

COMPARAÇÃO DE ESTRATÉGIAS DE CROSSOVER EM ALGORITMOS GENÉTICOS PARA ALOCAÇÃO DE TURMAS

COMPARISON OF CROSSOVER STRATEGIES IN GENETIC ALGORITHMS FOR CLASS SCHEDULING

COMPARACIÓN DE ESTRATEGIAS DE CROSSOVER EN ALGORITMOS GENÉTICOS PARA LA ASIGNACIÓN DE CLASES

Leonardo da Silva Sampaio¹, Tiago Oliveira Motta², Iuri Santos Souza³

DOI: 10.54899/dcs.v22i85.3976

Recibido: 07/12/2025 | Aceptado: 08/12/2025 | Publicación en línea: 19/12/2025.

RESUMO

O planejamento acadêmico em instituições de ensino envolve desafios significativos, especialmente na alocação física de turmas nos espaços disponíveis. A diversidade de cursos, conflitos de horários e exigências de infraestrutura agravam a complexidade do processo, especialmente na ausência de suporte tecnológico. Este trabalho apresenta uma solução computacional para automatizar a alocação de turmas, utilizando Algoritmos Genéticos como técnica de otimização de software. A metodologia adotada baseou-se na pesquisa-ação, abrangendo o levantamento de dados institucionais, modelagem do sistema, implementação e testes. Os experimentos compararam três estratégias de *crossover* (processo que gera novas soluções a partir de anteriores): Aleatória, Elitismo e Janela Deslizante, avaliando desempenho em relação à qualidade das soluções, tempo de processamento e capacidade de atender a restrições. Foram ajustados parâmetros como tamanho da população e quantidade de gerações. Os resultados indicaram que o *crossover* por Elitismo gerou soluções mais consistentes e com maior pontuação; a estratégia Aleatória promoveu diversidade, mas com evolução limitada; e Janela Deslizante apresentou pontuação intermediária, mas com melhor tempo. A pesquisa evidencia a importância da escolha adequada da técnica de *crossover* para cumprimento dos objetivos da aplicação.

Palavras-chave: Alocação de Turmas. Planejamento Acadêmico. Algoritmos Genéticos.

ABSTRACT

Academic planning in educational institutions involves significant challenges, especially regarding the physical allocation of classes within the available spaces. The diversity of courses, scheduling conflicts, and infrastructure requirements increase the complexity of the process,

¹Mestrando em Propriedade Intelectual e Transferência de Tecnologia em Inovação, Universidade Federal do Recôncavo da Bahia, Feira de Santana, Bahia, Brasil. E-mail: leonardosampaio@ufrb.edu.br

²Doutor em Ciência da Computação, Universidade Federal da Bahia, Salvador, Bahia, Brasil.
E-mail: motta.tiago@ufrb.edu.br

³Doutor em Ciência da Computação, Universidade Federal da Bahia, Salvador, Bahia, Brasil.
E-mail: iuri.souza@ufrb.edu.br

particularly in the absence of technological support. This work presents a computational solution to automate class allocation, using Genetic Algorithms as a software optimization technique. The adopted methodology was based on action research, encompassing institutional data collection, system modeling, implementation, and testing. The experiments compared three crossover strategies (a process that generates new solutions from previous ones): Random, Elitism, and Sliding Window, evaluating their performance regarding solution quality, processing time, and ability to meet constraints. Parameters such as population size and number of generations were adjusted. The results indicated that crossover by Elitism produced more consistent solutions with higher scores; the Random strategy promoted diversity but with limited evolution; and Sliding Window showed intermediate scoring but better processing time. The research highlights the importance of choosing the appropriate crossover technique to achieve the application's objectives.

Keywords: Timetabling. Academic Planning. Genetic Algorithms.

RESUMEN

La planificación académica en las instituciones educativas implica desafíos significativos, especialmente en la asignación física de clases en los espacios disponibles. La diversidad de cursos, los conflictos de horarios y las exigencias de infraestructura aumentan la complejidad del proceso, particularmente en ausencia de apoyo tecnológico. Este trabajo presenta una solución computacional para automatizar la asignación de clases, utilizando Algoritmos Genéticos como técnica de optimización de software. La metodología adoptada se basó en la investigación-acción, abarcando la recopilación de datos institucionales, la modelación del sistema, la implementación y las pruebas. Los experimentos compararon tres estrategias de cruce (proceso que genera nuevas soluciones a partir de las anteriores): Aleatorio, Elitismo y Ventana Deslizante, evaluando el desempeño en cuanto a la calidad de las soluciones, el tiempo de procesamiento y la capacidad de atender restricciones. Se ajustaron parámetros como el tamaño de la población y la cantidad de generaciones. Los resultados indicaron que el cruce por Elitismo generó soluciones más consistentes y con mayor puntuación; el modelo Aleatorio promovió diversidad, pero con evolución limitada; y la Ventana Deslizante presentó una puntuación intermedia, pero con mejor tiempo. La investigación destaca la importancia de elegir adecuadamente la técnica de cruce para cumplir con los objetivos de la aplicación.

