

# Uso de metaheurísticas e regras de associação na identificação de padrões em egressos de curso de Ciência da Computação

Marcus L. N. Filho<sup>1</sup>, Flávio M. Varejão<sup>1</sup>

<sup>1</sup>Departamento de Informática – Universidade Federal do Espírito Santo (UFES)  
Vitória – ES – Brasil

marcus.l.neves@edu.ufes.br, flavio.varejao@ufes.br

**Resumo.** *A mineração de regras de associação, uma técnica popular de mineração de dados, depende fortemente da configuração adequada de hiperparâmetros para gerar regras significativas e aplicáveis na prática. Este estudo explora a aplicação de três metaheurísticas — Busca Tabu (Tabu Search), Simulated Annealing (SA) e Algoritmos Genéticos (AG) — para ajustar hiperparâmetros de maneira eficaz e eficiente. Métodos tradicionais para ajuste de hiperparâmetros podem ser demorados e computacionalmente caros. Portanto, esta pesquisa visa avaliar o desempenho da Busca Tabu, Simulated Annealing e Algoritmos Genéticos na busca de configurações ótimas de hiperparâmetros. As técnicas foram avaliadas no problema de identificação de padrões relacionando vida acadêmica de estudante e desempenho profissional de egressos de curso de Ciência da Computação.*

## 1. Introdução

A mineração de regras de associação descobre padrões em grandes conjuntos de dados. O algoritmo APriori é o mais conhecido e popular para gerar regras de associação e depende da escolha adequada de hiperparâmetros como suporte e confiança. Ajustar esses parâmetros pode ser desafiador, equilibrando a quantidade e a qualidade das regras. Este trabalho investiga três metaheurísticas — Busca Tabu [Glover 1989, Glover 1990], Simulated Annealing [Van Laarhoven et al. 1987] e Algoritmos Genéticos [Golberg 1989] — para otimizar os hiperparâmetros na mineração de regras. Essas técnicas são eficazes em problemas complexos de otimização, explorando amplamente o espaço de soluções.

A base de dados usada no estudo foi obtida de egressos do curso de Ciência da Computação do Centro Tecnológico da Universidade Federal do Espírito Santo, contendo dados sobre suas trajetórias profissionais e acadêmicas, usados para identificar padrões e aplicar a mineração de regras. A avaliação das regras geradas nos métodos investigados neste trabalho foi realizada comparando-as com regras desejadas selecionadas manualmente e obtenção de valores das métricas de revocação, precisão e F1.

As principais contribuições deste trabalho são mostrar como usar metaheurísticas para definir o conjunto de boas regras de associação, aplicar esse método ao domínio de análise de vida acadêmica e profissional de egressos de curso de Ciência da Computação e apresentar uma análise experimental comparativa entre três metaheurísticas na qual o Algoritmo Genético obteve o melhor desempenho na identificação das regras.

A seção 2 deste artigo apresenta o algoritmo Apriori para geração de padrões frequentes, as métricas de avaliação usadas para geração de regras e as metaheurísticas

consideradas neste trabalho. A seção 3 apresenta as características do problema abordado neste trabalho e apresenta a os atributos da base de dados utilizada. A seção 4 apresenta detalhes da proposta de uso de metaheurísticas para minerar regras de associação. A seção 5 apresenta os resultados alcançados e a seção 6 apresenta as conclusões deste trabalho.

## 2. Regras de Associação e Metaheurísticas

Esta seção resume brevemente as técnicas empregadas neste trabalho.

### 2.1. Associação

O método de associação [Piatetsky-Shapiro 1991] é uma técnica de mineração de dados que descobre padrões e relações significativas entre itens em grandes conjuntos de dados, identificando associações frequentes e gerando regras que descrevem essas relações. O algoritmo mais popular para gerar essas associações é o Apriori [Agrawal et al. 1994], que gera candidatos de conjuntos de itens frequentes e filtra aqueles que não atendem a um suporte mínimo. Para gerar e validar regras de associação, utilizam-se métricas como suporte (*support*), confiança (*confidence*), e elevação (*lift*). Essas métricas são essenciais para identificar regras úteis e significativas na análise de dados.

