

# 유전 알고리즘 기반의 음악 교육 학습 경로 최적화

정우성

서울교육대학교 교육전문대학원 교수

## A Genetic Algorithm Based Learning Path Optimization for Music Education

Woosung Jung

Associate Professor, Graduate School of Education, Seoul National University of Education

요 약 맞춤형 교육을 위해 학습자에 맞는 학습 경로를 탐색하는 것은 필수적이다. 유전 알고리즘은 해공간이 매우 커서 결정적 방법으로 해를 구하기 어려울 때 타당한 시간 내에 최적해를 찾게 해준다. 본 연구는 유전 알고리즘을 이용하여 200 개 코드를 가진 악보 27개를 대상으로 학습자 부담을 최소화하고 단계별 학습량을 균등하게 분산함으로써 학습 효과를 최대화 할 수 있도록 학습 경로를 최적화하였다. 학습 콘텐츠가 27개만 되어도 학습 경로의 순열 크기는  $10^{28}$ 을 넘지만, 본 연구에서 구현한 도구로 평균 20분 이내에 최적해를 구할 수 있었다. 실험 결과는 유전 알고리즘이 다양한 목적의 맞춤형 교육을 위한 복잡한 학습 경로 설계에 효과적임을 보여주었다. 제안한 방법은 다른 교육 도메인에도 활용할 수 있을 것으로 기대된다.

주제어 : 음악 교육, MusicXML, 학습 경로, 유전 알고리즘, 최적화

**Abstract** For customized education, it is essential to search the learning path for the learner. The genetic algorithm makes it possible to find optimal solutions within a practical time when they are difficult to be obtained with deterministic approaches because of the problem's very large search space. In this research, based on genetic algorithm, the learning paths to learn 200 chords in 27 music sheets were optimized to maximize the learning effect by balancing and minimizing learner's burden and learning size for each step in the learning paths. Although the permutation size of the possible learning path for 27 learning contents is more than  $10^{28}$ , the optimal solution could be obtained within 20 minutes in average by an implemented tool in this research. Experimental results showed that genetic algorithm can be effectively used to design complex learning path for customized education with various purposes. The proposed method is expected to be applied in other educational domains as well.

**Key Words** : Music education, MusicXML, Learning path, Genetic algorithm, Optimization

### 1. 서론

최근, 여러 분야에서의 교육 콘텐츠가 디지털화되면서 교수, 학습 과정에서의 내용과 프로세스를 소프트웨어로 분석할 수 있게 되었다. 기존의 데이터 마이닝과 기계 학습 이론들이 경제, 사회, 의학, 공학 등의 분야에 적용되

면서 교육 분야에서도 관련 알고리즘을 활용한 응용 연구가 이루어지고 있다. 특히, 사용자로부터 획득한 데이터를 통해 문맥(context)을 이해함으로써 맞춤형 교육도 가능해졌다[1,2].

피아노 반주법을 배울 때는 적절한 코드(chord) 운지법을 익히는 것이 필요하다. 하지만, 특정 곡을 연주하는

\*This work was supported by the 2018 Research Fund of Seoul National University of Education.

\*Corresponding Author : Woosung Jung (wsjung@snu.ac.kr)

Received January 15, 2019

Accepted February 20, 2019

Revised February 7, 2019

Published February 28, 2019

데 필요한 코드 및 사전 지식이나 학습자의 역량, 악보의 종류 등에 따라 악보의 난이도와 단계별 학습량이 달라지기 때문에 학습자의 과거 경험에 따라 학습 순서 및 경로가 바뀌어야 한다. 하지만, 학습자의 학습 상황과 악보의 개수 등을 고려하면 학습 경로를 정하는 경우의 수가 매우 많기 때문에 가장 좋은 경로를 찾는 것은 일반적인 방법으로 불가능하다. 즉, 이를 사람이 확인하거나 컴퓨터를 활용한 순차 탐색으로 맞춤형 학습 경로를 설계하려는 시도는 고성능의 컴퓨터를 이용하더라도 현실적인 시간 내에 해결이 어렵다. 그러므로 본 연구에서는 대량의 악보 데이터를 전자적으로 추출할 수 있는 자동화 도구를 구현하고, 악보의 메타 정보를 구조화하여 스키마를 설계한 후, 악보 정보를 데이터베이스로 구축하여 이를 접근하여 분석함으로써 코드 학습 경로 최적화 문제를 해결하고자 한다. 특히, 학습 경로를 탐색할 때, 단계의 크기가  $N$ 이라면 탐색해야할 전체 경로의 개수는  $N!$ 이 되기 때문에 결정론적(deterministic) 방법으로는 해를 구하기 어렵다. 그러므로, NP-Hard 문제에서 최적해(optimal solution)를 효과적으로 구할 수 있는 유전 알고리즘을 통해 문제를 해결하였다.