Palabras clave: Asignación de Clases. Planificación Académica. Algoritmos Genéticos.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

O planejamento acadêmico em instituições de ensino superior envolve desafios administrativos que vão além das atividades de ensino em sala de aula. Entre eles, destaca-se a alocação física das turmas nos espaços institucionais disponíveis, uma tarefa que exige equilíbrio

entre a diversidade de cursos, a limitação de salas, os conflitos de horários e as exigências específicas de infraestrutura. Na Universidade Federal do Recôncavo da Bahia (UFRB), esse processo é realizado manualmente, o que resulta em elevado consumo de tempo, retrabalho e alocações frequentemente ineficientes.

Esse cenário caracteriza um típico problema de alocação de recursos, em que há uma oferta limitada de espaços físicos e uma demanda crescente representada por turmas com diferentes perfis e necessidades. Diante da grande quantidade de variáveis envolvidas, como tipo de aula, capacidade das salas, preferências docentes e restrições de horário, torna-se inviável obter a melhor solução por meio de métodos tradicionais e determinísticos. Assim, surge a necessidade de empregar técnicas computacionais capazes de encontrar soluções satisfatórias em tempo hábil.

Nesse contexto, o presente trabalho adota os Algoritmos Genéticos (AGs) como estratégia de otimização. Inspirados nos mecanismos evolutivos da natureza, os AGs operam com populações de soluções (indivíduos) que evoluem ao longo de gerações por meio dos operadores de seleção, *crossover* (cruzamento) e mutação. Essa abordagem é especialmente adequada para problemas com grandes espaços de busca e restrições complexas, como o da alocação de turmas.

Entre os operadores genéticos, o *crossover* tem papel central, pois é por meio dele que as características de soluções promissoras são combinadas para gerar novos indivíduos com potencial de desempenho superior. A forma como essa recombinação é realizada afeta diretamente a qualidade da população ao longo das gerações. Por esse motivo, este artigo concentra-se na comparação entre três modelos de *crossover*: Aleatório, Elitismo e Janela Deslizante. Cada um adota estratégias distintas de seleção e recombinação de genes, influenciando de forma diferente a diversidade e a convergência da população.

O objetivo da pesquisa é avaliar o desempenho dessas estratégias quanto à qualidade das soluções geradas (*score*), ao tempo de processamento e à estabilidade da evolução da população. Busca-se compreender como a escolha do método de *crossover* impacta os resultados do Algoritmo Genético na alocação de turmas, oferecendo contribuições práticas e teóricas para o uso de técnicas evolutivas na gestão acadêmica.

REFERENCIAL TEÓRICO

A Inteligência Artificial (IA) é uma das áreas mais relevantes da ciência da computação contemporânea, voltada para o desenvolvimento de sistemas capazes de simular habilidades

humanas como percepção, raciocínio, aprendizado e tomada de decisões. Concebida inicialmente por John McCarthy em 1962 como “a ciência e engenharia de produzir máquinas inteligentes”, a IA se consolidou ao longo das décadas com o surgimento de técnicas como aprendizado de máquina (*Machine Learning*), aprendizado profundo (*Deep Learning*) e computação evolutiva (RUSSELL & NORVIG, 2020).

Com o passar dos anos, a IA passou a abranger uma ampla variedade de abordagens. O aprendizado de máquina, por exemplo, busca desenvolver algoritmos que permitam aos sistemas aprender a partir de dados e ajustar-se automaticamente. O aprendizado profundo, por sua vez, utiliza redes neurais artificiais com múltiplas camadas e tem sido responsável por avanços notáveis em áreas como reconhecimento de imagens, voz e padrões, com aplicações que vão do diagnóstico médico a veículos autônomos, segurança e finanças (GOODFELLOW *et al.*, 2016).

Dentro da IA, destaca-se a Computação Evolutiva (CE), uma subárea que se inspira nos princípios da seleção natural propostos por Charles Darwin. A CE utiliza mecanismos de evolução biológica para resolver problemas complexos, por meio de populações de soluções que são refinadas ao longo de gerações por operadores como seleção, *crossover* e mutação (ÁVILA, 2020). Em vez de buscar diretamente a solução ótima, a CE explora grandes espaços de busca de forma adaptativa, sendo útil especialmente quando os métodos exatos são inviáveis ou ineficientes.

Entre as técnicas da computação evolutiva, os Algoritmos Genéticos (AGs) são os mais difundidos. Desenvolvidos por John Holland na década de 1960, os AGs baseiam-se em processos evolutivos naturais para encontrar boas soluções para problemas de otimização. Cada solução possível é representada como um cromossomo, e o algoritmo trabalha com populações de indivíduos que evoluem ao longo de gerações (LINDEN, 2012, p.32).

Algoritmos Genéticos

O funcionamento de um Algoritmo Genético pode ser descrito como um processo iterativo composto por etapas sucessivas e interdependentes. Inicialmente, ocorre a geração aleatória da população inicial, em que cada indivíduo representa uma solução potencial para o problema a ser resolvido. Em seguida, realiza-se a avaliação de desempenho de cada indivíduo por meio de uma função de aptidão (*fitness function*), que atribui uma pontuação ou *score* conforme critérios previamente definidos, levando em conta restrições e objetivos múltiplos.

