (2019). Observou-se que a técnicas propostas visitam/avaliam menos estados (tuplas de UMs). Por outro lado, o tempo computacional são relativamente próximos. Não é objetivo deste trabalho comparar as estratégias em termos de eficiência, mas sim verificar a possibilidade de empregar a solução de problemas via IA na identificação de dados críticos. Nesse sentido, as técnicas não apenas identificaram corretamente todas as criticidades como o fizeram de forma mais inteligente. Embora as buscas propostas pesquisem a mesma quantidade de estados visitados, não necessariamente o fazem com a mesma eficiência.

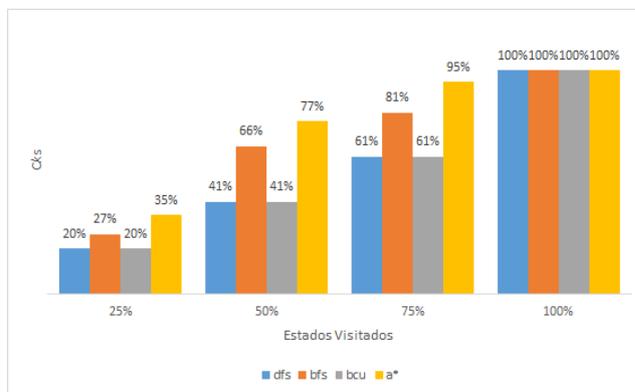


Fig. 3 Taxa de sucesso das buscas por estados visitados.

A Figura 3 apresenta o percentual de criticalidades identificadas em relação ao número de estados visitados ao longo da busca. Note que as buscas em Largura e Custo Uniforme tem desempenhos idênticos. O custo de caminho proposto implica que o custo do passo é o mesmo para todos os nós. Assim sendo, a busca de Custo Uniforme se reduz à busca em Largura (Russel, 2016). A busca A\* identifica com mais rapidez os dados críticos que as outras buscas. Isto mostra claramente que a informação heurística adotada resulta em ganhos nas identificações.

## 6. CONCLUSÕES

Este trabalho apresentou uma metodologia baseada em IA para identificação de dados críticos na EE em sistemas de potência. Métodos clássicos de solução de processos de busca foram investigados. Os resultados obtidos no sistema IEEE 30 barras mostram que os agentes desenvolvidos identificam corretamente as criticalidades.

Nota-se que, em comparação com o método B&B, as técnicas investigadas identificam as criticalidades com menos visitas de estados, mas por outro lado tem custos de tempo e memória mais elevados. Estas diferenças podem estar associadas à implementação computacional dos algoritmos. A formulação proposta, quando comparada à apresentada em Augusto (2019) é muito mais simples, o que mostra a versatilidade e caráter promissor da abordagem baseada em IA.

Para trabalhos futuros, pretende-se aprimorar a formulação do problema, de modo que os algoritmos encerrem as buscas assim que todas as criticalidades forem identificadas. O aperfeiçoamento da função heurística e implementação computacional das técnicas aqui adotadas também serão alvo de investigações futuras.

## AGRADECIMENTOS

Este trabalho foi desenvolvido com recursos financeiros da FAPERJ (Processo E-26/010.002731/2019), e do Programa de Bolsas de Iniciação Científica da UFF – CNPQ (vigência 2019 – 2020 e 2020 – 2021).

## REFERÊNCIAS

- Abur, A. and Gómez Expósito, A. (2004) *Power system state estimation: theory and implementation*. New York, NY: Marcel Dekker (Power engineering).
- Augusto, A. A. *et al.* (2014) ‘Most relevant measurements for state estimation according to information theoretic criteria’, in *2014 Int. Conf. on Probabilistic Methods Applied to Power Systems (PMAPS)*, Durham: IEEE, pp. 1–6.
- Augusto, A. A. *et al.* (2016) ‘Probabilistic assessment of state estimation capabilities for grid observation’, *IET Gen., Transm. & Distribution*, 10 (12), pp. 2933–2941.
- Augusto, A. A. *et al.* (2019) ‘Branch-and-Bound guided search for critical elements in state estimation’, *IEEE Trans. Power Syst.*, 34 (3), pp. 2292–2301.
- Braga Flôr, V. B. *et al.* (2021) ‘Tactics for improving computational performance of criticality analysis in state estimation’, *IET Gen., Transm. & Distribution*, 15 (7), pp. 1214–1226.
- Clements, K. A. and Davis, P. W. (1986) ‘Multiple bad data detectability and identifiability: A Geometric Approach’, *IEEE Trans. Power Delivery*, 1 (3), pp. 355–360.
- Coimbra, A. M. *et al.* (2021) ‘Network-based approach to identify criticalities in state estimation’, *IEEE Trans. Power Syst.*, 36 (4), pp.3394 – 3405.
- Do Coutto Filho, M. B., Stacchini de Souza, J. C. and Schilling, M. Th. (2007) ‘Handling critical data and observability’, *Electric Power Components and Systems*, 35 (5), pp. 553–573.
- Kosut, O. *et al.* (2010) ‘Malicious data attacks on smart grid state estimation: attack strategies and countermeasures’, in *2010 1st IEEE International Conference on Smart Grid Communications*, Gaithersburg, MD, USA: IEEE, pp. 220–225.
- London, J. B. A. *et al.* (2005) ‘Analysis of measurement set qualitative characteristics for state estimation purposes’, *IEEE Power Engineering Society General Meeting, 2005*, San Francisco, CA, USA: IEEE, pp. 589–596.
- Monticelli, A. (1999) *State estimation in electric power systems: a generalized approach*. Boston: Kluwer Academic Publishers.
- Phadke, A. G. and Thorp, J. S. (2011) *Synchronized phasor measurements and their applications*. New York; London: Springer.
- Russell, S. J., Norvig, P. and Davis, E. (2010) *Artificial intelligence: a modern approach*. 3rd ed. Upper Saddle River: Prentice Hall.
- Sou, K. C., Sandberg, H. and Johansson, K. H. (2012) ‘Computing Critical  $k$ -Tuples in Power Networks’, *IEEE Tran. Power Syst.*, 27 (3), pp. 1511–1520.