본 논문의 이후 구성은 다음과 같다. 2장에서는 교육도메인에서 유전 알고리즘을 활용한 연구를 포함한 관련 연구를 살펴보고, 3장에 본 논문이 해결하고자 하는 문제를 정의하고 제안하는 학습 경로 최적화 개요 및 접근 방법과 구현한 도구 및 알고리즘에 대한 구체적인 내용을 실었다. 4장에서는 27개의 실제 악보를 대상으로 최적 학습 경로 탐색을 위한 실험을 진행하여 결과를 정리하고, 5장에서 결론을 맺는다.

## 2. 관련 연구

교육 분야에서 학습자의 상황에 맞추어 학습 내용이나 순서를 추천하기 위해서는 다양한 학습 요소들을 고려해야 한다. 최적의 학습 경로(learning path)를 찾기 위해 우선 학습 대상을 추상화된 형태로 표현해야 하는데, Karampiperis는 가능한 모든 경우를 포함하는 비순환 방향 그래프로 학습 경로 그래프를 모델링하고, 학습 목표와 개념을 계층화시켰으며[3], 맞춤형 콘텐츠 선택 과정에서는 학습자의 지식 공간과 학습 스타일 및 선호 조건을 이용함으로써 이들의 가중치를 경로 그래프에 주고, 최단 경로를 탐색함으로써 최종 학습 경로를 선택하였다.

이와 유사하게 효과적인 학습 활동 순서를 결정하기 위해 방향성을 가진 학습 활동 그래프(learning activity graph)를 구성하여 각각의 노드에 사전, 사후 조건을 기술한 뒤 학습자의 선호 조건과 전문성을 이용한 연구도 있었다[4].

유전 알고리즘은 해공간의 크기가 너무 커서, 결정론적인 탐색 방법으로는 실용적인 시간 안에 좋은 해를 찾기 어려운 경우에 효과적이다. 이러한 접근법은 문제에 대한 해(solution)를 표현하기 위해 염색체(chromosome) 설계부터 시작하여, 해집단(population)을 구축하고 교차(crossover)와 변이(mutation) 등의 유전자 연산 사용한다. 유전 알고리즘은 이렇게 해집단에 속한 염색체들을 진화시키면서 수렴된 최적해를 구하는 일종의 메타 휴리스틱 알고리즘이다.

개별 학습자에 따른 맞춤형 교육을 제공하기 위해 유전 알고리즘을 활용한 연구들이 있다. 개념 지도를 이용하여 인간의 인지 작용을 여러 부류로 나누는 연구가 바탕이 되어, 유전 알고리즘을 통해 개념 지도를 구축하는 방법[5]이 연구되었고, 문제에 대한 최적해를 찾는 인간의 사고 능력에 대한 정성적 분석을 통해 이론, 수학, 실용성 영역에서의 교육 시스템 발전 방향을 제시한 연구[6]도 있었다. AEHS(Adaptive educational hypermedia systems)에서 교육 시스템 생성 과정보다 모순, 불충분 등의 '개념 공백'을 보완하는 검증 연구[3]도 진행되었다.

학생들의 학습 정도를 파악하는 데에 가장 중요하게 사용되는 방법 중 하나는 시험이다. 교육 내용에 포함되어 있는 키워드 분석을 통해 최적의 시험 순서를 제공하는 연구[7]가 진행된 바 있다. 인간의 학습을 마치 기계학습에서의 강화학습과 유사하게 설계한 온라인 교육 방법이 있으며, 인공지능이 인간에게 지식을 제공하진 않지만, 인간과의 상호작용과 히스토리를 이용해 효과적으로 새로운 정보를 제공하는 연구[8]도 있었다.

학습과정에서 학습자들의 협력은 교육적 측면에서 매우 효과적이다. 하지만 협력 학습을 위한 그룹 구성도 중요한데, 자연의 최적해 탐색 과정을 모방하여 가장 높은 효율의 그룹을 찾는 방법을 제시한 연구[9]가 있었다. 학생들의 학습 스타일 증진을 위한 자동화 방법에 대한 연구[10]도 있었는데, 마르코프 체인(Markov chains)과 유전 알고리즘(genetic algorithm)을 통해 정제된 결과를 얻었다. 자동화 학습 시스템의 정확도 개선을 위해 인공신경망(artificial neural network), 유전 알고리즘, 개미

집단 시스템(ant colony system)과 입자 군집 최적화(particle swarm optimization)를 이용한 연구도 있었다. 이는 학생들이 자신의 강점과 약점을 알아낼 수 있도록 하는 알고리즘에 주로 초점이 맞추어졌다[11].

학습 대상의 메타 데이터를 수집하고, 개개인의 인지 작용과 학습 스타일의 관계에 대한 분석을 통해 맞춤형 교육을 추구하는 연구가 있었다. Anithal은 이를 위해 학습 대상과 학습 방식을 대응시키는 새로운 방법[12]을 제시하였다. 학습 대상들의 관계를 분석한 배열을 제약 만족 문제(constraint satisfaction problem)로 정의하고 이를 풀기 위해 유전 알고리즘을 사용하기도 했다[13].