Com base nessas pontuações, é feita a seleção dos indivíduos mais aptos, os quais têm maior probabilidade de gerar descendentes. Entre os métodos de seleção mais utilizados estão a roleta, o torneio e o elitismo. A etapa seguinte é o *crossover*, em que dois indivíduos são combinados para gerar novos descendentes. Esse processo é determinante para a qualidade e diversidade da população, pois permite explorar diferentes combinações de características herdadas dos pais. Diferentes estratégias de *crossover*, como a Aleatória e a Elitista, podem produzir resultados significativamente distintos, influenciando diretamente a convergência do algoritmo.

Após o *crossover*, aplica-se a mutação, que introduz pequenas alterações aleatórias em alguns indivíduos, garantindo diversidade genética e evitando que a população apresente estagnação em soluções boas, mas não ótimas. Por fim, ocorre a substituição, na qual a nova geração, composta pelos descendentes gerados e possivelmente alguns indivíduos da geração anterior, passa a integrar a população ativa. O ciclo é então repetido até que um critério de parada seja atingido, como o número máximo de gerações ou a estabilização do desempenho das soluções.

A principal vantagem dos AGs é sua capacidade de lidar com espaços de busca grandes e multidimensionais, onde coexistem múltiplas variáveis e restrições, cenário típico da alocação de turmas em instituições de ensino, em que se busca equilibrar disponibilidade de salas, horários, turmas e recursos físicos.

METODOLOGIA

O presente estudo foi desenvolvido segundo o método pesquisa-ação, uma abordagem participativa que integra reflexão teórica e intervenção prática, buscando tanto compreender o fenômeno estudado quanto promover melhorias concretas no contexto analisado (THIOLLENT, 2009; LEWIN, 1946). Essa metodologia mostrou-se adequada à natureza aplicada do projeto, cujo objetivo é propor e avaliar uma solução computacional para a alocação de turmas em instituições de ensino, um problema caracterizado por múltiplas restrições e elevada complexidade combinatória.

A pesquisa-ação adota um ciclo contínuo de quatro etapas: observação, planejamento, execução e avaliação. Em cada uma delas, teoria e prática se articulam de forma interativa, permitindo que o sistema proposto evolua com base nas análises e resultados obtidos. No âmbito

deste trabalho, as etapas foram conduzidas conforme descrito a seguir.

Na fase de observação, realizou-se um diagnóstico detalhado do processo de planejamento acadêmico no campus estudado, identificando gargalos e desafios operacionais. Essa etapa possibilitou o levantamento dos requisitos funcionais e não funcionais do sistema de apoio à alocação, estabelecendo as bases para o desenvolvimento da solução computacional.

A etapa de planejamento fundamentou-se na literatura sobre computação evolutiva e otimização, com foco nos Algoritmos Genéticos (AGs). Nessa fase, foram definidos o modelo conceitual do sistema e seus principais processos internos, incluindo a estrutura de representação dos indivíduos, os critérios de avaliação e os parâmetros de evolução populacional.

A execução consistiu no desenvolvimento do sistema, implementado de forma incremental e iterativa, em abordagem semelhante aos métodos ágeis. Esse formato permitiu ajustes contínuos com base nos testes e resultados intermediários. Durante o processo, foram implementadas e comparadas três estratégias distintas de *crossover*. O modelo Aleatório promove alta diversidade na população, combinando de forma não determinística os genes (alocações) dos indivíduos pais. O modelo Elitismo prioriza a herança das melhores características dos indivíduos com maior pontuação, favorecendo a convergência acelerada das soluções. Já o modelo Janela Deslizante adota uma aleatoriedade controlada, preservando blocos de horários e reduzindo o tempo de processamento sem comprometer significativamente a qualidade das alocações.

Esses modelos foram aplicados sobre a mesma base de dados e submetidos a diferentes configurações de parâmetros, como tamanho da população e número de gerações, com o objetivo de avaliar seu impacto no desempenho e na qualidade das soluções. O desempenho de cada método foi mensurado por meio de indicadores quantitativos, como pontuação média das soluções e tempo de execução, e também por análises visuais dos mapas de alocação gerados, representando graficamente a distribuição das turmas nas salas.

Em síntese, o método de pesquisa-ação possibilitou alinhar o desenvolvimento técnico do sistema às necessidades reais do contexto acadêmico, garantindo relevância prática e validade científica à proposta. A utilização de algoritmos genéticos viabilizou a automatização do processo de alocação, conciliando múltiplas restrições de forma adaptativa. O estudo comparativo entre os métodos de *crossover*, foco deste artigo, representa uma das etapas centrais da pesquisa e contribui para compreender como diferentes estratégias evolutivas influenciam a eficiência e a qualidade das soluções geradas.