#### 2.1.1. Algoritmo Apriori

O algoritmo Apriori é um método clássico para a mineração de regras de associação, baseado na propriedade antimonotônica que estabelece que todos os subconjuntos de um conjunto de itens frequentes também devem ser frequentes. Ele opera em duas fases principais: a primeira fase gera candidatos de conjuntos de itens de tamanho crescente a partir dos conjuntos identificados na iteração anterior. Na segunda fase, o algoritmo realiza múltiplas varreduras no banco de dados para contar a frequência de cada conjunto candidato, utilizando o suporte como critério de filtragem.

O suporte é uma métrica essencial que mede a proporção de transações contendo um conjunto de itens específico em relação ao total de transações. O suporte para um conjunto de itens  $X$  é calculado como

$$\text{Suporte}(X) = \frac{\text{Número de transações contendo } X}{N},$$

onde  $N$  é o número total de transações.

Um suporte alto sugere que um padrão é comum, mas não garante a qualidade das regras derivadas desse padrão. É frequentemente usado em combinação com outras métricas para uma avaliação mais completa.

#### 2.1.2. Métricas para geração de regras

As métricas desempenham um papel fundamental na mineração de regras de associação, pois avaliam a força e a relevância das regras extraídas a partir dos dados. As regras de associação são formuladas para descrever relações entre diferentes itens, por exemplo, "Se um cliente compra pão, então é provável que compre manteiga". Para gerar essas

regras, algoritmos analisam os conjuntos de itens que ocorrem juntos com frequência. As métricas usadas incluem a confiança, a elevação, a influência (*leverage*), a convicção (*conviction*) e a métrica de Zhang [Hipp et al. 2000, Hahsler et al. 2005, Brin et al. 1997, Piatetsky-Shapiro 1991, Zhang and Zhang 2002].

A Confiança mede a probabilidade de ocorrência do item consequente dado que o item antecedente está presente. Para uma regra  $A \rightarrow B$ , a confiança é calculada como

$$\text{Confiança}(A \rightarrow B) = \frac{\text{Suporte}(A \cup B)}{\text{Suporte}(A)}$$

A Elevação avalia a força da associação entre dois itens comparando a frequência observada da regra com a frequência esperada se os itens fossem independentes.

$$\text{Elevação}(A \rightarrow B) = \frac{\text{Suporte}(A \cup B)}{\text{Suporte}(A) \times \text{Suporte}(B)}$$

onde um valor de Elevação maior que 1 indica uma associação mais forte do que seria o esperado por acaso, um valor igual a 1 sugere independência entre os itens, e um valor menor que 1 indica uma associação mais fraca do que o esperado.

A Influência mede a diferença entre a frequência observada de uma regra e a frequência esperada se os itens fossem independentes.

$$\text{Influência}(A \rightarrow B) = \text{Suporte}(A \cup B) - (\text{Suporte}(A) \times \text{Suporte}(B))$$

O valor da Influência pode variar de -1 a 1, onde valores positivos indicam uma associação mais forte do que a esperada por acaso, valores negativos sugerem uma associação mais fraca, e valores próximos a zero indicam pouca ou nenhuma associação entre os itens.

A Convicção mede a relação entre a frequência do antecedente e a frequência de ausência do consequente, considerando a frequência esperada se os itens fossem independentes.

$$\text{Convicção}(A \rightarrow B) = \frac{1 - \text{Suporte}(B)}{1 - \text{Confiança}(A \rightarrow B)}$$

A Convicção é um valor numérico contínuo e positivo, onde valores maiores indicam que a presença de  $A$  reduz significativamente a probabilidade de ausência de  $B$ , sugerindo uma forte associação. Valores próximos a 1 indicam uma associação mais fraca, semelhante à independência entre os itens.

A métrica de Zhang avalia a força da associação entre dois itens considerando tanto a presença quanto a ausência dos itens.

$$\text{Zhang}(A \rightarrow B) = \frac{\text{Suport}(A \rightarrow B) - \text{Confiança}(\bar{A} \rightarrow B)}{\max[\text{Confiança}(A \rightarrow B), \text{Confiança}(\bar{A} \rightarrow B)]}$$

A métrica de Zhang é um valor numérico contínuo e positivo, onde um valor maior que 1 indica uma associação mais forte entre  $A$  e  $B$  do que o esperado por acaso, e valores próximos a 1 indicam que a associação é aproximadamente igual à frequência esperada. Um valor menor que 1 sugere uma associação mais fraca.