음악 도메인에서 유전 알고리즘을 사용한 연구들도 있었다. 음악을 작곡하기 위해 리듬과 시작 음과의 상대적인 차이를 적합도 함수에 이용한 연구[14]가 있으며, 정규화된 유사도값을 이용하여 악보의 유사도를 적합도 함수로 사용함으로써 사전 정의된 스타일의 음악을 자동 생성한 연구[15]도 있었다. 하지만, 음악 교육 도메인에서의 학습 경로를 최적화하기 위한 구체적 실험 연구는 없었다.

### 3. 연구방법

#### 3.1 문제 정의

본 논문에서는 구체적 실험을 위해 악보 연주를 위한 코드를 학습의 단위로 가정한다. 하지만, 영단어와 같은 단순 유형부터 전문 지식에 이르기까지 학습 콘텐츠 요소들은 다양하게 지정할 수 있다. Fig. 1은 학습 경로 최적화 문제와 관련한 주요 시나리오를 보여준다.




Fig. 1. An overall scenario for problem definition

본 연구의 문제는 입력으로 주어진 N개의 악보와 학습자의 사전 지식, 즉 프로파일 정보로부터 크기 N의 시

퀀스로 이루어진 최적의 악보 학습 경로를 찾는 것이다. 악보는 기본적으로 코드 및 노트(note) 정보를 학습 요소로 가정한다. 최적 학습 경로는 사전 지식이 있는 출발점으로부터 순서대로 악보를 학습함에 있어서 각 단계별로 신규 학습 요소의 크기 또는 비율을 고루 분산하면서 전체 크기를 최소화함을 가정한다. 가령, 특정 단계에서 신규 코드를 한꺼번에 많이 학습하거나, 반대로 전혀 없는 경우가 발행하기 보다는 단계별로 균등하게 신규 코드를 분산하면서 학습 대상의 개수나 비율을 최소화하는 것이 학습에 효과적이고 학습자의 부담도 줄일 수 있다. 이는 사전 지식으로 이미 학습된 요소들의 상태에 따라 학습자별로 학습 경로가 바뀌어야 한다는 제약도 포함한다.

#### 3.2 연구 절차 및 자료 구조

Fig. 2는 학습 경로 최적화의 흐름을 표현한 UML(Unified Modeling Language) 액티비티 다이어그램이며, Fig. 3은 학습 경로 최적화 도구의 모듈을 나타낸 계층 아키텍처이다.

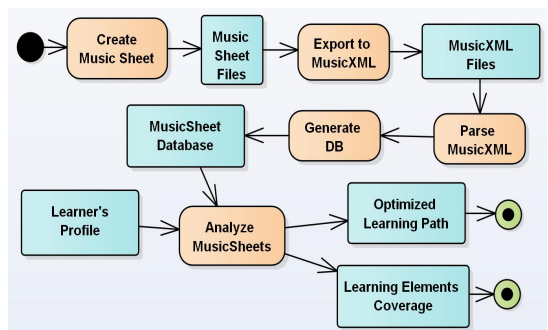


Fig. 2. Activity diagram for overall approach




Fig. 3. Layered architecture of the proposed optimizer

학습 경로 최적화를 위해서는 우선 N개의 악보로부터 MusicXML 형식의 파일을 생성해야 한다. 이를 위해 도구를 구현하거나 Sibelius, Encore, 등의 도구를 이용할 수 있다. MusicXMLParser는 입력 폴더의 MusicXML 파일을 모두 순차로 파싱(parsing)하여 measure, words,

root-step, degree-value 및 lyric 등 분석에 필요한 요소를 추출한다. 필요한 정보가 추출되면 학습 요소를 찾고, 각 요소별 악보 커버리지를 계산하거나, 학습자의 학습 상태에 따라 최적 학습 경로를 찾기 위한 분석이 가능하다. 본 연구에서는 분석 데이터 이식성(portability)과 모듈 독립성(independency)을 위해 파싱 정보를 xml로 변환한 후 MusicDBManager로 데이터베이스에 입력하고, MusicAnalyzer가 최적화 경로를 찾도록 구현하였다.

Fig. 4. 는 추출 정보를 저장하기 위한 데이터베이스 스키마(schema)이다. 본 연구에서는 학습 요소를 코드 또는 실제 건반으로 누르는 노트 조합으로 가정하였으나, 영어와 같은 다른 교육 콘텐츠 요소들로 가정해도 도메인 스키마 정의만 해주면 같은 방식으로 적용할 수 있다.

