

Designing a Draft for a Metaheuristic Curriculum Evaluation Model (MCEM) Based on the Examination of Various Metaheuristic Artificial Intelligence Optimization Applications

Volkan Duran^a  Gülay Ekici^b 

^a Assoc. Prof. Dr., Iğdır University, Iğdır, Türkiye, volkan.duran8@gmail.com

^b Prof. Dr., Gazi University, Ankara, Türkiye, gekici@gazi.edu.tr

ABSTRACT

This paper explores the integration of metaheuristic artificial intelligence (AI) optimization algorithms into the process of curriculum evaluation, proposing a novel approach that could enhance educational outcomes. A meta-synthesis of the existing literature on the application of AI optimization techniques—such as tabu search, simulated annealing, genetic algorithms, and ant colony optimization—in educational contexts was conducted. This study revealed a scarcity of direct applications of these algorithms in curriculum evaluation, thus identifying a gap in research and an opportunity for exploration. We proposed detailed models for adapting various metaheuristic optimization algorithms to assess curriculum components, including objectives, content, teaching methodologies, and assessment strategies. Our paper synthesizes insights from the literature review and suggests avenues for experimental studies to assess the effectiveness of AI optimization algorithms across diverse educational levels and curricula. Furthermore, we introduce a draft of the Metaheuristic Curriculum Evaluation Model (MCEM), synthesized from the reviewed optimization models and curriculum evaluation processes. This exploration into the integration of metaheuristic AI optimization algorithms within curriculum evaluation highlights a promising frontier in educational research. By detailing potential applications, addressing methodological rigor, and considering context-specific nuances, this paper lays the groundwork for future studies that could evaluate how curricula are developed, evaluated, and optimized from a different perspective.

Article Type
Research

Article Background
Received:
01.04.2024
Accepted:
08.07.2024

Keywords
Optimization
Algorithms,
Curriculum
Evaluation,
Artificial
Intelligence,
Meta-Synthesis

To cite this article: Duran, V. & Ekici, G. (2024). Designing a draft for a metaheuristic curriculum evaluation model (MCEM) based on the examination of various metaheuristic artificial intelligence optimization applications. *International Journal of Turkish Education Sciences*, 12 (2), 989-1055.
<https://doi.org/10.46778/goputeb.1463058>

Corresponding Author: Volkan Duran, e-mail: volkan.duran8@gmail.com

Introduction

The assessment in education has a profound history, tracing back to early examples such as the use of exams by Chinese officials around 2000 BCE to determine the qualifications of candidates for palace service and Socrates' oral assessments as part of the teaching process in Ancient Greece. However, in this field, the 20th century saw significant progress with Flexner's medical school evaluations, Tyler's distinction between measurement and evaluation, post-World War II federal initiatives, and education reforms triggered by Sputnik. By the 1960s and 1970s, assessment had been recognized as a professional discipline with developed standards (Yüksel, 2010).

Curriculum evaluation is defined as a process based on systematic data collection and analysis using empirical research methods. This process facilitates decision-making regarding various characteristics of a developed program, such as its accuracy, realism, adequacy, applicability, efficiency, effectiveness, impact, sustainability, success, and generalizability (Uşun, 2012). According to Richards (2003), this evaluation process is essential for observing the effectiveness of instructional methods and materials in a program, determining whether the program meets its goals, and monitoring students' progress in the learning process. Brown (1995) emphasized that curriculum evaluations are a continuous process of data collection, analysis, and synthesis for the ongoing improvement of the curriculum. Similarly, Demirel (2007) highlighted that systematic evaluation processes, which involve collecting data on the effectiveness of a curriculum, comparing and interpreting this data with criteria, and making decisions about the curriculum's effectiveness, can develop and enhance curricula.

Curriculum evaluation is a critical process for enhancing the effectiveness and efficiency of educational systems, featuring numerous classification types. Evaluation approaches classified by Uşun (2012) aim to determine whether the curriculum achieves its goals through various methodologies and models. These approaches include goal-oriented, systems-based, collaborative, participatory-oriented, adversary-oriented, qualitative, expertise-oriented, customer-oriented, postmodern, traditional, pragmatic, humanist, and academic evaluation approaches. Each offers different perspectives and focuses in the process of evaluating curriculum (Kandermir, 2016; Kocabatmaz, 2011; Özdemir, 2009; Uşun, 2012; Ünal, 2013). There is a scarcity of direct applications of metaheuristic algorithms in curriculum evaluation, highlighting a significant gap and opportunity for exploration. Existing literature lacks comprehensive models that adapt these algorithms to assess curriculum components systematically.

Curriculum evaluation models generally possess an algorithmic structure, with steps that must be followed in a particular order to systematically assess the program's effectiveness, excluding some approaches. These steps typically include: 1. Determining the evaluation approach, objectives, and criteria; 2. Data collection and analysis, 3. Interpreting findings and evaluating the program, 4. Making recommendations, 5. Implementing changes, 6. Documenting and reporting the process, 7. Repeating as necessary. The integration of metaheuristic AI optimization algorithms into curriculum evaluation represents a novel approach that has not been extensively explored in educational research. The proposed MCEM leverages the strengths of various metaheuristic algorithms to enhance the efficiency and effectiveness of curriculum evaluation processes, providing a structured yet flexible framework for continuous improvement. However, the existing literature reveals a scarcity of direct applications of these algorithms in curriculum evaluation, underscoring a significant gap and opportunity for further exploration.

Artificial intelligence optimization algorithms, defined by their capacity to solve complex problems through a systematic and iterative approach (Karaboga, 2018), offer a promising parallel to curriculum evaluation methods. Both domains aim to achieve specific objectives through structured processes, whether it be enhancing curriculum effectiveness or finding optimal solutions to problems. This intersection between education and AI underscores the potential for continuous improvement and adaptation in both fields, highlighting the significance of applying innovative strategies to complex problems. Furthermore, the application of metaheuristic methods, inspired by natural behaviors, in curriculum evaluation introduces a new horizon for exploring efficient and effective evaluation strategies (Blum & Roli, 2003; Chakraborty et al., 2021). This research seeks to critically analyze the literature on AI optimization algorithms in curriculum evaluation, aiming to identify their effectiveness, implementation challenges, and overall impact on educational curricula. By doing so, it aims to bridge knowledge gaps and address practical needs in the field, contributing to the ongoing development and excellence in educational assessment practices.

Methodology

This study employs a meta-synthesis approach to forge a new curriculum evaluation model underpinned by optimization algorithms. Meta-synthesis, a highly regarded qualitative research method, endeavors to provide a panoramic and elevated viewpoint by assimilating and interpreting findings from diverse qualitative studies. It is predicated on the principle of extracting, analyzing, and melding results from various qualitative investigations to forge a comprehensive understanding of a specific phenomenon through a holistic lens. As delineated by scholars such as Gülüm (2016) and Weed (2005), meta-synthesis transcends conventional qualitative analysis by seeking to interlace themes, concepts, and narratives from individual studies into new, overarching theoretical frameworks or interpretations that surpass the confines of singular inquiries.

The selection of articles for this synthesis was guided by a criterion sampling strategy, which was anchored in specific inclusion and exclusion criteria to ensure relevance and rigor. The inclusion criteria mandated that articles must (1) engage with AI optimization applications, (2) have a nexus to education, particularly concerning the evaluation of educational programs, and (3) be catalogued within recognized databases such as the Web of Science or the Turkish thesis center database (<https://tez.yok.gov.tr/>). Conversely, articles were excluded if they did not focus on AI optimization applications within the educational sector, were unrelated to program evaluation, remained unpublished, or were inaccessible through the designated databases.

The rationale behind selecting a meta-synthesis design for this research lies in its potential to synthesize extant qualitative studies into a more grandiose, nuanced understanding of how optimization algorithms can enhance curriculum development. This approach not only facilitates the integration of scattered insights from the field of educational technology but also allows for the generation of innovative frameworks or theories that could revolutionize curriculum evaluation and development practices. Through this process of aggregation and synthesis, the research aspires to contribute significantly to both the academic and practical realms of education by offering a novel curriculum evaluation model that leverages the cutting-edge capabilities of AI optimization.

Findings

In this section, we delve into various metaheuristic optimization algorithms, synthesizing their principles and methodologies with the process of curriculum evaluation. This synthesis aims to

harness the strengths of these algorithms to enhance the efficiency and effectiveness of evaluating educational curricula. These algorithms offer significant opportunities to make educational curricula more effective, efficient, and personalized. After conducting a needs analysis and determining the curriculum evaluation approach, we can explore examples emphasizing the creation of potential curriculum evaluation model populations.

Following the examination and synthesis of these metaheuristic optimization algorithms with curriculum evaluation methodologies, we propose a draft for a new curriculum evaluation model entitled the Metaheuristic Curriculum Evaluation Model (MCEM). The MCEM framework is designed to be adaptable, scalable, and capable of handling the dynamic nature of educational environments.

The Tabu Search Algorithm (TSA)

The Tabu Search Algorithm (TSA) is a meta-heuristic optimization algorithm developed in 1986 by F. Glover, inspired by the principles of human memory function. The core idea is to reach the optimal solution by transforming the initial solution space using methods such as swapping, adding, or removing elements. Its efficiency depends on the initial solution, the definition of the neighborhood, and the evaluation function (Arslan, 2018; Gürbüz, 2015). A curriculum evaluation algorithm based on the tabu algorithm can be outlined as follows:

1. Determining the Initial Solution: The first step in curriculum evaluation is to determine an initial solution, which could be the current state or design of the curriculum. This initial solution is stored in memory as both the current solution and the best solution.
2. Defining Moves: "Moves" must be defined for evaluating the curriculum, which may involve changing, adding, or removing design parameters or components of the curriculum. These changes should aim to improve the curriculum.
3. Tabu and Short-Term Memory: TSA's short-term memory facilitates the selection of the best move while generating a new solution and prevents the repetition of solutions. The tabu list records the unchosen neighboring solutions from the previous step, banning them for a while to avoid local optima.
4. Long-Term Memory: The best solution found throughout the algorithm is stored in long-term memory. This allows for all generated solutions to be compared with the best solution, enhancing overall performance.
5. Using the Evaluation Function: An evaluation function is used for curriculum evaluation, selecting the move with the highest evaluation score at each step. This measures and improves the program's performance.
6. Stopping Criteria: The algorithm's stopping criteria must be defined, such as reaching a number of iterations, not finding a better solution, or achieving a known optimal solution.

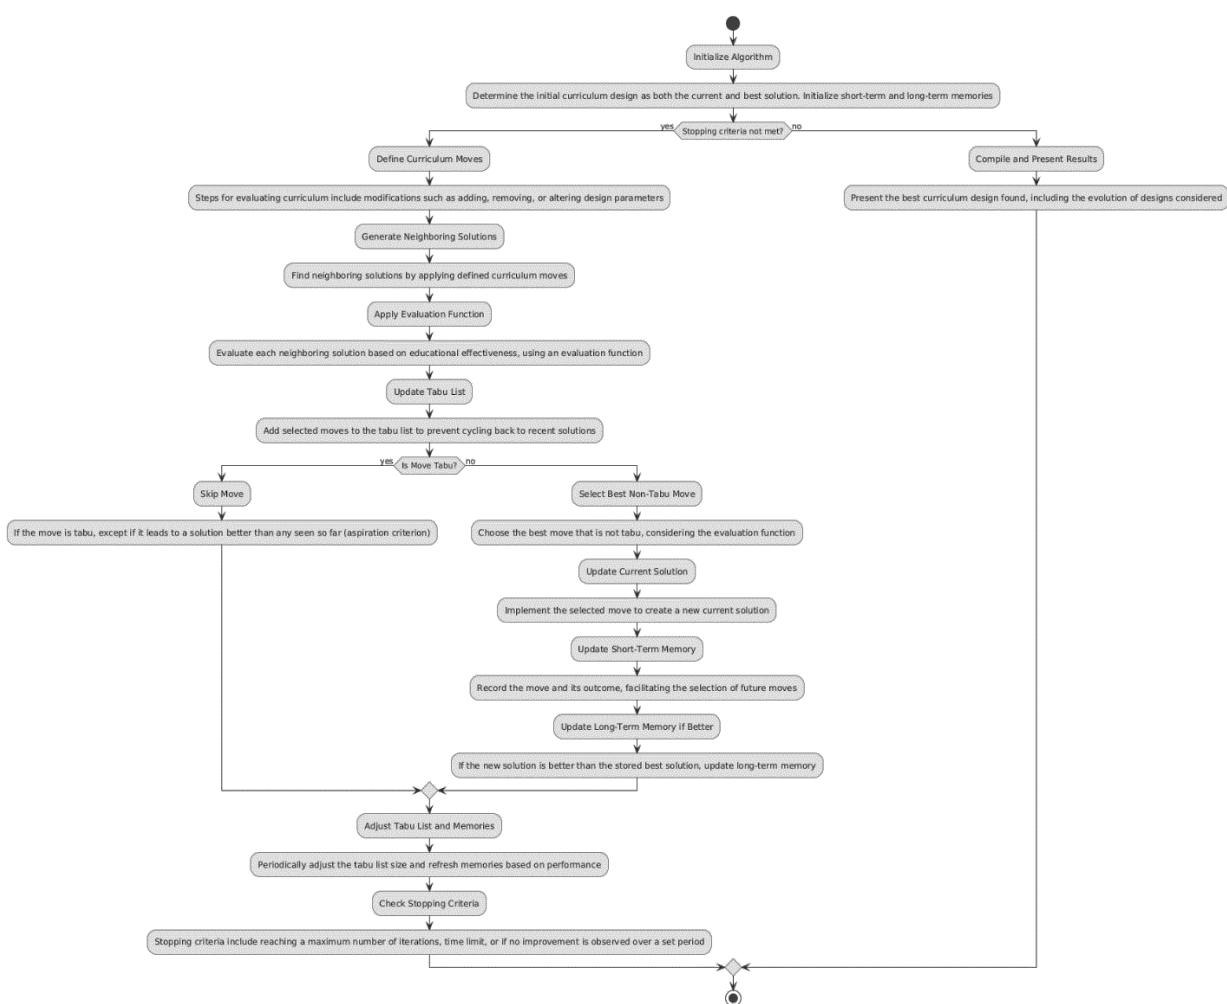
Thus, a curriculum evaluation algorithm based on TSA can be developed, utilizing it to optimize the design and performance of the curriculum with components like long and short-term memory, an evaluation function, and a tabu list tailored for this purpose.

To date, no thesis regarding the use of this algorithm has been found in the field of educational

sciences, according to Tezyök. However, a search on the Web of Science under the category of educational sciences yielded 14 studies. While some abstracts mention the application of these techniques to teaching (for example, presenting case studies to students), none directly address educational topics such as curriculum design, pedagogy, education policy, etc. This gap in the literature indicates an opportunity for future research to investigate how the Tabu Search Algorithm and similar optimization techniques can be systematically applied to broader educational challenges, potentially transforming curriculum evaluation and design processes to better meet the needs of students and educational institutions.

Figure 1

A Curriculum Evaluation Algorithm Based on the Tabu Search Algorithm in Education



The Annealing Algorithm

The Annealing Algorithm, an iterative approach aiming for continuous improvement of a solution in the solution space starting from a randomly selected initial point using an objective function, can be effectively adapted for curriculum evaluation. This algorithm generates new or neighboring solutions to enhance the value of a predefined objective function towards the best possible outcome (Gökçe et al., 2019). The algorithm's success also depends on accurately setting parameters such as the initial value of the control parameter T , the temperature decrease function, the number of iterations at each temperature stage, and the criteria for when the research will be terminated

(Karaboğa, 2018).

In this context, a curriculum evaluation model based on the Annealing Algorithm could be approached as follows (modified from Karaboğa, 2018):

Generating the Initial Solution: The initial goals, content, and objectives of the curriculum must be clearly defined. This forms the foundation of the evaluation process.

Defining the Neighbor Generation Mechanism: Fundamental components of the curriculum, such as objectives, scope, and target audience, should be outlined. The methods, tools, or approaches to be used for evaluating the curriculum should be determined. Measurable evaluation criteria and tools need to be identified.

Defining How the Neighborhood Will Be Explored: It should include determining the different components and implementation steps of the curriculum. Criteria and measurement methods to be used for evaluating the curriculum should be established. This includes the measurement tools used to assess the success and effectiveness of the curriculum.

Defining the Cooling Schedule: A plan for how the evaluation process will progress and how frequently evaluations will occur should be developed. This determines at which stages and how often the curriculum will be evaluated.

Setting the Initial Value of the Control Parameter Ts: At the start of the evaluation process, a focus point and initial value for the curriculum should be assigned. For instance, specific objectives can be set for the first stage or module of a curriculum.

Defining the Function to Decrease the Temperature: The methods, strategies, and processes to be used for the development and improvement of the curriculum should be outlined. This includes the stages of program development. Methods on how the program will be updated and improved over time can be included here.

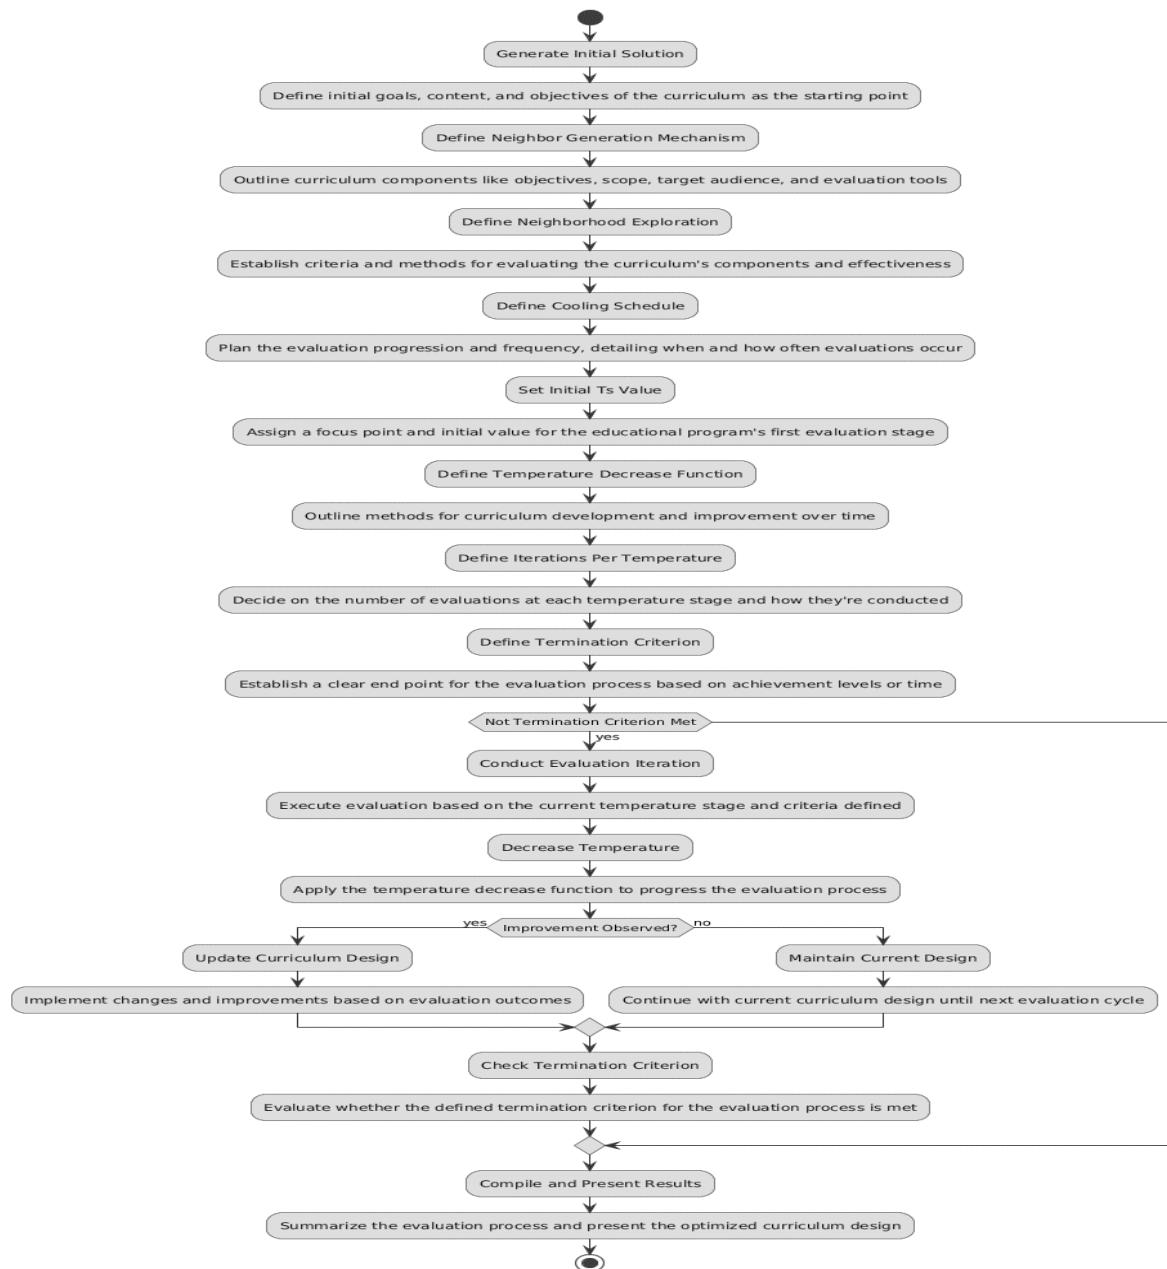
Determining the Number of Iterations to be Executed at Each Temperature Stage: It should be decided how many evaluations will be conducted at each stage of the curriculum evaluation and how these evaluations will be conducted. For example, student performance could be evaluated at every stage of a curriculum.

Defining a Criterion for Terminating the Research: A criterion that dictates when the evaluation process will end and when the success of the curriculum assessed should be defined. For example, the evaluation could end after a specific period, or once a certain level of achievement has been reached in the curriculum.

An Annealing Algorithm-based curriculum evaluation model could serve as a valuable tool in the optimization of educational materials, balancing the complexity of teaching materials with the comprehension levels of students. In the academic realm, no thesis has been found regarding the use of this algorithm in the field of educational sciences, according to <https://tez.yok.gov.tr/>. However, a search on the Web of Science under the keywords "education and teaching" yielded 38 studies, among which the study by Lee et al. (2021) was directly related to this topic. This indicates a potential for the application of Annealing Algorithm-based models in educational research, specifically in optimizing educational materials and programs. Such applications could revolutionize the way educational materials are evaluated and improved, offering a structured and

Figure 2.

Curriculum Evaluation Model Based on the Annealing Algorithm



The Genetic Algorithm

The Genetic Algorithm, inspired by natural selection and genetic mechanisms in nature, has been developed to generate and randomly modify solutions from one or more solution populations, as per David E. Tate. It also includes mechanisms for selecting individuals with better objective function values and culling solutions from populations. A key feature of genetic algorithms is conducting the search process from multiple solution points and utilizing probabilistic transformation rules. Among the basic concepts are genes, chromosomes, populations, fitness values, and functions. They have superior aspects such as working independently of the number of parameters, low risk of getting stuck in local optima, and easy parallelization (Yetkin, 2019). A

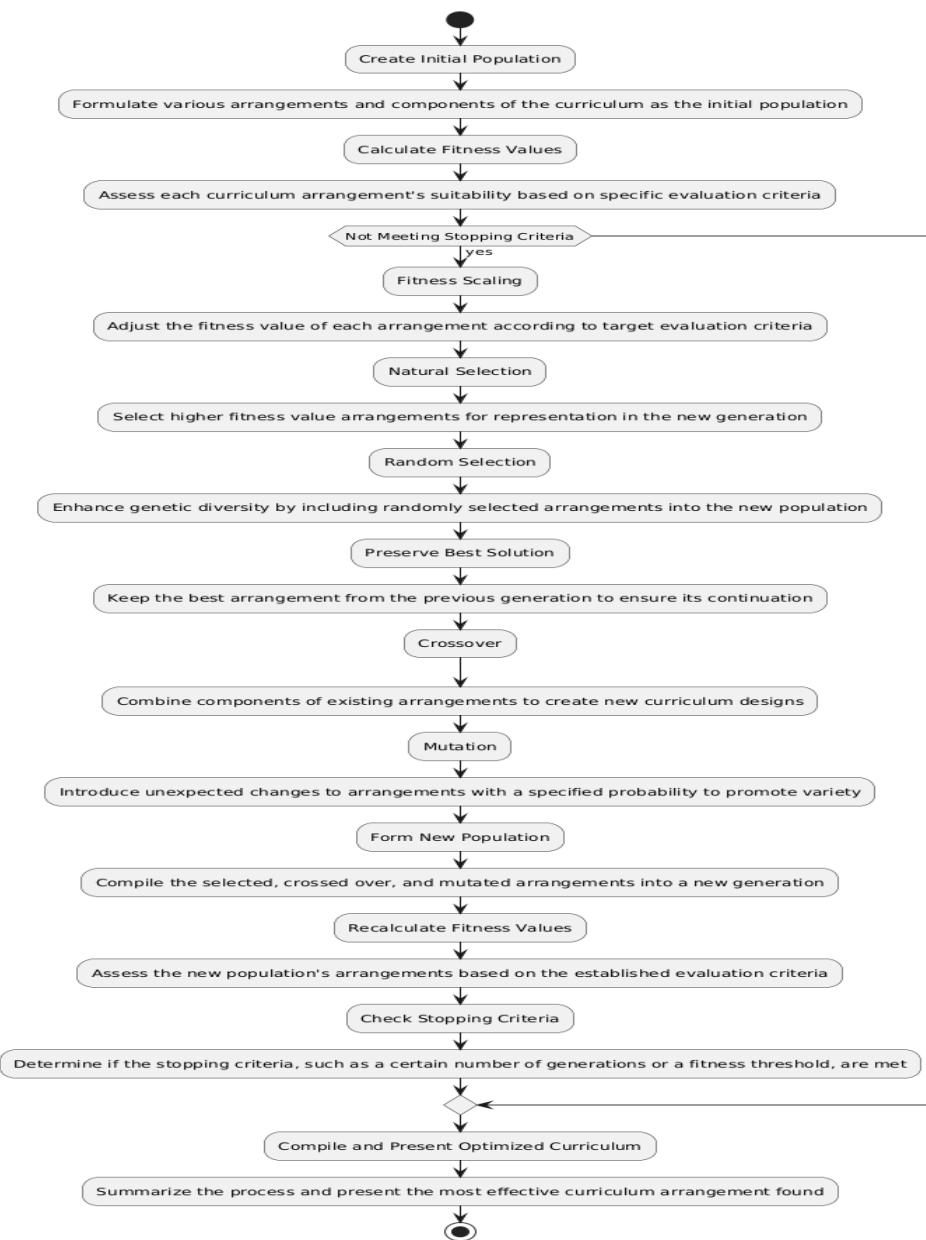
Curriculum Evaluation Model (Based on a Genetic Algorithm) can be outlined as follows (Figure 3):

1. Create Initial Population: Form the initial population containing different arrangements and components of the curriculum.
2. Calculate Fitness Values: Assess the suitability of each curriculum element's arrangement according to specific evaluation criteria.
3. Check Stopping Criteria: Perform the following steps until the stopping criterion is met:
 - a. Fitness Scaling: Scale the fitness value of each curriculum arrangement according to target values.
 - b. Natural Selection: Select curriculum arrangements with higher fitness values to be more represented in the new population.
 - c. Random Selection: Increase genetic diversity by subjecting part of the population to random selection instead of natural selection.
 - d. Preservation of the Best Solution: Preserve the best curriculum arrangement found in the previous population to ensure it is not lost.
 - e. Crossover: Produce two new arrangements from existing ones, combining different components.
 - f. Mutation: Allow unexpected changes by performing mutations in each curriculum arrangement with a certain probability.

This genetic algorithm-based model can be utilized to optimize the content, structure, and evaluation of curricula to enhance student success. In the field of educational sciences, Yetkin (2019) has prepared a master's thesis titled "Genetic Algorithm Approach to Estimate PISA Success," indicating the use of this algorithm in educational research. Yapıcı (2012) has prepared a master's thesis titled "Development of a timetabling software using genetic algorithm." In the Web of Science category, there are 546 studies involving genetic algorithms. Among these, studies directly related to education include the use of genetic algorithms and MATLAB to teach optimization algorithms and their applications to students (Cao & Wu, 1999), a course on optimum design using genetic algorithms for undergraduate students (Shyr, 2010), and an enhanced adaptive genetic algorithm developed for course scheduling in colleges and universities (Wang et al., 2019). While a few abstracts focus directly on educational topics, others seem more generally focused on proposing algorithms and optimization methods.