O desafio principal na mineração de regras de associação reside na escolha adequada dos valores mínimos dos hiperparâmetros de suporte e da métrica de geração de regras. Valores inadequados podem levar à geração de um grande número de regras irrelevantes ou à perda de regras importantes. A configuração manual desses parâmetros é um processo moroso e propenso a erros.

## 2.2. Metaheurísticas

As três metaheurísticas usadas neste estudo são descritas a seguir.

### 2.2.1. Busca Tabu

A Busca Tabu (BT) é uma técnica de otimização que utiliza uma memória adaptativa para melhorar a busca local. Sua principal característica é o uso de uma lista tabu, que registra os movimentos recentes para evitar ciclos e convergência prematura.

Um elemento importante da busca tabu é a função de vizinhança, que define um conjunto de soluções obtidas por pequenas alterações na solução atual. Nesse caso, a função de vizinhança calcula 30 vizinhos, variando um valor aleatório entre o mínimo possível para a métrica analisada e o valor atual dessa métrica. Por exemplo, ao ajustar o hiperparâmetro de suporte a partir de uma solução com suporte de 0,1, a vizinhança pode incluir valores entre o mínimo permitido e 0,05, como 0,02 ou 0,04, gerando variações. Da mesma forma, para uma confiança de 0,6, seriam considerados valores entre o mínimo e 0,6, como 0,55 ou 0,65, permitindo explorar diferentes combinações para refinar as soluções.

A lista tabu armazena os movimentos recentes (alterações de valores dos hiperparâmetros) para evitar que a busca retorne às soluções previamente visitadas. Essa lista tem um tamanho finito e é atualizada conforme novos movimentos são realizados.

Além disso, para melhorar a eficiência da Busca Tabu, foi definido que a lista tabu teria um tamanho fixo de 30, evitando que soluções recentes fossem revisitadas e garantindo uma exploração mais ampla do espaço de busca. Além disso, estabeleceu-se um limite de 200 iterações sem melhora, permitindo que o algoritmo continue a buscar soluções melhores mesmo após uma fase inicial de estagnação, aumentando as chances de encontrar resultados mais otimizados.

### 2.2.2. Simulated Annealing

Simulated Annealing (SA) é uma metaheurística inspirada no processo de recozimento de metais, onde o material é aquecido e resfriado lentamente para minimizar defeitos estruturais. Por também ser uma metaheurística de busca local, o SA também requer uma função de vizinhança, que no problema em estudo é a mesma utilizada pelo algoritmo de busca tabu.

O SA também possui uma função de aceitação que determina se uma nova solução deve ser aceita. Se for melhor que a atual, é aceita; caso contrário, é aceita com uma probabilidade que diminui exponencialmente com a temperatura e a diferença de qualidade, dada por  $P = \exp\left(-\frac{\Delta E}{T}\right)$ , onde  $\Delta E$  é a diferença de qualidade e  $T$  é a temperatura.

Tipicamente, a temperatura inicial do SA é alta, permitindo a aceitação de soluções piores para escapar de mínimos locais. Com o tempo, a temperatura diminui, reduzindo a probabilidade de aceitar soluções piores e convergindo para uma solução ótima.

No experimento, a temperatura inicial foi ajustada para 400, com um fator de resfriamento (alfa) de 0,5 e um número máximo de 30 iterações. Esses parâmetros foram escolhidos para permitir uma exploração inicial mais ampla do espaço de busca, aceitando soluções piores com maior frequência no início. Conforme a temperatura diminui, o algoritmo se concentra em soluções de maior qualidade, aumentando as chances de convergir para uma solução ótima.

