

## ISA: Um Sistema para Identificação e Suporte às Dificuldades Acadêmicas de Estudantes no Ensino Superior

Débora da C. Araújo<sup>1,2</sup>, Catarina Cysneiros Sampaio<sup>1</sup>, Athams Menezes Ferreira<sup>1</sup>,  
Iago Bruno F. e Souza<sup>3</sup>, Máverick André D. Ferreira<sup>4</sup>

<sup>1</sup>Universidade Federal do Vale do São Francisco (UNIVASF)  
Bacharelado em Ciência da Computação – Salgueiro, PE – Brazil

<sup>2</sup>Centro de Informática, Universidade Federal de Pernambuco (CIn/UFPE)  
Recife, PE – Brazil

<sup>3</sup>Instituto Federal do Sertão Pernambucano (IF-Sertão), Salgueiro-PE – Brazil

<sup>4</sup>3CON Consultoria e Sistemas – Rio de Janeiro, RJ – Brazil

debora.caraujo@univasf.edu.br  
{catarina.sampaio, athams.menezesf}@discente.univasf.edu.br  
iago.ferreira@aluno.ifsertao-pe.edu.br,  
maverick.ferreira@trescon.com.br

**Abstract.** *This paper describes the development and evaluation of ISA, a System for Identifying and Supporting Academic Difficulties of higher education students. The system consists of three main modules: Module 1 identifies areas where students are struggling; Module 2 recommends personalized study materials based on the needs identified in Module 1; and Module 3 suggests collaborative study groups using genetic algorithms. A synthetic dataset was used to evaluate the proposed system. Initial analyses indicate that ISA is effective and suggest applying it in a real-world setting as the next step.*

**Resumo.** *Nos últimos anos tem-se observado o ingresso de estudantes no Ensino Superior com dificuldades em assuntos importantes da Educação Básica. Identificar tais assuntos se mostra importante para que ações sejam idealizadas afim de permitir que os estudantes superem as dificuldades iniciais. Neste cenário, a presente pesquisa descreve o ISA, um sistema para Identificação e Suporte às Dificuldades Acadêmicas de estudantes no ensino superior. O ISA é capaz de identificar os conteúdos que precisam da atenção do aluno, além de recomendar materiais de estudos personalizados e sugerir grupos colaborativos. Testado em uma base de dados sintética, o sistema demonstrou eficácia, e o próximo passo é aplicá-lo em um ambiente real.*

### 1. Introdução

Nos últimos anos, mudanças substanciais ocorreram nos variados segmentos da sociedade, afetando as pessoas tanto no âmbito pessoal, quanto profissional. Ao considerarmos o contexto específico da Educação durante e após a pandemia de COVID-19, observou-se um processo de ensino remoto de emergência sendo colocado em prática em um ritmo acelerado e, em sua maioria, não estruturado [Oliveira et al. 2021].

Como consequência da massificação do ensino remoto, os docentes tem se deparado com dificuldades no controle de fraude nas avaliações dos estudantes [Oliveira et al. 2021], com o difícil acesso a materiais, advindo da falta de recursos financeiros e tecnológicos [da Silva et al. 2021], além do aumento de doenças psicológicas, como ansiedade e depressão, na comunidade escolar [Deng et al. 2021]. Diante desse cenário muitos estudantes ingressam no ensino superior com limitações em conteúdos fundamentais estudados na Educação Básica. É importante salientar que tal situação já existia, mas a pandemia intensificou essa condição, impactando ainda mais a preparação dos alunos [Oliveira et al. 2021, de Macêdo and Gregor 2020]. Assim, muitos estudantes estão ingressando no ensino superior com dificuldades em conteúdos fundamentais, tais como probabilidade, equações e matrizes, que são de grande importância para os ingressos nas diversas licenciaturas e bacharelados, incluindo Matemática, Computação e nas Engenharias [Sazhin 1998, Yan-hui 2011].