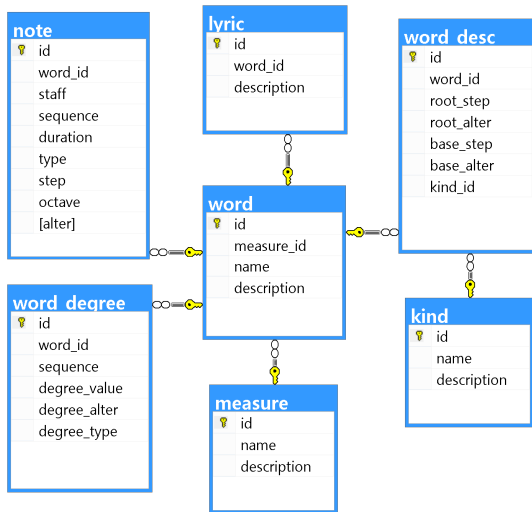


Fig. 4. Database schema for MusicXMLParser

학습 요소의 커버리지는 신규 학습 요소가 학습 콘텐츠에서 차지하는 비율이기 때문에, 악보를 보기 전에 선수 학습 자료 선정에 활용할 수 있다. 뿐만 아니라, 학습 요소의 커버리지 척도를 통해 학습자 프로필에 따른 학습 콘텐츠의 맞춤형 난이도를 계산하는 것도 가능하다.

학습자의 프로필은 학습 요소가 학습된 상태 정보를 의미하므로, 가장 쉽게는 해당 요소의 학습 횟수나 평가 결과, 학습 기간 등을 조합하여 다양하게 정의할 수 있다. 즉, 학습자의 프로필은 학습요소와 포인트로 구성하여 Fig. 5와 같은 메타모델로 표현할 수 있다. element 테이블의 ref\_id 속성은 구체적인 학습요소를 가리키도록 한다. 본 연구에서는 word, note, lyric 등이 가능하며, 실험

을 위해서는 word\_desc로 구분 가능한 코드 정보와 note 값을 통해 알 수 있는 건반 조합 결과를 이용하였다. 다른 요소를 기준으로도 실험이 가능하다.




Fig. 5. A meta-model for learner's profile

결과적으로 학습자의 프로필을 이용하면, 학습자의 학습 커버리지 상황을 파악할 수 있을 뿐 아니라 콘텐츠에 대한 난이도도 정량적으로 파악할 수 있다. 뿐만 아니라, 최적 학습 경로를 찾기 위한 출발점으로 사용할 수 있다.

학습 커버리지는 해당 요소가 특정 학습 대상, 즉 본 연구에서는 악보에서 어느 정도 차지하는지에 대한 비율이므로 비교적 쉽게 계산할 수 있다. 학습 경로 최적화를 위해서는 학습 콘텐츠, 즉 악보의 고유 번호를 배열로 표현하여 검색체를 만들고, 유전 알고리즘을 통해 최적의 해를 탐색하는 방법을 이용한다.

### 3.3 실험 설계

실험을 위해 총 27개의 MusicXML 즉,  $c_0 \sim c_{26}$ 에서 2,214개의 measure, 3,276개의 word, 14,681개의 note를 분석하였다. 27개의 악보로 학습하게 되는 전체 코드의 패턴은 200개이다. 학습 경로의 경우 수는 총  $27! (>10^{28})$  이기 때문에 하나의 해를 검사하는 시간을  $10^{-10}$ 초로 가정하더라도 순차적인 방법으로는  $10^{18}$ 초, 즉 300억년 이상이 걸린다. 그러므로, 유전 알고리즘을 이용하여 최적의 학습 경로를 탐색함으로써 합리적인 시간 이내에 최적해를 찾아야 한다.

Fig. 6는 학습 경로를 위한 길이 27로 고정된 검색체 구조이다. 학습 대상의 개수가 많아지면 검색체의 길이가 늘어나야 하므로, 일반적으로는 가변 길이의 검색체 구조를 가지게 된다. 실험을 위해  $c_0 \sim c_{26}$  중 하나를 사용자의 프로필로 가정하여 실험을 진행하였으며, 사전 지식이 전혀 없는 경우도 가정하여 실험을 진행하였다. 학습 경로의 해를 검색체 형태로 표현하여 해집단을 구성한 후 교차 및 변이를 통한 여러 세대의 진화를 거쳐 최적화된 학습 경로를 찾는 방식으로 실험을 진행했다.