Figure 3

Curriculum Evaluation Model Based on Genetic Algorithm



The Ant Colony Algorithm

The Ant Colony Algorithm is based on the principle that ants leave pheromone trails, and the intensity of these trails guides the most efficient path to food. Paths with stronger pheromone signals are preferred, while less frequented paths diminish over time, revealing the shortest path. Initially tested in NP-hard optimization problems like the Traveling Salesman Problem, ACO has shown effective results (Can, 2022). The Ant Colony Algorithm (ACA), inspired by ants' ability to find the shortest path to a food source, is an optimization method where virtual ants move randomly from a starting point along various paths (Keser, 2020).

A curriculum evaluation model based on the Ant Colony Algorithm (ACA) can leverage the principles of collective intelligence to optimize curriculum structures, content, and delivery methods

to enhance educational outcomes:

Define the Curriculum Components (Initial Population)

Start by identifying the key components of the curriculum to be evaluated, such as learning objectives, content modules, teaching methodologies, and assessment strategies. Each component can be considered as a node similar to a food source or a nest in the ACA.

Set Evaluation Criteria (Objective Function)

Establish clear criteria for curriculum evaluation, akin to the food sources in an ant colony. These might include student engagement, learning outcomes, alignment with educational standards, and feedback from educators and learners.

Initialize Virtual Ants (Curriculum Evaluators)

Deploy virtual ants to explore the curriculum components. Each ant represents an evaluation agent tasked with assessing different arrangements and paths through the curriculum based on the set criteria.

Pheromone Trails (Evaluation Scores)

As ants explore various paths through the curriculum components, they leave behind a pheromone trail equivalent to evaluation scores. Higher pheromone levels indicate more effective or efficient curriculum pathways based on the evaluation criteria.

Pheromone Evaporation and Intensification

Incorporate mechanisms for pheromone evaporation, which simulates the diminishing influence of outdated or less effective curriculum elements over time. Conversely, paths that continually receive high scores see an intensification of pheromone levels, signaling their effectiveness.

Iterative Exploration and Optimization

Through multiple iterations, virtual ants explore, evaluate, and refine the curriculum paths. This iterative process allows for the dynamic adaptation and optimization of the curriculum based on real-time feedback and evolving educational goals.

Identify Optimal Curriculum Path

The optimal curriculum path is identified as the one with the strongest pheromone trail, indicating the highest collective evaluation scores across iterations. This path represents the most effective combination and sequencing of curriculum components.

Implement and Monitor

Implement the optimized curriculum and continue to monitor its effectiveness. Virtual ants can be redeployed periodically to ensure the curriculum remains responsive to changes in educational standards, technological advancements, and learner needs.

Continuous Improvement

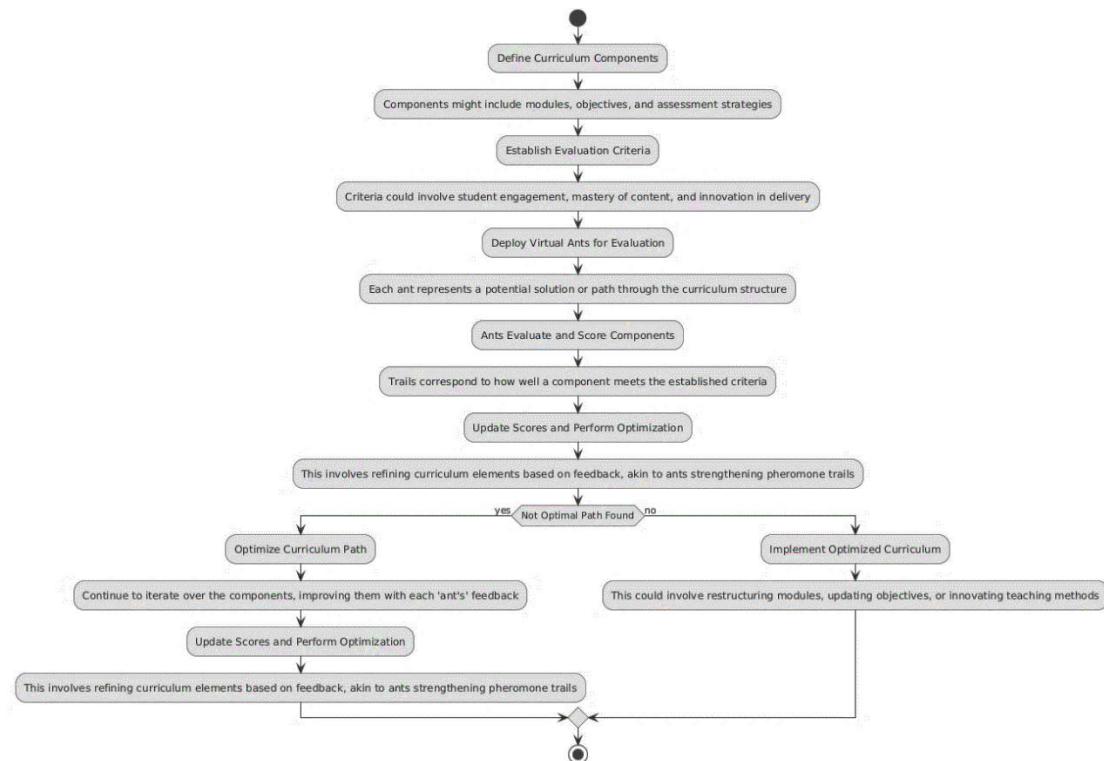
The ACA-based model facilitates continuous improvement by allowing for the easy addition of new

curriculum components, teaching methods, and technologies into the evaluation process. This ensures that the curriculum remains cutting-edge and aligned with best practices.

The Ant Colony Optimization algorithm can be a powerful tool to make curriculum evaluation more effective (Figure 4) and to enhance student success. No thesis on the use of this algorithm in the field of educational sciences was found at <https://tez.yok.gov.tr/>. However, 90 studies related to this topic under the category of educational sciences were found in Web of Science (Duan et al., 2015; Dwivedi et al., 2018; El Fazazi et al., 2019; Hoe, 2014; Jiang & Lu, 2022; Khamparia & Pandey, 2015; Kickmeier-Rust & Holzinger, 2019; Niknam & Thulasiraman, 2020; Sharma & Harkishan, 2022; Li, 2019; Madalina & Serbanescu, 2016; Rastegarmoghadam & Ziarati, 2017; Shen & Qi, 2020; Shukhman et al., 2018; Yepes et al., 2011; Vuong et al., 2018; Wong & Looi, 2012; Zilinskiene et al., 2012; Zan, 2019). These studies merge the fields of educational sciences and artificial intelligence, exploring how AI technologies can be utilized in education and how they can enhance learning experiences.

Figure 4

Curriculum Evaluation Model Based on Ant Colony Algorithm



The Artificial Immune Algorithm

The development of Artificial Immune Algorithms draws inspiration from certain characteristics of the natural immune system. Modeling the immune system as an algorithm could be crucial for intelligent systems, curricula, and curriculum evaluation approaches. The immune system is considered intelligent because it is equipped with a series of complex features and strategies, protecting the body against potential threats while offering various advantages. Here are some key characteristics that interpret why the immune system is considered an intelligent system (Karaboga, 2018; Yurttakal, 2014):

1. *Uniqueness:* Each individual's immune system is unique and necessary for recognizing

pathogens threatening the body and developing a customized defense against these pathogens. This provides the ability to uniquely protect against potential threats.

2. *Abnormal Detection*: The immune system can recognize foreign pathogens it has never encountered before and respond to them. This can be considered a sign of an intelligent system that constantly monitors the body for potential dangers and detects discrepancies.
3. *Reinforcement Learning*: The immune system can learn the structure of pathogens to develop a faster and more effective defense. This indicates intelligence in terms of the ability to benefit from learning and experiences.
4. *Diversification*: The immune system encourages the development of various antibodies and defense mechanisms against threats. This reflects the system's ability to adapt to many different scenarios.
5. *Memory*: The immune system retains the memory of pathogens it has encountered before and uses this information against future threats. This is a sign of intelligence that learns from previous experiences and responds better to future threats.
6. *Adaptability to External Environment*: The immune system stands out with its ability to quickly adapt to environmental changes. This reflects the capability to protect the body against instant threats.
7. *Distributed Detection*: The system's cells are distributed throughout the body without any central control system.
8. *Tolerance to Non-specific Detection (Noise tolerance)*: A complete definition of the pathogen is not required for reaction. This situation is tolerated by the immune system.

In this context, artificial immune system algorithms include:

1. Negative Selection Algorithm
2. Artificial Immune Network Algorithm
3. Dendritic Cell Algorithm
4. Clonal Selection Algorithm

Discrete immune network models, in particular, emerge as a frequently approached method for solving problems in pattern recognition, data analysis, machine learning, and optimization areas (De Castro & Timmis, 2003; Tanış, 2019).

Implementing these principles in curriculum evaluation could revolutionize the way curricula are developed, monitored, and improved by emulating the adaptive, resilient, and distributed characteristics of the natural immune system.

An Artificial Immune Algorithm inspired by the natural immune system's ability to adapt and respond to challenges offers a dynamic method for continuous curriculum improvement and alignment with student needs. Here's how such a model could be structured (Figure 5):

1. Create the Repertoire and Memory Pool:

- Construct a pool of objectives and content in N dimensions.
- Consider each objective and content as an antibody.
- Form a memory pool containing successful objectives and content from the curriculum.

2. Calculate Sensitivity for Objectives:

- Randomly select an educational objective or content.
- Calculate its sensitivity (effectiveness, accessibility, and applicability).

3. Select Antibodies (Objectives/Content) with the Best Sensitivity:

- Choose n objectives and content with the highest sensitivity.
- Clone these selected objectives and content based on criteria such as student success and engagement.

4. Cloning and Mutation:

- Produce clones of the selected best objectives and content.
- Apply mutations to the clone set to include variables such as learning methods and technological tools.
- Calculate the sensitivity of the clone set (adaptation to new and old educational methods).

5. Select Candidate Memory Cells:

- Select improved objectives and content after mutation.
- Nominate these objectives and content as new memory cells.

6. Replace Antibodies (Objectives/Content) with the Lowest Sensitivity:

- Replace low-performing objectives and content in the curriculum.
- Integrate new and more effective objectives and content into the program.

7. Process Evaluation and Update:

- Re-evaluate the program and make necessary updates.
- Periodically repeat the algorithm for continuous updating and development of objectives and content.

8. Analysis and Reporting of the Curriculum Effectiveness:

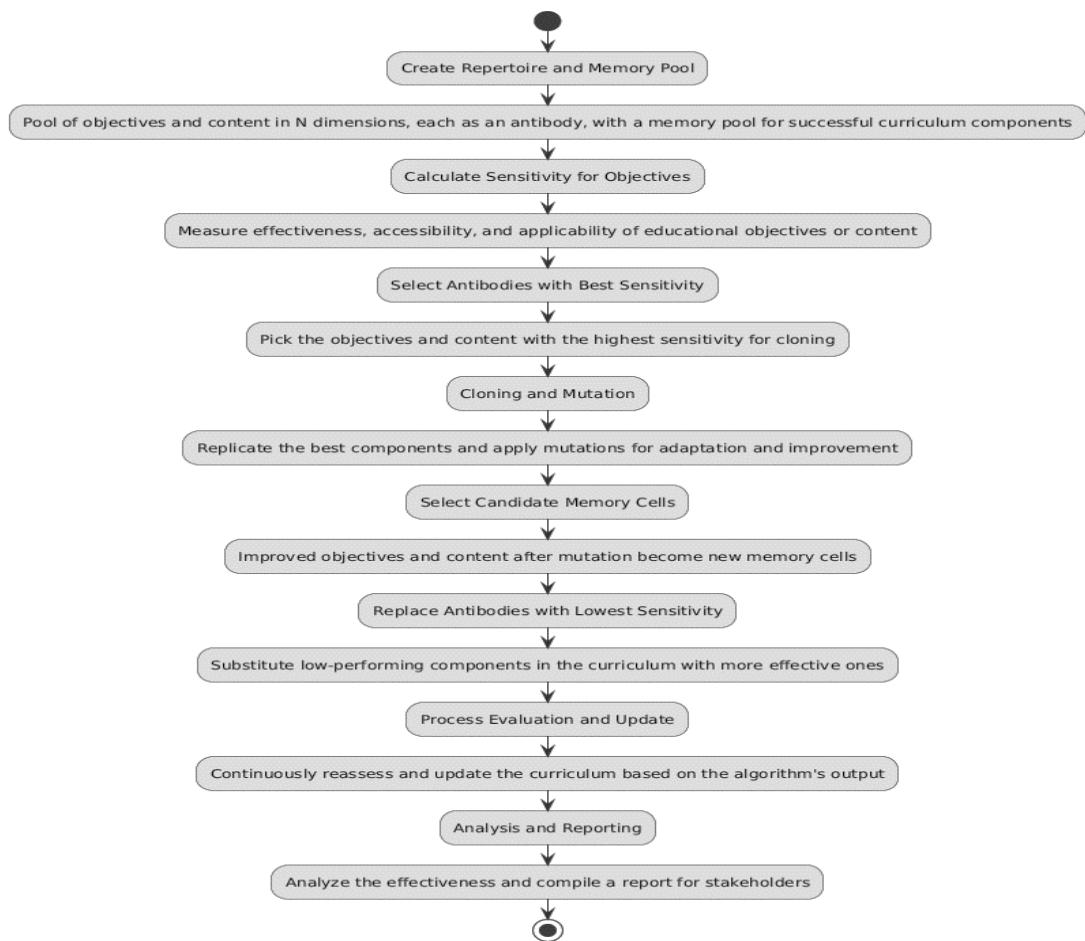
- Analyze the results of the algorithm.
- Prepare a comprehensive report on the effectiveness of the curriculum.

- Share the report with relevant stakeholders (teachers, administrators, students, parents).

In Tezyök, no thesis has been found regarding the use of this algorithm in the field of educational sciences. However, 31 studies related to this topic under the category of educational sciences were found on the Web of Science, with only two of them directly or indirectly addressing this topic (Hussain et al., 2019; Samigulina & Samigulina, 2016).

Figure 5.

Curriculum Evaluation Algorithm Based on Algorithm (a) and Clonal Selection Algorithm Flow Chart



The Teaching-Learning Based Optimization (TLBO) Algorithm

The Teaching-Learning Based Optimization (TLBO) algorithm, developed by Rao, Savsani, and Vakharia in 2011, is a population-based method that utilizes a population of solutions to reach a global solution. In this context, the population is considered as a group of students or a classroom of students. The TLBO process consists of two parts: the 'Teacher Phase' and the 'Student Phase.' The 'Teacher Phase' represents learning from the teacher, while the 'Student Phase' represents learning through interaction among students. The application of TLBO can be described step-by-step as follows (Mohammadi, 2022). The Curriculum Program Optimization using Teaching-Learning Based Optimization (CPO-TLBO) Algorithm can be presented as follows (Figure 6):

Step 1: Define the Optimization Problem and Initialize Parameters

Initiate optimization parameters such as the number of students (population size), the number of generations (iterations), the number of courses (number of design variables), and the limits of the courses (upper and lower limits). The optimization problem is defined as minimizing the function $f(X)$, where X is considered a vector of courses, and each course must be within specified limits.

Step 2: Initialize Population

Create a random population based on the population size and the number of courses. In CPO-TLBO, the population size represents the number of students, and the design variables represent the courses offered.

Step 3: Teacher Phase

Calculate the column-wise average for the population. This will give the average grades for a specific course. The best solution for that iteration is to take on the role of the teacher and try to improve the average grades of the other students (solutions).

Step 4: Student Phase

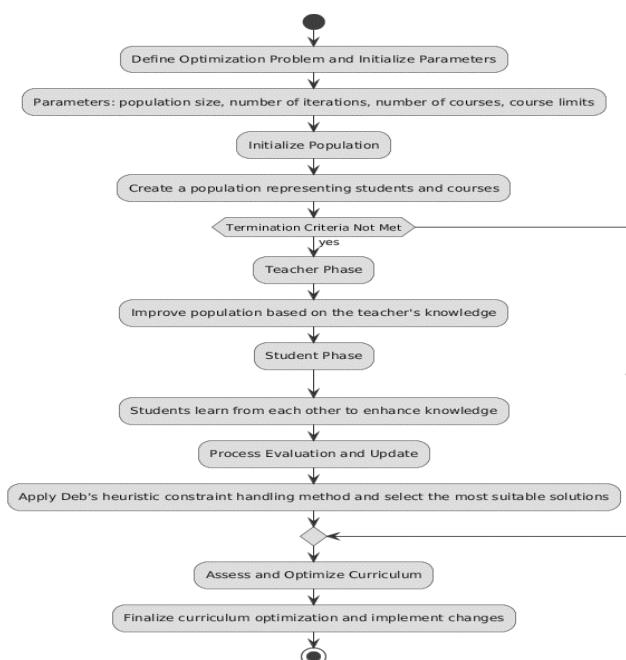
Students interact with each other to enhance their knowledge and skills. In this phase, two randomly selected solutions are compared, and they learn from each other to improve themselves.

Step 5: Termination Criterion

The process ends when the maximum number of generations is reached, or other termination criteria are met.

Figure 6

The Teaching-Learning Based Optimization (TLBO) Algorithm



No thesis related to the use of this algorithm in the field of educational sciences has been found in Tezyök. However, among 10 studies related to this topic under the category of educational sciences in Web of Science, one study has been identified as directly related to education (Arashpour et al., 2023). This indicates that while the application of the Teaching-Learning Based Optimization (TLBO) algorithm in educational sciences may still be emerging, there is growing interest and potential for its use in optimizing curriculums and improving teaching and learning processes. The study by Arashpour et al., 2023, could provide valuable insights into how the TLBO algorithm can be applied in educational settings, potentially offering innovative solutions to enhancing curriculum design, student engagement, and overall educational outcomes.

The Differential Evolution (DE) Algorithm

The Differential Evolution (DE) Algorithm, based on the differences between solution vectors, is specifically developed for numerical optimization problems. This algorithm is a genetic algorithm-based, population-based heuristic global optimization technique (Dumlu, 2023). A curriculum evaluation algorithm grounded on the Differential Evolution (DE) Algorithm can be utilized to enhance the curriculum in terms of objectives, content, teaching scenarios, and evaluation dimensions. Below is a model adapted for curriculum evaluation using this algorithm (Figure 7):

1. Initialization

- Define Optimization Problem: Set the objectives, content, teaching scenarios, and evaluation methods of the curriculum.
- Create Initial Population: Generate NP random curriculum arrangements (solutions). Each arrangement represents the curriculum's objectives, content, teaching scenarios, and evaluation strategies.

2. Mutation

- Random Selection: For each program arrangement (X_i), randomly select three different curriculum arrangements (X_{r1} , X_{r2} , X_{r3}) from the population.
- Generate Mutant Curriculum Arrangement: Use the selected three curriculum arrangements to calculate a new mutant program arrangement (V_i). This process involves combining different curriculum elements (objectives, content, etc.).

3. Crossover

- Obtain Temporary Solution: The characteristics of the mutant program arrangement are altered with the current program arrangement's characteristics with a certain probability (CR) to obtain a new temporary curriculum arrangement (U_i). This implies changes to the program's objectives, content, or evaluation methods.

4. Selection

- Evaluation and Comparison: The temporary curriculum arrangement is compared with the current program arrangement according to predefined evaluation criteria. The better arrangement is determined and carried over to the next generation.

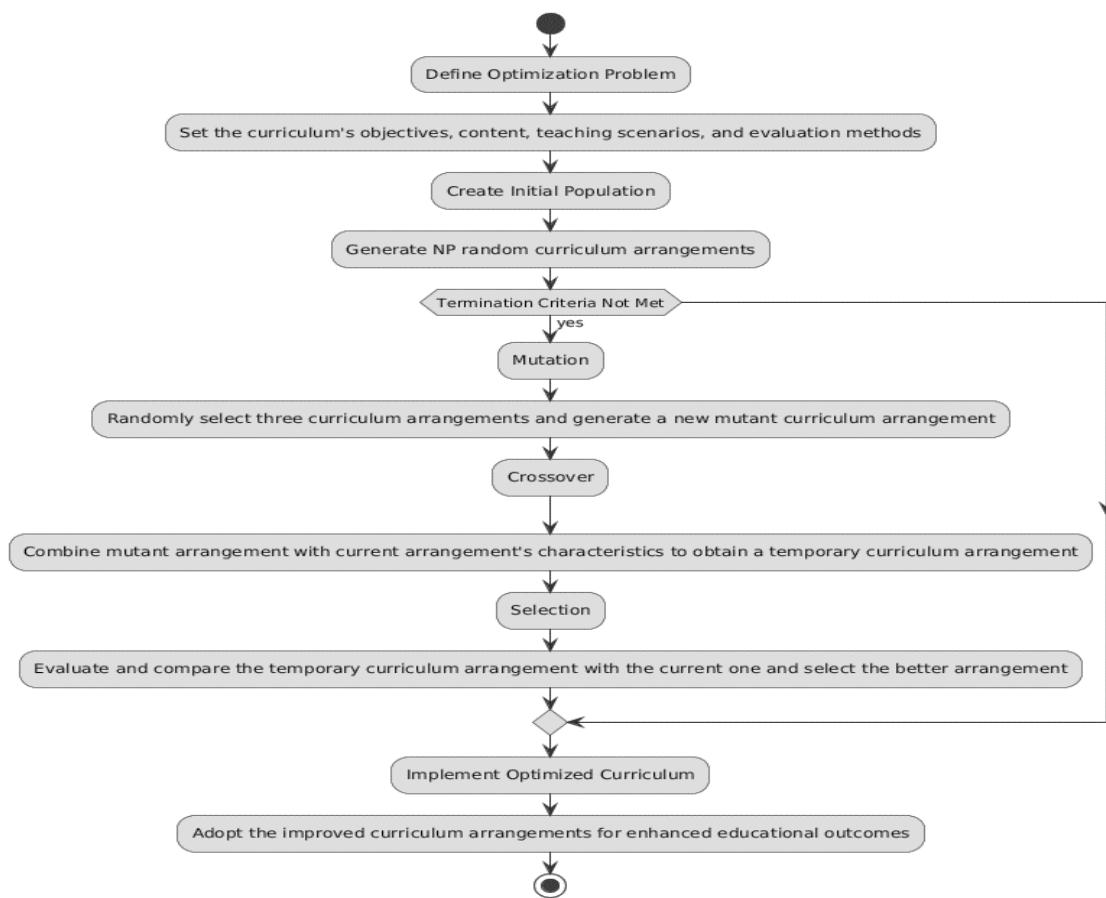
5. Termination Criterion

- Iteration Repetition: Repeat the mutation, crossover, and selection steps until a defined termination criterion is met. This could be reaching a certain number of iterations, achieving a certain level of improvement, or another termination condition.

-

Figure 7

The Process of Evaluating Curriculum Using the Differential Evolution Algorithm



In Tezyök, no thesis has been found regarding the use of this algorithm in the field of educational sciences. However, in Web of Science, 30 studies related to this keyword in the field of educational sciences have been identified, but only three of them are directly related to the application of this algorithm in educational sciences (Liu et al., 2017; Wang et al., 2009a-b).

Particle Swarm Optimization (PSO)

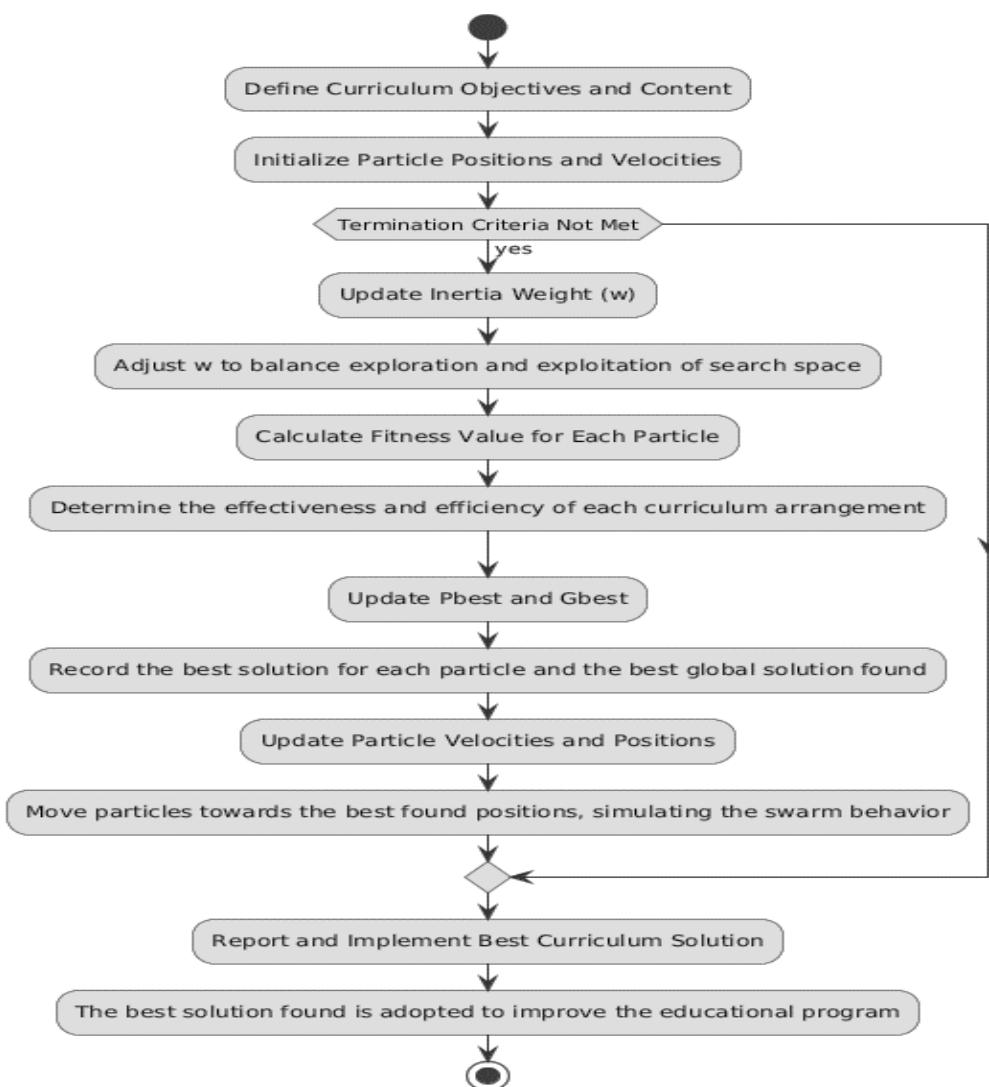
Particle Swarm Optimization (PSO) is inspired by the behavior of a particle swarm, where each particle has its position and velocity, remembers its best position, and shares information with each other. This approach is based on behavioral modeling and differs from genetic algorithms by drawing inspiration from the behaviors of living beings instead of evolutionary principles (Şahin, 2019). For curriculum evaluation using the PSO algorithm, the following model can be proposed

(Gülcü, 2017) (Figure 8).

A thesis by Aram (2012) on this topic exists in Tezyök, demonstrating early exploration of applying PSO in educational settings. Moreover, among 77 studies in the field of education found in the Web of Science journal, four directly relate to this topic (Alhunitah & Menai, 2016; Rashid & Ahmad, 2016; Zervoudakis et al., 2020). These studies underscore the potential and growing interest in leveraging PSO to optimize and evaluate curricula.

Figure 8

A Curriculum Evaluation Model Based on Particle Swarm Optimization (PSO) within the Educational Field



The Artificial Bee Colony Algorithm

The Artificial Bee Colony Algorithm is inspired by the intelligent behaviors exhibited by honey bee colonies in searching for rich nectar food sources. Karaboga (2005) developed this algorithm inspired by the natural food-foraging processes of bees. The algorithm mimics the behaviors of bees in finding food and sharing information. Employed worker bees bring food sources back to the hive and communicate this information to other bees through a dance, which represents the location and

quality of the food source (Karaboga, 2018). Applying the Artificial Bee Colony Algorithm for curriculum evaluation in education, a process model can be developed as follows (Figure 9):

1. Generation of Initial Food Source Regions:

- Create various "food sources" representing the objectives, contents, teaching methods, and assessment techniques of the curriculum.

2. Sending Employed Bees:

- Each "employed bee" (curriculum arrangement) evaluates a specific food source (curriculum component).

3. Calculation of Probability Values:

- Based on the information collected by the employed bees (success of the program), calculate a probability value for each food source.