Identificar as limitações existentes na formação dos estudantes que estão ingressando no ensino superior representa uma alternativa para que ações sejam idealizadas afim de proporcionar o suporte adequado, permitindo que tais estudantes superem dificuldades iniciais e alcancem melhores desempenhos acadêmicos.

Ao considerar o exposto, o presente artigo descreve o Sistema de Identificação e Suporte às Dificuldades Acadêmicas (ISA) voltado para estudantes no ensino superior. Três módulos principais compõem o sistema proposto, a saber:

1. Diagnóstico de Conhecimentos Prévios - este módulo foca na identificação dos conteúdos em que o estudante apresenta dificuldades.
2. Sistema de Recomendação (SR) de Material de Estudo - com base nos conteúdos identificados no Módulo 1, este módulo utiliza um sistema de recomendação para sugerir materiais de estudo personalizados.
3. Sugestão de Grupos Colaborativos - este módulo recomenda a formação de grupos de estudo, por meio de um sistema baseado em Algoritmo Genético (AG), agrupando estudantes com necessidades e dificuldades complementares.

Para melhor detalhar a abordagem proposta, este artigo foi estruturado com as seguintes seções, além desta introdutória: 2 Trabalhos Relacionados; 3 Sistema Proposto; 4 Avaliação do sistema proposto; 5 Considerações Finais e; Referências.

## **2. Trabalhos Relacionados**

Com o avanço da internet, uma grande quantidade de informação se tornou disponível de forma rápida e gratuita, porém, em meio a tanto conteúdo, é cada vez mais difícil minerar o que consiste em um material relevante ou não. Nesse sentido, os Sistemas de Recomendação aparecem como alternativas à sobrecarga de informação *on-line*, de modo a mitigar o tempo gasto em busca do conteúdo desejado, além de auxiliar na qualidade do material recuperado [Urdaneta-Ponte et al. 2021].

No contexto da Educação, os SR são propostos para atuar como soluções de problemas diversos. Em [Andrade et al. 2023] tem-se apresentado um SR que tem por objetivo mitigar o problema da evasão escolar na Educação à Distância (EaD) a partir da integração de metodologias ativas e mineração de dados. Também no contexto da EaD, SR de grupos de estudos baseados em algoritmos genéticos são apresentados tanto em [Kurniadi et al. 2023], quanto em [Balieiro et al. 2017]. Ao considerarmos o sistema

presencial de ensino, tem-se em [Okubo et al. 2022] a proposta de um SR de conteúdos para revisão de assuntos acadêmicos. Além dos trabalhos supracitados, outros artigos e aplicações relacionadas aos SR no contexto da Educação podem ser encontrados na revisão sistemática exposta em [Oliveira and Frango 2021].

Este trabalho se diferencia aos demais por propor um *framework* completo, que identifica os conteúdos que precisam ser revisados, recomenda os materiais de estudo necessários de forma personalizada e sugere a formação de grupos colaborativos. Dois SR compõem a solução proposta, em que o primeiro constitui-se de um sistema baseado em conhecimento e tem o intuito de recomendar os materiais de estudo, enquanto o segundo é baseado em algoritmos genéticos e tem a finalidade de sugerir grupos de estudos considerando as habilidades e conhecimentos complementares dos estudantes.

### 3. Sistema Proposto

Esta seção apresenta o processo de desenvolvimento do ISA, um *framework* para Identificação e Suporte de Dificuldades Acadêmicas de estudantes no ensino superior. Para tal, o sistema proposto é subdividido em 3 (três) módulos principais, detalhados nas subseções 3.1, 3.2 e 3.3. A versão final do sistema está disponível em <https://github.com/SamCatarina/isa.git>.

#### 3.1. Módulo I

O Módulo I consiste no diagnóstico dos conhecimentos prévios dos estudantes. A partir do diagnóstico é possível identificar tanto os conteúdos que o estudante possui mais conhecimento quanto os conteúdos que ele possui mais dificuldade.