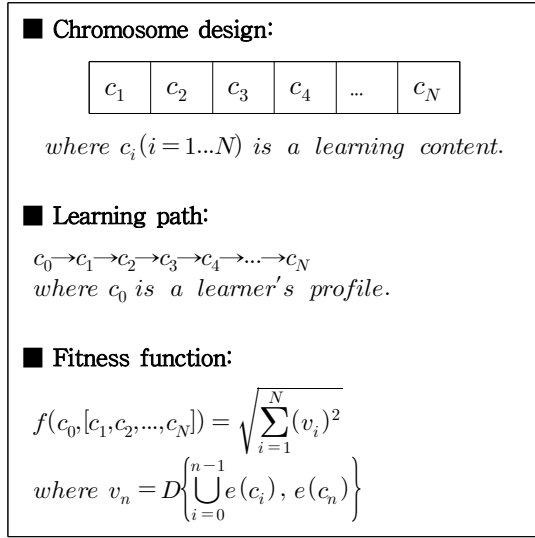


Fig. 6. Chromosome and fitness function for learning path optimization

학습 경로 최적화 알고리즘을 Fig. 7에 의사 코드(pseudocode)로 표현하였다. 적합도 함수에 사용한  $e()$ 는 학습 콘텐츠로부터 학습 요소 집합을 생성하는 함수이며,  $D()$ 는 새로운 교육 콘텐츠를 배우기 직전까지의 누적 정보와 새로 학습할 콘텐츠를 인자로 이용하여 학습의 증분을 계산하는 함수로 최적화 목적에 맞추어서 정의할 수 있다. 본 연구에서는 새로 학습할 요소의 비율을 요소로 가지는 N차원 벡터로 정의하여, 벡터의 크기가 최소화되는 학습 경로를 최적으로 정하였다. 본 연구에서는 실험을 위해  $size_{population}$ 를 1,500으로 설정하고,  $cond_{saturation}$ 는 1,000세대 이상 진행되거나 염색체 중 적합도의 크기가 0.05 미만이 되는 것으로 정하였다.  $r_{replacement}=0.6$ ,  $r_{mutation}=0.15$ 로 설정하였다.

교차 연산은 염색체가 순열로 표시되는 경우이므로 PMX(Partially Mapped Crossover)를 이용하여 두 부모해를 임의로 같은 위치에서 3등분하여 교차하여 결합시킨 후 모든 유전자가 중복되지 않도록 수선한 후 자식해를 생성하도록 하였다. 유전자의 변이 확률은 0.15로 27개 중 평균적으로 4개의 유전자에서 변이가 발생한다.

적합도 함수(fitness function)는 누적된 학습 콘텐츠의 요소들을 기반으로 다음 단계에 학습할 학습 콘텐츠 요소의 개수 또는 새로 학습해야 할 요소들의 비율로 구성된 벡터의 크기를 사용하였다. 즉, 최적해를 구하기 위해서는 매 단계 학습하는 요소들의 개수나 그 비율이 전

체적으로 고루 분포하면서 크기가 작을수록 적합도 함수 값이 작아지도록 한 것이다. 이는 학습 과정에서 단계가 진행될 때 한꺼번에 너무 많이 배우거나 적게 배우는 것 보다는 고루 분산되도록 하면서, 가급적 최소화하는 것이 학습에 효과적이라는 가정에 의한 것이다. 첫 학습 콘텐츠는 학습자의 프로필을 출발점으로 기준하여 최적화 되도록 하였다.

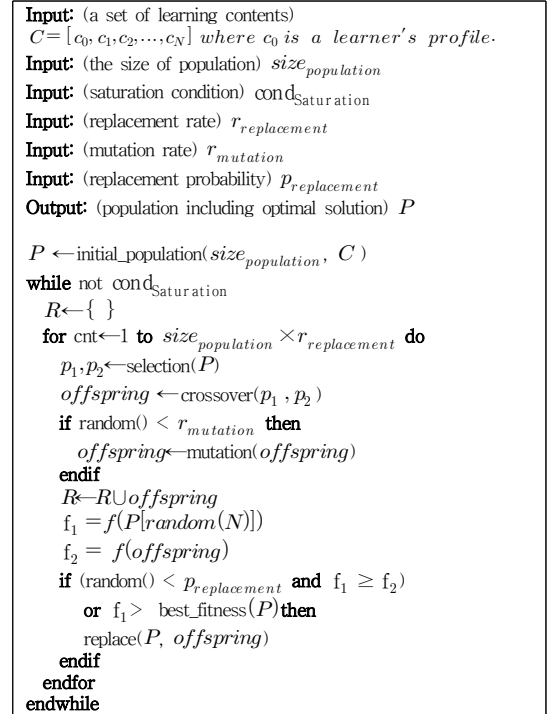


Fig. 7. Genetic algorithm for learning path optimization

#### 4. 실험 결과 및 검증

본 연구에서는 새로 학습할 요소의 비율 크기를 적합도 함수에 사용하여 학습 경로를 최적화하였다. 실험은 32.0GB 메모리와 Intel(R) Core(TM) i7-5820K CPU @ 3.30GHz 프로세서를 가진 64비트 윈도우즈 운영체제에서 진행하였다.

Table 1은 27건의 악보를 대상으로 사용자 프로파일을 0번부터 26번 악보까지 변경하면서 실험한 결과이다. 최종적으로 구한 최적 학습 경로(opt. l. p.)를 살펴보면 사용자의 프로파일이 주어진 모든 경우에 대해 정확하게 처음 학습해야할 악보를 사용자의 프로파일과 일치하는

악보로 선택하였다. 이는 이미 알고 있는 코드를 활용하여 시작하기에 가장 쉬운 단계가 동일한 악보이기 때문에 제한한 학습 경로 최적화 방법이 최소한 출발점을 탐색하는데 효과적임을 보여준다. 또한, 초기 적합도(i. fit)가 평균적으로 1.443 인에 비해 진화를 통한 평균 935.7세대에서의 최적 적합도(o. fit.)는 평균 0.115가 되어 평균 12.5배 좋은 적합도값을 가지게 되었음을 확인하였다.