RESULTADOS E DISCUSSÃO

Com o sistema implementado e os métodos de *crossover* devidamente configurados, iniciou-se a fase experimental da pesquisa. Nessa etapa, buscou-se verificar, de forma prática, o desempenho do algoritmo genético frente a diferentes combinações de parâmetros e estratégias de *crossover*. Os testes foram conduzidos em ambiente controlado, utilizando dados reais do planejamento acadêmico institucional, a fim de avaliar a eficiência, a qualidade das soluções e o comportamento evolutivo do modelo em condições próximas às de uso real. A seguir, apresentam-se os resultados obtidos a partir desses experimentos comparativos.

Conjunto de Dados e Configuração Experimental


O conjunto de dados utilizado refere-se ao planejamento do semestre 2025.1, composto por 367 turmas distribuídas em 7 cursos de graduação, 5 dias da semana e 2 turnos (matutino e vespertino). O campus dispõe de 40 salas, sendo 18 teóricas e 22 práticas. Para os experimentos, foi selecionada uma amostra representativa de 45 turmas (29 teóricas e 16 práticas) e 10 salas (7 teóricas e 3 laboratórios), correspondendo a aproximadamente 50% da ocupação média de um dia letivo. A escolha dessa amostra baseou-se na independência da alocação diária, permitindo a extrapolação dos resultados para os demais dias da semana.

Os experimentos foram organizados para comparar os três operadores de *crossover* implementados: Aleatório, Elitismo e Janela Deslizante. Para garantir a comparabilidade, todos os testes partiram da mesma população inicial de 30 indivíduos, e o número de gerações foi variando progressivamente de 1 a 10. A avaliação foi realizada em duas dimensões: (i) uma análise quantitativa dos *scores* de aptidão e do tempo de execução; e (ii) uma análise qualitativa por meio de mapas gráficos de alocação.

Análise Quantitativa

Qualidade da Solução (*Score* x Gerações)

A Figura 1 apresenta a evolução do *score* do melhor indivíduo ao longo das gerações para cada método de *crossover*.

Figura 1. Comparativo *score* em função do número de gerações

Fonte: Elaborada pelos próprios autores

A análise da Figura 1 revela diferenças significativas no desempenho dos métodos. O *crossover* por Elitismo (linha vermelha contínua) demonstrou uma convergência mais rápida e consistente, estabilizando o *score* máximo a partir da 7ª geração. Este método manteve uma vantagem de desempenho de aproximadamente 30% em relação aos demais. Em contraste, os métodos Aleatório (linha azul pontilhada) e Janela Deslizante (linha amarela tracejada) exibiram uma convergência mais lenta e irregular, com melhorias incrementais e descontínuas no *score* ao longo das gerações.

Esta disparidade pode ser atribuída às características intrínsecas de cada operador. Enquanto os métodos Aleatório e Janela Deslizante dependem de seleções estocásticas para compor a prole, o que pode diluir as características dos melhores indivíduos, o método Elitismo adota uma estratégia determinística. Neste, cada gene (alocação de turma) no descendente é herdado diretamente do progenitor com o melhor *score* para aquela turma específica, resultando em uma exploração mais eficiente do espaço de busca e em uma convergência acelerada.

Desempenho Computacional (Tempo de Execução)

A Tabela 1 sumariza os tempos médios de execução (em milissegundos) para cada método de *crossover*, medidos após a etapa comum de inicialização da primeira geração.

Tabela 1. Tempos de execução para os diferentes métodos de *crossover*.

Método de Crossover	Tempo de Execução Médio (ms)
Aleatório	126
Elitismo	91
Janela Deslizante	57

Fonte: Elaborada pelos próprios autores

O método Janela Deslizante apresentou o melhor desempenho computacional, com um tempo de execução aproximadamente 55% menor que o método Aleatório. O método Elitismo registrou um tempo intermediário, cerca de 28% mais rápido que o Aleatório. O método Aleatório foi o mais custoso, devido ao alto número de chamadas à função geradora de números aleatórios.

A superioridade do método Janela Deslizante em termos de velocidade deve-se à sua arquitetura, que opera com blocos de horários (e.g., 1 a 3 horários) em vez de realizar operações gene-a-gene, reduzindo significativamente o número total de iterações. O Elitismo, por sua vez, substitui os sorteios aleatórios por comparações diretas de *scores*, uma operação computacionalmente mais leve. Considerando o equilíbrio entre qualidade da solução e eficiência, o método Elitismo surge como a abordagem mais vantajosa para o contexto em questão. Dessa forma, o sistema computacional de alocação de turmas, desenvolvido neste trabalho, foi configurado para utilizar o método de *crossover* por Elitismo, o qual se revelou a estratégia mais robusta para a implementação do software


Qualidade da Solução (*Score* x População)

Para avaliar o impacto do tamanho da população no desempenho do algoritmo, foram conduzidos testes variando o número de indivíduos entre 10, 20, 30, 40 e 50, mantendo-se fixo o total de 10 gerações para todos os cenários. A Figura 15 apresenta a evolução do *score* do melhor

indivíduo em função do tamanho populacional para os três métodos de *crossover* investigados. A representação visual segue o mesmo padrão adotado no gráfico anterior.