Nessa etapa, o usuário cadastrado com perfil de professor será capaz de criar questionários de múltipla escolha. Cada pergunta cadastrada está relacionada à no mínimo uma *tag* e no máximo três, em que cada *tag* indica quais são os assuntos tratados na questão. Quando o estudante responde ao questionário, o sistema recebe as respostas e calcula a porcentagem de erro de cada *tag* usando a Equação 1:

$$P_n = \frac{E_n}{Q_n} \quad (1)$$

Em que  $P$  é a porcentagem de erro do estudante na *tag*  $n$ ;  $E$  é o número de respostas incorretas na *tag* e  $Q$  é o número total de perguntas que contém a *tag*.

Após o cálculo, as *tags* são classificadas de forma decrescente de acordo com as suas respectivas porcentagens de erro e então são exibidas para o usuário. Dessa forma, o aluno possui uma orientação sobre quais assuntos merecem mais atenção nos seus estudos para o bom desempenho na disciplina em questão. Por fim, quando dois ou mais estudantes respondem ao questionário, este módulo fornece ao professor uma visão geral dos conhecimentos prévios dos discentes da disciplina, para que o docente possa definir estratégias de ensino-aprendizagem condizentes com as necessidades da turma.

#### 3.2. Módulo II

O Módulo II consiste em um sistema baseado em conhecimento que tem por objetivo recomendar materiais de estudo de acordo com as necessidades dos estudantes identificadas

no Módulo I. O processo de recomendar os materiais para estudo ocorre de acordo com os assuntos que o diagnóstico inicial identificou, conforme detalha o Algorithm 1.

---

**Algorithm 1** Sistema de Recomendação de Materiais de Estudo

---

**Require:** Diagnóstico do aluno  $i$  com uma lista de tags para estudo, Preferências de tipo de material para estudo

**Ensure:** Lista de materiais de estudo relevantes  $materiaisRelevantes$

- 1: **Receber** diagnóstico com lista de tags, ex.:  $diagnostico = ['fracao', 'matrizes']$
  - 2: **Inicializar**  $materiaisRelevantes$  como lista vazia
  - 3: **Inicializar**  $materiais$  como lista vazia
  - 4: **for all** tag em  $diagnostico$  **do**
  - 5:     **Buscar** materiais de estudo na base de dados que abordem o tema da tag
  - 6:     **Adicionar** materiais encontrados em  $materiais$
  - 7: **end for**
  - 8: **for all** material em  $materiais$  **do**
  - 9:     **Inicializar**  $tagsMaterial$  como lista vazia
  - 10:     **Adicionar** as tags do material em  $tagsMaterial$
  - 11:     **if** material.tag **está em**  $diagnostico$  **then**
  - 12:         **Adicionar** material em  $materiaisRelevantes$
  - 13:     **end if**
  - 14: **end for**
  - 15: **Ranquear**  $materiaisRelevantes$  baseado em  $preferencia$
  - 16: **return**  $materiaisRelevantes$
- 

Do mesmo modo que o professor cadastra as questões relacionando-as com as tags/conteúdos no Módulo I, materiais de estudo também são cadastrados e associados aos conteúdos propostos. O processo de recomendação descrito no Algoritmo 1 detalha como o sistema identifica os materiais cadastrados que correspondem às tags relacionadas às áreas de dificuldade do aluno. Em seguida, o sistema realiza a busca desses materiais para recomendação com base nas dificuldades do usuário aluno e na categoria de material que o estudante prefere estudar. A categoria de material (vídeo, questões, livro ou artigo) que o estudante prefere é escolhida no momento que o discente se cadastra no programa e pode ser modificada a qualquer momento. A categoria define o ranqueamento dos materiais retornados, conforme descreve o Algoritmo 1, porém, caso não existam materiais cadastrados com a categoria de preferência do estudante, os dados retornados são baseados exclusivamente nas tags.