4. Selection of Onlooker Bees:

- "Onlooker Bees" (evaluation teams) select the best food source (curriculum component) based on probability values.

5. Renewal of Abandoned Sources:

- Abandon low-performing curriculum components and replace them with new "scout bees" (new educational ideas or methods).

6. Termination Criterion:

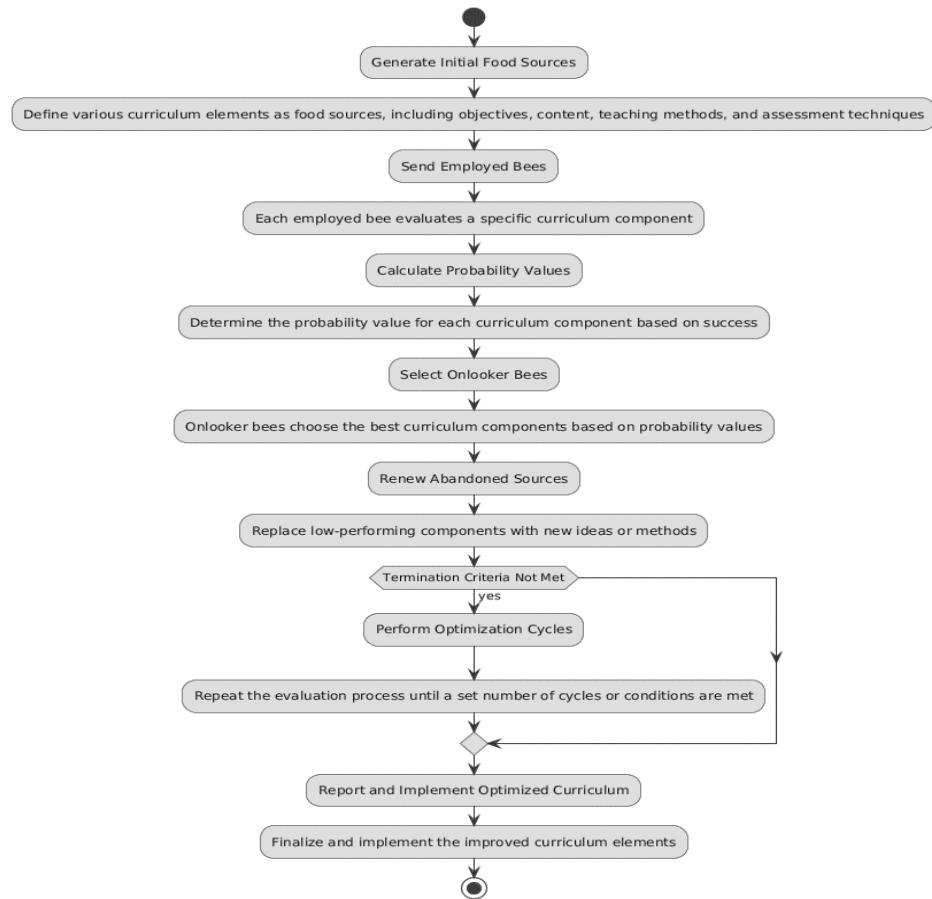
- End the process when a set number of cycles is reached, or other termination conditions are met.

7. Reporting Final Food Positions:

- Report and implement the final state of the optimized curriculum components.

This process provides a framework for the continuous improvement and adaptation of the curriculum. No thesis on the use of this algorithm in the field of educational sciences has been found at <https://tez.yok.gov.tr/>. However, in Web of Science, under the educational sciences category, one study related to the use of this algorithm in education has been identified (Alhunitah & Menai, 2016). This showcases the potential application of the Artificial Bee Colony Algorithm in enhancing and optimizing curriculums through a collaborative and iterative process.

Figure 9

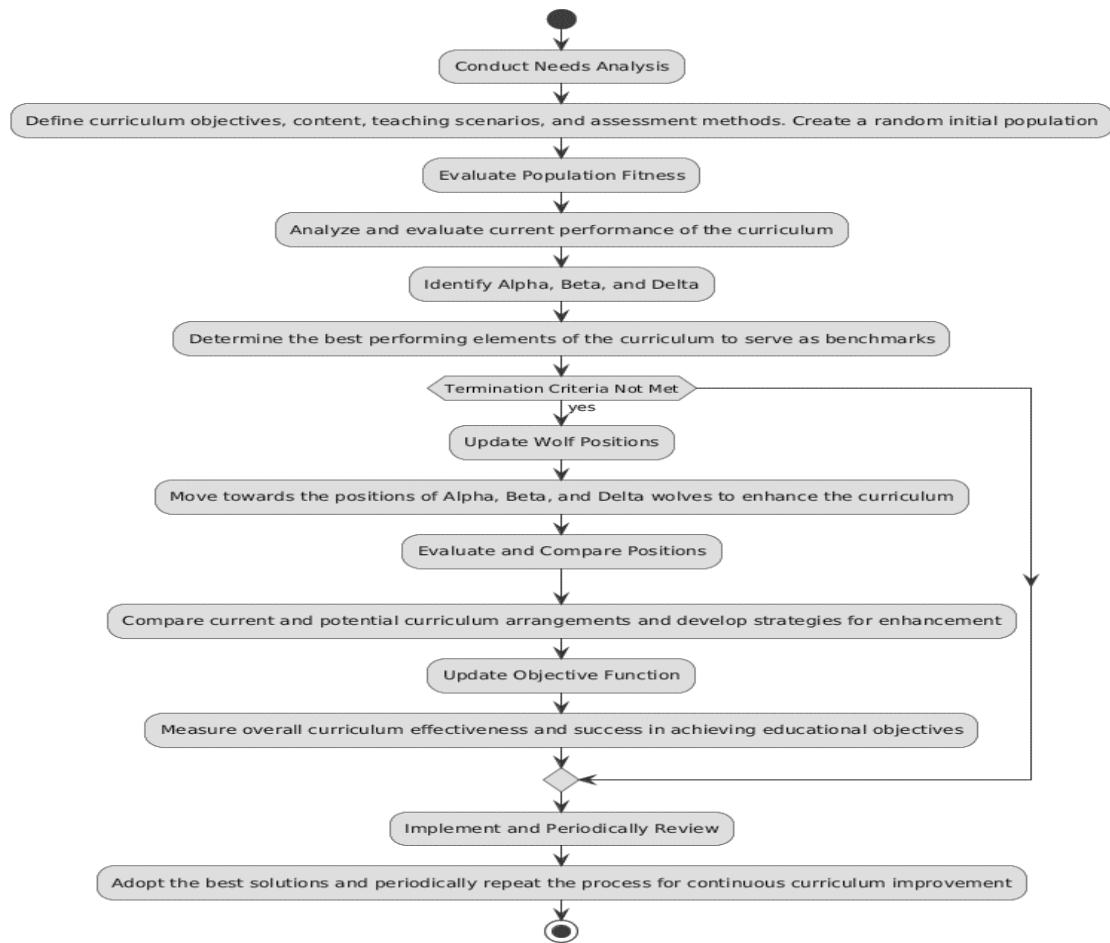
Curriculum Evaluation Using Artificial Bee Colony Algorithm**The Grey Wolf Optimizer (GWO)**

The Grey Wolf Optimizer (GWO) is an optimization algorithm developed based on the social hierarchy and hunting behaviors of grey wolf packs, featuring four levels of hierarchy within the pack: alpha, beta, delta, and omega, where the alpha is the leader. The hunting behavior includes tracking, encircling, harassing, and finally attacking the prey (Şahin, 2019). Applying the Grey Wolf Optimization Algorithm for curriculum evaluation, a process model can be constructed as follows, considering the key elements (Figure 10): 1. Initialization Phase, 2. Evaluate Population Fitness, 3. Update the Positions of Alpha, Beta, and Delta Wolves, 4. Evaluate the Relationship Between the Old and New Positions of the Wolves; 5. Objective Function, 6. Termination Criterion

No thesis on the use of this algorithm in the field of educational sciences has been found in <https://tez.yok.gov.tr/>, nor has any study related to the use of this algorithm in education been identified in Web of Science.

Figure 10

Curriculum Evaluation Model Based on the Grey Wolf Optimization (GWO)



Proposed Model: The Metaheuristic Curriculum Evaluation Model (MCEM)

Based on the comprehensive analysis of various metaheuristic artificial intelligence (AI) optimization algorithms and their potential applications within curriculum evaluation processes, we propose a novel Metaheuristic Curriculum Evaluation Model (MCEM). This model aims to leverage the strengths of different AI optimization algorithms to enhance curriculum design, content, delivery, and assessment within educational programs. MCEM is designed to be flexible, adaptive, and efficient, capable of addressing the dynamic needs of modern education systems. The proposed model incorporates the following key components:

1. Model Initialization

- **Needs Analysis:** Conduct a thorough needs analysis to identify the goals and objectives of the curriculum, considering the specific requirements of the target student population.
- **Objective Setting:** Clearly define the objectives that the curriculum aims to achieve, aligning them with educational standards and student needs.
- **Algorithm Selection:** Choose the most suitable metaheuristic AI optimization algorithms based on the curriculum's specific needs and objectives. For example, the

Genetic Algorithm might be ideal for optimizing course sequences, while the Ant Colony Algorithm could enhance resource allocation strategies.

2. Curriculum Component Optimization

- Curriculum Mapping: Develop a comprehensive map of the curriculum, including learning objectives, course content, teaching methodologies, and assessment techniques.
- Algorithm Application: Apply the selected metaheuristic algorithms to optimize each component of the curriculum map. This step involves iterative processes of exploration, evaluation, and adaptation based on the algorithms' feedback.
- Component Integration: Integrate the optimized components into a coherent curriculum structure, ensuring that all elements work synergistically to achieve the defined educational goals.

3. Data Collection and Analysis

- Performance Metrics: Establish performance metrics to evaluate the effectiveness of the curriculum, such as student engagement, learning outcomes, and feedback from educators and learners.
- Data Processing: Utilize AI algorithms to process and analyze collected data, identifying patterns, strengths, weaknesses, and opportunities for further improvement.

4. Iterative Improvement and Adaptation

- Model Evaluation: Regularly evaluate the curriculum using the defined performance metrics and AI-processed data analysis.
- Feedback Loop: Create a feedback loop where insights from the evaluation phase inform further optimization of the curriculum components, ensuring continuous improvement.
- Adaptation: Allow for dynamic adaptation of the curriculum based on evolving educational goals, technological advancements, and learner feedback.

5. Implementation and Monitoring

- Rollout: Implement the optimized curriculum within the target educational program or institution.
- Continuous Monitoring: Continuously monitor the curriculum's performance using AI algorithms, adjusting components as necessary to maintain or enhance effectiveness.

6. Stakeholder Engagement

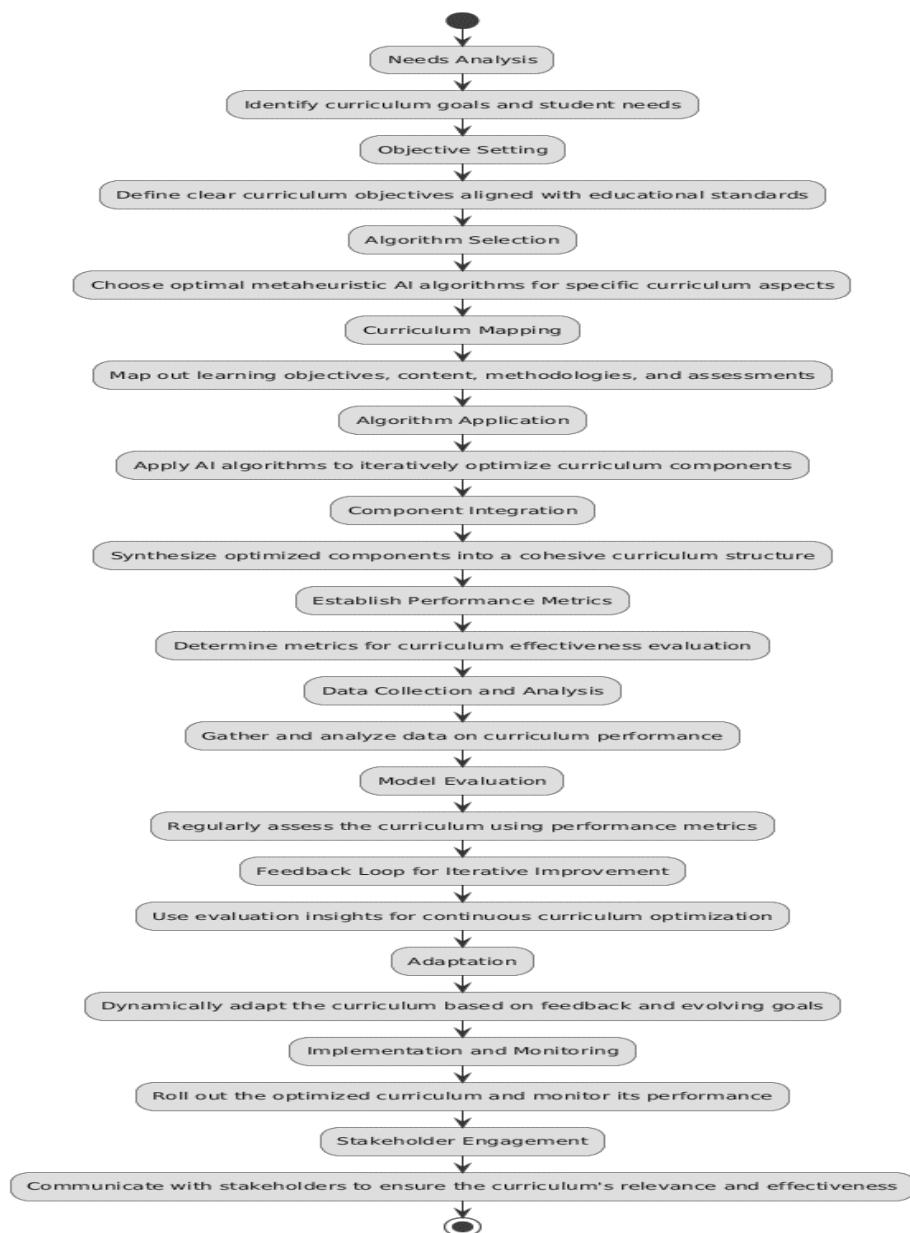
- Communication: Regularly communicate with all stakeholders, including educators, students, administrators, and parents, to gather feedback and ensure the curriculum

meets their needs and expectations.

- Collaboration: Encourage collaboration among stakeholders to foster a sense of ownership and commitment to the curriculum's success.

Figure 11

The Metaheuristic Curriculum Evaluation Model (MCEM)



The Metaheuristic Curriculum Evaluation Model (MCEM) represents a novel approach to curriculum development and evaluation, harnessing the power of metaheuristic AI optimization algorithms to create educational programs that are not only effective and efficient but also highly adaptable to the needs of both students and educators. By integrating these algorithms into the curriculum evaluation process, educational institutions can significantly enhance the quality of education they provide, preparing students more effectively for the challenges of the 21st century.

Implementation Plan for Integrating the Metaheuristic Curriculum Evaluation Model (MCEM) into Education Systems

Phase 1: Planning and Preparation

1.1 Needs Assessment

- Objective: Identify the specific needs and goals.
- Activities:
 - Conduct surveys and focus group discussions with stakeholders (educators, administrators, students, and parents).
 - Review current curriculum and evaluation practices.
 - Identify gaps and areas for improvement.

1.2 Stakeholder Engagement

- Objective: Ensure buy-in and support from all stakeholders.
- Activities:
 - Organize informational meetings and workshops to explain the benefits and workings of the MCEM.
 - Create a project team that includes representatives from all stakeholder groups.

Phase 2: Design and Development

2.1 Customization of the MCEM

- Objective: Tailor the MCEM to meet the specific needs identified in the needs assessment.
- Activities:
 - Select appropriate metaheuristic algorithms based on the curriculum components to be evaluated.
 - Develop a comprehensive curriculum map including learning objectives, course content, teaching methodologies, and assessment techniques.

2.2 Algorithm Development and Integration

- Objective: Integrate selected metaheuristic algorithms into the curriculum evaluation process.
- Activities:
 - Develop or adapt software tools to apply the chosen algorithms.
 - Test the algorithms on sample curriculum data to ensure functionality.

Phase 3: Training and Capacity Building

3.1 Training Programs for Educators and Administrators

- Objective: Equip educators and administrators with the skills and knowledge to effectively use the MCEM.
- Activities:
 - Develop training materials and manuals.
 - Conduct hands-on training workshops covering:
 - The principles and benefits of the MCEM.
 - How to input data and interpret algorithm outputs.
 - How to use the software tools developed in Phase 2.
 - Provide follow-up support and refresher courses.

3.2 Creation of Support Structures

- Objective: Ensure ongoing support and continuous improvement.
- Activities:
 - Establish a helpdesk or support team to assist with technical issues.

- Create online forums or communities of practice for sharing experiences and solutions.

Phase 4: Pilot Testing and Refinement

4.1 Pilot Implementation

- Objective: Test the MCEM in a controlled environment to identify potential issues.
- Activities:
 - Select pilot schools or programs to implement the MCEM.
 - Collect and analyze data from the pilot implementation.
 - Gather feedback from participants.

4.2 Refinement

- Objective: Improve the MCEM based on pilot results.
- Activities:
 - Analyze feedback and performance data.
 - Make necessary adjustments to the algorithms, processes, and training materials.
 - Re-test as needed.

Phase 5: Full-Scale Implementation

5.1 Rollout Plan

- Objective: Implement the MCEM across the entire education system.
- Activities:
 - Develop a detailed rollout plan, including timelines and responsibilities.
 - Scale up training and support to cover all schools or programs.
 - Monitor implementation progress and address issues promptly.

5.2 Continuous Monitoring and Improvement

- Objective: Ensure the MCEM remains effective and relevant.
- Activities:
 - Establish regular review and evaluation processes.
 - Collect ongoing feedback from educators, administrators, and students.
 - Update the MCEM as needed to reflect changes in educational standards, technologies, and best practices.

Phase 6: Evaluation and Reporting

6.1 Evaluation

- Objective: Assess the impact of the MCEM on curriculum effectiveness and educational outcomes.
- Activities:
 - Conduct formal evaluations at regular intervals.
 - Compare educational outcomes before and after the implementation of the MCEM.
 - Use performance metrics established during the planning phase.

6.2 Reporting

- Objective: Share findings with stakeholders and the broader educational community.
- Activities:
 - Prepare comprehensive reports detailing the implementation process, outcomes, and lessons learned.
 - Present findings at conferences, workshops, and through academic publications.
 - Provide recommendations for further research and practice.

Summary Timeline

Phase

- Planning and Preparation
- Design and Development
- Training and Capacity Building
- Pilot Testing and Refinement
- Full-Scale Implementation
- Evaluation and Reporting

Resources Needed

1. Human Resources:
 - Project team (educators, administrators, IT specialists).
 - Training facilitators.
 - Technical support staff.
2. Financial Resources:
 - Budget for software development and licenses.
 - Training and workshop costs.
 - Ongoing support and evaluation expenses.
3. Technological Resources:
 - Software tools for algorithm integration and data analysis.
 - Hardware for data processing and storage.
 - Online platforms for training and support.

By following this implementation plan, educational researchers and institutions can effectively integrate the MCEM into their existing systems, leading to improved curriculum evaluation and enhanced educational outcomes.

Ethical Framework for the Integration of the Metaheuristic Curriculum Evaluation Model (MCEM)

Integrating the Metaheuristic Curriculum Evaluation Model (MCEM) into educational systems involves various ethical considerations. Addressing these issues is crucial to ensure the responsible and equitable implementation of AI-driven evaluation methods. This framework outlines the ethical principles and measures to ensure confidentiality, reduce bias, and maintain transparency in the use of the MCEM.

Ethical Principles

1. Confidentiality and Privacy:
 - Protecting the privacy of all individuals involved in the evaluation process, including students, educators, and administrators.
 - Ensuring that personal data is collected, stored, and processed securely.
2. Fairness and Equity:
 - Ensuring that the MCEM does not introduce or perpetuate biases that could disadvantage any group of individuals.
 - Promoting equitable access to the benefits of the MCEM across all educational settings.
3. Transparency and Accountability:
 - Providing clear and understandable information about how the MCEM operates and the rationale behind its recommendations.

- Establishing mechanisms for accountability to address any concerns or grievances related to the MCEM's implementation.

Measures to Ensure Confidentiality

1. Data Anonymization:
 - Anonymize all personal data used in the MCEM to prevent the identification of individuals.
 - Remove or obscure any identifiers in data sets used for training and evaluation.
2. Secure Data Storage and Transmission:
 - Implement robust encryption methods for storing and transmitting data.
 - Use secure servers and databases with restricted access to authorized personnel only.
3. Data Access Controls:
 - Define and enforce strict access controls to ensure that only authorized individuals can access sensitive data.
 - Regularly audit access logs to monitor and manage data access.

Measures to Reduce Bias

1. Diverse Data Sets:
 - Ensure that the data used to train and evaluate the MCEM is representative of the diverse population it serves.
 - Include data from various demographic groups to prevent biases related to race, gender, socioeconomic status, etc.
2. Bias Detection and Mitigation:
 - Regularly test the MCEM for biases in its recommendations and performance.
 - Implement bias detection algorithms and corrective measures to address any identified biases.
3. Inclusive Design and Development:
 - Involve diverse stakeholders, including educators, students, and experts in ethics and social justice, in the design and development process.
 - Conduct impact assessments to understand how different groups might be affected by the MCEM.

Measures to Ensure Transparency

1. Clear Documentation:
 - Provide comprehensive documentation of the MCEM's algorithms, data sources, and decision-making processes.
 - Make this documentation accessible to all stakeholders.
2. Explainability:
 - Develop tools and interfaces that allow users to understand how the MCEM arrives at its recommendations.
 - Offer explanations that are understandable to non-experts, including educators and administrators.
3. Regular Reporting and Communication:
 - Establish regular reporting mechanisms to communicate the performance and impact of the MCEM to stakeholders.
 - Create channels for feedback and dialogue to address concerns and improve the model continuously.

Accountability Measures

1. Ethics Oversight Committee:
 - Establish an independent ethics oversight committee to monitor the implementation and operation of the MCEM.
 - The committee should include members from diverse backgrounds, including ethics experts, educators, and community representatives.
2. Grievance Mechanism:
 - Develop a clear and accessible process for stakeholders to raise concerns or complaints about the MCEM.
 - Ensure that grievances are addressed promptly and fairly.
3. Regular Audits and Evaluations:
 - Conduct regular audits of the MCEM's performance and adherence to ethical standards.
 - Use external evaluators to provide an unbiased assessment of the model's impact and ethical compliance.

Implementing the MCEM in educational systems requires a strong commitment to ethical principles. By ensuring confidentiality, reducing bias, and maintaining transparency, we can create a fair and trustworthy evaluation model that benefits all stakeholders. Adhering to this ethical framework will help build trust, promote equity, and achieve the intended educational outcomes through the responsible use of AI-driven curriculum evaluation.

Stakeholder Participation in the Implementation of MCEM

Stakeholder participation is essential for the successful implementation and continuous improvement of the Metaheuristic Curriculum Evaluation Model (MCEM). Involving stakeholders such as educators, administrators, students, parents, and community members ensures that the MCEM is aligned with the needs and expectations of those it serves. This section details how stakeholders will be involved in the implementation and continuous improvement cycle and how their feedback will be received and evaluated.

Phases of Stakeholder Involvement

Phase 1: Planning and Preparation

1. Stakeholder Identification and Engagement:
 - Activity: Identify all relevant stakeholders, including educators, administrators, students, parents, and community members.
 - Method: Conduct meetings and workshops to introduce the MCEM and its objectives.
 - Outcome: Build a diverse project team representing all stakeholder groups.
2. Needs Assessment:
 - Activity: Engage stakeholders in identifying the specific needs and goals of the curriculum evaluation.
 - Method: Use surveys, focus groups, and interviews to gather input.
 - Outcome: Develop a comprehensive needs assessment report reflecting stakeholder perspectives.

Phase 2: Design and Development

1. Collaborative Design Workshops:
 - Activity: Involve stakeholders in customizing the MCEM to meet identified needs.

- Method: Conduct design workshops to gather ideas and feedback on the proposed model and algorithms.
- Outcome: Create a tailored MCEM that addresses specific requirements and expectations.

2. Pilot Program Development:

- Activity: Develop pilot programs in collaboration with stakeholders.
- Method: Form working groups with representatives from each stakeholder group to design and implement pilot projects.
- Outcome: Pilot programs that test the MCEM in real-world settings with stakeholder input.

Phase 3: Training and Capacity Building

1. Training Programs:

- Activity: Develop and deliver training programs for educators and administrators.
- Method: Conduct hands-on workshops and provide training materials.
- Outcome: Ensure stakeholders are well-equipped to use and support the MCEM.

2. Ongoing Support:

- Activity: Establish support structures for continuous stakeholder engagement.
- Method: Create online forums, helpdesks, and regular follow-up sessions.
- Outcome: Provide continuous support and foster a collaborative learning environment.

Phase 4: Pilot Testing and Refinement

1. Stakeholder Feedback Collection:

- Activity: Collect feedback from stakeholders during the pilot phase.
- Method: Use surveys, feedback forms, and interviews to gather insights on the pilot program's effectiveness.
- Outcome: Compile a feedback report to inform refinements to the MCEM.

2. Feedback Evaluation and Model Refinement:

- Activity: Evaluate stakeholder feedback to identify areas for improvement.
- Method: Form a feedback evaluation committee with representatives from each stakeholder group to review and analyze feedback.
- Outcome: Refine the MCEM based on stakeholder input and pilot results.

Phase 5: Full-Scale Implementation

1. Rollout Planning with Stakeholders:

- Activity: Involve stakeholders in planning the full-scale rollout of the MCEM.
- Method: Conduct planning meetings and workshops to develop a detailed implementation plan.
- Outcome: A comprehensive rollout plan with stakeholder buy-in and support.

2. Ongoing Communication and Monitoring:

- Activity: Maintain regular communication with stakeholders during the rollout.
- Method: Use newsletters, meetings, and online platforms to provide updates and gather feedback.
- Outcome: Ensure transparency and continuous stakeholder engagement.

Continuous Improvement Cycle

1. Regular Feedback Collection:

- Activity: Continuously collect feedback from stakeholders.
- Method: Use regular surveys, focus groups, and suggestion boxes.

- Outcome: Gather ongoing insights into the MCEM's performance and areas for improvement.
2. Feedback Evaluation:
 - Activity: Regularly evaluate the collected feedback.
 - Method: Convene the feedback evaluation committee quarterly to review and analyze feedback.
 - Outcome: Identify trends and areas for improvement based on stakeholder input.
 3. Stakeholder Involvement in Decision-Making:
 - Activity: Involve stakeholders in decision-making processes related to the MCEM.
 - Method: Hold participatory meetings and workshops to discuss potential changes and improvements.
 - Outcome: Ensure that stakeholder voices are heard and considered in all decisions.
 4. Documentation and Reporting:
 - Activity: Document all feedback and decisions made based on stakeholder input.
 - Method: Prepare regular reports and share them with all stakeholders.
 - Outcome: Maintain transparency and accountability in the continuous improvement process.

Stakeholder participation is critical for the successful implementation and continuous improvement of the MCEM. By involving stakeholders at every phase, from planning to full-scale implementation, and ensuring their feedback is regularly collected and evaluated, the MCEM can be effectively tailored to meet the needs of the educational community it serves. This inclusive approach fosters a collaborative environment, ensuring the MCEM's sustainability and success.

Conclusion and Discussion

The integration of metaheuristic artificial intelligence (AI) optimization algorithms into curriculum evaluation represents a new perspective in educational research and practice. This meta-synthesis research has illuminated the underexploited potential of these algorithms in refining and enhancing curriculum development and evaluation processes. The central contributions of this study lie in its innovative approach to curriculum evaluation, leveraging the strengths of metaheuristic algorithms to address the complexities and dynamism inherent in modern educational systems. The proposed Metaheuristic Curriculum Evaluation Model (MCEM) emerges as a novel framework designed for adaptability, scalability, and efficacy in navigating the educational landscape's evolving demands. This research contributes to the disciplinary understanding by:

1. Highlighting the emerging interest in AI optimization within educational sciences, yet noting the sparse application specifically within curriculum evaluation.
2. Demonstrating the variety of algorithms explored and their promising outcomes in related fields, suggesting a fertile ground for their application in education.
3. Underscoring the necessity for customized approaches and interdisciplinary collaboration to harness the full potential of AI optimization in curriculum development.