### **2.2.3. Algoritmo Genético**

Algoritmos Genéticos (AG) são inspirados pelo processo de evolução natural, utilizando operadores genéticos para evoluir uma população de soluções. Nesse experimento, cada população foi composta por 100 indivíduos, e o algoritmo foi executado por 200 gerações. Uma população inicial de soluções é gerada aleatoriamente, onde cada solução (indivíduo) representa um conjunto de valores dos hiperparâmetros. Os indivíduos da população são selecionados para reprodução com base em sua qualidade (fitness). O crossover combina duas soluções (pais) para gerar novas soluções (filhos), enquanto a mutação introduz variações aleatórias nos filhos, garantindo a diversidade genética da população. As novas soluções são avaliadas e substituem as soluções menos aptas. O ciclo de seleção, crossover e mutação é repetido até que um critério de parada seja atingido, como o número máximo de gerações ou a convergência para uma solução ótima.

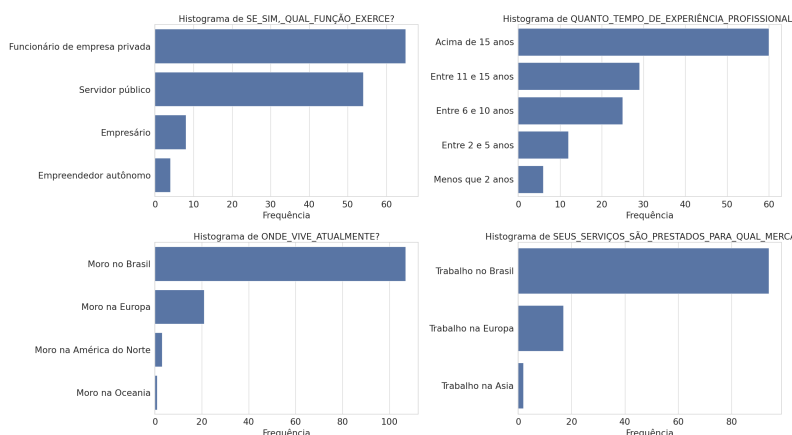
## **3. Correlação de Vida Acadêmica e Profissional de Cientistas da Computação**

Identificar padrões entre a vida acadêmica e o desempenho profissional de egressos de cursos de computação é desafiador, pois envolve analisar variáveis acadêmicas, como notas e tempo de conclusão do curso, e como elas influenciam fatores profissionais como tipo de emprego e satisfação no trabalho. Identificar correlações que ajudem a entender como a formação acadêmica impacta a carreira pode auxiliar na melhoria dos currículos e práticas pedagógicas, além do desenvolvimento de estratégias e programas de apoio para melhorar a preparação dos estudantes para o mercado de trabalho e sua satisfação profissional. Esta seção descreve a base de dados utilizada nos experimentos, o conjunto de regras consideradas relevantes e as métricas utilizadas para avaliar os conjuntos de regras geradas pelas metaheurísticas.