### 3.3. Módulo III

O Módulo III consiste na sugestão de grupos de estudos gerada a partir das informações identificadas no Módulo I. A solução proposta conta com três características essenciais para cada estudante, a saber:

- Conhecimento consolidado (CO) - consiste na lista de tags com assuntos que o aluno não apresentou dificuldade;
- Conhecimento para aperfeiçoar (CA) - lista de tags com conteúdos que o estudante mais apresentou dificuldades;

- Turno disponível para estudo (TD) - consiste no horário extraclasse que o aluno tem preferência/disponibilidade para participar dos encontros do grupo.

A partir das características de cada estudante, uma solução baseada em Algoritmo Genético (AG) [Holland 1992] foi desenvolvida. A solução proposta foi modelada considerando cada estudante  $E$  em uma posição fixa do indivíduo  $I$ . Um indivíduo consiste em um vetor com  $k$  posições, sendo  $k$  a quantidade de estudantes. A figura 1 exemplifica o AG proposto considerando uma população com  $N$  indivíduos (soluções) e  $k = 10$ . A solução está dividida em 3 (três) grupos de estudos, que correspondem aos genes dos indivíduos, conforme detalha a figura 1.

|       | $E_1$ | $E_2$ | $E_3$ | $E_4$ | $E_5$ | $E_6$ | $E_7$ | $E_8$ | $E_9$ | $E_{10}$ |
|-------|-------|-------|-------|-------|-------|-------|-------|-------|-------|----------|
| $I_1$ | 1     | 2     | 2     | 1     | 3     | 2     | 3     | 1     | 1     | 3        |
| ...   |       |       |       |       |       |       |       |       |       |          |
| $I_N$ | 3     | 1     | 1     | 2     | 2     | 2     | 3     | 1     | 3     | 3        |

Figura 1. População Inicial do AG

A heurística definida como função de aptidão (*fitness*) para avaliar cada solução ( $I$ ) inicia o fitness de  $I$  com o valor 0 (zero). Em seguida, para cada grupo em  $I$ , tem sua aptidão calculada, por uma função chamada 'fitness\_grupo' que indica a qualidade específica daquele grupo, o resultado de cada grupo em  $I$  é acumulado no fitness final do indivíduo.

A função *fitness\_grupo* avalia cada grupo com base nas 3 características de cada estudante (CO, CA e TD) e pondera o tamanho do grupo. O conhecimento complementar (CC) dos estudantes de um grupo é calculado verificando se o CO de um estudante é uma área que outro estudante do mesmo grupo precisa aperfeiçoar. A compatibilidade de turno (TC) é determinada verificando se os estudantes têm turnos disponíveis compatíveis. Por fim, a função ajusta a pontuação do grupo com base na diferença entre o tamanho ideal do grupo e o tamanho real, sendo o tamanho ideal do grupo ( $T$ ) definido por:  $T = K/Q$ , em que  $Q$  representa a quantidade de grupos. Assim, a função aplica uma penalidade para grupos muito pequenos ou muito grandes. A Equação 2 indica o cálculo final de aptidão de um determinado indivíduo  $I$ .

$$fitness_i = \sum_{j=1}^Q fitness\_grupo(G_{ji}, df, Q) \quad (2)$$

Em que  $G_{ji}$  é o fitness do grupo  $j$  no indivíduo  $i$  e  $df$  é a base de conhecimento com os dados dos estudantes.

Após o cálculo de aptidão das soluções, o método *roulette wheel* [Yu et al. 2016] é utilizado para selecionar os indivíduos que devem passar pelos operadores de Cruzamento e Mutação para construir a próxima geração. Os pseudocódigos em 2 e 3 detalham o funcionamento de cada operador.