Table 1. Experimental results based on chord rate

#	cho.	mea.	note	gen.	t(sec)	i. fit	o. fit	opt. l.p.
0	33	74	153	896	1,039	1.509	0.079	0,8,7,24,20,...
1	51	76	145	996	1,207	1.470	0.141	1,0,10,15,14,...
2	16	60	89	966	1,147	1.296	0.138	2,7,24,12,14,...
3	26	103	174	788	970	1.419	0.071	3,5,1,21,17,...
4	19	62	124	989	1,170	1.338	0.158	4,17,18,2,7,...
5	43	71	158	898	1,069	1.423	0.156	5,0,16,10,6,...
6	10	120	120	998	1,192	1.223	0.142	6,2,3,8,24,15,...
7	11	32	45	922	1,078	1.563	0.070	7,0,17,18,24,...
8	16	128	189	943	1,142	1.478	0.160	8,6,2,3,13,2,...
9	14	56	82	812	989	1.446	0.099	9,12,21,15,1,...
10	12	65	71	905	1,152	1.325	0.080	10,3,13,17,20,...
11	13	88	126	791	1,003	1.570	0.076	11,14,,9,3,8,...
12	21	77	115	841	1,039	1.366	0.148	12,13,22,5,20,...
13	54	67	143	974	1,250	1.535	0.133	13,12,25,0,8,...
14	8	115	114	958	1,188	1.385	0.098	14,22,17,26,12,...
15	29	59	104	956	1,199	1.279	0.076	15,3,21,20,22,...
16	18	94	129	984	1,230	1.351	0.071	16,20,4,11,23,...
17	30	61	134	958	1,202	1.633	0.070	17,8,1,13,11,...
18	22	77	102	996	1,271	1.621	0.077	18,8,11,25,5,...
19	11	80	117	993	1,197	1.387	0.220	19,1,26,21,15,...
20	5	98	174	997	1,335	1.479	0.078	20,4,22,5,23,...
21	16	127	127	994	1,259	1.455	0.142	21,24,1,12,3,...
22	33	63	105	920	1,154	1.486	0.163	22,20,12,7,10,...
23	24	56	93	984	1,204	1.561	0.137	23,0,19,21,13,...
24	11	104	104	943	1,202	1.498	0.079	24,1,11,23,6,...
25	12	113	137	904	1,122	1.466	0.143	25,26,6,12,14,...
26	14	88	102	959	1,240	1.389	0.095	26,4,11,5,22,...
sum	572	2,214	3,276	25,265	31,250	38.951	3.1	
avg	21.2	82	121	935.7	1,157	1.443	0.115	

실험 결과 적합도가 가장 좋았던 사용자 프로파일 17번 실험의 경우 27개의 악보를 학습하는데 추가적으로 학습해야하는 코드의 평균 비율과 표준편차는 초기 염색체가 0.102와 0.224로, 최적화된 염색체가 0.047과 0.019로 평균과 표준편차에서 각각 2.17배, 4.77배 품질이 향상되었음을 확인하였다.

Table 2는 비율이 아닌 신규 학습 코드의 크기를 기준

으로 정의한 적합도 실험 결과를 보여준다. 최적 적합도가 상대적으로 매우 낮은 1번과 13번 프로파일의 경우는 코드 크기가 각각 51과 54로 매우 많은 코드가 이미 학습되어 있는 상태에서 최적화했기 때문이다. 반대로 20번 프로파일의 경우는 코드가 5개밖에 되지 않기 때문에 최적 적합도값이 1,569로 높은 편이다. 재미있는 것은 비율의 경우와 다르게 크기 기준일 경우 대부분 20번부터 시작하는 학습 경로가 최적화 결과라는 점이다. 이는 20번 악보의 코드 크기가 5개밖에 되지 않기 때문에 사전 학습상태의 영향을 상대적으로 적게 받기 때문이다.