Figura 2. Comparativo *score* em função do número de gerações

Pop. Inicial, Aleatorio, Elitismo e Jan. Deslizante



Fonte: Elaborada pelos próprios autores

A análise dos resultados revela padrões distintos de comportamento entre os métodos frente à variação populacional. O modelo Elitismo manteve superioridade consistente em todos os tamanhos de população testados, alcançando os maiores *scores* absolutos. Seu desempenho demonstrou uma progressão estável e crescente, atingindo um *score* de 2980 com população de 50 indivíduos, um ganho superior a 250% em relação ao *score* inicial de 849 registrado para essa configuração populacional. Esta escalabilidade positiva indica uma capacidade robusta de explorar eficientemente espaços de busca ampliados, característica fundamental para problemas de otimização complexos.

O método Aleatório apresentou um comportamento de saturação precoce. Embora tenha promovido melhorias significativas em relação às populações iniciais, observa-se uma estabilização dos *scores* a partir de populações com 30 indivíduos, sugerindo limitações na capacidade de exploração do método. Esta estagnação indica que o componente estocástico do

operador, sem mecanismos direcionados de preservação de características ótimas, torna-se menos eficaz conforme aumenta a diversidade genética disponível.

O desempenho do método Janela Deslizante mostrou-se particularmente sensível à variação populacional. Além de registrar os menores *scores* entre as três abordagens em todas as configurações, apresentou comportamento errático, com quedas significativas de desempenho em populações intermediárias (notadamente em 30 indivíduos). Esta inconsistência sugere que a estratégia baseada em blocos pode sofrer de baixa capacidade evolutiva quando submetida a diferentes níveis de diversidade genética, possivelmente devido a perdas de sinergia entre os blocos recombinações.

Um achado adicional, que merece ser ressaltado, refere-se ao comportamento das populações iniciais. Os *scores* iniciais não apresentaram correlação positiva consistente com o aumento do tamanho populacional, chegando mesmo a decrescer em algumas configurações. Este fenômeno ressalta a importância crítica dos operadores de *crossover* para direcionar a busca por soluções viáveis, uma vez que o mero aumento da diversidade inicial não garante melhor qualidade de partida.

Em síntese, os resultados reforçam a robustez do método Elitismo como a escolha mais adequada para o problema em questão, demonstrando escalabilidade e eficiência across diferentes tamanhos populacionais. O método Aleatório mostra-se aplicável em cenários com restrições computacionais mais severas, porém com limitações evidentes em contextos que demandam alta qualidade de solução. Já o método Janela Deslizante apresentou desempenho insatisfatório, não se mostrando recomendável para implementações práticas do sistema de alocação proposto.

Análise Qualitativa por Mapas de Alocação

A representação visual do mapa de alocação adota uma estrutura matricial, onde as colunas representam as salas e as linhas, os horários. A nomenclatura segue um padrão claro para salas (e.g., "Sala 208 (P 30)") e turmas (e.g., "Turma 7 (P 20 -15)"), complementada por um esquema de cores (tons de azul para teóricas e cinza para práticas).

A Figura 2 exibe o melhor indivíduo da população inicial, gerado aleatoriamente. A natureza estocástica desta geração é evidente na distribuição irregular e nos *scores* variáveis. Por exemplo, a Turma 7 apresenta *score* negativo (-15) devido à incompatibilidade de tipo (prática

em sala teórica) e má distribuição de horários, enquanto a Turma 39 alcança *score* elevado (35) por estar perfeitamente adequada à sala.

Figura 2. Mapa de alocação da população inicial.

Turno	Horário	Lab 01 Química (P 20)	Lab 04 Física (P 20)	Lab 05 Biologia (P 20)	Sala 103 (T 60)	Sala 201 (T 40)	Sala 202 (T 40)	Sala 203 (T 40)	Sala 208 (T 20)	Sala 210 (T 30)	Sala 212 (T 20)
Manhã	07-08h	Turma17 (T 10 25pts)	Turma16 (P 15 32pts)	--	Turma36 (T 40 31pts)	Turma39 (T 40 35pts)	Turma31 (T 30 12pts)	Turma41 (T 40 15pts)	--	Turma18 (T 10 28pts)	--
	08-09h			Turma25 (T 20 30pts)					Turma7 (P 20 -15pts)		Turma11 (P 15 2pts)
	09-10h	--	Turma42 (T 60 -30pts)			Turma43 (T 60 -5pts)	--	Turma15 (P 15 -2pts)		--	
	10-11h	Turma12 (P 15 12pts)		--	Turma4 (P 20 -22pts)		Turma19 (T 10 27pts)		Turma29 (T 30 -5pts)	Turma38 (T 60 5pts)	Turma26 (T 20 35pts)
	11-12h		Turma27 (T 20)	Turma24 (T 20 30pts)		Turma33 (T 40 35pts)		Turma35 (T 40 35pts)			
	12-13h	--	--		--		--			--	
Tarde	13-14h	Turma1 (P 15 32pts)	Turma40 (T 40 0pts)	--	Turma21 (T 10 26pts)	--	Turma6 (P 20 -20pts)	Turma34 (T 40 15pts)	Turma8 (P 15 2pts)	Turma5 (P 15 -20pts)	Turma30 (T 30 15pts)
	14-15h			Turma37 (T 60 -30pts)		Turma10 (P 20 -20pts)					
	15-16h	Turma13 (P 15 32pts)					Turma28 (T 30 12pts)	Turma9 (P 15 -22pts)	--	--	
	16-17h		Turma14 (P 15 32pts)	Turma2 (P 15 12pts)	Turma23 (T 15 27pts)	Turma3 (P 20 0pts)			Turma20 (T 10 10pts)	Turma22 (T 10 28pts)	Turma32 (T 30 15pts)
	17-18h	--					--	--			