---

### Algorithm 2 Operador de Cruzamento

---

**Require:** Dois pais  $pai1$  e  $pai2$  de mesmo comprimento

**Ensure:** Dois filhos  $filho1$  e  $filho2$

- 1: Verificar se os pais têm o mesmo comprimento
  - 2: Selecionar um ponto de corte aleatório entre 1 e  $comprimento(pai1) - 1$
  - 3:  $filho1 = pai1[:ponto\_corte] + pai2[ponto\_corte:]$
  - 4:  $filho2 = pai2[:ponto\_corte] + pai1[ponto\_corte:]$
  - 5: **return**  $filho1, filho2$
- 

---

### Algorithm 3 Operador de Mutação

---

**Require:** Um indivíduo  $individuo$  e uma taxa de mutação  $taxa\_mutacao$

**Ensure:** Indivíduo mutado

- 1: **for** cada gene  $i$  no  $individuo$  **do**
  - 2:     **if** um número aleatório entre 0 e 1 for menor que  $taxa\_mutacao$  **then**
  - 3:          $individuo[i] =$  um valor aleatório entre 1 e 5
  - 4:     **end if**
  - 5: **end for**
  - 6: **return**  $individuo$
- 

O operador de cruzamento, detalhado no Algoritmo 2, combina partes de dois indivíduos (pais) para gerar novos indivíduos (filhos), promovendo a troca de informações genéticas entre as soluções há uma taxa de cruzamento (0.75), caso contrário os pais são repassados em sua forma original para a próxima geração. Especificamente, um ponto de corte é escolhido aleatoriamente e os segmentos dos pais são trocados para formar dois novos filhos. No operador de mutação (Algoritmo 3), cada gene do indivíduo é considerado para mutação e se um número aleatório for menor que a taxa de mutação (0.01), o gene é substituído por um valor aleatório dentro de um intervalo específico. Para finalizar a próxima geração, o operador de elitismo inclui na próxima geração a solução com o melhor fitness da população atual. Esse processo se repete por  $X$  gerações, até que um critério de parada seja obedecido. Neste trabalho  $X = 50$ .

## 4. Análise do Sistema Proposto

A qualidade das recomendações realizadas e dos grupos sugeridos foram analisadas em um ambiente simulado. Os dados sintéticos foram gerados com a API GPT-4o e analisados de forma manual. A turma sintética é composta por 30 (trinta) estudantes que responderam a um questionário com assuntos relacionados à matemática básica, sendo estes: função exponencial, trigonometria, frações, equações de primeiro e segundo grau, progressão aritmética, geométrica e operações com matrizes. Na base de dados há as seguintes informações: 1) Conhecimentos consolidados; 2) Conhecimentos para aperfeiçoar; 3) Turno disponível para estudo; 4) Categoria de preferência dos materiais de estudo. Uma segunda base de dados com diferentes materiais de estudo foi considerada, cada material está associado a uma categoria e pelo menos uma 'tag', ou seja, pelo menos um conteúdo presente no questionário do professor. O ISA foi considerado para recomendar os materiais e sugerir grupos de estudos com base nas informações sintéticas da turma.

#### 4.1. Avaliação dos Materiais de Estudo Recomendados

Para avaliar as recomendações realizadas pelo ISA, a base de dados foi gerada de modo supervisionado, ou seja, contendo as recomendações ideais de material de estudo para cada estudante, de modo a ponderar o conteúdo e o tipo de material que o estudante prefere. Sendo assim, a métrica *F-score* foi considerada para avaliar a qualidade das recomendações realizadas. A *F-score* é uma medida harmônica das métricas *precision* e *recall*, em que *precision* deve considerar a proporção de recomendações corretas entre todas as recomendações realizadas, enquanto *recall* pondera a proporção de recomendações corretas entre todas as possíveis recomendações corretas [Derczynski 2016]. As equações 3, 4 e 5 detalham os cálculos das métricas *precision*, *recall* e *F-score*, respectivamente.

$$P = \frac{VP}{VP + FP} \quad (3) \quad R = \frac{VP}{VP + FN} \quad (4) \quad F\text{-score} = 2 \times \frac{P \times R}{P + R} \quad (5)$$

Em que VP representa a quantidade de verdadeiros positivos, FP refere-se a quantidade de falsos positivos e FN representa a quantidade de falsos negativos. A tabela 1 detalha os valores de *Precision*, *Recall* e *F-score* das recomendações realizadas pelo ISA.