Table 2. Experimental results based on chord count

#	Initial			optimal			
	fit.	std	max	fit.	std	max	l. p.
0	2,523	7.43	30	1,201	2.49	12	20,19,25,14,6,....,13,5,1
1	2,059	6.77	28	947	2.15	10	20,24,25,19,9,....,13,0,5
2	3,486	8.14	35	1,424	2.51	12	20,7,25,9,14,....,2,5,1
3	3,180	8.73	47	1,308	2.63	12	20,14,19,6,9,....,3,5,1
4	3,789	9.77	50	1,397	2.61	12	20,14,19,9,25,....,22,1,5
5	2,519	7.71	37	1,107	2.68	12	20,19,26,25,6,....,22,13,1
6	3,756	9.47	38	1,502	2.47	12	20,14,11,26,19,....,5,22,1
7	3,613	9.21	49	1,503	2.58	12	10,25,20,9,14,....,5,13,1
8	3,082	8.23	37	1,434	2.58	12	20,19,9,24,25,....,13,5,1
9	3,718	9.50	39	1,474	2.67	12	14,6,19,11,25,....,13,5,1
10	3,542	9.09	42	1,494	2.62	12	20,19,14,6,7,....,13,1,5
11	3,309	8.64	43	1,467	2.52	12	20,6,14,19,9,....,5,1,11
12	3,223	8.68	43	1,367	2.58	12	20,14,19,24,9,....,5,13,1
13	1,624	5.56	22	960	2.51	12	20,6,19,25,14,....,13,1,5
14	4,088	10.04	50	1,530	2.47	12	20,19,9,25,7,....,13,5,1
15	3,001	8.43	41	1,257	2.54	12	24,20,19,14,6,....,13,1,5
16	3,390	8.95	42	1,414	2.63	12	2,20,6,11,7,....,5,22,1
17	3,400	9.29	43	1,274	2.75	12	20,19,25,14,24,....,22,13,1
18	2,448	6.87	26	1,382	2.78	12	10,20,19,14,9,....,18,1,5
19	3,617	9.22	43	1,499	2.55	12	14,20,24,9,6,....,13,5,1
20	4,083	9.95	50	1,569	2.44	12	14,19,9,6,25,....,5,13,1
21	3,810	9.73	43	1,410	2.40	12	20,19,9,25,7,....,5,13,1
22	2,827	8.15	37	1,285	3.06	12	7,9,10,14,6,....,13,5,1
23	3,770	7.57	34	1,340	2.67	12	20,19,14,6,11,....,13,1,5
24	3,249	8.45	33	1,481	2.42	12	14,20,19,9,25,....,5,13,1
25	3,722	9.45	45	1,486	2.56	12	24,25,20,19,9,....,13,5,1
26	3,736	9.53	51	1,452	2.51	12	6,20,11,7,10,....,13,1,5
avg	3,280	8.61	39.9	1,369	2.57	11.9	

최적 경로의 경우 초기값에 비해 표준편차가 평균적으로 3.35배 줄어들었으며, 회당 최대 학습량이 1번 프로파일을 제외하고 모두 12인데, 이는 1번 악보의 51개 코드 중 12개는 다른 악보에 전혀 등장하지 않기 때문이다.

최적 학습 경로는 모두 비교적 코드 개수가 많은 1번 또는 5번 악보로 종료한다는 점도 재미있는 결과이다. 13년이 5번보다 코드 개수가 많음에도 학습 경로의 앞에 등장하는 이유는 신규 코드 개수의 최적 분산과 관련됨을 확인하였다.

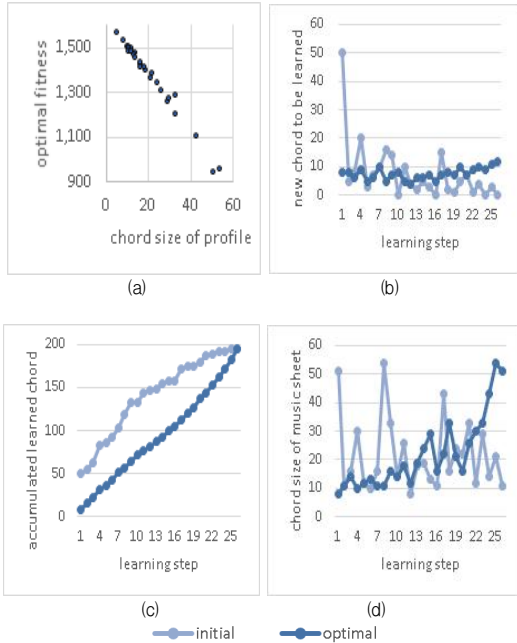


Fig. 8. static analysis of the results

Fig. 8은 실험 결과를 분석하여 시각화시킨 자료이다. (a)는 사용자 프로필에서 코드량이 최적 적합도에 반비례함을 보여준다. 이는 사용자의 사전 지식이 많을수록 적합도의 값, 즉 신규 학습 비용이 낮아짐을 의미한다. (b)는 최적화된 학습 경로의 단계적 학습량이 상대적으로 고루 분포했음을 보여주고, (c)는 최적화된 학습 경로가 상대적으로 불필요한 학습없이 적은 부담으로 최종 목표 학습량을 달성할 수 있게 해줌을 알 수 있다. (d)는 단계별로 학습하게 되는 악보의 전체 코드량을 보여주는데, 비교적 순차적으로 적은 코드로 구성된 악보부터 시작해서 많은 코드로 구성된 악보를 보는 패턴을 보인다. 하지만, 코드 개수를 기준으로 학습 경로가 설정되는 것이 항상 최적화가 아님도 확인할 수 있다.

## 5. 결론

악보를 이용한 최적화 실험을 통해 학습 요소의 비례 벡터와 같은 단순한 방법으로도 사용자의 프로필에 따라 맞춤형 학습 경로를 효과적으로 계획할 수 있음을 확인하였다. 사용자의 프로필을 학습 대상에 대해 학습 여부만을 구분하여 단순화시킨 실험이었지만 유전 알고리즘을 이용한 학습 경로 최적화의 효과성을 보일 수 있었다. 만약 학습 정도를 고려한 추가적인 속성을 활용하고, 코드의 난이도에 따라 가중치를 주는 방식으로 적합도 함수를 개선한다면 보다 다양한 목적의 최적화 경로를 구축할 수 있을 것으로 보인다.