Fonte: Elaborada pelos próprios autores

A Figura 3 apresenta o mapa de alocação resultante da aplicação do modelo Aleatório após 10 gerações de evolução. Em comparação com a configuração inicial (Figura 2), observa-se uma evolução positiva na organização, embora ainda marcada pela inconsistência. Nota-se um esboço de estruturação, evidenciado por um maior equilíbrio entre a capacidade das salas e o número de alunos, como na frequente alocação de turmas de 40 alunos em salas de capacidade equivalente. Um segundo avanço reside na tendência, ainda que incipiente, de alocar turmas práticas em laboratórios.

Contudo, a análise detalhada revela as limitações intrínsecas do método estocástico. Inconsistências significativas permanecem abundantes, destacando-se: (i) a alocação da Turma 6 (Prática) na Sala 202 (Teórica), gerando um *score* fortemente negativo e configurando uma violação clara de restrição; (ii) a Turma 44, com 20 alunos, ocupando a Sala 103 com capacidade para 60, indicando uma severa subutilização do espaço; e (iii) uma distribuição temporal irregular,

com aglomerados de horários vagos (ex.: bloco da tarde na Sala 202) seguidos de horários completamente preenchidos. Estas imperfeições, que persistem após 10 gerações, corroboram quantitativamente o crescimento lento e irregular do *score*, demonstrando que o método, embora capaz de melhorias graduais, carece de uma direção evolutiva eficiente para consolidar soluções robustas.

Figura 3. Mapa de alocação gerado pelo método Aleatório

Turmo	Horário	Lab 01 Química (P 20)	Lab 04 Física (P 20)	Lab 05 Biologia (P 20)	Sala 103 (T 60)	Sala 201 (T 40)	Sala 202 (T 40)	Sala 203 (T 40)	Sala 208 (T 20)	Sala 210 (T 30)	Sala 212 (T 20)
Manhã	07-08h						--				
	08-09h	Turma33 (T 40 0pts)	Turma19 (T 10 25pts)	Turma5 (P 15 32pts)	Turma35 (T 40 31pts)	Turma29 (T 30 12pts)	--	Turma36 (T 40 35pts)	Turma18 (T 10 30pts)	Turma17 (T 10 28pts)	Turma10 (P 20 5pts)
	09-10h										
	10-11h	Turma2 (P 15 32pts)	Turma25 (T 20 30pts)	Turma26 (T 20 30pts)	Turma44 (T 20 28pts)	Turma28 (T 30 32pts)	Turma9 (P 15 -2pts)		Turma24 (T 20 35pts)	Turma39 (T 40 15pts)	Turma23 (T 15 12pts)
	11-12h	Turma38 (T 60 -10pts)	Turma20 (T 10 25pts)		Turma15 (P 15 -3pts)		Turma34 (T 40 35pts)	Turma40 (T 40 15pts)	Turma31 (T 30 -5pts)	--	Turma22 (T 10 10pts)
	12-13h			--		--				--	
Tarde	13-14h										Turma27 (T 20)
	14-15h	Turma7 (P 20 35pts)	Turma3 (P 20 35pts)	Turma21 (T 10 25pts)	Turma37 (T 60 15pts)	Turma8 (P 15 -2pts)	Turma30 (T 30 32pts)	Turma11 (P 15 -22pts)	Turma1 (P 15 2pts)	Turma42 (T 60 5pts)	--
	15-16h										
	16-17h	Turma12 (P 15 32pts)	Turma4 (P 20 35pts)		Turma41 (T 40 31pts)	Turma32 (T 30 32pts)		Turma14 (P 15 -2pts)	Turma13 (P 15 2pts)	Turma45 (T 30 35pts)	--
	17-18h	--	--	Turma16 (P 15 12pts)	--	--	Turma6 (P 20 -20pts)	--	--	--	Turma43 (T 60 -5pts)

Fonte: Elaborada pelos próprios autores

A Figura 4 ilustra o mapa de alocação produzido pelo modelo Elitismo após 10 gerações, representando um salto qualitativo notável em relação aos demais métodos. A solução exibe um alto nível de otimização, com uma aderência quase total aos critérios de viabilidade. A precisão do método é evidenciada em múltiplas dimensões: (i) Compatibilidade de Tipo: Praticamente todas as turmas práticas estão corretamente alocadas em laboratórios, com a exceção da Turma 14, que, embora em uma sala teórica (Sala 212), encontra nela uma capacidade perfeitamente adequada; (ii) Adequação de Capacidade: Observa-se um rigor no pareamento, como a Sala 103 (capacidade 60) recebendo exclusivamente turmas de 60 alunos, e a Sala 201 sendo utilizada por turmas de menor porte.