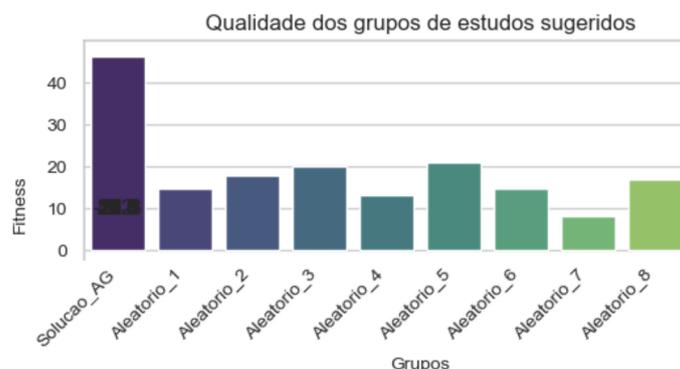
**Tabela 1. Métricas de Avaliação das Recomendações de Materiais de Estudo**

| Base de Dados   | Precision | Recall | F-score |
|-----------------|-----------|--------|---------|
| Turma Sintética | 0.5       | 0.9    | 0.64    |

A partir das informações descritas, observa-se um valor alto de *recall*, o que indica que o sistema está recomendando a maior parte dos materiais relevantes, porém ao analisarmos a métrica *precision* torna-se possível observar que mesmo recomendando a maior parte dos materiais relevantes, existem recomendações irrelevantes que estão sendo realizadas. Acredita-se que definir uma quantidade limite de documentos recomendados pode mitigar a quantidade de materiais irrelevantes sugeridos. Este ajuste será realizado em trabalhos futuros.

#### 4.2. Avaliação dos Grupos de Estudo Sugeridos

Para avaliar a qualidade dos grupos de estudo sugeridos no Módulo III também foi utilizada a base de dados sintética dos estudantes. Assim, o fitness da melhor solução do AG foi comparado ao fitness de 8 soluções de grupos geradas aleatoriamente.



**Figura 2. Valores de aptidão dos grupos de estudos**

A figura 2 analisa a qualidade do grupo sugerido pelo ISA em comparação à qualidade de grupos formados aleatoriamente, de acordo com a heurística definida na subseção 3.3. Os resultados demonstram que o grupo sugerido pelo sistema proposto se apresenta como a melhor solução, por realizar a ponderação que se mostra mais adequada quando se considera o turno que os estudantes estão disponíveis para os encontros do grupo e os conhecimentos complementares para o bom desenvolvimento do grupo.

## 5. Considerações Finais

Este trabalho apresentou o desenvolvimento do ISA, um sistema para Identificação e Suporte às Dificuldades Acadêmicas de estudantes no ensino superior. O sistema é composto por três módulos principais: 1) diagnóstico de conhecimentos prévios; 2) sistema de recomendação de materiais de estudo; e 3) sugestão de grupos colaborativos através de algoritmos genéticos.

Para análise do Módulo 2, a recomendação de materiais de estudo realizada pelo ISA foi avaliada em uma base de dados sintética e supervisionada, onde a base já contém informações sobre os materiais ideais a serem recomendados para cada estudante. Para análise do Módulo 3, a avaliação dos grupos de estudos sugeridos foi realizada a partir da heurística definida neste trabalho, que pondera os horários disponíveis e os conhecimentos complementares dos estudantes. Os resultados das avaliações mostraram que o sistema é capaz de identificar dificuldades acadêmicas de maneira eficaz, recomendando materiais de estudo personalizados e sugerindo grupos colaborativos com estudantes que possuem conhecimentos complementares.

A principal limitação deste estudo está relacionada a utilização de uma base de dados sintética para os testes iniciais. Como trabalhos futuros e para uma validação mais robusta, serão realizados testes em um ambiente real. Isso permitirá ajustes mais precisos no sistema, levando em consideração variáveis e nuances do ambiente educacional real. Espera-se, ainda, integrar novas tecnologias de aprendizado de máquina para melhorar a análise e a recomendação dos materiais de estudo. Por fim, pretendemos expandir o ISA para incluir outros níveis de ensino e diferentes áreas do conhecimento, tornando o sistema abrangente e acessível para uma maior diversidade de estudantes e instituições de ensino.