The findings elaborate on and support existing theories by introducing the MCEM as a paradigm shift toward a more dynamic, responsive educational ecosystem. This model not only aligns with the continuous cycle of evaluation and optimization essential for quality education but also propels the discourse around curriculum development into new, uncharted territories. Comparatively, the MCEM distinguishes itself from prior models by its foundation in metaheuristic optimization, offering a structured yet flexible approach to curriculum evaluation. This marks a departure from traditional evaluation methods, presenting a more nuanced understanding of curriculum optimization's complexities. However, this study acknowledges its limitations, particularly in the

practical application and empirical testing of the MCEM across diverse educational settings. The reliance on existing literature rather than primary data collection may also impact the depth of insights into the model's practical implications.

The scope of transferability is limited by the variability in educational contexts, necessitating cautious application across different systems and levels of education. Ethical considerations around the use of AI in education, including privacy, bias, and accountability, must be navigated carefully, with future research aimed at addressing these challenges.

Implications for future research include the design of experimental studies to apply and test the MCEM across various educational levels, comparative analyses to identify the most suitable algorithms for different curriculum components, and the development of hybrid models that combine different AI algorithms. Additionally, contrasting AI-supported models with traditional approaches could offer valuable insights into their relative strengths and weaknesses.

In conclusion, the study underscores the transformative potential of AI optimization algorithms in curriculum evaluation, paving the way for a new era of educational excellence. By fostering a continuous cycle of improvement and adaptation, the MCEM promises to elevate the quality and relevance of education, aligning it more closely with societal needs and individual learner aspirations.

Future Research Directions

Validation Studies

Experimental studies can be conducted to test the effectiveness of the MCEM across different educational levels and contexts. The MCEM can be compared with traditional curriculum evaluation models to highlight its advantages.

Algorithm Development

The development of hybrid models can be explored to combine multiple metaheuristic algorithms for enhanced optimization.

The application of emerging AI technologies (e.g., machine learning and neural networks) can be investigated in curriculum evaluation.

Ethics Committee Approval: Since our study is a theoretical study, it does not require ethics committee approval.

Author Contributions: Volkan Duran %70, Gülay Ekici %30.

Conflict of Interest: There is no possibility of any conflict of interest regarding the author or authors.

Çeşitli Meta-Sezgisel Yapay Zekâ Optimizasyon Uygulamalarının İncelenmesine Dayalı Bir Meta-Sezgisel Eğitim Programı Değerlendirme Modeli Taslağı Tasarlanması

Volkan Duran^a  Gülay Ekici^b 

^a Doç. Dr., İğdır Üniversitesi, İğdır, Türkiye, volkan.duran8@gmail.com

^b Prof. Dr., Gazi Üniversitesi, Ankara, Türkiye, gekici@gazi.edu.tr

ÖZET

Bu araştırma, metasezgisel yapay zeka (AI) optimizasyon algoritmalarının eğitim programı değerlendirme sürecine entegrasyonunu araştırmaktadır ve bunun eğitsel sonuçlarını artırabilecek yeni bir yaklaşım önermektedir. Çalışmada tabu arama, benzetilmiş tavlama, genetik algoritmalar ve karınca kolonisi optimizasyon gibi yapay zeka optimizasyon tekniklerinin eğitim bağlamlarında uygulanmasına ilişkin mevcut literatürün bir meta sentezi gerçekleştirilmiştir. Bu çalışma, eğitimde program değerlendirme medde bu algoritmaların doğrudan uygulanmasının literatürdeki azlığını ortaya çıkarmıştır, böylece literatürde bir boşluk ve bir keşif fırsatı olduğunu göstermiştir. Hedefler, içerik, öğretim yöntemleri ve değerlendirme stratejileri dahil olmak üzere eğitim programı bileşenlerini değerlendirmek için çeşitli meta-sezgisel optimizasyon algoritmalarını uyarlamak için ayrıntılı modeller önerilmiştir. Makale, literatür taramasından elde edilen bilgileri sentezlemiş ve çeşitli eğitim seviyeleri ve programlarıyla yapay zeka optimizasyon algoritmalarının etkinliğini değerlendirmek için deneysel çalışmalar için yollar önermiştir. Ayrıca, incelenen optimizasyon modellerinden ve eğitim programı değerlendirme süreçlerinden sentezlenen Metasezgisel Eğitim Programı Değerlendirme Modeli'nin bir taslağı sunulmuştur. Meta-sezgisel yapay zeka optimizasyon algoritmalarının eğitimde program değerlendirmesine entegrasyonuna yönelik bu araştırma, eğitim araştırmalarında yeni bir alana vurgu yapmaktadır. Potansiyel uygulamaları detaylandırarak, metodolojik titizliği ele alarak ve bağlama özgü nüansları göz önünde bulundurarak bu çalışmada, eğitimde program geliştirilme, değerlendirme ve optimize edilme şekline farklı bakacak olan gelecekteki çalışmalara zemin hazırlanmaktadır.

MAKALE BİLGİSİ

Makale Türü

Araştırma

Makale Geçmişi

Gönderim tarihi:

01.04.2024

Kabul tarihi:

08.07.2024

Anahtar Kelimeler

Optimizasyon
Algoritmaları,
Eğitimde Program
Değerlendirme,
Yapay Zekâ,
Meta-Sentez

Atıf Bilgisi: Duran, V. ve Ekici, G. (2024). Çeşitli meta-sezgisel yapay zekâ optimizasyon uygulamalarının incelenmesine dayalı bir meta-sezgisel eğitim programı değerlendirme modeli taslağı tasarlanması. *Uluslararası Türk Eğitim Bilimleri Dergisi*, 12 (2), 989-1055. <https://doi.org/10.46778/goputeb.1463058>

Sorumlu yazar: Volkan Duran, e-mail: volkan.duran8@gmail.com

Giriş

Eğitimde değerlendirmenin derin bir geçmişi vardır; kökeni M.Ö. 2000 yılında Çinli yetkililerin saray hizmeti adaylarının niteliklerini belirlemek için sınavlara başvurması ve Antik Yunan'da öğretim sürecinin bir parçası olarak Sokrates'in sözlü değerlendirmeleri gibi erken örneklerle kadar uzanır. Ancak 20. yüzyılda bu alanda Flexner'in tıp fakültesi değerlendirmeleri, Tyler'in ölçme ve değerlendirme ayrimı, İkinci Dünya Savaşı sonrası federal girişimler ve Sputnik'in tetiklediği eğitim reformları ile önemli ilerlemeler kaydedilmiştir. 1960'lı ve 1970'li yıllara gelindiğinde değerlendirme, geliştirilen standartlarla mesleki bir disiplin olarak kabul edilmiştir (Yüksel, 2010).

Program değerlendirme, ampirik araştırma yöntemleri kullanılarak sistematik veri toplama ve analize dayalı bir süreç olarak tanımlanmaktadır. Bu süreç, geliştirilen bir programın doğruluğu, gerçekçiliği, yeterliliği, uygulanabilirliği, verimliliği, etkililiği, etkisi, sürdürilebilirliği, başarısı, genellenebilirliği gibi çeşitli özelliklerine ilişkin karar almayı kolaylaştırır (Uşun, 2012). Richards'a (2003) göre bu değerlendirme süreci, bir programdaki öğretim yöntem ve materyallerinin etkililiğinin gözlemlenmesi, programın amacına ulaşıp ulaşmadığının belirlenmesi ve öğrencilerin öğrenme sürecindeki ilerlemelerinin izlenmesi açısından önemlidir. Brown (1995) program değerlendirmelerinin, programın sürekli iyileştirilmesi için sürekli bir veri toplama, analiz ve sentez süreci olduğunu vurgulamıştır. Benzer şekilde Demirel (2007), bir programın etkililiğine ilişkin veri toplamayı, bu verileri kriterlerle karşılaştırıp yorumlamayı ve programın etkililiğine ilişkin kararlar almayı içeren sistematik değerlendirme süreçlerinin, programları geliştirip zenginleştirebileceğini vurgulamıştır.

Eğitimde program değerlendirme, çok sayıda sınıflandırma türü bünyesinde barındıran, eğitim sistemlerinin etkililiğini ve verimliliğini artırmak için kritik bir süreçtir. Uşun (2012) tarafından sınıflandırılan değerlendirme yaklaşımları, çeşitli yöntem ve modeller aracılığıyla programın amacına ulaşıp ulaşmadığını belirlemeyi amaçlamaktadır. Bu yaklaşımlar; hedef odaklı, sistem tabanlı, işbirlikçi, katılımcı odaklı, rakip odaklı, niteliksel, uzmanlık odaklı, müşteri odaklı, postmodern, geleneksel, pragmatik, hümanist ve akademik değerlendirme yaklaşımlarını içerir. Her biri program değerlendirme sürecine farklı bakış açıları sunmakta ve odaklanmaktadır (Kandermir, 2016; Kocabatmaz, 2011; Özdemir, 2009; Uşun, 2012; Ünal, 2013). Program değerlendirmede meta-sezgisel algoritmaların doğrudan uygulamalarının azlığı, bu noktada önemli bir boşluğun ve keşif fırsatının altını çizmektedir. Mevcut literatür, eğitim program bileşenlerini sistematik olarak değerlendirmek için bu algoritmaları uyarlayan kapsamlı modellerden yoksundur.

Program değerlendirme modelleri genel olarak bazı yaklaşımlar hariç olmak üzere programın etkililiğini sistematik olarak değerlendirmek için belirli bir sırayla izlenmesi gereken adımları içeren algoritmik bir yapıya sahiptir. Bu adımlar genellikle şunları içerir: 1. Değerlendirme yaklaşımının, hedeflerinin ve kriterlerinin belirlenmesi, 2. Veri toplama ve analiz, 3. Bulguların yorumlanması ve programın değerlendirilmesi, 4. Önerilerde bulunulması, 5. Değişikliklerin uygulanması, 6. Sürecin belgelenmesi ve raporlanması, 7. Gerektiği kadar tekrarlamak. Meta-sezgisel yapay zeka optimizasyon algoritmalarının eğitimde program değerlendirmesine entegrasyonu, eğitim araştırmalarında kapsamlı bir şekilde araştırılmamış yeni bir yaklaşımı temsil etmektedir. Önerilen taslak, eğitim programı değerlendirme süreçlerinin etkinliğini ve verimliliğini artırmak için çeşitli meta-sezgisel algoritmaların güçlü yönlerinden yararlanmaktadır ve sürekli iyileştirme için yapılandırılmış ancak esnek bir çerçeve sağlamaktadır. Ancak mevcut literatür, eğitimde program

değerlendirmede bu algoritmaların doğrudan uygulanmasının az olduğunu ortaya koymaktadır ve bu da önemli bir boşluğun ve daha fazla araştırma fırsatının altını çizmektedir.

Karmaşık sorunları sistematik ve yinelemeli bir yaklaşımla çözme kapasiteleriyle tanımlanan yapay zeka optimizasyon algoritmaları (Karaboga, 2018), eğitimde program değerlendirme yöntemlerine umut verici bir paralellik sunmaktadır. Her iki alan da, ister eğitim programının etkililiğini artırmak ister sorunlara en uygun çözümleri bulmak olsun, yapılandırılmış süreçler aracılığıyla belirli hedeflere ulaşmayı amaçlamaktadır. Eğitim ve yapay zeka arasındaki bu kesişim, her iki alanda da sürekli iyileştirme ve uyum potansiyelinin altını çizmektedir ve karmaşık sorunlara yenilikçi stratejiler uygulamanın önemini vurgulamaktadır. Ayrıca, doğal davranışlardan ilham alan meta-sezgisel yöntemlerin eğitim programı değerlendirme uygulanması, verimli ve etkili değerlendirme stratejilerinin keşfedilmesi için yeni bir ufuk sunmaktadır (Blum ve Roli, 2003; Chakraborty ve diğerleri, 2021). Bu araştırma, eğitimde program değerlendirme yapay zeka optimizasyon algoritmalarına ilişkin literatürü eleştirel bir şekilde analiz etmeyi, bunların etkililiğini, uygulama zorluklarını ve eğitim müfredatı üzerindeki genel etkisini belirlemeyi amaçlamaktadır. Bunu yaparak, eğitimsel değerlendirme uygulamalarında süregelen gelişime ve mükemmelliğe katkıda bulunarak bilgi boşluklarını kapatmayı ve alandaki pratik ihtiyaçları gidermeyi amaçlamaktadır.

Yöntem

Bu çalışma, optimizasyon algoritmaları tarafından desteklenen yeni bir eğitimde program değerlendirme modeli oluşturmak için bir meta-sentez yaklaşımını kullanmaktadır. Oldukça kabul gören bir nitel araştırma yöntemi olan meta-sentez, çeşitli nitel çalışmalarдан elde edilen bulguları özümseyip yorumlayarak panoramik ve üst düzey bir bakış açısı sağlamaya çalışır. Belirli bir olgunun bütünsel bir bakış açısıyla kapsamlı bir şekilde anlaşılmasını sağlamak için çeşitli nitel araştırmalardan sonuçların çıkarılması, analiz edilmesi ve birleştirilmesi ilkesine dayanmaktadır. Gülüm (2016) ve Weed (2005)'in de tanımladığı gibi meta-sentez, bireysel çalışmalarдан gelen temaları, kavramları ve anlatıları yeni, kapsayıcı teorik çerçevelere veya tekilliğin sınırlarını aşan yorumlara bağlamaya çalışarak geleneksel nitel analizi aşar.

Bu sentez için makalelerin seçimi, uygunluk ve titizlik sağlamak amacıyla spesifik dahil etme ve hariç tutma kriterlerine bağlanan bir kriterli örneklemeye stratejisi tarafından yönlendirilmiştir. Dahil etme kriterleri, makalelerin: (1) Yapay Zeka optimizasyon uygulamalarıyla ilgili olması, (2) özellikle eğitim programlarının değerlendirilmesiyle ilgili olarak eğitimle bir bağlantısı olması ve (3) Web of Science veya Türkçe tez merkezi veri tabanı (<https://tez.yok.gov.tr/>) gibi tanınmış veri tabanlarında kataloglanması içermektedir. Bunun tersine, eğitim sektöründeki yapay zeka optimizasyon uygulamalarına odaklanmayan, program değerlendirme ile ilgisi olmayan, yayınlanmamış veya belirlenen veri tabanları aracılığıyla erişilemeyen makaleler hariç tutulmuştur.

Bu araştırma için bir meta-sentez tasarımlı seçmenin ardından mantık, mevcut nitel çalışmaları, optimizasyon algoritmalarının eğitimde programları nasıl geliştirebileceğine dair daha incelikli bir anlayışla sentezleme potansiyeline dayanmaktadır. Bu yaklaşım yalnızca eğitim teknolojisi alanından dağınık görüşlerin entegrasyonunu kolaylaştırmakla kalmaz, aynı zamanda müfredat değerlendirme ve geliştirme uygulamalarında devrim yaratabilecek yenilikçi çerçevelerin veya teorilerin üretilmesine de olanak tanımaktadır. Bu titiz toplama ve sentez süreci aracılığıyla araştırma, yapay zeka optimizasyonunun en ileri yeteneklerini güçlendiren yeni bir eğitimde

program değerlendirme modeli sunarak eğitimin hem akademik hem de pratik alanlarına önemli ölçüde katkıda bulunmayı amaçlamaktadır.

Bulgular

Bu bölümde, ilkelerini ve metodolojilerini eğitimde program değerlendirme süreciyle sentezleyerek çeşitli meta-sezgisel optimizasyon algoritmalarını incelenecektir. Bu sentez, eğitimde program değerlendirme sürecinin etkinliğini ve verimliliğini artırmak için bu algoritmaların güçlü yönlerinden yararlanmayı amaçlamaktadır. Bu algoritmalar eğitim programını daha etkili, verimli ve kişiselleştirilmiş hale getirmek için önemli fırsatlar sunmaktadır. İhtiyaç analizi yaptıktan ve program değerlendirme yaklaşımını belirledikten sonra potansiyel program değerlendirme modeli popülasyonunun oluşturulmasını vurgulayan örneklerle incelenebilir. Böylece metasezgisel optimizasyon algoritmalarının eğitim programı değerlendirme metodolojileriyle incelenmesi ve sentezinin ardından, Metasezgisel Eğitim Programı Değerlendirme Modeli (MEPDM) adı verilen yeni bir program değerlendirme modeli taslağı önerilmiştir. MEPDM çerçevesi uyarlanabilir, ölçeklenebilir ve eğitim ortamlarının dinamik doğasını idare edebilecek şekilde tasarlanmıştır.

Tabu Arama Algoritması (TSA)

Tabu Arama Algoritması (TSA), 1986 yılında F. Glover tarafından geliştirilen, insan hafızası fonksiyonu prensiplerinden esinlenen bir meta-sezgisel optimizasyon algoritmasıdır. Temel fikir, elemanların değiştirilmesi, eklenmesi veya çıkarılması gibi yöntemleri kullanarak başlangıç çözüm uzayını dönüştürerek en uygun çözüme ulaşmaktadır. Verimliliği başlangıç çözümüne, bölge tanımına ve değerlendirme fonksiyonuna bağlıdır (Arslan, 2018; Gürbüz, 2015). Tabu algoritmasını temel alan bir program değerlendirme algoritması şu şekilde özetlenebilir:

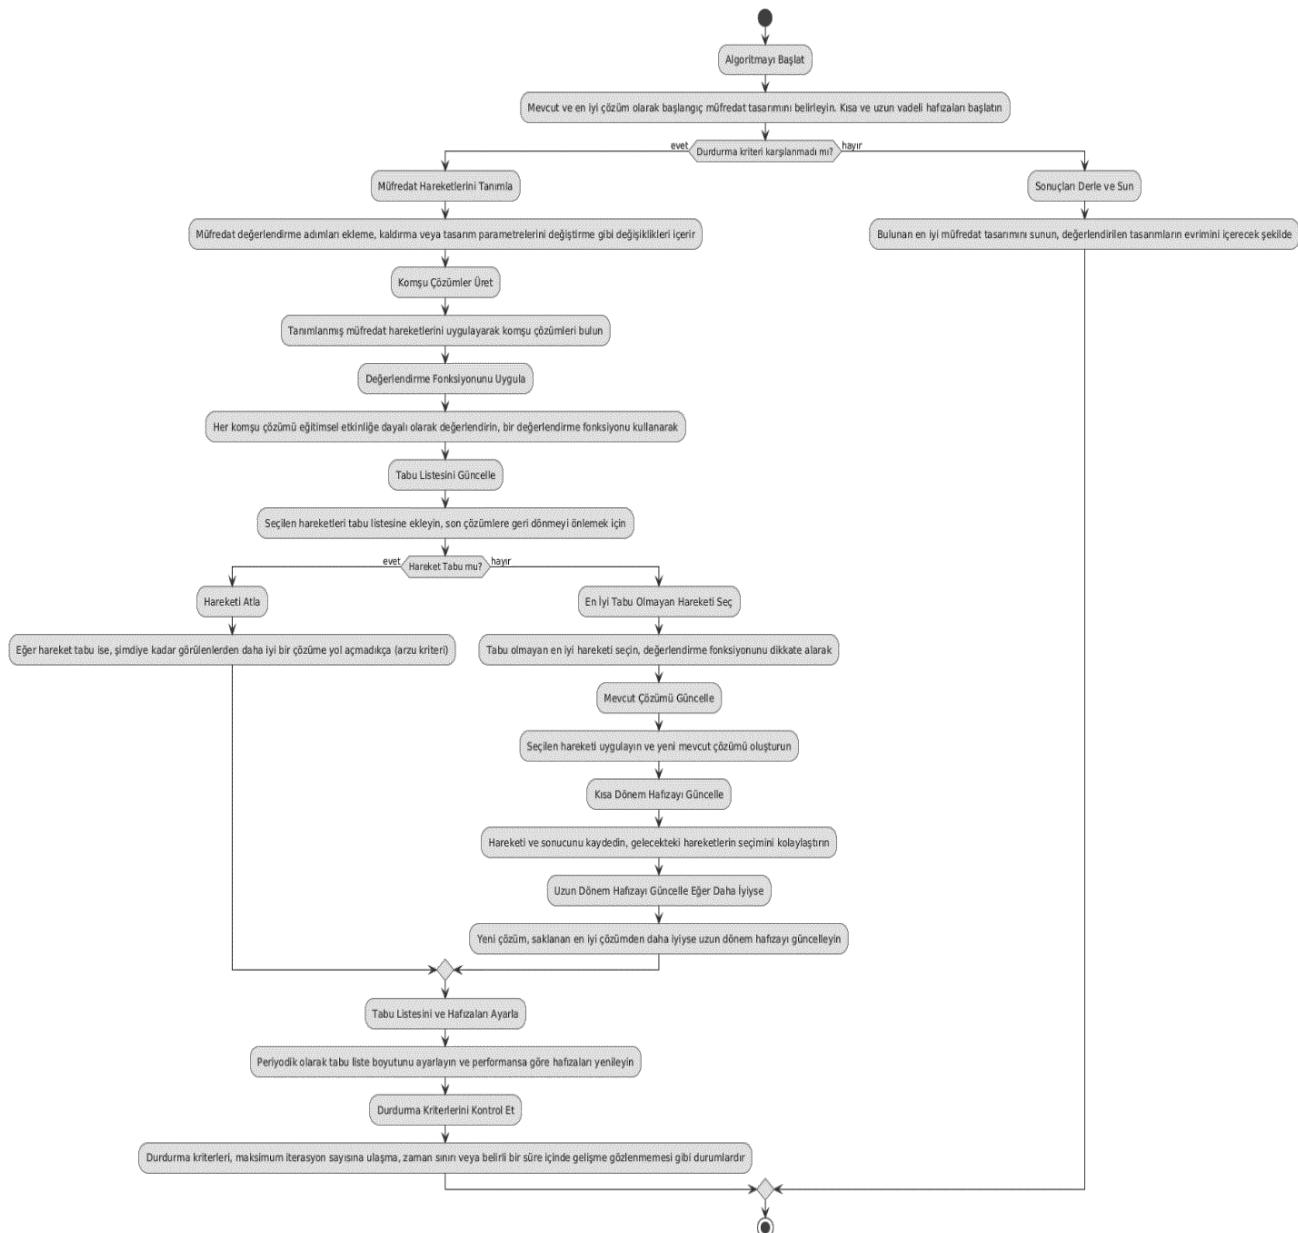
1. Başlangıç Çözümünün Belirlenmesi: Program değerlendirmede ilk adım, programın mevcut durumu veya tasarımları olabilecek bir başlangıç çözümü belirlemektir. Bu başlangıç çözümü hem mevcut çözüm hem de en iyi çözüm olarak hafızada saklanır.
2. Hareketlerin Tanımlanması: Eğitim programı değerlendirme için "Hareketler" tanımlanmalıdır; bu, eğitim programının tasarım parametrelerini veya bileşenlerini değiştirmeyi, eklemeyi veya kaldırmayı içerebilir. Bu değişiklikler eğitim programının iyileştirilmesini amaçlamalıdır.
3. Tabu ve Kısa Süreli Bellek: TSA'nın kısa süreli belleği, yeni bir çözüm üretirken en iyi hamlenin seçimini kolaylaştırır ve çözümlerin tekrarını önler. Tabu listesi, bir önceki adımdaki seçilmemiş komşu çözümleri kaydeder ve yerel optimumdan kaçınmak için bunları bir süreliğine yasaklar.
4. Uzun Süreli Bellek: Algoritma boyunca bulunan en iyi çözüm, uzun süreli bellekte saklanır. Bu, üretilen tüm çözümlerin en iyi çözümle karşılaşmasına olanak tanıyarak genel performansı artırır.
5. Değerlendirme Fonksiyonunun Kullanılması: Eğitim programı değerlendirme için her adımda en yüksek değerlendirme puanına sahip hareketin seçildiği bir değerlendirme fonksiyonu kullanılır. Bu, programın performansını ölçer ve iyileştirir.
6. Durdurma Kriterleri: Algoritmanın durdurma kriterleri tanımlanmalıdır; örneğin belirli sayıda iterasyona ulaşmak, daha iyi bir çözüm bulamamak veya bilinen bir optimal çözüme ulaşmak.

Böylece, uzun ve kısa süreli hafıza, değerlendirme fonksiyonu ve bu amaca uygun tabu listesi gibi bileşenlerle eğitim programının tasarımını ve performansını optimize etmek için Tabu Arama Algoritmasına dayalı bir eğitim programı değerlendirme algoritması geliştirilebilir. Tezyöök'e göre

bu algoritmanın kullanımına ilişkin bugüne kadar eğitim bilimleri alanında herhangi bir tez bulunamamıştır. Ancak Web of Science'ta eğitim bilimleri kategorisi altında yapılan aramada 14 çalışmaya ulaşılmıştır. Bazı özetler bu tekniklerin öğretime uygulanmasından bahsederken (örneğin, öğrencilere vaka çalışmaları sunmak), hiçbir eğitim program tasarımlı, pedagoji, eğitim politikası vb. gibi eğitim konularını doğrudan ele almamıştır. Literatürdeki bu boşluk gelecekteki araştırmalar için Tabu Arama Algoritmasının ve benzer optimizasyon tekniklerinin daha geniş eğitimsel zorluklara sistematik olarak nasıl uygulanabileceğini araştırmak, öğrencilerin ve eğitim kurumlarının ihtiyaçlarını daha iyi karşılamak için potansiyel olarak müfredat değerlendirme ve tasarım süreçlerini dönüştürmek açısından bir fırsatı işaret etmektedir.

Şekil 1

Eğitimde Tabu Arama Algoritmasını Temel Alan Bir Eğitim Programı Değerlendirme Algoritması



Tavlama Algoritması

Bir amaç fonksiyonu kullanarak rastgele seçilen bir başlangıç noktasından başlayarak çözüm uzayındaki bir çözümün sürekli iyileştirilmesini amaçlayan yinelemeli bir yaklaşım olan Tavlama

Algoritması, eğitim programı değerlendirmesine etkili bir şekilde uyarlanabilir. Bu algoritma, önceden tanımlanmış bir amaç fonksiyonunun değerini mümkün olan en iyi sonuca doğru artırmak için yeni veya komşu çözümler üretir (Gökçe ve diğerleri, 2019). Algoritmanın başarısı aynı zamanda kontrol parametresi T 'nin başlangıç değeri, sıcaklık azaltma fonksiyonu, her sıcaklık aşamasındaki yineleme sayısı ve araştırmanın ne zaman sonlandırılacağına ilişkin kriterler gibi parametrelerin doğru ayarlanması da bağlıdır (Karaboğa, 2018).

Bu bağlamda Tavlama Algoritmasını temel alan bir program değerlendirme modeline şu şekilde yaklaşılabilir (Karaboğa, 2018'den değiştirilmiştir):

İlk Çözümün Üretilmesi: Eğitim programının başlangıç amaçları, içeriği ve hedefleri açıkça tanımlanmalıdır. Bu değerlendirme sürecinin temelini oluşturur.

Komşu Nesil Mekanizmasının Tanımlanması: Hedefler, kapsam, hedef kitle gibi müfredatın temel bileşenleri ana hatlarıyla belirtilmelidir. Programın değerlendirilmesinde kullanılacak yöntem, araç veya yaklaşımlar belirlenmelidir. Ölçülebilir değerlendirme kriterleri ve araçlarının tanımlanması gerekmektedir.

Çevrenin Nasıl Keşfedileceğinin Tanımlanması: Eğitim programının farklı bileşenlerinin ve uygulama adımlarının belirlenmesini içermelidir. Eğitim programının değerlendirilmesinde kullanılacak kriterler ve ölçüm yöntemleri oluşturulmalıdır. Buna eğitim programının başarısını ve etkiliğini değerlendirmek için kullanılan ölçüm araçları da dahildir.

Soğutma Programının Tanımlanması: Değerlendirme sürecinin nasıl ilerleyeceğini ve değerlendirmelerin ne sıklıkta gerçekleşeceğine ilişkin bir plan geliştirilmelidir. Bu, eğitim programının hangi aşamalarda ve ne sıklıkla değerlendirileceğini belirler.

Kontrol Parametresi T_s 'nin Başlangıç Değerinin Ayarlanması: Değerlendirme sürecinin başlangıcında eğitim programı için bir odak noktası ve başlangıç değeri atanmalıdır. Örneğin, bir eğitim programının ilk aşaması veya modülü için özel hedefler belirlenebilir.