A principal contrapartida desta estratégia é a persistência de horários vagos entre turmas, em uma proporção superior à observada no método Aleatório. Esta característica, como na sequência de horários vazios na Sala 103 e 203, sugere que o critério de seleção por *score* máximo para cada gene individual não prioriza a compactação ou a minimização de janelas no cronograma como um todo. O algoritmo privilegia a excelência pontual em detrimento da eficiência espacial global, um trade-off que deverá ser considerado e possivelmente ajustado na função de fitness em investigações futuras. Apesar desta ressalva, a solução gerada pelo Elitismo mantém-se incontestavelmente como a mais robusta e confiável entre as testadas.

Figura 4. Mapa de alocação gerado pelo método Elitismo

Turno	Horário	Lab 01 Química (P 20)	Lab 04 Física (P 20)	Lab 05 Biologia (P 20)	Sala 103 (T 60)	Sala 201 (T 40)	Sala 202 (T 40)	Sala 203 (T 40)	Sala 208 (T 20)	Sala 210 (T 30)	Sala 212 (T 20)
Manhã	07-08h				--			--			
	08-09h	Turma9 (P 15 32pts)	Turma16 (P 15 32pts)	Turma2 (P 15 32pts)	--	Turma35 (T 40 35pts)	Turma34 (T 40 35pts)	--	Turma26 (T 20 35pts)	Turma25 (T 20 31pts)	Turma19 (T 10 30pts)
	09-10h										
	10-11h	Turma15 (P 15 32pts)	Turma10 (P 20 35pts)	Turma11 (P 15 32pts)	Turma38 (T 60 35pts)	Turma44 (T 20 30pts)	Turma36 (T 40 35pts)	Turma33 (T 40 35pts)		Turma20 (T 10 28pts)	Turma24 (T 20 35pts)
	11-12h										
	12-13h	Turma13 (P 15 12pts)	Turma6 (P 20 35pts)	Turma5 (P 15 32pts)	Turma37 (T 60 35pts)	--	--	Turma39 (T 40 35pts)	--	Turma28 (T 30 35pts)	Turma17 (T 10 30pts)
Tarde	13-14h	--						--			
	14-15h		Turma7 (P 20 35pts)	Turma1 (P 15 32pts)	Turma42 (T 60 35pts)		Turma41 (T 40 35pts)	--	Turma21 (T 10 30pts)	Turma29 (T 30 35pts)	Turma23 (T 15 32pts)
	15-16h	Turma3 (P 20 35pts)				Turma30 (T 30 32pts)	--				
	16-17h		Turma8 (P 15 32pts)	Turma4 (P 20 35pts)	Turma43 (T 60 35pts)			Turma40 (T 40 35pts)			Turma14 (P 15 2pts)
	17-18h	Turma12 (P 15 32pts)	--	--	--	Turma32 (T 30 32pts)	Turma45 (T 30 32pts)		Turma22 (T 10 30pts)	Turma31 (T 30 35pts)	Turma27 (T 20)

Fonte: Elaborada pelos próprios autores

A Figura 5 apresenta o mapa de alocação produzido pelo modelo de Janela Deslizante, que demonstra um desempenho qualitativo intermediário. O método conseguiu consolidar algumas melhorias estruturais em relação ao Aleatório, notadamente: (i) um aumento na taxa de sucesso na alocação de turmas práticas em laboratórios; e (ii) uma redução significativa na quantidade de horários vagos, resultando em um cronograma visualmente mais compacto.

No entanto, a análise crítica evidencia que o modelo ainda enfrenta desafios fundamentais na busca por uma solução otimizada. Inconsistências notáveis persistem, tais como a Turma 11 (Prática) incorretamente posicionada na Sala 201 (Teórica); e a Turma 44 (20 alunos) ocupando

a Sala 103 (60 lugares), repetindo erros observados no mapa Aleatório. Isto indica que, embora a operação em blocos acelere o processamento, a natureza probabilística da seleção dentro dessas janelas ainda permite que configurações subótimas se perpetuem ao longo das gerações. Portanto, a principal vantagem competitiva deste modelo permanece sendo seu desempenho computacional superior, como quantificado na Tabela 1. Ele se apresenta como uma opção viável para cenários que demandam respostas rápidas, onde se pode tolerar um certo nível de imperfeição na alocação em troca de uma redução substancial no tempo de processamento.