## Referências

- Andrade, T., Almeida, C., Barbosa, J., and Rigo, S. (2023). Avaliação de um modelo de sistema de recomendação que integra metodologias ativas e mineração de dados educacionais para mitigar a evasão na educação a distância. In *Anais do XXXIV Simpósio Brasileiro de Informática na Educação*, pages 187–198, Porto Alegre, RS, Brasil. SBC.
- Balieiro, A., Melo, I., Araújo, D., Neto, S., Galdino, E., and Gomes, A. (2017). Uma abordagem baseada em algoritmo genético para formação de grupos de estudos em ambientes virtuais de aprendizagem. In *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*, volume 28, page 1287.
- da Silva, M. D., Soares, G. C. A., Cardoso, C. M. L., Guerreiro, T. S. B., Guimarães, C. C., Chicre, G. R., de Siqueira, L. R. M., Seffair, R. P., do Amaral Domingues, N.,

- and de França Trindade, F. (2021). Coronavírus: consequências da pandemia no ensino superior. *Revista Eletrônica Acervo Saúde*, 13(5):e7120–e7120.
- de Macêdo, J. A. and Gregor, I. C. S. (2020). Dificuldades nos processos de ensino e de aprendizagem de cálculo diferencial e integral. *Educação Matemática Debate*, 4:1–24.
- Deng, J., Zhou, F., and Huang, E. (2021). The prevalence of depressive symptoms, anxiety symptoms and sleep disturbance in higher education students during the covid-19 pandemic: A systematic review and meta-analysis. *Psychiatry Research*, 301:113863 – 113863.
- Derczynski, L. (2016). Complementarity, F-score, and NLP evaluation. In Calzolari, N., Choukri, K., Declerck, T., Goggi, S., Grobelnik, M., Maegaard, B., Mariani, J., Mazo, H., Moreno, A., Odijk, J., and Piperidis, S., editors, *Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)*, pages 261–266, Portorož, Slovenia. European Language Resources Association (ELRA).
- Holland, J. H. (1992). Genetic algorithms. *Scientific american*, 267(1):66–73.
- Kurniadi, D., Hidayat, H., Anwar, M., Budayawan, K., Syaifar, A. L., Zuhendra, Efrizon, and Safitri, R. (2023). Genetic algorithms for optimizing grouping of students classmates in engineering education. *International Journal of Information and Education Technology*.
- Okubo, F., Shiino, T., Minematsu, T., Taniguchi, Y., and Shimada, A. (2022). Adaptive learning support system based on automatic recommendation of personalized review materials. *IEEE Transactions on Learning Technologies*, 16(1):92–105.
- Oliveira, F. and Frango, I. (2021). Recommender systems in education: Systematic mapping. In *2021 XVI Latin American Conference on Learning Technologies (LACLO)*, pages 282–289. IEEE.
- Oliveira, G., Teixeira, J., Torres, A., and Morais, C. (2021). An exploratory study on the emergency remote education experience of higher education students and teachers during the covid-19 pandemic. *British Journal of Educational Technology*, 52:1357 – 1376.
- Sazhin, S. (1998). Teaching mathematics to engineering students. *International Journal of Engineering Education*, 14:145–152.
- Urdaneta-Ponte, M. C., Mendez-Zorrilla, A., and Oleagordia-Ruiz, I. (2021). Recommendation systems for education: Systematic review. *Electronics*, 10(14):1611.
- Yan-hui, X. (2011). On mathematical computing and its teaching. *Journal on Mathematics Education*.
- Yu, F., Fu, X., Li, H., and Dong, G. (2016). Improved roulette wheel selection-based genetic algorithm for tsp. In *2016 International conference on network and information systems for computers (ICNISC)*, pages 151–154. IEEE.