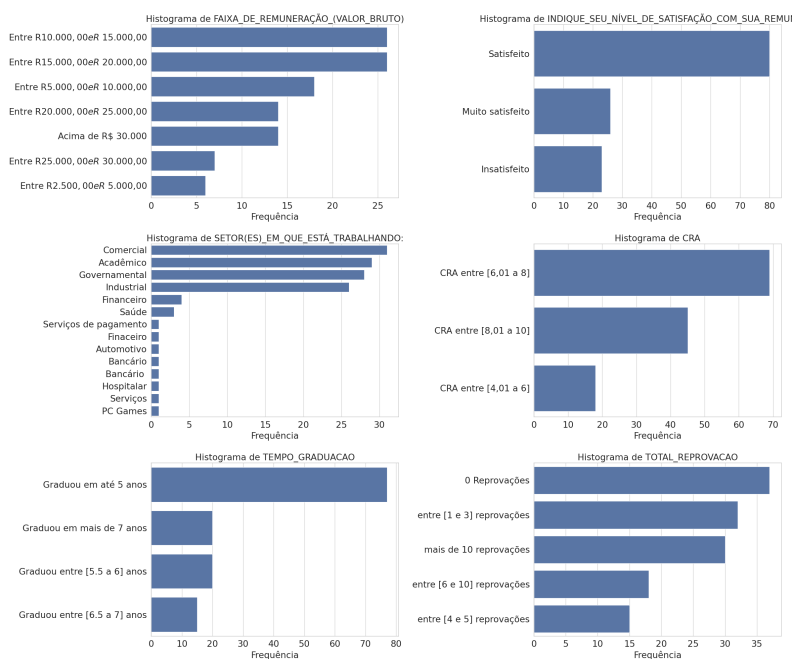
### **3.1. Base de Dados**

A base de dados foi coletada por meio de uma pesquisa direcionada aos egressos do curso de Ciência da Computação do Centro Tecnológico da Universidade Federal do Espírito Santo entre 1990 e 2022, visando obter informações sobre suas trajetórias acadêmicas e profissionais. Os participantes forneceram dados sobre suas atuais funções, experiências, localização, remuneração e níveis de satisfação. Além das respostas à pesquisa, a base inclui informações acadêmicas dos egressos, como coeficiente de rendimento acadêmico (CRA), duração da graduação e número de reprovações. A base de dados abrange informações de 132 egressos que responderam à pesquisa, de um total de 644 egressos.

As figuras 1 e 2 apresentam histogramas representando os dados de cada uma das características da base de dados.



**Figura 1. Histograma das características função exercida, tempo de experiência profissional, local de residência e local de prestação de serviços**



**Figura 2. Histograma das características faixa de remuneração, satisfação com remuneração, setores que trabalha, coeficiente de rendimento, duração da graduação e total de reprovações no curso**

### 3.2. Regras de Associação Referências

Para poder avaliar os métodos propostos neste trabalho é preciso definir as regras de associação utilizadas como referência, isto é, as consideradas boas. Isso foi realizado através da aplicação de um grupo de estratégias explicadas a seguir.

- **Seleção Manual de Itens:** Foi feita uma seleção manual para garantir que itens específicos não aparecessem em regras opostas, assegurando que a relação entre

informações acadêmicas e o impacto no desempenho profissional e satisfação dos egressos fosse clara. Esse processo buscou analisar como o Coeficiente de Rendimento Acadêmico (CRA), tempo de graduação e número de reprovações afetam aspectos como trajetória profissional, remuneração e satisfação no trabalho, com o objetivo de fornecer informações úteis.

- **Exclusão de Regras Inversas:** Regras inversas foram removidas para evitar redundância e melhorar a clareza dos resultados. A seleção das regras a serem excluídas baseou-se na métrica usada para formar o conjunto, com a regra inversa de menor valor na métrica sendo escolhida para exclusão. Esse processo visou eliminar regras de menor relevância, reduzindo redundância e mantendo um conjunto mais conciso e significativo, com maior clareza e utilidade para análise.
- **Limitação das Melhores Regras:** Apenas as 100 melhores regras foram selecionadas para análise detalhada. Esta limitação arbitrária ajuda a focar nas regras mais significativas, reduz o volume de dados a ser processado e evita a produção excessiva de regras, pois, sem essa limitação, o algoritmo tenderia a gerar todas as regras possíveis, tornando desnecessária a aplicação da metaheurística.

### 3.3. Avaliação do Conjunto de Regras Elaboradas

Para avaliar a qualidade do conjunto de regras selecionado, utilizamos métricas de desempenho como revocação (recall), precisão (precision) e F1 (F-measure) [Olson and Delen 2008, Taha and Hanbury 2015]. Essas métricas são calculadas comparando o conjunto de regras encontrado com um conjunto de regras previamente determinado como referência.

- **Revocação:** Mede a proporção de regras verdadeiramente boas que foram corretamente identificadas, calculada como o número de regras boas encontradas dividido pelo número total de regras boas na referência. Uma alta revocação indica que o modelo identifica a maioria das regras relevantes.

$$\text{Recall} = \frac{TP}{TP + FN}$$

onde:

- $TP$  (True Positives): Número de Verdadeiros Positivos.
  - $FN$  (False Negatives): Número de Falsos Negativos.
- **Precisão:** Avalia a proporção de regras encontradas que são realmente boas, calculada como o número de regras boas encontradas dividido pelo número total de regras identificadas. Alta precisão significa que o modelo evita identificar regras irrelevantes.

$$\text{Precision} = \frac{TP}{TP + FP}$$

onde:

- $FP$  (False Positives): Número de Falsos Positivos.
- **F1:** É a média harmônica entre revocação e precisão, calculada como 2 vezes a multiplicação de precisão e revocação dividida pela soma de precisão e revocação. A métrica F1 oferece um balanço entre precisão e revocação, sendo útil para avaliar o desempenho geral do modelo.

$$F1 = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

Essas métricas fornecem uma visão abrangente sobre a qualidade das regras geradas e ajudam a garantir que o conjunto de regras selecionado é relevante.