Figura 5. Mapa de alocação gerado pelo método Janela Deslizante

Turmo	Horário	Lab 01 Química (P 20)	Lab 04 Física (P 20)	Lab 05 Biologia (P 20)	Sala 103 (T 60)	Sala 201 (T 40)	Sala 202 (T 40)	Sala 203 (T 40)	Sala 208 (T 20)	Sala 210 (T 30)	Sala 212 (T 20)
Manhã	07-08h	Turma19 (T 10 25pts)	Turma33 (T 40 0pts)	Turma6 (P 20 35pts)	Turma43 (T 60 15pts)	Turma26 (T 20 30pts)	Turma45 (T 30 12pts)	Turma34 (T 40 35pts)	Turma20 (T 10 30pts)	Turma39 (T 40 15pts)	Turma30 (T 30 -5pts)
	08-09h										
	09-10h						--		--		
	10-11h	Turma5 (P 15 32pts)	Turma25 (T 20 30pts)	Turma9 (P 15 32pts)	Turma38 (T 60 35pts)	Turma11 (P 15 -2pts)		Turma35 (T 40 35pts)	--	Turma31 (T 30 15pts)	Turma42 (T 60 -25pts)
	11-12h						Turma36 (T 40 35pts)		--	--	
	12-13h	Turma12 (P 15 12pts)	Turma13 (P 15 12pts)	Turma15 (P 15 32pts)	Turma44 (T 20 28pts)	--		Turma24 (T 20 30pts)	--	--	--
Tarde	13-14h	Turma16 (P 15 12pts)	Turma32 (T 30 10pts)	Turma1 (P 15 32pts)	Turma21 (T 10 26pts)	Turma10 (P 20 -20pts)	Turma40 (T 40 35pts)	Turma22 (T 10 27pts)	Turma23 (T 15 32pts)	Turma29 (T 30 35pts)	Turma4 (P 20 5pts)
	14-15h										
	15-16h										
	16-17h	Turma3 (P 20 35pts)	Turma7 (P 20 35pts)	Turma2 (P 15 12pts)	Turma37 (T 60 15pts)	Turma14 (P 15 -2pts)	Turma41 (T 40 35pts)	Turma18 (T 10 7pts)	Turma17 (T 10 10pts)	Turma28 (T 30 15pts)	Turma8 (P 15 2pts)
	17-18h	--	--	--		--		--	--		Turma27 (T 20)

Fonte: Elaborada pelos próprios autores

CONCLUSÃO

O estudo apresentou o desenvolvimento e a avaliação de um sistema computacional para alocação automática de turmas em instituições de ensino, fundamentado em Algoritmos Genéticos e estruturado metodologicamente sob o enfoque da pesquisa-ação. A metodologia adotada permitiu alinhar a construção técnica do sistema às necessidades reais do contexto acadêmico, garantindo tanto relevância prática quanto rigor científico.

Os resultados experimentais evidenciaram diferenças marcantes entre as três estratégias de *crossover* implementadas. O modelo Elitismo mostrou-se superior na geração de soluções de alta qualidade, com convergência rápida e estável, sendo a abordagem mais equilibrada entre desempenho computacional e qualidade da alocação. O modelo Aleatório, embora promovesse diversidade, apresentou evolução lenta e irregular. Já o método Janela Deslizante destacou-se pelo desempenho computacional, sendo aproximadamente duas vezes mais rápido que o Aleatório, mas gerando soluções de qualidade inferior ao Elitismo, tornando-o adequado para cenários onde o tempo de processamento é um fator crítico.

Esses achados indicam que a escolha da técnica de *crossover* influencia diretamente a eficiência e a qualidade das soluções geradas pelo algoritmo genético. O modelo por Elitismo mostrou-se a alternativa mais equilibrada entre desempenho computacional e qualidade de alocação, sendo o sistema final de alocação de turmas foi implementado utilizando este modelo.

Em síntese, o sistema proposto confirmou o potencial dos Algoritmos Genéticos como ferramenta de otimização aplicada ao planejamento acadêmico, automatizando um processo tradicionalmente complexo e suscetível a erros humanos. Estudos futuros poderão explorar ajustes nos critérios de avaliação e novas combinações de operadores genéticos, visando ampliar a compactação dos horários e aprimorar a eficiência global do modelo em contextos institucionais diversos.

Como trabalhos futuros, sugere-se: (i) a investigação de funções de avaliação multicritério que balanceiam a qualidade individual da alocação com a compactação temporal global; (ii) a inclusão de restrições adicionais do contexto acadêmico, como preferências docentes e deslocamentos entre salas; e (iii) a validação do modelo em cenários de maior escala e em diferentes contextos institucionais.

REFERÊNCIAS

ÁVILA, S. L. **Otimização paramétrica com computação evolutiva**. 1.ed. Publicação do IFSC, 2020.

GOODFELLOW, I., BENGIO, Y., & COURVILLE, A. **Deep learning**. 1. ed. MIT Press, 2016.

LEWIN, K. **Action research and minority problems**. *Journal of Social Issues*, v.2, n.4, p.34-46, 1946. Disponível em: <https://doi.org/10.1111/j.1540-4560.1946.tb02295.x>. Acesso em: 03 out. 2025.

LINDEN, R. **Algoritmos genéticos**. 3. ed. Rio de Janeiro: Brasport, 2012.

RUSSELL, S. J., & NORVIG, P. **Artificial intelligence: A modern approach**. 4. ed. Pearson, 2020.

THIOLLENT, M. **Pesquisa-ação nas organizações**. 2. ed. São Paulo: Atlas, 2009.