Sıcaklığa Düşürme Fonksyonunun Tanımlanması: Eğitim programının geliştirilmesi ve iyileştirilmesi için kullanılacak yöntem, strateji ve süreçler ana hatlarıyla belirtilmelidir. Buna program geliştirme aşamaları da dahildir. Programın zaman içinde nasıl güncelleneceğine ve geliştirileceğine ilişkin yöntemlere buraya yer verilebilir.

Her Sıcaklık Aşamasında Yapılacak İterasyon Sayısının Belirlenmesi: Program değerlendirmenin her aşamasında kaç değerlendirme yapılacağına ve bu değerlendirmelerin nasıl yapılacağına karar verilmelidir. Örneğin öğrenci performansı bir müfredatın her aşamasında değerlendirilebilir.

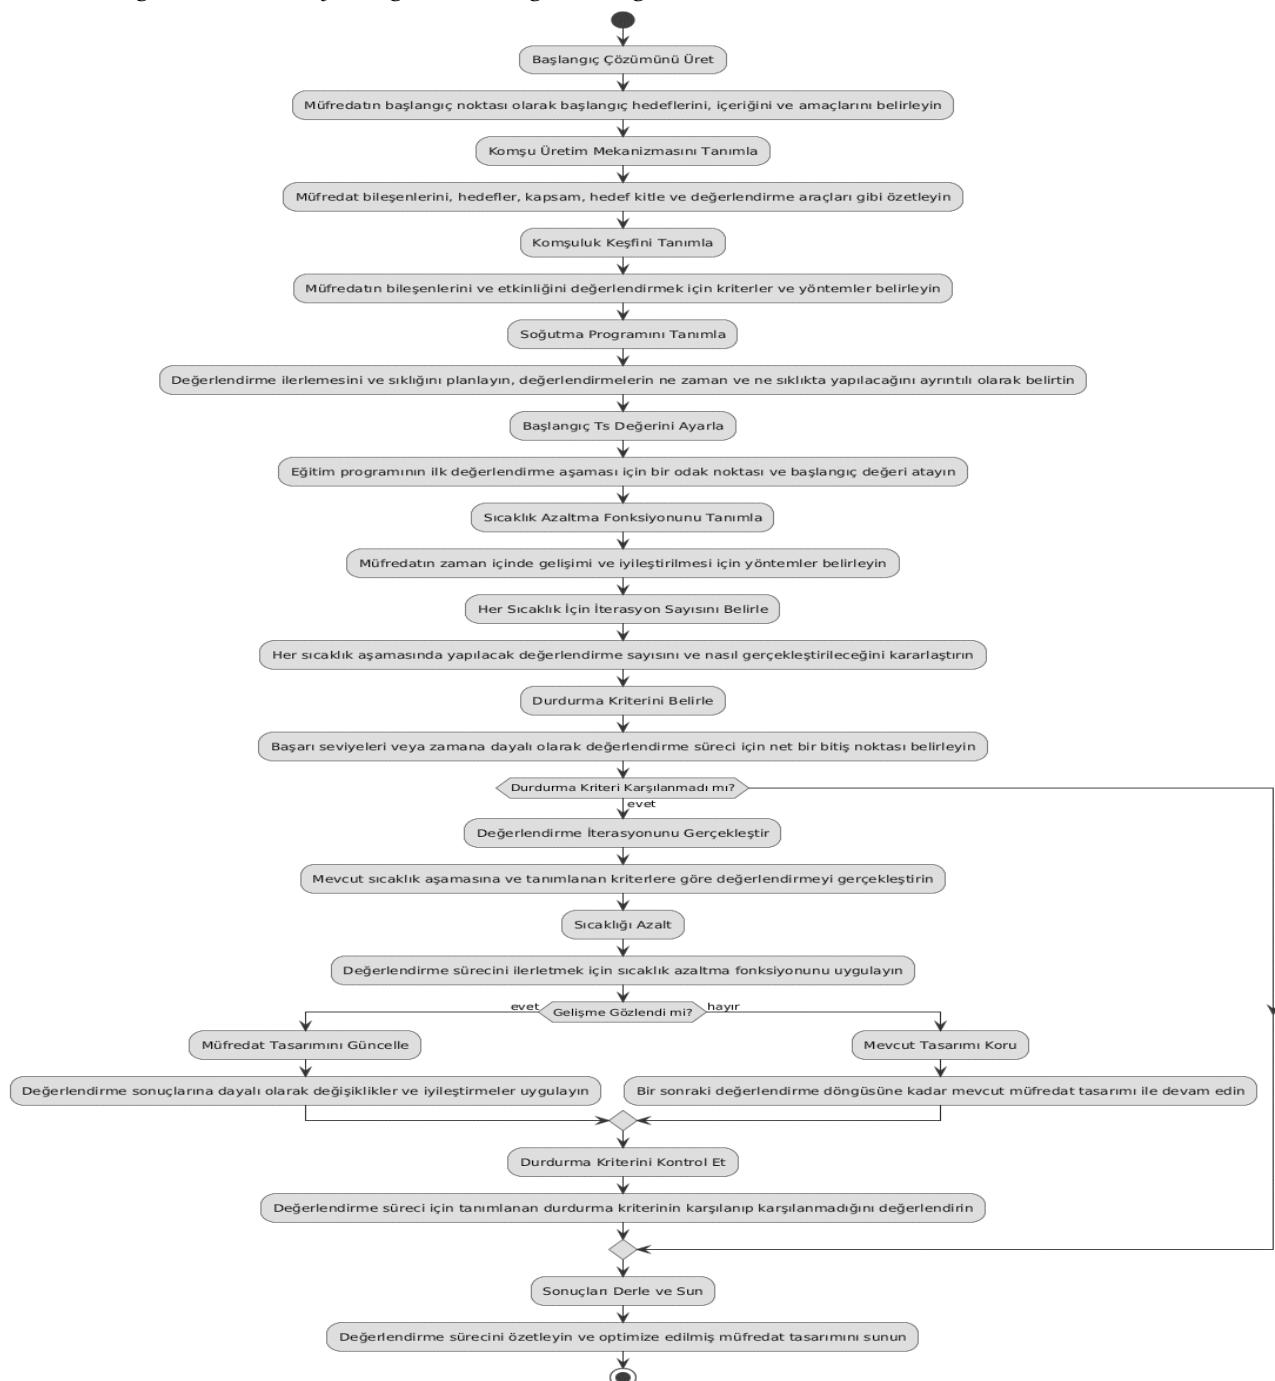
Araştırmayı Sonlandırma Kriterinin Belirlenmesi: Değerlendirme sürecinin ne zaman biteceğini ve değerlendirilen programın başarısının ne zaman olacağını belirleyen bir kriter tanımlanmalıdır. Örneğin, değerlendirme belirli bir süre sonra veya eğitim programında belirli bir başarı düzeyine ulaşıldığında sona erebilir.

Tavlama Algoritmasına dayalı bir eğitim programı değerlendirme modeli, öğretim materyallerinin karmaşaklılığını öğrencilerin anlama düzeyleriyle dengeleyerek eğitim materyallerinin optimizasyonunda değerli bir araç olarak hizmet edebilir. Akademik alanda <https://tez.yok.gov.tr/> adresine göre bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin herhangi bir tez

bulunamamıştır. Ancak Web of Science'ta "eğitim ve öğretim" anahtar kelimeleri altında yapılan bir arama, 38 çalışma ortaya çıkarılmıştır; bunların arasında Lee ve ark. (2021) bu konuya doğrudan ilgilidir. Bu, Tavlama Algoritması tabanlı modellerin eğitim araştırmalarında, özellikle eğitim materyalleri ve programlarının optimize edilmesinde uygulanması için bir potansiyele işaret etmektedir. Bu tür uygulamalar, eğitim materyallerinin değerlendirilmesi ve geliştirilmesinde devrim yaratarak, öğretme ve öğrenme deneyimlerini geliştirmek için yapılandırılmış ve etkili bir yöntem sunabilir.

Şekil 2

Tavlama Algoritmasına Dayalı Eğitimde Program Değerlendirme Modeli



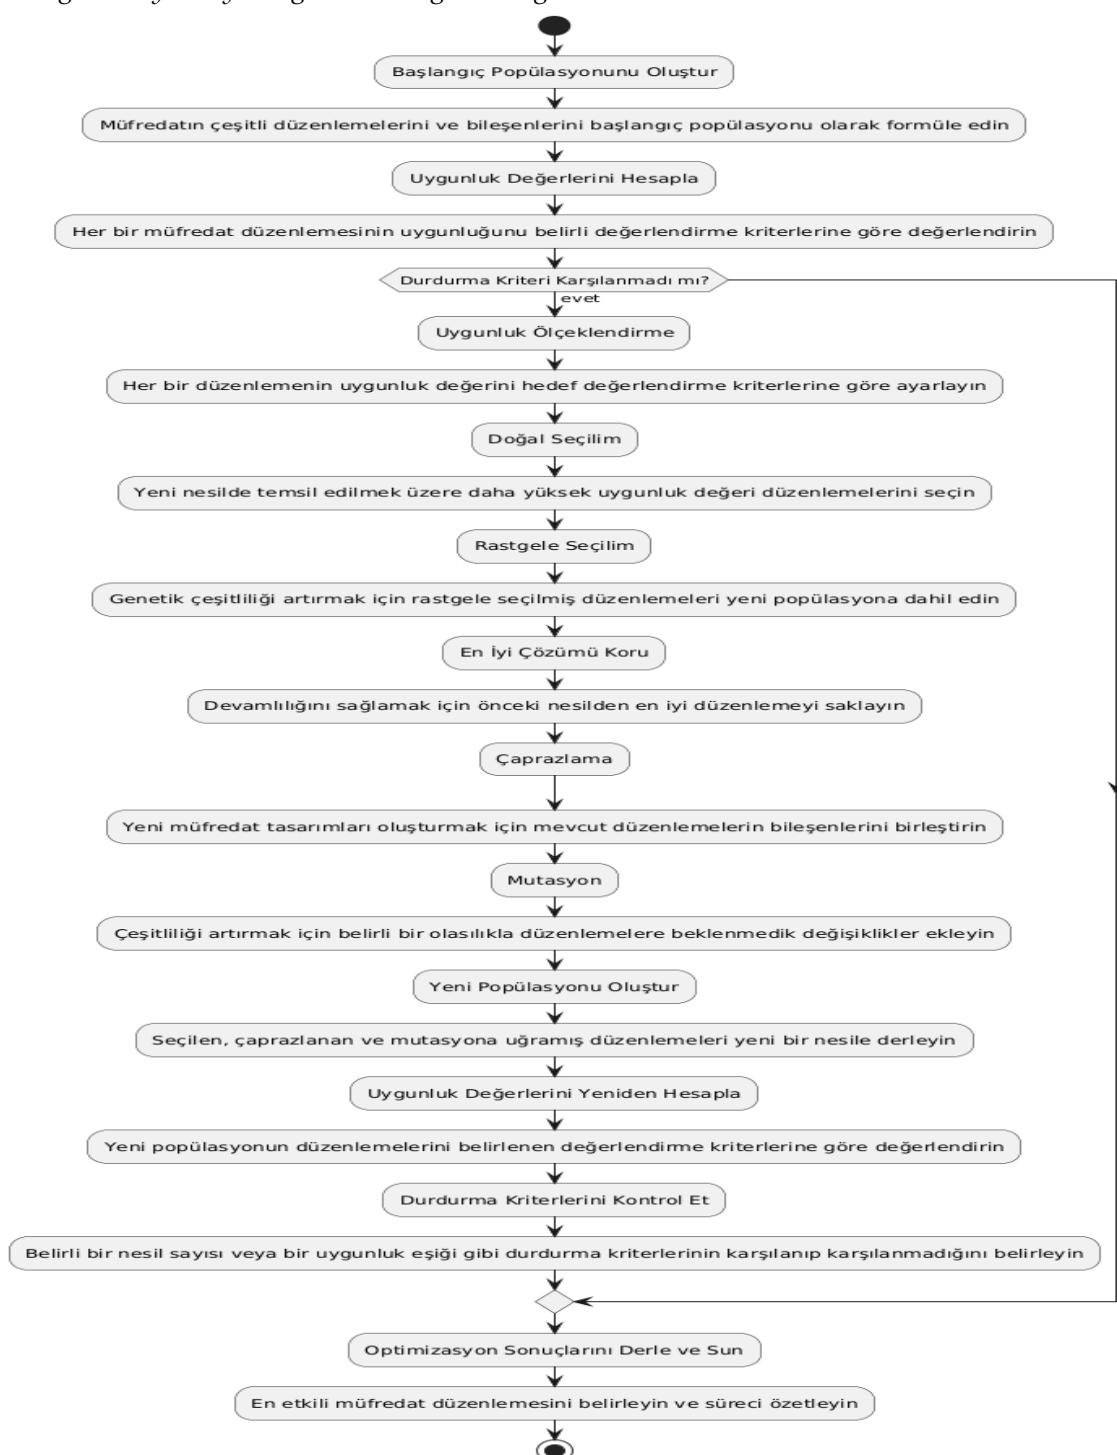
Genetik Algoritma

David E. Tate'e göre, doğal seçim ve doğadaki genetik mekanizmalardan ilham alan Genetik Algoritma, bir veya daha fazla çözüm popülasyonundan çözümler üretmek ve rastgele değiştirmek için geliştirilmiştir. Aynı zamanda daha iyi amaç fonksiyonu değerlerine sahip bireylerin seçilmesi ve popülasyonlardan çözümlerin ayıklanması için mekanizmalar da içerir. Genetik algoritmaların önemli bir özelliği, arama sürecini birden fazla çözüm noktasından yürütmemek ve olasılıksal dönüşüm kurallarını kullanmaktadır. Temel kavramlar arasında genler, kromozomlar, popülasyonlar, uygunluk değerleri ve işlevler yer almaktır. Parametre sayısından bağımsız çalışabilmeleri, yerel optimumlara takılma riskinin düşük olması ve paralelleştirmenin kolay olması gibi üstün yönleri vardır (Yetkin, 2019). Genetik Algoritmaya Dayalı Bir Program Değerlendirme Modeli şu şekilde özetlenebilir (Şekil 3):

1. Başlangıç Popülasyonunun Oluşturulması: Eğitim programının farklı düzenlemelerini ve bileşenlerini içeren başlangıç popülasyonunu oluşturun.
2. Uygunluk Değerlerini Hesaplayın: Her eğitim programı ögesinin düzenlemesinin uygunluğunu belirli değerlendirme kriterlerine göre değerlendirin.
3. Durdurma Kriterlerini Kontrol Edin: Durdurma kriteri karşılanana kadar aşağıdaki adımları uygulayın:
 - a. Uygunluk Ölçeklendirmesi: Her eğitim programı düzenlemesinin uygunluk değerini hedef değerlere göre ölçeklendirin.
 - b. Doğal Seçim: Yeni popülasyonda daha fazla temsil edilmek için daha yüksek uygunluk değerlerine sahip eğitim programları düzenlemelerini seçin.
 - c. Rastgele Seçim: Popülasyonun bir kısmını doğal seçim yerine rastgele seçilime tabi tutarak genetik çeşitliliği artırın.
 - d. En İyi Çözümün Korunması: Kaybolmamasını sağlamak için önceki popülasyonda bulunan en iyi eğitim programı düzenlemesini koruyun.
 - e. Çaprazlama: Farklı bileşenleri birleştirerek mevcut düzenlemelerden iki yeni düzenleme üretin.
 - f. Mutasyon: Her eğitim program düzenlemesinde belirli bir olasılıkla mutasyonlar yapılarak beklenmeyen değişikliklere izin verilir.

Bu genetik algoritma tabanlı model, öğrenci başarısını artırmak amacıyla eğitim programının içeriğini, yapısını ve değerlendirmesini optimize etmek için kullanılabilir. Yetkin (2019) eğitim bilimleri alanında bu algoritmanın eğitim araştırmalarında kullanımını gösteren "PİSA başarısını tahmin etmede genetik algoritma yaklaşımı" başlıklı yüksek lisans tezi hazırlamıştır. Yapıçı (2012) "Genetik algoritma kullanılarak ders çizelgeleme yazılımının geliştirilmesi" başlıklı yüksek lisans tezi hazırlamıştır. Web of Science kategorisinde genetik algoritmalar içeren 546 çalışma bulunmaktadır. Bunlar arasında doğrudan eğitimle ilgili çalışmalar arasında genetik algoritmaların ve MATLAB'ın optimizasyon algoritmalarını ve uygulamalarını öğretmek için kullanılması (Cao ve Wu, 1999), lisans öğrencileri için genetik algoritmalar kullanılarak optimum tasarım üzerine bir ders (Shyr, 2010), ve kolejlerde ve üniversitelerde ders planlaması için geliştirilen geliştirilmiş uyarlanabilir genetik algoritma (Wang ve diğerleri, 2019) gibi çalışmaları içermektedir. Birkaç özeti doğrudan eğitim konularına odaklanırken, diğerleri daha genel olarak algoritmalar ve optimizasyon yöntemleri önermeye odaklanmış görülmektedir.

Şekil 3

Genetik Algortimaya Dayalı Eğitimde Program Değerlendirme Modeli**Karınca Kolonisi Algoritması**

Karınca Kolonisi Algoritması, karıncaların feromon izleri bırakması prensibine dayanmaktadır ve bu izlerin yoğunluğu, besine giden en verimli yolu yönlendirmektedir. Daha güçlü feromon sinyaline sahip yollar tercih edilirken, daha az sıkıkta kullanılan yollar zamanla azalarak en kısa yolu ortaya çıkarır. Başlangıçta Gezgin Satıcı Problemi gibi NP-zor optimizasyon problemlerinde test edilen KKA, etkili sonuçlar göstermiştir (Can, 2022). Karıncaların bir besin kaynağına giden en kısa yolu bulma yeteneğinden ilham alan Karınca Kolonisi Algoritması (ACA), sanal karıncaların

bir başlangıç noktasından çeşitli yollar boyunca rastgele hareket ettiği bir optimizasyon yöntemidir (Keser, 2020).

Karinca Kolonisi Algoritmasını (ACA) temel alan bir eğitim programı değerlendirme modeli, eğitsimsel sonuçları iyileştirmek amacıyla eğitim programı yapılarını, içeriğini ve öğretim durumlarını optimize etmek için kolektif zeka ilkelerinden yararlanabilir:

Eğitim Programı Bileşenlerini Tanımlayın

Öğrenme hedefleri, içerik modülleri, öğretim metodolojileri ve değerlendirme stratejileri gibi değerlendirilecek eğitim programının temel bileşenlerini tanımlayarak başlayın. Her bileşen, ACA'daki bir besin kaynağına veya yuvaya benzer bir düğüm olarak düşünülebilir.

Değerlendirme Kriterlerini Belirleyin (Amaç İşlevi)

Eğitim programı değerlendirmesi için karınca kolonisindeki besin kaynaklarına benzer net kriterler belirleyin. Bunlar arasında öğrenci katılımı, öğrenme sonuçları, eğitim standartlarıyla uyum ve eğitimcilerden ve öğrencilerden gelen geri bildirimler yer alabilir.

Sanal Karıncaları Başlat (Eğitim Programı Değerlendiricileri)

Eğitim programı bileşenlerini keşfetmek için sanal karıncaları konuşlandırın. Her karınca, belirlenen kriterlere göre müfredattaki farklı düzenlemeleri ve yolları değerlendirmekle görevli bir değerlendirme aracısını temsil eder.

Feromon İzleri (Değerlendirme Puanları)

Karıncalar eğitim programı bileşenleri boyunca çeşitli yolları keşfettikçe, arkalarında değerlendirme puanlarına eşdeğer bir feromon izi bırakırlar. Daha yüksek feromon seviyeleri, değerlendirme kriterlerine göre daha etkili veya verimli eğitim programı yollarını gösterir.

Feromon Buharlaşması ve Yoğunlaşması

Güncellliğini yitirmiş veya daha az etkili eğitim programı unsurlarının zaman içinde azalan etkisini simüle eden, feromon buharlaşmasına yönelik mekanizmaların dahil edilmesi. Tersine, sürekli olarak yüksek puanlar alan yollarda feromon seviyelerinin yoğunlaşması görülür ve bu da onların etkililiğine işaret eder.

Yinelemeli Araştırma ve Optimizasyon

Birden fazla yineleme yoluyla, sanal karıncalar eğitim programı yollarını keşfeder, değerlendirme geliştirir. Bu yinelemeli süreç, gerçek zamanlı geri bildirime ve gelişen eğitim hedeflerine dayalı olarak müfredatın dinamik olarak uyarlanması ve optimize edilmesine olanak tanır.

En Uygun Eğitim Programı Yolunu Belirleyin

En uygun eğitim programı yolu, yinelemeler boyunca en yüksek toplu değerlendirme puanlarını gösteren, en güçlü feromon izine sahip olan yol olarak tanımlanır. Bu yol, müfredat bileşenlerinin en etkili birleşimini ve sıralamasını temsil eder.

Uygulama ve İzleme

Optimize edilmiş eğitim programını uygulayın ve etkinliğini izlemeye devam edin. Eğitim programının standartlarındaki, teknolojik ilerlemelerdeki ve öğrenci ihtiyaçlarındaki değişikliklere duyarlı kalmasını sağlamak için sanal karıncalar periyodik olarak yeniden konuşlandırılabilir.

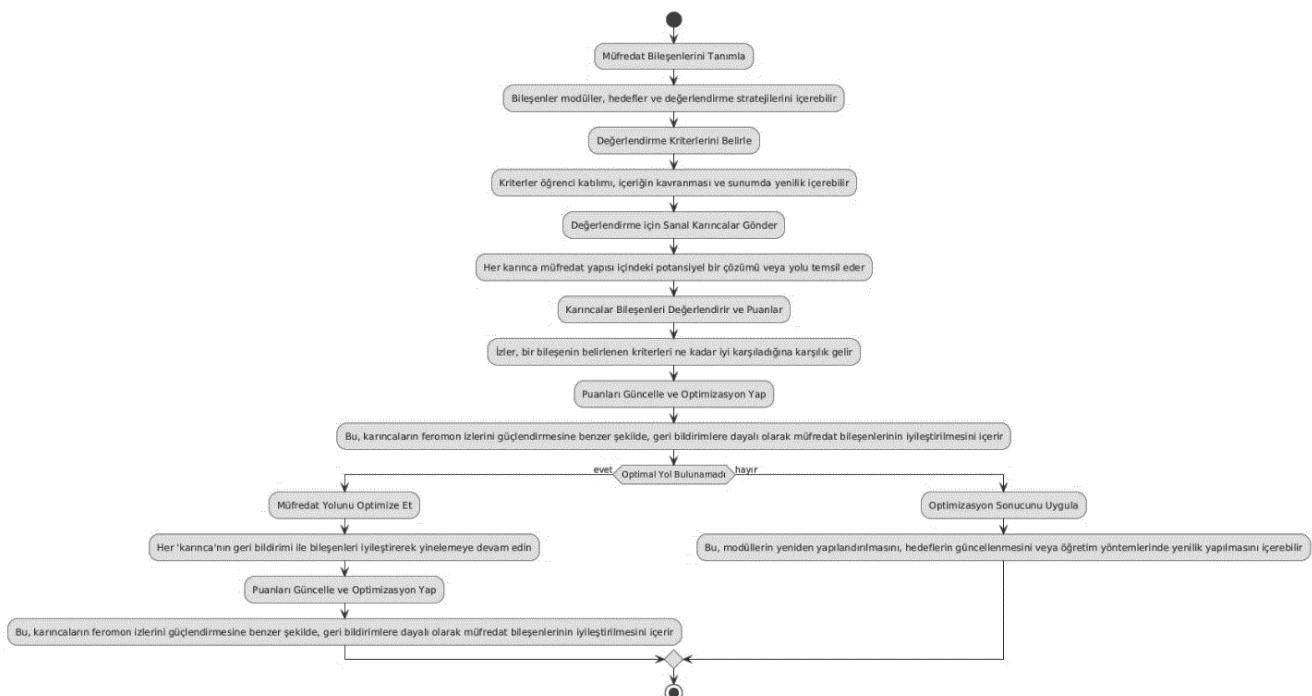
Devamlı Gelişme

ACA tabanlı model, yeni müfredat bileşenlerinin, öğretim yöntemlerinin ve teknolojilerin değerlendirmeye sürecine kolayca eklenmesine izin vererek sürekli iyileştirmeyi kolaylaştırır. Bu, eğitim programının en ileri düzeyde kalmasını ve en iyi uygulamalarla uyumlu olmasını sağlar.

Karınca Kolonisi Optimizasyon algoritması, müfredat değerlendirmesini daha etkili hale getirmek (Şekil 4) ve öğrenci başarısını artırmak için güçlü bir araç olabilir. <https://tez.yok.gov.tr/> adresinde bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin herhangi bir teze rastlanmamıştır. Ancak Web of Science'da bu konuya ilgili eğitim bilimleri kategorisi altında 90 çalışmaya rastlanmıştır (Duan ve diğerleri, 2015; Dwivedi ve diğerleri, 2018; El Fazazi ve diğerleri, 2019; Hoe, 2014; Jiang ve Lu), 2022; Khamparia ve Pandey, 2015; Kickmeier-Rust ve Holzinger, 2020; Sharma ve Harkishan, 2019; 2020 ; Shukhman ve diğerleri, 2018; Vuong ve diğerleri, 2018; Zilinskiene ve diğerleri, 2012; Bu çalışmalar, eğitim bilimleri ve yapay zeka alanlarını birleştirerek yapay zeka teknolojilerinin eğitimde nasıl kullanılabileceğini ve öğrenme deneyimlerini nasıl geliştirebileceğini araştırmaktadır.

Şekil 4

Karınca Kolonisi Algoritmasına Dayalı Eğitim Programı Değerlendirme Modeli



Yapay Bağışıklık Algoritması

Yapay Bağışıklık Algoritmalarının geliştirilmesi, doğal bağışıklık sisteminin belirli özelliklerinden ilham almaktadır. Bağışıklık sisteminin bir algoritma olarak modellenmesi akıllı sistemler, eğitim

programları ve eğitim programı değerlendirme yaklaşımları için çok önemli olabilir. Bağışıklık sistemi, çeşitli avantajlar sunarken vücutu potansiyel tehditlere karşı koruyan bir dizi karmaşık özellik ve stratejiyle donatıldığı için akıllı kabul edilir. Bağışıklık sisteminin neden akıllı bir sistem olarak kabul edildiğini yorumlayan bazı temel özellikler şunlardır (Karaboga, 2018; Yurttakal, 2014):

1. Benzersizlik: Her bireyin bağışıklık sistemi benzersizdir ve vücutu tehdit eden patojenleri tanımak ve bu patojenlere karşı özelleştirilmiş bir savunma geliştirmek için gereklidir. Bu, potansiyel tehditlere karşı benzersiz bir koruma yeteneği sağlar.
2. Anormal Tespit: Bağışıklık sistemi daha önce hiç karşılaşmadığı yabancı patojenleri tanıyabilir ve onlara tepki verebilir. Bu, vücutu olası tehlikelere karşı sürekli izleyen ve tutarsızlıklarını tespit eden akıllı bir sistemin işaretini olarak düşünülebilir.
3. Takviyeli Öğrenme: Bağışıklık sistemi, daha hızlı ve daha etkili bir savunma geliştirmek için patojenlerin yapısını öğrenebilir. Bu, öğrenme ve deneyimlerden yararlanma yeteneği açısından zekayı gösterir.
4. Çeşitlendirme: Bağışıklık sistemi çeşitli antikorların ve tehditlere karşı savunma mekanizmalarının gelişimini teşvik eder. Bu, sistemin birçok farklı senaryoya uyum sağlama yeteneğini yansıtır.
5. Hafıza: Bağışıklık sistemi daha önce karşılaştığı patojenlerin hafızasını tutar ve bu bilgiyi gelecekteki tehditlere karşı kullanır. Bu, önceki deneyimlerden ders alan ve gelecekteki tehditlere daha iyi yanıt veren bir zekanın işaretidir.
6. Dış Ortamlara Uyum Yeteneği: Bağışıklık sistemi çevresel değişikliklere hızlı uyum sağlama yeteneğiyle öne çıkar. Bu, vücutu anlık tehditlere karşı koruma yeteneğini yansıtır.
7. Dağıtılmış Tespit: Sistemin hücreleri, herhangi bir merkezi kontrol sistemi olmadan vücutun her yerine dağılmıştır.
8. Spesifik Olmayan Saptamaya Tolerans (Gürültü toleransı): Reaksiyon için patojenin tam tanımı gerekli değildir. Bu durum bağışıklık sistemi tarafından tolere edilir.