#### 4. Metaheurísticas para Associação de Vida Acadêmica e Profissional de Egressos

Esta seção descreve o conjunto de valores possíveis de cada hiperparâmetro do algoritmo de regras de associação que define o espaço de estados da busca realizada e apresenta como cada metaheurística foi customizada para serem aplicadas neste problema. Um estado é composto pela valor do suporte mínimo, pela métrica usada para a geração de regras e pelo valor mínimo dessa métrica. A tabela 1 associa cada hiperparâmetro ao seu conjunto de possíveis valores. Apesar de não haver diferenciação clara na tabela ref-tab:hiperparametros. é importante notar que somente o suporte está presente em todos os estados da busca.

A métrica *FI* foi usada como função objetivo principal para avaliar a qualidade das soluções geradas pelas metaheurísticas. Durante a aplicação das metaheurísticas, os estados com valores mais altos de *FI* foram considerados superiores.

Hiperparâmetro	Intervalo de Valor
Suporte	0 a 100%
Confiança	0 a 100%
Elevação	>0
Influência	0 a 100%
Convicção	>0
Métrica de Zhang	-1 a 1

**Tabela 1. Hiperparâmetros considerados e seus intervalos de valores.**

Cada metaheurística foi ajustada com funções, procedimentos e valores específicos adaptados para serem executados neste problema. As subseções seguintes descrevem os detalhes necessários para essa adaptação.

##### 4.1. Busca Tabu

A solução inicial é construída gerando valores aleatórios para o suporte mínimo, a métrica de avaliação e o limiar associado. A função de vizinhança ajusta o suporte mínimo, a métrica de avaliação e o limiar da métrica de forma aleatória para explorar variações dos parâmetros do estado inicial. Por exemplo, se o estado inicial tem suporte mínimo de 0.2 e usa confiança como métrica, a vizinhança pode gerar estados com suporte mínimo ajustado em 0.05, mudança na métrica, ou alteração no limiar da métrica. A lista tabu armazena os 10 estados mais recentes para evitar revisitações e garantir diversidade. O critério de parada é alcançado após 20 iterações sem melhoria nas soluções.



## 4.2. Simulated Annealing

A solução inicial e a função de vizinhança são as mesmas usadas no método da busca tabu. A temperatura inicial é definida como 400 e o fator de resfriamento, denotado por alfa, é 0.5. A quantidade de interações que o algoritmo realiza em cada temperatura foi fixado em 20. O único critério de parada é quando a temperatura cai abaixo de 1, garantindo que o algoritmo pare de explorar novas soluções à medida que a temperatura diminui e se estabiliza.

## 4.3. Algoritmos Genéticos

O algoritmo genético utilizado neste estudo começa com uma população inicial de 100 indivíduos, gerados aleatoriamente para garantir diversidade. O elitismo é aplicado com uma taxa de 10%. A seleção é feita pelo método de roleta, que atribui uma probabilidade proporcional ao valor da função de objetivo de cada indivíduo. O operador de crossover é o crossover de um ponto, onde cada par de pais gera dois filhos trocando parte de seus parâmetros: o suporte mínimo do pai é combinado com a métrica e o limiar da mãe, e vice-versa, com uma taxa de crossover de 60%. O operador de mutação altera aleatoriamente o suporte mínimo, a métrica e o limiar da métrica com uma taxa de 10%. O critério de parada é a conclusão de 100 gerações ou iterações.