본 연구에서는 새로 학습할 요소의 비율 크기를 이용하여 학습 경로를 구하였으나 비율이 아닌 개수나 기타 속성들의 조합으로 적합도 함수를 정의할 수도 있다. 학습의 목적에 따라 다양한 적합도 함수를 정의할 수 있기 때문에 본 연구의 스키마와 알고리즘을 크게 바꾸지 않고도 다양한 맞춤형 학습 경로를 구할 수 있다.

## REFERENCES

- [1] M. Bhaskar, M. Das, T. Chithralekha & S. Sivasatya. (2010). Genetic Algorithm Based Adaptive Learning Scheme Generation For Context Aware E-Learning. *International Journal on Computer Science and Engineering*, 2(4), 1271-1279.
- [2] A. Kumar, N. Singh & N. Ahuja. (2017). Learning Styles based Adaptive Intelligent Tutoring Systems: Document Analysis of Articles Published between 2001 and 2016. *International Journal of Cognitive Research in Science, Engineering and Education*, 5(2), 83-97.
- [3] P. Karampiperis & D. Sampson. (2008). Adaptive Learning Resources Sequencing in Educational Hypermedia Systems. *Educational Technology & Society*, 8(4), 128-147.
- [4] Z. Fan & C. Jiaheng. (2008). Learning Activity Sequencing in Personalized Education System. *Journal of Natural Sciences*, 13(4), 461-465.
- [5] F. Edson & J. Valente. (2004). A New Approach to Meaningful Learning Assessment Using Concept Maps: Ontologies and Genetic Algorithms. *Proc. of the 1st Conference on Concept Mapping*. (pp.175-182). Pamplona.
- [6] T. Lakshmi, A. Martin & V. Venkatesan. (2013). An Analysis of Students Performance Using Genetic

- Algorithm. *Journal of Computer Science and Applications*, 1(4). 75-79.
- [7] D. Anastasiu, N. Bold & D. Nijloveanu. (2016). A Method Based on Genetic Algorithms for Generating Assessment Tests Used for Learning. *Polibits*, 54(1). 53-60.
- [8] B. Velusamy, S. Anouneia & G. Abraham. (2013). Reinforcement Learning Approach for Adaptive E-learning Systems using Learning Styles. *Information Technology Journal*, 12(12), 2306-2314.
- [9] A. Sukstrienwong. (2017). A Genetic-algorithm Approach for Balancing Learning Styles and Academic Attributes in Heterogeneous Grouping of Students. *International Journal of Emerging Technologies in Learning*, 12(3). 4-25.
- [10] F. Dorca, L. Lima, M. Fernandes & C. Lopes. (2013). Automatic student modeling in adaptive educational systems through probabilistic learning style combinations: a qualitative comparison between two innovative stochastic approaches. *Journal of the Brazil Computer Society*. 19(1). 43-58.
- [11] J. Bernard, T. Chang, E. Popescu & S. Graf. (2017). Learning Style Identifier: Improving the Precision of Learning Style Identification Through Computational Intelligence Algorithms. *Expert Systems with Applications*, 75. 94-108.
- [12] D. Anitha & C. Chelliah. (2013). A Novel Approach for Selection of Learning Objects for Personalized Delivery of E-Learning Content. *International Conference on Computer Science & Information Technology*. (pp.413-420). Yogyakarta.
- [13] L. Marcos, J. Martinez, J.-A. Gutierrez, R. Barchino, J. Hilera, S. Oton & J.-M. Gutierrez. (2011). Genetic Algorithms for Courseware Engineering. *International Journal of Innovative Computing, Information and Control*, 7(7). 3981-4004.
- [14] D. Matic (2010). A Genetic Algorithm for Composing Music. *Yugoslav Journal of Operations Research*, 20(1). 157-177.
- [15] M. Alfonseca, M. Cebrian & A. Puente (2007). A Simple Genetic Algorithm for Music Generation by Means of Algorithmic Information Theory. *Proc. of the IEEE Congress on Evolutionary Computation*. (pp.25-28). Singapore.

정 우 성(Jung, Woosung)

[중신회원]



- 2003년 2월 : 서울대학교 컴퓨터 공학과(공학사)
- 2011년 8월 : 서울대학교 컴퓨터 공학과(공학박사)
- 1998년 9월 ~ 2002년 2월 : SK 유비케어 연구원
- 2011년 9월 ~ 2012년 2월 : LG전자 CTO 선임연구원
- 2012년 3월 ~ 2016년 8월 : 충북대학교 교수
- 2016년 9월 ~ 현재 : 서울교육대학교 교수
- 관심분야 : SW교육, SW공학, SW저장소 마이닝
- E-Mail : wsjung@snu.ac.kr