Bu bağlamda yapay bağışıklık sistemi algoritmaları şunları içerir:

1. Negatif Seçim Algoritması
2. Yapay Bağışıklık Ağı Algoritması
3. Dendritik Hücre Algoritması
4. Klonal Seçim Algoritması

Özellikle ayrık bağışıklık ağı modelleri, örüntü tanıma, veri analizi, makine öğrenmesi ve optimizasyon alanlarındaki sorunların çözümünde sıkılıkla başvurulan bir yöntem olarak karşımıza çıkmaktadır (De Castro ve Timmis, 2003; Tanış, 2019).

Eğitimde program değerlendirmesinde bu ilkelerin uygulanması, doğal bağışıklık sisteminin uyarlanabilir, dirençli ve dağıtılmış özelliklerini taklit ederek eğitim programının geliştirilme, izlenme ve iyileştirilmesi biçiminde devrim yaratılabilir.

Doğal bağışıklık sisteminin zorluklara uyum sağlama ve bunlara yanıt verme yeteneğinden ilham alan Yapay Bağışıklık Algoritması, müfredatın sürekli iyileştirilmesi ve öğrenci ihtiyaçlarına uyum sağlanması için dinamik bir yöntem sunar. Böyle bir model şu şekilde yapılandırılabilir (Şekil 5):

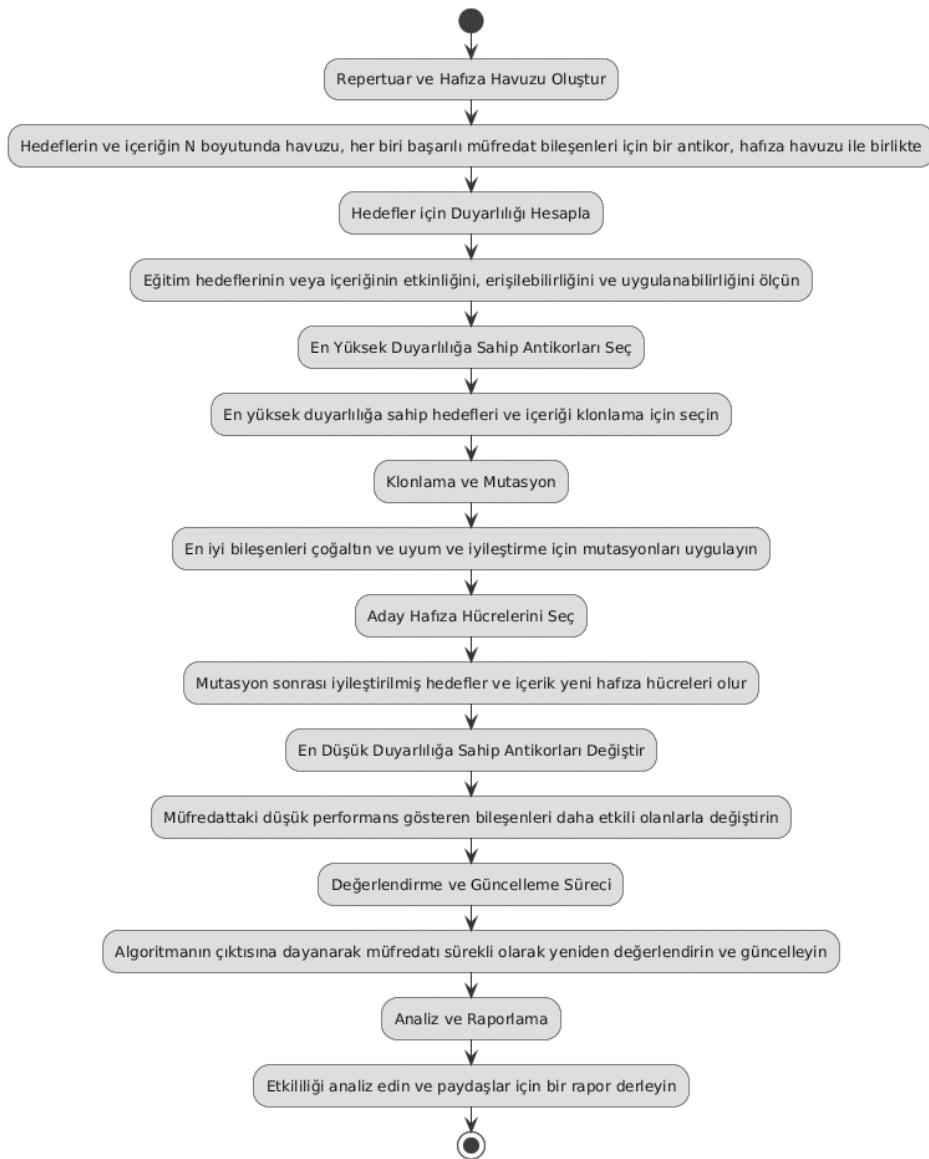
1. Repertuar ve Hafıza Havuzunu Oluşturun:
 - N boyutta bir hedef ve içerik havuzu oluşturun.

- Her hedefi ve içeriği bir antikor olarak düşünün.
 - Eğitim programının başarılı hedeflerini ve içeriğini içeren bir hafıza havuzu oluşturun.
2. Hedefler için Hassasiyeti Hesaplayın:
 - Rastgele bir eğitim hedefi veya içeriği seçin.
 - Duyarlılığını (etkinlik, erişilebilirlik ve uygulanabilirlik) hesaplayın.
 3. En İyi Hassasiyete Sahip Antikorları (Hedefler/İçerik) Seçin:
 - En yüksek hassasiyete sahip n hedef ve içeriği seçin.
 - Öğrenci başarısı ve katılımı gibi kriterlere göre seçilen bu hedefleri ve içeriği kopyalayın.
 4. Klonlama ve Mutasyon:
 - Seçilen en iyi hedeflerin ve içeriğin klonlarını üretin.
 - Öğrenme yöntemleri ve teknolojik araçlar gibi değişkenleri içerecek şekilde klon setine mutasyonlar uygulayın.
 - Klon setinin hassasiyetini hesaplayın (yeni ve eski eğitim yöntemlerine uyum).
 5. Aday Bellek Hücrelerini seçin:
 - Mutasyondan sonra geliştirilmiş hedefleri ve içeriği seçin.
 - Bu hedefleri ve içeriği yeni hafıza hücreleri olarak aday gösterin.
 6. Antikorları (Hedefler/İçerik) En Düşük Hassasiyetle Değiştirin:
 - Müfredattaki düşük performanslı hedefleri ve içeriği değiştirin.
 - Yeni ve daha etkili hedefleri ve içeriği programa entegre edin.
 7. Süreç Değerlendirmesi ve Güncelleme:
 - Programı yeniden değerlendirip gerekli güncellemeleri yapın.
 - Hedeflerin ve içeriğin sürekli güncellenmesi ve geliştirilmesi için algoritmayı periyodik olarak tekrarlayın.
 8. Eğitim Programının Etkililiğinin Analizi ve Raporlanması:
 - Algoritmanın sonuçlarını analiz edin.
 - Müfredatın etkililiğine ilişkin kapsamlı bir rapor hazırlayın.
 - Raporu ilgili paydaşlarla (öğretmenler, yöneticiler, öğrenciler, veliler) paylaşın.

Tezyök'te bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin herhangi bir teze rastlanmamıştır. Ancak Web of Science'da bu konuya ilgili eğitim bilimleri kategorisi altında 31 çalışmaya rastlanmış olup bunlardan sadece ikisi doğrudan veya dolaylı olarak bu konuyu ele almıştır (Hussain ve diğerleri, 2019; Samigulina ve Samigulina, 2016).

Şekil 5

Klonal Seçim Algortimasına Dayalı Eğitim Program Değerlendirme Akyış Diyagramı



Öğrenme-Öğretmeye Tabanlı Optimisasyon Algoritması

Rao, Savsani ve Vakharia tarafından 2011 yılında geliştirilen Öğretme-Öğretme Tabanlı Optimizasyon (ÖÖTO) algoritması, küresel bir çözüme ulaşmak için çözüm popülasyonunu kullanan popülasyon tabanlı bir yöntemdir. Bu bağlamda evren, bir grup öğrenci veya bir sınıf öğrenci olarak kabul edilir. ÖÖTO süreci iki bölümden oluşur: 'Öğretmen Aşaması' ve 'Öğrenci Aşaması'. 'Öğretmen Aşaması' öğretmenden öğrenmeyi temsil ederken, 'Öğrenci Aşaması' öğrenciler arasındaki etkileşim yoluyla öğrenmeyi temsil eder. ÖÖTO uygulaması adım adım şekilde anlatılabilir (Mohammadi, 2022). Öğretme-Öğrenim Temelli Optimizasyon (CPO-TLBO) Algoritmasını Kullanarak Müfredat Programı Optimizasyonu şu şekilde sunulabilir (Şekil 6):

Adım 1: Optimizasyon Problemini Tanımlayın ve Parametreleri Başlatın

Öğrenci sayısı (nüfus büyülüğu), nesil sayısı (ynelemeler), ders sayısı (tasarım değişkenlerinin sayısı) ve derslerin sınırları (üst ve alt sınırlar) gibi optimizasyon parametrelerini başlatın. Optimizasyon problemi, X 'in rotaların bir vektörü olduğu ve her rotanın belirli sınırlar içinde olması gereği $f(X)$ fonksiyonunun en aza indirilmesi olarak tanımlanır.

Adım 2: Popülasyonu Başlatın

Popülasyon büyüklüğüne ve kurs sayısına göre rastgele bir popülasyon oluşturun. ÖÖTO'da popülasyon büyülüğu öğrenci sayısını, tasarım değişkenleri ise sunulan dersleri temsil etmektedir.

Adım 3: Öğretmen Aşaması

Popülasyonun sütun bazında ortalamasını hesaplayın. Bu, belirli bir ders için ortalama notları verecektir. Bu yineleme için en iyi çözüm, öğretmenin rolünü üstlenir ve diğer öğrencilerin ortalama notlarını yükseltmeye çalışır (çözümler).

Adım 4: Öğrenci Aşaması

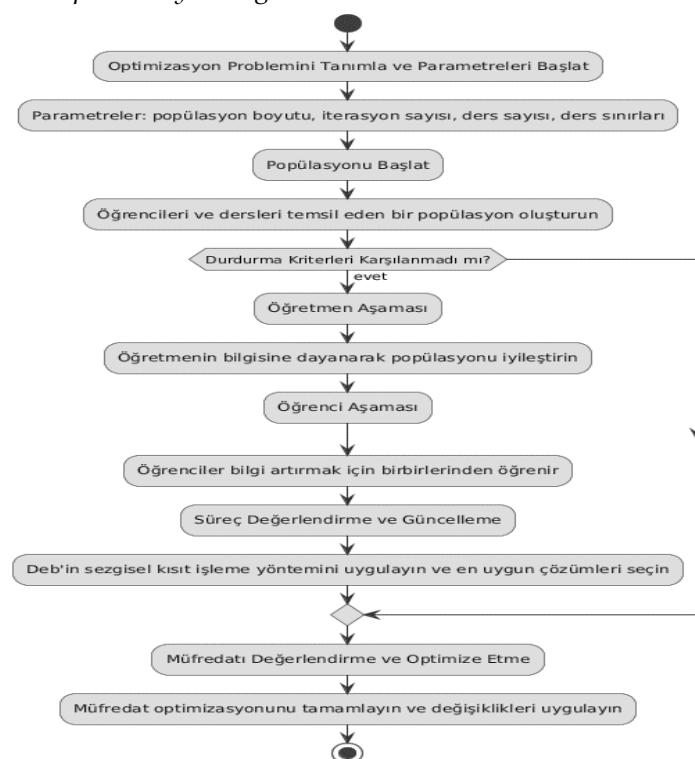
Öğrenciler bilgi ve becerilerini geliştirmek için birbirleriyle etkileşime girerler. Bu aşamada rastgele seçilen iki çözüm karşılaştırılır ve birbirlerinden öğrenerek kendilerini geliştirirler.

Adım 5: Durdurma Kriteri

Maksimum nesil sayısına ulaşıldığında veya diğer sonlandırma kriterleri karşılandığında süreç sona erer.

Şekil 6

Öğrenme-Öğretme Tabanlı Optimisasyon Algoritması



Tezyök'te bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin herhangi bir teze rastlanmamıştır. Ancak Web of Science'ta eğitim bilimleri kategorisi altında bu konuya ilgili yapılan 10 çalışmadan bir tanesinin doğrudan eğitimle ilgili olduğu tespit edilmiştir (Arashpour ve diğerleri, 2023). Bu, Öğretme-Öğrenim Temelli Optimizasyon (TLBO) algoritmasının eğitim bilimlerinde uygulanması hala ortaya çıkıyor olsa da, müfredatların optimize edilmesi ve öğretme ve öğrenme süreçlerinin iyileştirilmesinde kullanımına yönelik ilginin ve potansiyelin arttığını göstermektedir. Arashpour ve diğerleri (2023) tarafından yapılan çalışma, TLBO algoritmasının eğitim ortamlarında nasıl uygulanabileceğine dair değerli bilgiler sağlayabilir ve potansiyel olarak müfredat tasarımini, öğrenci katılımını ve genel eğitim sonuçlarını geliştirmeye yönelik yenilikçi çözümler sunabilir.

Diferansiyel Gelişim Algoritması

Çözüm vektörleri arasındaki farkları temel alan Diferansiyel Evrim (DE) Algoritması, özellikle sayısal optimizasyon problemleri için geliştirilmiştir. Bu algoritma genetik algoritma tabanlı, popülasyon tabanlı sezgisel bir küresel optimizasyon tekniğidir (Dumlu, 2023). Eğitim programını hedefler, içerik, öğretim senaryoları ve değerlendirme boyutları açısından geliştirmek için Diferansiyel Evrim (DE) Algoritmasını temel alan bir eğitim programı değerlendirme algoritması kullanılabilir. Aşağıda bu algoritmayı kullanarak eğitim programı değerlendirme için uyarlanmış bir model bulunmaktadır (Şekil 7):

1. Başlatma

- Optimizasyon Problemini Tanımlayın: Eğitim programının hedeflerini, içeriğini, öğretim senaryolarını ve değerlendirme yöntemlerini belirleyin.
- Başlangıç Nüfusunun Oluşturulması: NP rastgele eğitim programı düzenlemeleri (çözümler) oluşturun. Her düzenleme eğitim programının hedeflerini, içeriğini, öğretim senaryolarını ve değerlendirme stratejilerini temsil eder.

2. Mutasyon

- Rastgele Seçim: Her program düzenlemesi (X_i) için popülasyondan rastgele üç farklı eğitim programı düzenlemesi (X_{r1}, X_{r2}, X_{r3}) seçin.
- Mutant Eğitim Program Düzenlemesi Oluşturun: Yeni bir mutant program düzenlemesini (V_i) hesaplamak için seçilen üç eğitim programı düzenlemesini kullanın. Bu süreç farklı müfredat öğelerinin (hedefler, içerik vb.) birleştirilmesini içerir.

3. Geçiş

- Geçici Çözümün Elde Edilmesi: Mutant program düzenlemesinin özelliklerini, mevcut program düzenlemesinin özellikleriyle belirli bir olasılıkla (CR) değiştirilerek yeni bir geçici eğitim programı düzenlemesi (u_i) elde edilir. Bu, programın hedeflerinde, içeriğinde veya değerlendirme yöntemlerinde değişiklik anlamına gelir.

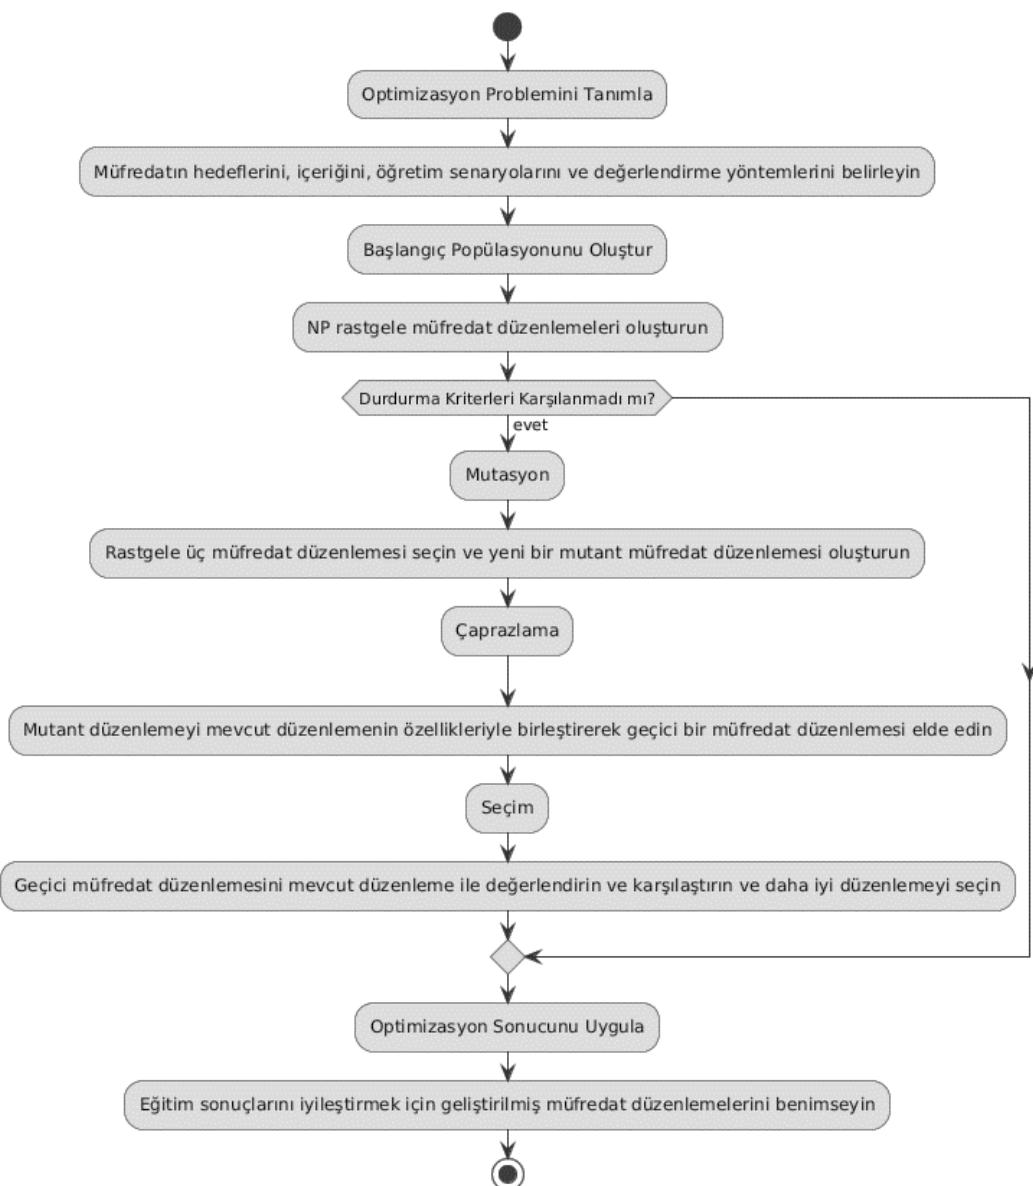
4. Seçim

- Değerlendirme ve Karşılaştırma: Geçici eğitim programı düzenlemesi, önceden belirlenen değerlendirme kriterlerine göre mevcut program düzenlemesi ile karşılaştırılır. Daha iyi olan düzenleme belirlenerek bir sonraki nesle aktarılır.

5. Durdurma Kriteri

- Yineleme Tekrarı: Tanımlanmış bir sonlandırma kriteri karşılanana kadar mutasyon, çaprazlama ve seçim adımlarını tekrarlayın. Bu, belirli sayıda yinelemeye ulaşmak, belirli bir düzeyde iyileştirme elde etmek veya başka bir sonlandırma koşulu olabilir.

Şekil 7

Diferansiyel Gelişim Algortimasına Dayalı Bir Eğitim Program Değerlendirme Akış Diyagramı

Tezyök'te bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin herhangi bir teze rastlanmamıştır. Ancak Web of Science'da eğitim bilimleri alanında bu anahtar kelimeyle ilgili 30 çalışma tespit edilmiş ancak bunlardan sadece üçü doğrudan bu algoritmanın eğitim bilimlerinde uygulanmasıyla ilgilidir (Liu ve diğerleri, 2017; Wang ve diğerleri, 2009a-b).

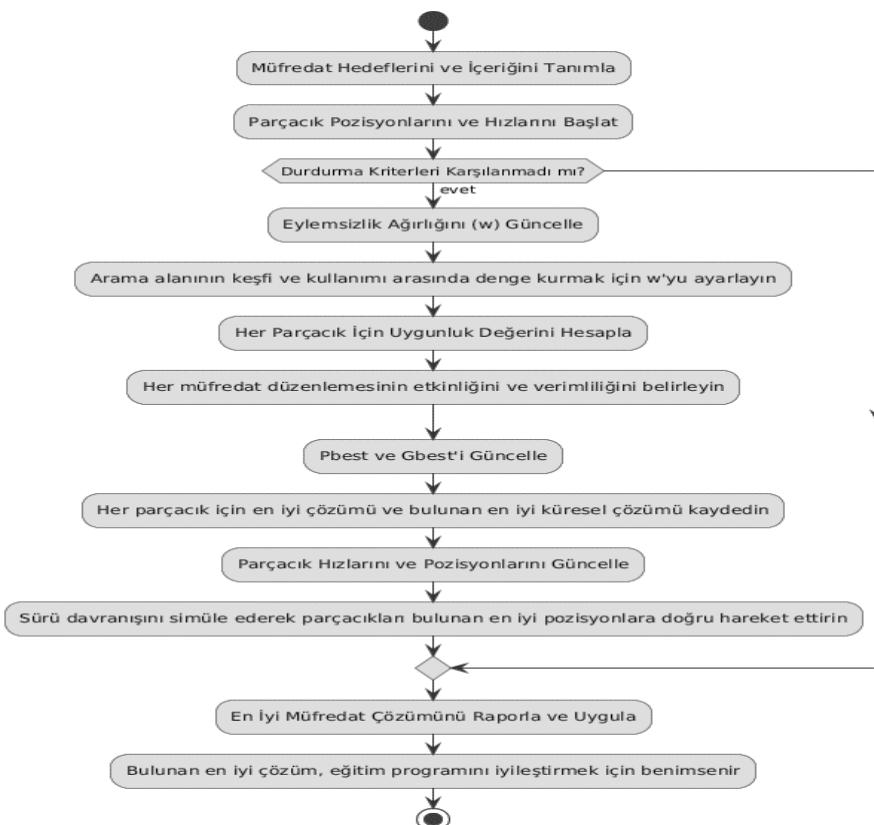
Parçacık Sürü Optimisasyonu

Parçacık Sürü Optimisasyonu (PSO), her parçacığın kendi konumunu ve hızına sahip olduğu, en iyi konumunu hatırladığı ve birbirleriyle bilgi paylaştığı bir parçacık sürüsünün davranışından ilham alır. Bu yaklaşım davranışsal modellemeye dayanmaktadır ve evrimsel prensipler yerine canlıların davranışlarından ilham almasıyla genetik algoritmaların ayrılmaktadır (Şahin, 2019). PSO algoritması kullanılarak program değerlendirme için aşağıdaki model önerilebilir (Gülcü, 2017) (Şekil 8).

Aram'ın (2012) bu konuya ilgili bir tezi Tezyök'te mevcuttur ve bu tez, eğitim ortamlarında PSO uygulamasının erken dönem araştırmalarını göstermektedir. Ayrıca Web of Science dergisinde eğitim alanında bulunan 77 çalışmadan dördü doğrudan bu konuya ilgilidir (Alhunitah ve Menai, 2016; Rashid ve Ahmad, 2016; Zervoudakis ve diğerleri, 2020). Bu çalışmalar, eğitim programlarının optimize edilmesi ve değerlendirilmesi için PSO'dan yararlanmaya yönelik potansiyelin ve artan ilginin altını çizmektedir.

Şekil 8

Parçacık Sürüsü Algortimasına Dayalı Bir Eğitim Program Değerlendirme Akyış Diyagramı



Yapay Arı Kolonisi Algoritması

Yapay Arı Kolonisi Algoritması, bal arısı kolonilerinin zengin nektar besin kaynaklarını ararken sergilediği akıllı davranışlarından ilham almıştır. Karaboğa (2005) bu algoritmayı arıların doğal yiyecek toplama süreçlerinden esinlenerek geliştirmiştir. Algoritma, arıların yiyecek bulma ve bilgi paylaşım davranışlarını taklit eder. Görevli işçi arılar besin kaynaklarını kovana geri getirir ve bu bilgiyi besin kaynağının konumunu ve kalitesini temsil eden bir dans aracılığıyla diğer arılara iletirler (Karaboğa, 2018). Eğitimde program değerlendirme için Yapay Arı Kolonisi Algoritması uygulanarak aşağıdaki gibi bir süreç modeli geliştirilebilir (Şekil 9):

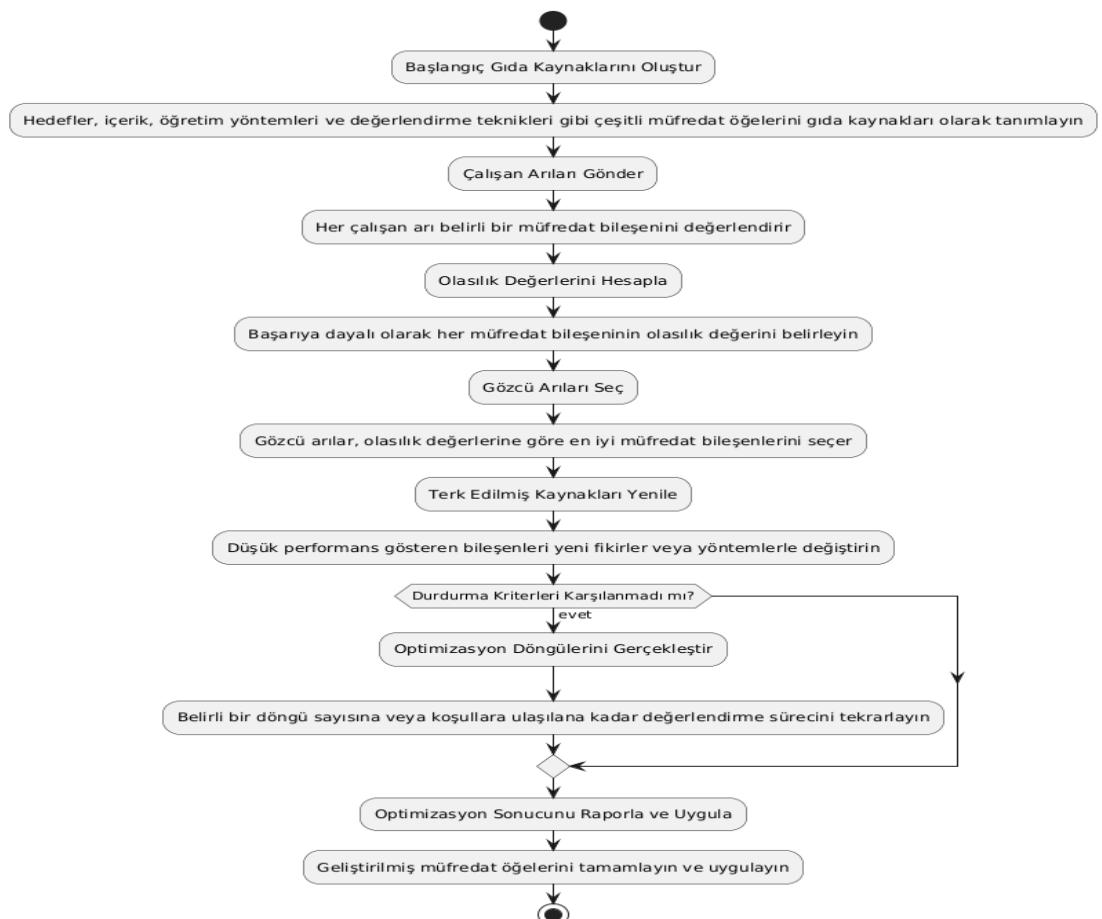
1. İlk Gıda Kaynağı Bölgelerinin Oluşturulması:
 - Eğitim programının hedeflerini, içeriğini, öğretim yöntemlerini ve değerlendirme tekniklerini temsil eden çeşitli "besin kaynakları" oluşturun.
2. Çalışan Arıların Gönderilmesi:
 - Her "görevli arı" (müfredat düzenlemesi) belirli bir besin kaynağını (müfredat bileşeni) değerlendirir.