## 5. Resultados

A tabela 2 apresenta as melhores soluções encontradas por cada metaheurística assim como sua avaliação da métrica *F1*. Pode-se observar o desempenho bem superior obtido pelo Algoritmo Genético. Acredita-se que esse resultado se deve ao fato de que as outras duas técnicas, Busca Tabu e Simulated Annealing (SA), são mais sensíveis ao estado inicial. Enquanto tanto a Busca Tabu quanto a SA requerem um estado inicial único, o Algoritmo Genético opera com uma população inicial, ou seja, um conjunto de estados iniciais. Isso permite que a metaheurística genética explore uma área mais ampla do espaço de busca simultaneamente, aumentando a probabilidade de encontrar soluções ótimas.

**Tabela 2. Melhores Soluções Obtidas para Cada Metaheurística**

Metaheurística	Min Support	Metric	Metric Threshold	Precisão	Recall	F1 Score
Tabu Search	0.04	Confidence	0.39	0.55	1.00	0.71
Simulated Annealing	0.04	Zhang's Metric	0.01	0.56	1.00	0.72
Genetic Algorithm	0.03	Lift	0.46	0.86	1.00	0.93

## 6. Conclusão

Este trabalho demonstrou como usar metaheurísticas para definir o melhor conjunto de regras de associação em uma base de dados. Como prova de conceito, foi realizado um experimento com dados sobre a vida acadêmica e profissional de egressos do curso de Ciência da Computação do Centro Tecnológico da UFES. Os resultados alcançados com a abordagem de Algoritmo Genético foi bastante superior as demais.

Para poder comparar os resultados foi necessário fazer uma categorização manual de todas as possíveis regras boas. De forma geral, isso é inviável de ser realizado. Se o fosse, não seria necessário usar algoritmos de regras de associação. Porém, isso não

inviabiliza a abordagem proposta neste trabalho. Para aplicar essa abordagem de forma geral, pode-se fazer uma pequena amostra de regras boas e usá-las para identificar a melhor configuração de valores dos hiperparâmetros para aquela amostra. De posse desses valores, o algoritmo de regra de associação pode ser aplicado a toda a base de dados para gerar as regras de associação.

Em suma, este trabalho mostra que as metaheurísticas oferecem uma abordagem flexível e poderosa para a mineração de regras de associação, ampliando o alcance das análises de dados. Sua capacidade de explorar soluções complexas e diversas torna essas técnicas uma escolha interessante para problemas de mineração de dados desafiadores.

## Referências

- Agrawal, R., Srikant, R., et al. (1994). Fast algorithms for mining association rules. In *Proc. 20th int. conf. very large data bases, VLDB*, volume 1215, pages 487–499. Santiago.
- Brin, S., Motwani, R., Ullman, J. D., and Tsur, S. (1997). Dynamic itemset counting and implication rules for market basket data. In *Proceedings of the 1997 ACM SIGMOD international conference on Management of data*, pages 255–264.
- Glover, F. (1989). Tabu search—part i. *ORSA Journal on computing*, 1(3):190–206.
- Glover, F. (1990). Tabu search—part ii. *ORSA Journal on computing*, 2(1):4–32.
- Golberg, D. E. (1989). Genetic algorithms in search, optimization, and machine learning. *Addion wesley*, 1989(102):36.
- Hahsler, M., Grün, B., and Hornik, K. (2005). arules—a computational environment for mining association rules and frequent item sets. *Journal of statistical software*, 14(15):1–25.
- Hipp, J., Güntzer, U., and Nakhaeizadeh, G. (2000). Algorithms for association rule mining—a general survey and comparison. *ACM sigkdd explorations newsletter*, 2(1):58–64.
- Olson, D. L. and Delen, D. (2008). *Advanced data mining techniques*. Springer Science & Business Media.
- Piatetsky-Shapiro, G. (1991). Discovery, analysis, and presentation of strong rules. *Knowledge Discovery in Data-bases*, pages 229–248.
- Taha, A. A. and Hanbury, A. (2015). Metrics for evaluating 3d medical image segmentation: analysis, selection, and tool. *BMC medical imaging*, 15:1–28.
- Van Laarhoven, P. J., Aarts, E. H., van Laarhoven, P. J., and Aarts, E. H. (1987). *Simulated annealing*. Springer.
- Zhang, C. and Zhang, S. (2002). *Association rule mining: models and algorithms*. Springer.