3. Olasılık Değerlerinin Hesaplanması:
 - Görevli arılar tarafından toplanan bilgilere (programın başarısı) dayanarak, her yiyecek kaynağı için bir olasılık değeri hesaplayın.
4. Gözcü Arıların Seçimi:
 - "Gözcü arılar" (değerlendirme ekipleri) olasılık değerlerine göre en iyi yiyecek kaynağını (müfredat bileşeni) seçerler.
5. Terk Edilen Kaynakların Yenilenmesi:
 - Düşük performanslı müfredat bileşenlerini terk edin ve bunları yeni "keşif arıları" (yeni eğitim fikirleri veya yöntemleri) ile değiştirin.
6. Durdurma Kriteri:
 - Belirli bir çevrim sayısına ulaşıldığında veya diğer sonlandırma koşulları karşılandığında işlemi sonlandırın.
7. Nihai Gıda Pozisyonlarının Raporlanması:
 - Optimize edilmiş müfredat bileşenlerinin son durumunu raporlayın ve uygulayın.

Bu süreç eğitim programlarının sürekli iyileştirilmesi ve uyarlanması için bir çerçeve sağlar. <https://tez.yok.gov.tr/> adresinde bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin herhangi bir teze rastlanmamıştır. Ancak Web of Science'da eğitim bilimleri kategorisinde bu algoritmanın eğitimde kullanımına ilişkin bir çalışma tespit edilmiştir (Alhunitah ve Menai, 2016). Bu, Yapay Arı Kolonisi Algoritmasının işbirlikçi ve yinelemeli bir süreç yoluyla müfredatların geliştirilmesi ve optimize edilmesinde potansiyel uygulamasını göstermektedir.

Şekil 9

Yapay Arı Kolonisi Algortimasına Dayalı Bir Program Değerlendirme Akış Diyagramı



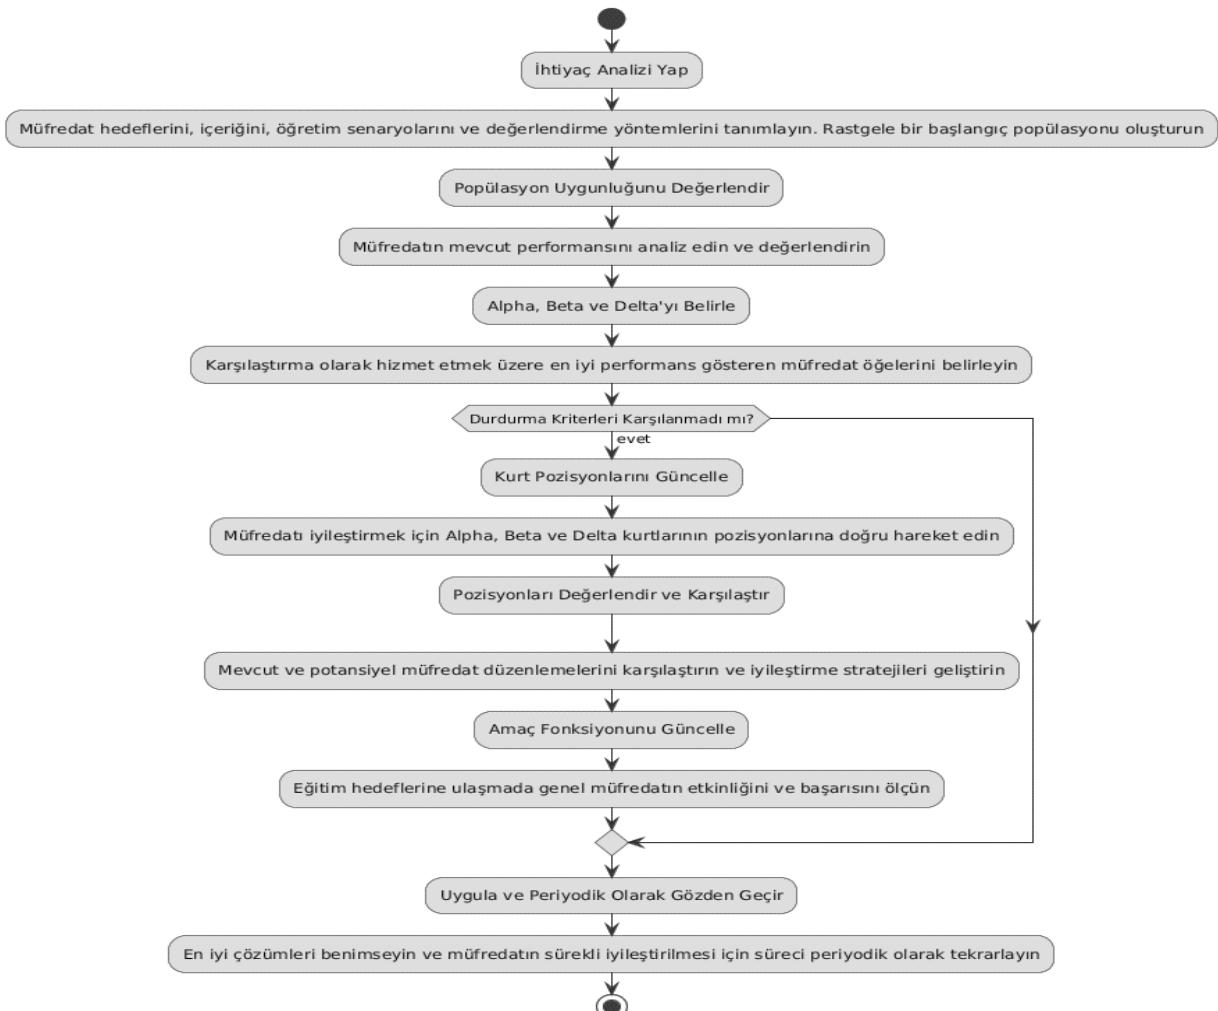
Bozkurt Algoritması

Bozkurt Optimisasyon Algortiması, bozkurt sürülerinin sosyal hiyerarşisi ve avlanma davranışları temel alınarak geliştirilmiş ve içinde dört hiyerarşi düzeyine sahip bir optimizasyon algoritmasıdır: alfa, beta, delta ve alfanın lider olduğu omega. Avlanma davranışları avı takip etmeyi, kuşatmayı, taciz etmeyi ve son olarak da ona saldırmayı içerir (Şahin, 2019). Eğitimde program değerlendirme için Bozkurt Optimizasyon Algoritması uygulandığında, temel unsurlar dikkate alınarak aşağıdaki gibi bir süreç modeli oluşturulabilir (Şekil 10): 1. Başlatma Aşaması, 2. Nüfus Uygunluğunu Değerlendirme, 3. Alfa, Beta ve Konumlarının Güncellenmesi Delta Wolves, 4. Kurtların Eski ve Yeni Pozisyonları Arasındaki İlişkinin Değerlendirilmesi, 5. Amaç Fonksiyonu, 6. Sonlandırma Kriteri

<https://tez.yok.gov.tr/> adresinde bu algoritmanın eğitim bilimleri alanında kullanımına ilişkin bir teze rastlanmadığı gibi Web of Science'ta da bu algoritmanın eğitimde kullanımına ilişkin bir çalışmaya rastlanmamıştır.

Şekil 10

Bozkurt Optimisasyon Algoritmasına Dayalı Eğitimde Program Değerlendirme Akış Diyagramı



Önerilen Model: Metasezgisel Eğitim Programı Değerlendirme Modeli (MEPDM)

Çeşitli metasezgisel yapay zeka (AI) optimizasyon algoritmalarının ve bunların eğitim program değerlendirme süreçlerindeki potansiyel uygulamalarının kapsamlı analizine dayanarak, yeni bir Metasezgisel Eğitim Programı Değerlendirme Modeli (MEPDM) önerilebilir. Bu model, eğitim programlarında müfredat tasarımını, içeriğini, sunumunu ve değerlendirmeyi geliştirmek için farklı yapay zeka optimizasyon algoritmalarının güçlü yönlerinden yararlanmayı amaçlamaktadır. MEPDM, modern eğitim sistemlerinin dinamik ihtiyaçlarını karşılayabilecek, esnek, uyarlanabilir ve verimli olacak şekilde tasarlanmıştır. Önerilen model aşağıdaki temel bileşenleri içermektedir:

1. Model Başlatma

- İhtiyaç Analizi: Hedef öğrenci nüfusunun özel gereksinimlerini dikkate alarak eğitim programının amaç ve hedeflerini belirlemek için kapsamlı bir ihtiyaç analizi yapın.
- Hedef Belirleme: Eğitim programının ulaşmayı amaçladığı hedefleri eğitim standartları ve öğrenci ihtiyaçlarıyla uyumlu hale getirerek açıkça tanımlayın.
- Algoritma Seçimi: Eğitim programının özel ihtiyaçlarına ve hedeflerine göre en uygun meta-sezgisel yapay zeka optimizasyon algoritmalarını seçin. Örneğin, Genetik Algoritma ders dizilerini optimize etmek için ideal olabilirken, Karınca Kolonisi Algoritması kaynak tahsis stratejilerini geliştirebilir.

2. Eğitim Programı Bileşeni Optimizasyonu

- Eğitim Programı Haritalaması: Öğrenme hedeflerini, ders içeriğini, öğretim metodolojilerini ve değerlendirme tekniklerini içeren kapsamlı bir eğitim programı haritası geliştirin.
- Algoritma Uygulaması: Eğitim program haritasının her bir bileşenini optimize etmek için seçilen meta-sezgisel algoritmaları uygulayın. Bu adım, algoritmaların geri bildirimlerine dayalı olarak yinelemeli keşif, değerlendirme ve uyarlama süreçlerini içerir.
- Bileşen Entegrasyonu: Optimize edilmiş bileşenleri tutarlı bir eğitim programı yapısına entegre edin ve tüm öğelerin tanımlanan eğitim hedeflerine ulaşmak için sinerji içinde çalışmasını sağlayın.

3. Verilerin toplanması ve analizi

- Performans Ölçümleri: Eğitim programının etkinliğini değerlendirmek için öğrenci katılımı, öğrenme sonuçları ve eğitimcilerden ve öğrencilerden gelen geri bildirimler gibi performans ölçümleri oluşturun.
- Veri İşleme: Toplanan verileri işlemek ve analiz etmek, kalıpları, güçlü yönleri, zayıf yönleri ve daha fazla iyileştirme fırsatlarını belirlemek için yapay zeka algoritmalarından yararlanın.

4. Yinelemeli İyileştirme ve Adaptasyon

- Model Değerlendirmesi: Tanımlanan performans ölçümlerini ve yapay zeka tarafından işlenmiş veri analizini kullanarak eğitim programını düzenli olarak değerlendirin.
- Geribildirim Döngüsü: Değerlendirme aşamasından elde edilen bilgilerin eğitim programı bileşenlerinin daha fazla optimizasyonu için bilgi sağladığı ve sürekli iyileştirme sağlayan bir geri bildirim döngüsü oluşturun.
- Uyarlama: Eğitim programının gelişen eğitim hedeflerine, teknolojik gelişmelere ve öğrenci geri bildirimlerine dayalı olarak dinamik olarak uyarlanması izin verin.

5. Uygulama ve İzleme

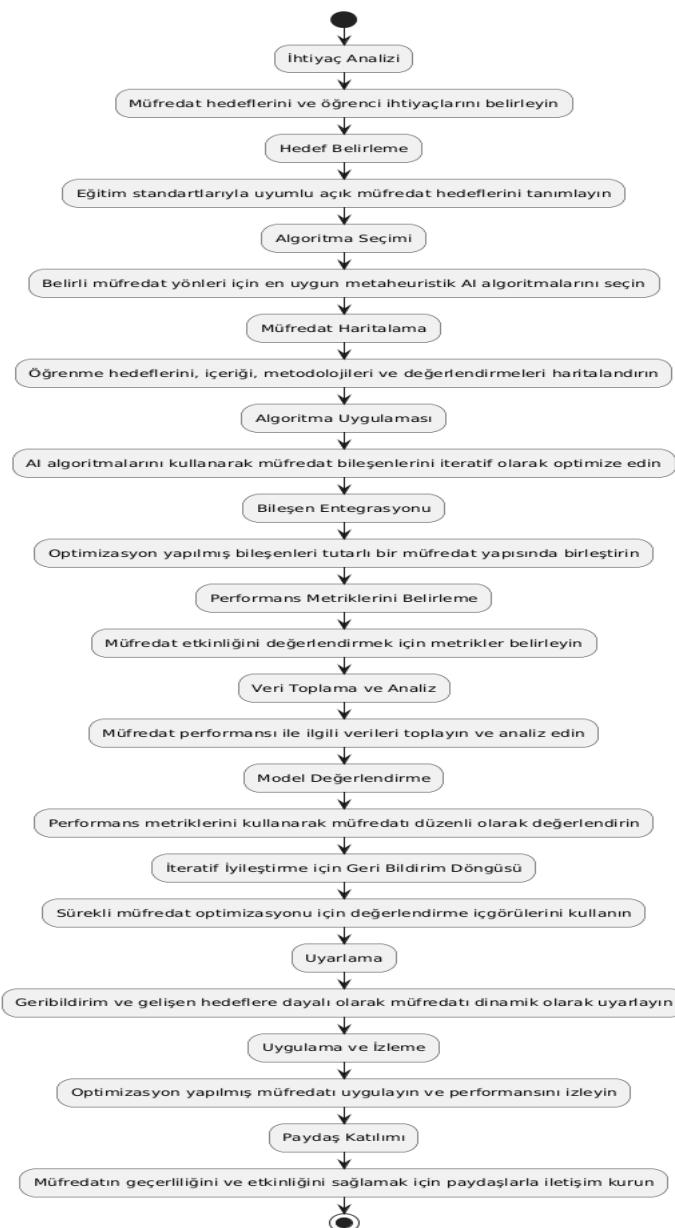
- Kullanıma sunma: Optimize edilmiş müfredatın hedef eğitim programı veya kurumda uygulanması.
- Sürekli İzleme: Yapay zeka algoritmalarını kullanarak eğitim programının performansını sürekli olarak izleyin ve etkililiği korumak veya artırmak için bileşenleri gerektiği gibi ayarlayın.

6. Paydaş Katılımı

- İletişim: Geri bildirim toplamak ve eğitim programının onların ihtiyaç ve bekłentilerini karşıladığından emin olmak için eğitimciler, öğrenciler, yöneticiler ve veliler de dahil olmak üzere tüm paydaşlarla düzenli olarak iletişim kurun.
- İşbirliği: Eğitim programının başarısına yönelik sahiplenme ve bağlılık duygusunu geliştirmek için paydaşlar arasında işbirliğini teşvik edin.

Şekil 11

Metasezgisel Eğitim Program Değerlendirme Modeli (MEPDM)



Metasezgisel Eğitim Programı Değerlendirme Modeli (MEPDM), yalnızca etkili ve verimli değil aynı zamanda hem öğrencilerin hem de eğitimcilerin ihtiyaçlarına son derece uyaranabilir eğitim programları oluşturmak için metasezgisel yapay zeka optimizasyon algoritmalarının gücünden yararlanarak müfredat geliştirme ve değerlendirme yeni bir yaklaşımı temsil eder. Eğitim kurumları, bu algoritmaları müfredat değerlendirme sürecine entegre ederek, sağladıkları eğitimin kalitesini önemli ölçüde artırabilir ve öğrencileri 21. yüzyılın zorluklarına daha etkili bir şekilde hazırlayabilirler.

Meta-Sezgisel Eğitim Programı Değerlendirme Modeli (MEPDM) Eğitim Sistemlerine Entegre Etme Uygulama Planı

Aşama 1: Planlama ve Hazırlık

1. İhtiyaç Değerlendirmesi

- Hedef
 - Belirli ihtiyaçları ve hedefleri belirlemek.
- Faaliyetler
 - Paydaşlarla (eğitimciler, yöneticiler, öğrenciler ve veliler) anketler ve odak grup tartışmaları yapmak.
 - Mevcut eğitim programı ve değerlendirme uygulamalarını gözden geçirmek.
 - Boşlukları ve iyileştirme alanlarını belirlemek.

2. Paydaş Katılımı

- Hedef
 - Tüm paydaşlardan destek ve katılım sağlamak.
- Faaliyetler
 - MEPDM'in faydalarını ve işleyişini açıklamak için bilgilendirme toplantıları ve atölye çalışmaları düzenlemek.
 - Tüm paydaş gruplarından temsilciler içeren bir proje ekibi oluşturmak.

Aşama 2: Tasarım ve Geliştirme

1. MEPDM'in Özelleştirilmesi

- Hedef
 - İhtiyaç değerlendirmesinde belirlenen özel ihtiyaçlara göre MEPDM'i uyarlamak.
- Faaliyetler
 - Değerlendirilecek eğitim programı bileşenlerine göre uygun meta-sezgisel algoritmaları seçmek.
 - Öğrenme hedefleri, ders içeriği, öğretim yöntemleri ve değerlendirme tekniklerini içeren kapsamlı bir eğitim programı haritası geliştirmek.

2. Algoritma Geliştirme ve Entegrasyonu

- Hedef
 - Seçilen meta-sezgisel algoritmaları eğitim programı değerlendirme sürecine entegre etmek.
- Faaliyetler
 - Seçilen algoritmaları uygulamak için yazılım araçları geliştirmek veya uyarlamak.

- Algoritmaların işlevselliğini sağlamak için örnek eğitim programı verileri üzerinde testler yapmak.

Aşama 3: Eğitim ve Kapasite Geliştirme

1. Eğitimciler ve Yöneticiler için Eğitim Programları

- Hedef
 - Eğitimciler ve yöneticileri MEPDM'i etkin bir şekilde kullanabilmeleri için gerekli beceri ve bilgilerle donatmak.
- Faaliyetler
 - Eğitim materyalleri ve kılavuzlar geliştirmek.
 - Uygulamalı eğitim atölyeleri düzenlemek:
 - MEPDM'in ilkeleri ve faydalari.
 - Verilerin nasıl girileceği ve algoritma çıktılarının nasıl yorumlanacağı.
 - Aşama 2'de geliştirilen yazılım araçlarının nasıl kullanılacağı.
 - Sürekli destek ve tazeleme kursları sağlamak.

2. Destek Yapılarının Oluşturulması

- Hedef
 - Sürekli destek ve sürekli iyileştirme sağlamak.
- Faaliyetler
 - Teknik sorunlar için yardımcı masa veya destek ekibi kurmak.
 - Deneyimlerin ve çözümlerin paylaşılması için çevrimiçi forumlar veya uygulama toplulukları oluşturmak.

Aşama 4: Pilot Test ve İyileştirme

1. Pilot Uygulama

- Hedef
 - Olası sorunları belirlemek için MEPDM'i kontrollü bir ortamda test etmek.
- Faaliyetler
 - MEPDM'i uygulamak için pilot okullar veya programlar seçmek.
 - Pilot uygulamadan veri toplamak ve analiz etmek.
 - Katılımcılardan geri bildirim toplamak.

2. İyileştirme

- Hedef
 - Pilot sonuçlara dayanarak MEPDM'i geliştirmek.
- Faaliyetler
 - Geri bildirimleri ve performans verilerini analiz etmek.
 - Algoritmalar, süreçler ve eğitim materyallerinde gerekli ayarlamaları yapmak.
 - Gerektiğinde yeniden test etmek.

Aşama 5: Tam Ölçekli Uygulama

1. Yaygınlaştırma Planı

- Hedef
 - MEPDM'i tüm eğitim sistemi genelinde uygulamak.
- Faaliyetler

- Zaman çizelgeleri ve sorumluluklar içeren ayrıntılı bir yaygınlaştırma planı geliştirmek.
 - Tüm okulları veya programları kapsayacak şekilde eğitim ve desteği genişletmek.
 - Uygulama ilerlemesini izlemek ve sorunları hızlıca çözmek.
2. Sürekli İzleme ve İyileştirme
- Hedef
 - MEPDM'in etkili ve ilgili kalmasını sağlamak.
 - Faaliyetler
 - Düzenli inceleme ve değerlendirme süreçleri oluşturmak.
 - Eğitimciler, yöneticiler ve öğrencilerden sürekli geri bildirim toplamak.
 - Eğitim standartlarındaki, teknolojilerdeki ve en iyi uygulamalardaki değişiklikleri yansıtmak için MEPDM'i güncellemek.

Aşama 6: Değerlendirme ve Raporlama

1. Değerlendirme
 - Hedef
 - MEPDM'in eğitim programının etkinliği ve eğitimsel sonuçlar üzerindeki etkisini değerlendirmek.
 - Faaliyetler
 - Belirli aralıklarla resmi değerlendirmeler yapmak.
 - MEPDM'in uygulanmasından önceki ve sonraki eğitimsel sonuçları karşılaştırmak.
 - Planlama aşamasında belirlenen performans metriklerini kullanmak.
2. Raporlama
 - Hedef
 - Bulguları paydaşlar ve daha geniş eğitim topluluğu ile paylaşmak.
 - Faaliyetler
 - Uygulama süreci, sonuçlar ve çıkarılan dersleri ayrıntılı olarak içeren kapsamlı raporlar hazırlamak.
 - Bulguları konferanslarda, atölye çalışmalarında ve akademik yaynlarda sunmak.
 - Daha fazla araştırma ve uygulama için önerilerde bulunmak.
3. Özeti Zaman Çizelgesi
 - Planlama ve Hazırlık
 - Tasarım ve Geliştirme
 - Eğitim ve Kapasite Geliştirme
 - Pilot Test ve İyileştirme
 - Tam Ölçekli Uygulama
 - Değerlendirme ve Raporlama

Gerekli Kaynaklar

1. İnsan Kaynakları:
 - Proje ekibi (eğitimciler, yöneticiler, IT uzmanları).
 - Eğitim kolaylaştırıcıları.
 - Teknik destek personeli.

2. Finansal Kaynaklar:

- Yazılım geliştirme ve lisanslar için bütçe.
- Eğitim ve atölye çalışması maliyetleri.
- Sürekli destek ve değerlendirme masrafları.

3. Teknolojik Kaynaklar:

- Algoritma entegrasyonu ve veri analizi için yazılım araçları.
- Veri işleme ve depolama için donanım.
- Eğitim ve destek için çevrimiçi platformlar.

Bu uygulama planını izleyerek, eğitim araştırmacıları ve kurumlar, MEPDM'i mevcut sistemlerine etkili bir şekilde entegre edebilir, böylece eğitim programı değerlendirmesini iyileştirir ve eğitimsel sonuçları artırır.

Meta-Sezgisel Eğitim Programı Değerlendirme Modeli (MEPDM) Entegrasyonu için Etik Çerçeve

Meta-sezgisel Eğitim Programı Değerlendirme Modeli (MEPDM)'nin eğitim sistemlerine entegrasyonu çeşitli etik konuları içerir. Bu konuları ele almak, yapay zeka destekli değerlendirme yöntemlerinin sorumlu ve adil bir şekilde uygulanmasını sağlamak için önemlidir. Bu çerçeve, MEPDM'nin kullanımında gizliliği sağlamak, önyargıyı azaltmak ve şeffaflığı korumak için etik ilkeleri ve önlemleri özetler.

Etik İlkeler

1. Gizlilik ve Mahremiyet:

- Değerlendirme sürecine dahil olan tüm bireylerin, öğrenciler, eğitimciler ve yöneticiler dahil olmak üzere, mahremiyetini korumak.
- Kişisel verilerin güvenli bir şekilde toplanmasını, saklanmasını ve işlenmesini sağlamak.

2. Adalet ve Eşitlik:

- MEPDM'nin herhangi bir grup bireyi dezavantajlı duruma sokabilecek önyargıları tanıtmamasını veya sürdürmemesini sağlamak.
- MEPDM'nin faydalaraına tüm eğitim ortamlarında eşit erişim sağlamak.

3. Şeffaflık ve Hesap Verebilirlik:

- MEPDM'nin nasıl çalıştığı ve önerilerinin ardından mantık hakkında açık ve anlaşılır bilgiler sağlamak.
- MEPDM'nin uygulanmasıyla ilgili herhangi bir endişeyi veya şikayetü ele almak için hesap verebilirlik mekanizmaları oluşturmak.

Gizliliği Sağlama Önlemleri

1. Veri Anonimleştirme:

- MEPDM'de kullanılan tüm kişisel verileri anonim hale getirmek, böylece bireylerin kimliklerinin tespit edilmesini önlemek.
- Eğitim ve değerlendirme için kullanılan veri setlerindeki tanımlayıcıları kaldırmak veya gizlemek.

2. Güvenli Veri Depolama ve İletim:

- Verileri depolamak ve iletmek için güçlü şifreleme yöntemlerini uygulamak.

- Sadece yetkili personelin erişebileceği güvenli sunucular ve veritabanları kullanmak.
3. Veri Erişim Kontrolleri:
- Hassas verilere yalnızca yetkili kişilerin erişmesini sağlamak için sıkı erişim kontrolleri tanımlamak ve uygulamak.
 - Veri erişiminizizi izlemek ve yönetmek için erişim kayıtlarını düzenli olarak denetlemek.

Önyargıyı Azaltma Önlemleri

1. Çeşitli Veri Setleri:
 - MEPDM'yi eğitmek ve değerlendirmek için kullanılan verilerin hizmet verdiği çeşitli nüfusu temsil etmesini sağlamak.
 - İrk, cinsiyet, sosyoekonomik durum vb. ile ilgili önyargıları önlemek için çeşitli demografik gruplardan veri dahil etmek.
2. Önyargı Tespiti ve Azaltma:
 - MEPDM'nin önerilerinde ve performansında önyargıları düzenli olarak test etmek.
 - Belirlenen önyargıları ele almak için önyargı tespiti algoritmaları ve düzeltici önlemler uygulamak.
3. Kapsayıcı Tasarım ve Geliştirme:
 - Tasarım ve geliştirme sürecine eğitimciler, öğrenciler ve etik ile sosyal adalet uzmanları gibi çeşitli paydaşları dahil etmek.
 - MEPDM'den farklı grupların nasıl etkileneceğini anlamak için etki değerlendirmeleri yapmak.

Şeffaflığı Sağlama Önlemleri

1. Açık Dokümantasyon:
 - MEPDM'nin algoritmaları, veri kaynakları ve karar alma süreçleri hakkında kapsamlı dokümantasyon sağlamak.
 - Bu dokümantasyonu tüm paydaşların erişimine sunmak.
2. Açıklanabilirlik:
 - Kullanıcıların MEPDM'nin önerilerine nasıl ulaştığını anlamalarını sağlayacak araçlar ve arayüzler geliştirmek.
 - Eğitimciler ve yöneticiler gibi uzman olmayanlar için anlaşılır açıklamalar sunmak.
3. Düzenli Raporlama ve İletişim:
 - MEPDM'nin performansı ve etkisi hakkında paydaşlara bilgi vermek için düzenli raporlama mekanizmaları oluşturmak.
 - Endişeleri ele almak ve modeli sürekli olarak iyileştirmek için geri bildirim ve diyalog kanalları oluşturmak.

Hesap Verebilirlik Önlemleri

1. Etik Gözetim Komitesi:
 - MEPDM'nin uygulanmasını ve işletilmesini izlemek için bağımsız bir etik gözetim komitesi kurmak.
 - Komite, etik uzmanları, eğitimciler ve toplum temsilcileri gibi çeşitli geçmişlere sahip üyeleri içermelidir.
2. Şikayet Mekanizması:

- Paydaşların MEPDM hakkında endişelerini veya şikayetlerini iletebilecekleri açık ve erişilebilir bir süreç geliştirmek.
 - Şikayetlerin hızlı ve adil bir şekilde ele alınmasını sağlamak.
3. Düzenli Denetimler ve Değerlendirmeler:
- MEPDM'nin performansını ve etik standartlara uyumunu düzenli olarak denetlemek.
 - Modelin etkisi ve etik uyumu hakkında tarafsız bir değerlendirme sağlamak için dış değerlendirciler kullanmak.

MEPDM'nin eğitim sistemlerine entegrasyonu, güçlü bir etik ilkelere bağlılığı gerektirir. Gizliliği sağlayarak, önyargıyı azaltarak ve şeffaflığı koruyarak, tüm paydaşlara fayda sağlayan adil ve güvenilir bir değerlendirme modeli oluşturabiliriz. Bu etik çerçeveye bağlı kalmak, güven inşa etmeye, eşitliği teşvik etmeye ve yapay zeka destekli eğitim programı değerlendirmesinin sorumlu kullanımı yoluyla istenilen eğitim sonuçlarına ulaşmaya yardımcı olacaktır.

MEPDM'nin Uygulanmasında Paydaş Katılımı

Meta-sezgisel Eğitim Programı Değerlendirme Modeli (MEPDM)'nin başarılı bir şekilde uygulanması ve sürekli olarak iyileştirilmesi için paydaş katılımı gereklidir. Eğitimciler, yöneticiler, öğrenciler, veliler ve toplum üyeleri gibi paydaşların katılımı, MEPDM'nin hizmet ettiği ihtiyaçlara ve beklenilere uygun olmasını sağlar. Bu bölüm, paydaşların nasıl uygulamaya ve sürekli iyileştirme döngüsüne dahil edileceğini ve geri bildirimlerinin nasıl alınacağını ve değerlendirileceğini ayrıntılarıyla açıklar.

Paydaş Katılım Aşamaları

Aşama 1: Planlama ve Hazırlık

1. Paydaş Belirleme ve Katılımı:
 - Faaliyet: Eğitimciler, yöneticiler, öğrenciler, veliler ve toplum üyeleri gibi tüm ilgili paydaşları belirlemek.
 - Yöntem: MEPDM ve hedeflerini tanıtmak için toplantılar ve atölye çalışmaları düzenlemek.
 - Sonuç: Tüm paydaş gruplarını temsil eden çeşitli bir proje ekibi oluşturmak.
2. İhtiyaç Değerlendirmesi:
 - Faaliyet: Eğitim programı değerlendirmesinin belirli ihtiyaçlarını ve hedeflerini belirlemek için paydaşları dahil etmek.
 - Yöntem: Anketler, odak grup görüşmeleri ve mülakatlar kullanarak bilgi toplamak.
 - Sonuç: Paydaş perspektiflerini yansitan kapsamlı bir ihtiyaç değerlendirme raporu hazırlamak.

Aşama 2: Tasarım ve Geliştirme

1. Ortak Tasarım Atölyeleri:
 - Faaliyet: Belirlenen ihtiyaçları karşılamak için MEPDM'yi özelleştirme sürecine paydaşları dahil etmek.
 - Yöntem: Önerilen model ve algoritmalar hakkında fikir ve geri bildirim toplamak için tasarım atölyeleri düzenlemek.

- Sonuç: Belirli gereksinimleri ve bekłentileri karşılayan özelleştirilmiş bir MEPDM oluşturmak.
2. Pilot Program Geliştirme:
- Faaliyet: Paydaşlarla iş birliği içinde pilot programlar geliştirmek.
 - Yöntem: Pilot projeleri tasarlamak ve uygulamak için her paydaş grubundan temsilciler içeren çalışma grupları oluşturmak.
 - Sonuç: Paydaş girdisi ile gerçek dünya ortamlarında test edilen pilot programlar oluşturmak.

Aşama 3: Eğitim ve Kapasite Geliştirme

1. Eğitim Programları:
 - Faaliyet: Eğitimciler ve yöneticiler için eğitim programları geliştirmek ve sunmak.
 - Yöntem: Uygulamalı atölye çalışmaları düzenlemek ve eğitim materyalleri sağlamak.
 - Sonuç: Paydaşların MEPDM'yi kullanma ve destekleme konusunda iyi donanımlı olmalarını sağlamak.
2. Sürekli Destek:
 - Faaliyet: Sürekli paydaş katılımı için destek yapıları oluşturmak.
 - Yöntem: Çevrimiçi forumlar, yardım masaları ve düzenli takip oturumları oluşturmak.
 - Sonuç: Sürekli destek sağlamak ve iş birliğine dayalı bir öğrenme ortamı oluşturmak.

Aşama 4: Pilot Test ve İyileştirme

1. Paydaş Geri Bildirimini Toplama:
 - Faaliyet: Pilot aşamasında paydaşlardan geri bildirim toplamak.
 - Yöntem: Anketler, geri bildirim formları ve mülakatlar kullanarak pilot programın etkinliği hakkında bilgi toplamak.
 - Sonuç: MEPDM'yi iyileştirmeye yönelik bir geri bildirim raporu hazırlamak.
2. Geri Bildirimini Değerlendirme ve Modeli İyileştirme:
 - Faaliyet: İyileştirme alanlarını belirlemek için paydaş geri bildirimlerini değerlendirmek.
 - Yöntem: Her paydaş grubundan temsilciler içeren bir geri bildirim değerlendirme komitesi oluşturmak ve geri bildirimleri gözden geçirmek.
 - Sonuç: Paydaş girdileri ve pilot sonuçlarına dayalı olarak MEPDM'yi iyileştirmek.

Aşama 5: Tam Ölçekli Uygulama

1. Paydaşlarla Yaygınlaştırma Planlaması:
 - Faaliyet: MEPDM'nin tam ölçekli yaygınlaştırma planlamasına paydaşları dahil etmek.
 - Yöntem: Detaylı bir uygulama planı geliştirmek için planlama toplantıları ve atölye çalışmaları düzenlemek.
 - Sonuç: Paydaşların desteğiyle kapsamlı bir yaygınlaştırma planı oluşturmak.
2. Sürekli İletişim ve İzleme:
 - Faaliyet: Yaygınlaştırma sırasında paydaşlarla düzenli iletişimini sürdürmek.
 - Yöntem: Haber bültenleri, toplantılar ve çevrimiçi platformlar kullanarak güncellemeler sağlamak ve geri bildirim toplamak.

- Sonuç: Şeffaflığı sağlamak ve sürekli paydaş katılımlını sağlamak.

Sürekli İyileştirme Döngüsü

1. Düzenli Geri Bildirim Toplama:

- Faaliyet: Paydaşlardan sürekli geri bildirim toplamak.
- Yöntem: Düzenli anketler, odak grup görüşmeleri ve öneri kutuları kullanmak.
- Sonuç: MEPDM'nin performansı ve iyileştirme alanları hakkında sürekli bilgi toplamak.

2. Geri Bildirimi Değerlendirme:

- Faaliyet: Toplanan geri bildirimleri düzenli olarak değerlendirmek.
- Yöntem: Geri bildirim değerlendirme komitesini üç ayda bir toplayarak geri bildirimleri gözden geçirmek ve analiz etmek.
- Sonuç: Paydaş girdilerine dayalı olarak trendleri ve iyileştirme alanlarını belirlemek.

3. Karar Alma Süreçlerinde Paydaş Katılımı:

- Faaliyet: MEPDM ile ilgili karar alma süreçlerine paydaşları dahil etmek.
- Yöntem: Olası değişiklikler ve iyileştirmeler hakkında tartışmak için katılımcı toplantılar ve atölye çalışmaları düzenlemek.
- Sonuç: Tüm kararlarda paydaş seslerinin duyulmasını ve dikkate alınmasını sağlamak.

4. Dokümantasyon ve Raporlama:

- Faaliyet: Paydaş girdilerine dayalı olarak yapılan tüm geri bildirimleri ve kararları belgelemek.
- Yöntem: Düzenli raporlar hazırlamak ve tüm paydaşlarla paylaşmak.
- Sonuç: Sürekli iyileştirme sürecinde şeffaflık ve hesap verebilirliği sağlamak.

MEPDM'nin başarılı bir şekilde uygulanması ve sürekli iyileştirilmesi için paydaş katılımı kritik öneme sahiptir. Planlama aşamasından tam ölçekli uygulamaya kadar her aşamada paydaşları dahil ederek ve geri bildirimlerini düzenli olarak toplayarak ve değerlendirerek, MEPDM, hizmet verdiği eğitim topluluğunun ihtiyaçlarını karşılayacak şekilde etkili bir şekilde uyaranabilir. Bu kapsayıcı yaklaşım, iş birliğine dayalı bir ortamı teşvik eder, MEPDM'nin sürdürülebilirliğini ve başarısını sağlar.

Sonuç ve Tartışma

Meta-sezgisel Yapay Zeka (YZ) optimizasyon algoritmalarının eğitim programı değerlendirmesine entegrasyonu, eğitim araştırma ve uygulamalarında yeni bir bakış açısı sunmaktadır. Bu metasentez araştırması, bu algoritmaların eğitim programı geliştirme ve değerlendirme süreçlerini iyileştirmede ve geliştirmede henüz tam olarak kullanılmayan potansiyelini aydınlatlığı düşünülmektedir. Bu çalışmanın ana katkıları, meta-sezgisel algoritmaların güçlü yönlerini kullanarak modern eğitim sistemlerinin karmaşıklıklarını ve dinamik yapısını ele alma konusundaki yenilikçi yaklaşımında yatkınlıkta. Önerilen Meta-sezgisel Eğitim Programı Değerlendirme Modeli (MEPDM), eğitim alanının değişen taleplerini karşılamada uyanabilirlik, ölçeklenebilirlik ve etkinlik için tasarlanmış yeni bir çerçeve olarak ortaya çıkmaktadır. Bu araştırma, disiplinler arası anlayışa şu katkılarda bulunmaktadır:

1. Eğitim bilimlerinde YZ optimizasyonuna yönelik ortaya çıkan ilgiyi vurgulamak, ancak özellikle eğitim programı değerlendirmesinde nadiren uygulandığını belirtmek.

2. Keşfedilen çeşitli algoritmaların ve ilgili alanlardaki umut verici sonuçların gösterilmesi, bu algoritmaların eğitimde uygulanması için verimli bir zemin sunmaktadır.
3. Eğitim programı geliştirmede YZ optimizasyonunun tam potansiyelinden yararlanmak için özelleştirilmiş yaklaşımlar ve disiplinler arası iş birliğinin gerekliliğinin altını çizmek.

Bulgular, mevcut teorileri desteklemekte ve MEPDM'yi daha dinamik, duyarlı bir eğitim ekosistemine yönelik bir paradigma değişimi olarak tanımaktadır. Bu model, kaliteli eğitim için gerekli olan sürekli değerlendirme ve optimizasyon döngüsü ile uyumlu olmakla kalmayıp, aynı zamanda eğitim programı geliştirme söylemini yeni, keşfedilmemiş alanlara taşımaktadır. Karşılaştırmalı olarak, MEPDM, meta-sezgisel optimizasyon temeliyle önceki modellerden ayrılmakta ve eğitim programı değerlendirmesine yapılandırılmış ancak esnek bir yaklaşım sunmaktadır. Bu, geleneksel değerlendirme yöntemlerinden bir kopuşu işaret ederek, eğitim programı optimizasyonun karmaşıklıklarına daha incelikli bir anlayış sunduğu düşünülmektedir. Ancak, bu çalışma, özellikle MEPDM'nin çeşitli eğitim ortamlarında pratik uygulaması ve ampirik testlerinde sınırlamaları kabul etmektedir. Birincil veri toplama yerine mevcut literatüre dayanması, modelin pratik sonuçlarına dair içgörülerin derinliğini de etkileyebilir.

Transfer edilebilirlik kapsamı, eğitim bağamlarındaki değişkenlik nedeniyle önerilen taslak sınırlıdır ve farklı sistemler ve eğitim seviyeleri arasında dikkatli bir uygulama gerektirmektedir. Eğitimde YZ kullanımına ilişkin etik hususlar, gizlilik, önyargı ve hesap verebilirlik gibi konular dikkatle ele alınmalı ve gelecekteki araştırmalar bu zorlukları ele almayı hedeflemelidir.

Gelecek araştırmalar için çıkarımlar, MEPDM'yi çeşitli eğitim seviyelerinde uygulamak ve test etmek için deneysel çalışmaların tasarımını, farklı eğitim programı bileşenleri için en uygun algoritmaları belirlemek amacıyla karşılaştırmalı analizleri ve farklı YZ algoritmalarını birleştiren hibrit modellerin geliştirilmesini içermektedir. Ayrıca, YZ destekli modelleri geleneksel yaklaşımalarla karşılaştırmak, onların görece güçlü ve zayıf yönleri hakkında değerli içgörüler sunabilir.

Sonuç olarak, çalışma, eğitim programı değerlendirmesinde YZ optimizasyon algoritmalarının dönüştürücü potansiyelini vurgulamakta ve eğitim mükemmeliyetinde yeni bir bakış açısı sunmaktadır. Sürekli iyileştirme ve uyarlama döngüsünü teşvik ederek, MEPDM, eğitim kalitesini ve önemini artırmayı vaat ettiği düşünülmektedir ve bunu toplumsal ihtiyaçlar ve bireysel öğrenici hedefleri ile daha yakından uyumlu hale getirmektedir.

Gelecek Araştırma Önerileri

Doğrulama Çalışmaları

MEPDM'nin farklı eğitim seviyelerinde ve bağamlarında etkinliğini test etmek için deneysel çalışmalar yapılabılır. MEPDM, avantajlarını vurgulamak için geleneksel eğitim programı değerlendirme modelleri ile karşılaştırılabilir.

Algoritma Geliştirme

Gelişmiş optimizasyon için birden fazla meta-sezgisel algoritmayı birleştiren hibrit modellerin geliştirilmesi araştırılabilir. Eğitim programı değerlendirmesinde makine öğrenimi, sinir ağları gibi yeni YZ teknolojilerinin uygulanması araştırılabilir.

Eтик Kurul Onayı: Çalışmamız teorik çalışma olduğu için etik kurul onayı gerektirmemektedir.

Araştırmacıların Katkı Oranı: Volkan Duran %70, Gülay Ekici %30

Çatışma Beyanı: Yazar veya yazarlara ilişkin herhangi bir çıkar çatışması olasılığı yoktur.

References

- Alhunitah, H., & Menai, M.E. (2016). Solving the student grouping problem in e-learning systems using swarm intelligence metaheuristics. *Computer Applications in Engineering Education*, 24(6), 831-842. <https://doi.org/10.1002/cae.21752>
- Aram, K. (2012). *Parçacık sürü optimizasyon algoritması ile çok ölçütlü performans değerlendirme modelinin oluşturulması [Creating multi criteria performance evaluation model with using particle swarm optimization]*, [Unpublished master's thesis]. Marmara University.
- Arashpour, M., Golafshani, E.M., Parthiban, R., Lamborn, J., Kashani, A., Li, H., & Farzanehfar, P. (2023). Predicting individual learning performance using machine-learning hybridized with the teaching-learning-based optimization. *Computer Applications in Engineering Education*, 31(1), 83-99. <https://doi.org/10.1002/cae.22572>
- Arslan, H. (2018). *Realization of robot speed control with FPGA using taboo search algorithm*, [Unpublished master's thesis]. Kocaeli University
- Blum, C., & Roli, A. (2003). Metaheuristics in combinatorial optimization: Overview and conceptual comparison. *ACM Computing Surveys*, 35(3), 268–308. <https://doi.org/10.1145/937503.937505>
- Brown, J. D. (1995). *The elements of language curriculum*. Heinle & Heinle Publishers
- Can, B. (2022). *Ant colony algorithm for household care/nutrition service direction problem with time window and fuzzy demand*, [Unpublished master's thesis], Mersin University.
- Cao Y. J., & Wu Q. H. (1999). Teaching genetic algorithm using matlab. *International Journal of Electrical Engineering & Education*, 36(2), 139-153. <https://doi.org/10.7227/IJEEE.36.2.4>
- Chakraborty, S., Saha, A. K., Sharma, S., Mirjalili, S., & Chakraborty, R. (2021). A novel enhanced whale optimization algorithm for global optimization. *Computers & Industrial Engineering*, 153, 107086. <https://doi.org/10.1016/j.cie.2020.107086>
- Demirel, Ö. (2007). *Kuramdan uygulamaya eğitimde program geliştirme [Curriculum development in education from theory to practice]*. Pegem
- De Castro, L. N., & Von Zubben, F. J. (2000a). *The clonal selection algorithm with engineering applications*. Artificial Immune Workshop, Genetic and Evolutionary Computation Conference (GECCO), Las Vegas, Nevada, ABD, 36-37.
- Duan, H. B., Li, P., Shi, Y. H. Zhang, X. Y., & Sun, C. H. (2015). Interactive learning environment for bio-inspired optimization algorithms for UAV path planning. *IEEE Transactions on Education*, 58(4), 276-281. <https://doi.org/10.1109/TE.2015.2402196>
- Dumlu, H. (2023). *A self-adaptive differential evolution algorithm design and implementation*, [Unpublished M.S. Thesis], Kütahya Dumlupınar University
- Dwivedi, P., Kant, V., & Bharadwaj, K. K. (2018). Learning path recommendation based on modified variable length genetic algorithm. *Educational Technology Research and Development*, 23(2), 819-836. <https://doi.org/10.1007/s10639-017-9637-7>
- El Fazazi, H. Qbadou, M., & Mansouri, K. (2019). *Personalized learning path recommendation based on learning activities for specific students' needs*. In L.G. Chova, A.L. Martinez, & I.C. Torres (Eds.), 12th International Conference of Education, Research, and Innovation (ICERI2019) - ICERI Proceedings (pp. 11194-11194).

- Gökçe, H., Top, N., & Şahin, İ. (2019). *Investigation of minimum weight problem for spur gear using cad based simulated annealing algorithms*, 19th national machine theory symposium. Iskenderun Technical University.
- Gülcü, S. (2017). *Parallelization of the particle swarm and ant colony optimization algorithms by using the greedy information swap strategy*, [Unpublished doctoral thesis], Selçuk University.
- Gülüm, İ. V. (2016). Mindfulness training and practice for effective therapist characteristics: A meta-synthesis study. *Current Approaches in Psychiatry*, 8(4), 337-353. <https://doi.org/10.18863/pgy.253439>
- Gürbüz, Ö. (2015). *Application of tabu search algorithm to queue problem*, [Unpublished M.S. Thesis], Hacettepe University.
- Hoe, D. (2014). Promoting undergraduate research in the electrical engineering curriculum. In *ASEE Annual Conference & Exposition, Proceedings Paper*. ASEE.
- Hussain, S., Muhsin, Z.F., Salal, Y.K., Theodorou, P., Kurtoglu, F., & Hazarika, G.C. (2019). Prediction model on student performance based on internal assessment using deep learning. *International Journal of Emerging Technologies in Learning*, 14(8), 4-22. <https://doi.org/10.3991/ijet.v14i08.10001>
- İyitoğlu, O., & Gürol, M. (2017). Michael Scriven: Değerlendirme üzerine kavramsal devrim önerileri [Michael Scriven: Conceptual revolution suggestions on evaluation]. *International Journal of Social Research*, 10 (49), 452-458.
- Jiang, H., & Lu, C. (2022). Information exchange platform for digital art teaching in colleges and universities based on Internet of Things technology. *International Journal of Continuing Engineering Education and Life-Long Learning*, 32(4), 459-473. <https://doi.org/10.1504/IJCEELL.2022.124969>
- Kandemir, A. (2016). *An evaluation of 2nd grade English curriculum within a participant oriented program evaluation approach*, [Unpublished master's thesis], Pamukkale University.
- Karaboğa, D. (2018). *Yapay eka optimisazyon algoritmaları* [Artificial intelligence optimization algorithms], Nobel akademi.
- Keser, B. (2020). *Karinca kolonisi optimizasyon algoritması* [Ant colony optimization algorithm]. <https://medium.com/@berkekeser/kar%C4%B1nca-kolonisi-optimizasyon-algoritmas%C4%B1-4da0b37cb393>
- Khamparia, A., & Pandey, B. (2015). Knowledge and intelligent computing methods in e-learning. *International Journal of Technology Enhanced Learning*, 7(3), 221-242. <https://doi.org/10.1504/IJTEL.2015.072810>
- Kickmeier-Rust, M. D., & Holzinger, A. (2019). Interactive ant colony optimization to support adaptation in serious games. *International Journal of Serious Games*, 6(3), 37-50. <https://doi.org/10.17083/ijsg.v6i3.308>
- Kocabatmaz, H. (2011). *The evaluation of the technology and design curriculum*, [Unpublished doctoral thesis], Ankara University.
- Lee, C. Y., Ruan, L. M., Lee, Z. J., Huang, J. Q., Yao, J., Ning, Z. Y., & Tu, J. F. (2021). Study on the university students' satisfaction of the wisdom tree massive open online course platform based on parameter optimization intelligent algorithm. *Science progress*, 104(3_suppl), 368504211054256. <https://doi.org/10.1177/00368504211054256>
- Li, R. X. (2019). Adaptive learning model based on ant colony algorithm. *International Journal of Emerging Technologies in Learning*, 14(1), 49-57. <https://doi.org/10.3991/ijet.v14i01.9487>
- Qiang, L., Xin, K., Yu, G., Yi, S., Liping, S., & Feixue, Y. (2017). Influence mechanism of external social capital of university teachers on evolution of generative digital learning resources of educational

- technology of university teachers - empirical analysis of differential evolution algorithm and structural equation model of bootstrap self-extraction technique. *Eurasia Journal of Mathematics, Science and Technology Education*, 13(8), 5327-5341. <https://doi.org/10.12973/eurasia.2017.00985a>
- Madalina, M., & Serbanescu, L. (2016). Application software architecture for learning physics, based on ant colony optimization type mechanisms. In M. Vlada, G. Albeanu, A. Adascalitei, & M. Popovici (Eds.), *Proceedings of the 11th International Conference on Virtual Learning* (pp. 334-338). Proceedings of the International Conference on Virtual Learning.
- Mohammadi, M. O. (2022). *Zaman-maliyet-kalite ödünlüşim problemlerinin çözümünde baskın olmayan sıralma-II öğretme-öğrenme tabanlı optimizasyon'un (NDSII-TLBO) kullanılması* [Using non-dominated sorting-II teaching learning-based optimization (NDSII-TLBO) in solving time-cost-quality trade-off problems], [Unpublished master's thesis], Karadeniz Technical University.
- Menai, M. E. B. Alhunitah, H., & Al-Salman, H. (2018). Swarm intelligence to solve the curriculum sequencing problem. *Computer Applications in engineering Education*, 26(5), 1393-1404. <https://doi.org/10.1002/cae.22046>
- Niknam, M., & Thulasiraman, P. (2020). LPR: A bio-inspired intelligent learning path recommendation system based on meaningful learning theory. *Education and Information Technologies*, 25(5), 3797-3819. <https://doi.org/10.1007/s10639-020-10133-3>
- Rao, R.V., Savsani, V.J., & Vakharia, D.P. (2011). Teaching–learning-based optimization: A novel method for constrained mechanical design optimization problems. *Computer-Aided Design*, 43(3), 303–315. <https://doi.org/10.1016/j.cad.2010.12.015>
- Özdemir, S.M. (2009). Curriculum evaluation in education and examination of the curriculum evaluation studies in Turkey. *Van Yüzüncü Yıl University Faculty of Education Journal*, 6(2), 126-149.
- Rashid, T.A., & Ahmad, H.A. (2016). Lecturer performance system using neural network with Particle Swarm Optimization. *Computer Applications in Engineering Education*, 24(4), 629-638. <https://doi.org/10.1002/cae.21737>
- Rastegarmoghadam, M., & Ziarati, K. (2017). Improved modeling of intelligent tutoring systems using ant colony optimization. *Education and Information Technologies*, 22(3), 1067-1087. <https://doi.org/10.1007/s10639-016-9472-2>
- Richards, J.C. (2003). *Curriculum development in language teaching*. Cambridge University Press.
- Samigulina, G., & Samigulina, Z. (2016). Intelligent system of distance education of engineers, based on modern innovative technologies. In J. Domenech, M.C. VincentVela, R. PenaOrtiz, E. DeLaPoza, & D. Blazquez (Eds.), *2nd International Conference on Higher Education Advances, HEAD'16* (Vol. 228, ss. 229-236). <https://doi.org/10.1016/j.sbspro.2016.07.034>
- Sharma, P., & Harkishan, M. (2022). Designing an intelligent tutoring system for computer programming in the Pacific. *Journal of Computers in Education*, 27(5), 6197-6209. <https://doi.org/10.1007/s10639-021-10882-9>
- Shen, C. C., & Qi, A. L. (2020). An adaptive learning model of "Public psychology" based on creative thinking with virtual simulation technology. *International Journal of Emerging Technologies in Learning*, 15 (23), 131-144. <https://doi.org/10.3991/ijet.v15i23.18957>
- Shukhman, A. E., Bolodurina, I. P., Polezhaev, P. N., Ushakov, Y. A., & Legashev, L. V. (2018). Adaptive technology to support talented secondary school students with the educational IT infrastructure. In *Proceedings of 2018 IEEE Global Engineering Education Conference (EDUCON) - Emerging Trends and Challenges of Engineering Education* (pp. 993-998). IEEE.

- Shyr, W.J. (2010). Parameters determination for optimum design by evolutionary algorithm. Convergence and Hybrid Information Technologies. In M. Crisan (Ed.). Convergence and hybrid information Technologies, <https://doi.org/10.5772/9638>
- Şahin, T. (2019). *Multi objective design optimization of bearings using grey wolf optimization technique*, [Unpublished master's thesis]. Gazi University.
- Uşun, S. (2012). *Eğitimde Program Değerlendirme [Curriculum Evaluation in Education]*. Anı Yayınları
- Ünal, M. (2013). *The evaluation of European Union Erasmus Student Mobility Programme in the framework of CIP (context, input, process, product) evaluation model*, [Unpublished doctoral thesis], Gazi University.
- Tanış, Y. (2019). *Analysis of radio frequency electromagnetic waves of compact florescent lamps using artificial immune system*, [Unpublished master's thesis], Ankara University.
- Vuong, Q. L., Rigaut, C., & Gossuin, Y. (2018). Refraction law and Fermat principle: a project using the ant colony optimization algorithm for undergraduate students in physics. *European Journal of Physics*, 39(4), 045806. <https://doi.org/10.1088/1361-6404/aab6e0>
- Yapıcı, M.M. (2012). *Development of a timetabling software using genetic algorithm*, [Unpublished master's thesis]. Gazi University.
- Yetkin, Y. (2019). *Genetic algorithm approach to estimate PISA success*, [Unpublished master's thesis], Van Yüzüncü Yıl University.
- Yepes, V., Gonzalez-Vidosa, F., Martí, J.V., & Alcalá, J. (2011). A short postgraduate course on heuristic design of prestressed concrete road bridge decks. In L.G. Chova, I.C. Torres, & A.L. Martinez (Eds.), *INTED2011: 5th International Technology, Education and Development Conference*, 5132-5141.
- Yurttakal, H. (2014). *Solving permutation flowshop scheduling problem by artificial immune system*, [Unpublished master's thesis], Selçuk University.
- Yüksel, İ. (2010). *Development of Turkish program evaluation standards*, [Unpublished doctoral thesis], Anadolu University.
- Wang, P. Xu, X., & Liu, C. (2019). *An improved adaptive genetic algorithm and its application in intelligent course scheduling system*, 6th International Conference on Information Science and Control Engineering (ICISCE), Shanghai, China, 2019, pp. 121-125, <https://doi.org/10.1109/ICISCE48695.2019.00034>
- Wang, F.R., Wang, W.H. Pan, Q.K. Zuo, F.C., & Liang, J.J. (2009a). A novel test-sheet composition approach using differential evolution algorithm for computer-aided testing systems. In C. Zhao (Ed.), *ICAIE 2009: Proceedings of the 2009 International Conference on Artificial Intelligence and Education*, Vols 1 and 2 (pp. 794-800).
- Wang, F.R. Wang, W.H. Pan, Q.K., Zuo, F.C., & Liang, J.J. (2009b). *A novel online test-sheet composition approach for web-based testing*. In H. Liu & X.G. Zheng (Eds.), *2009 IEEE International Symposium on IT in Medicine & Education*, Vols 1 and 2, Proceedings (pp. 700-+). <https://doi.org/10.1109/ITIME.2009.5236331>
- Weed, M. (2005). Meta interpretation: A method for the interpretive synthesis of qualitative research. <http://www.qualitative-research.net/index.php/fqs/article/view/508/1096>
- Wong, L. H., & Looi, C. K. (2012). Swarm intelligence: new techniques for adaptive systems to provide learning support. *Educational Technology Research and Development*, 20(1), 19-40. <https://doi.org/10.1080/10494821003714681>

- Zan, C. (2019). A distributed distribution and scheduling algorithm of educational resources based on vector space model. *International Journal of Emerging Technologies in Learning*, 14(4), 58-72. <https://doi.org/10.3991/ijet.v14i04.10132>
- Zervoudakis, K., Mastrothanasis, K., & Tsafarakis, S. (2020). Forming automatic groups of learners using particle swarm optimization for applications of differentiated instruction. *Computer Applications in Engineering Education*, 28(2), 282-292. <https://doi.org/10.1002/cae.22191>
- Zilinskiene, I., Dagiene, V., & Kurilovas, E. (2012). A swarm-based approach to adaptive learning: Selection of a dynamic learning scenario. In H. Beldhuis (Ed.), *Proceedings of the 11th European Conference on E-Learning* (pp. 583-593).