출품번호
1434

제72회 전국과학전람회

물소리만 듣고 컵의 모양을 알 수 있을까? 역할 분담 신경망과 물리 법칙으로 풀어낸 음향 형상 역추적

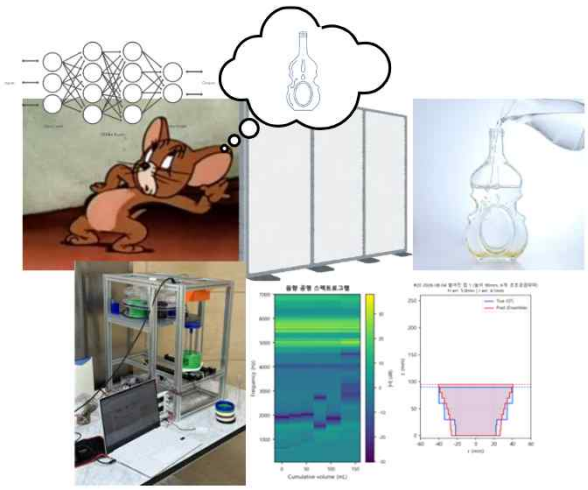

2026. 8. 12.

출품학생	
지도교원	
구 분	학생부
출품부문	산업 및 에너지

<차례>

Ⅰ. 탐구 동기 및 목적 1

1. 탐구 동기 1

2. 탐구 목적 2

Ⅱ. 탐구 개요 2

1. 탐구 절차 2

Ⅲ. 이론적 배경 및 선행연구 조사 3

1. 이론적 배경 3

2. 선행 연구 조사 6

Ⅳ. 탐구 내용 8

1. 물과 소리로 어떻게 형상을 복원하는가 - 물 주사를 통한 유일성 복원 8

가. 물 주사를 통해 공명 특성을 얻는 기본적 원리 8

2. 컵의 소리에 귀를 기울이다 - 실제 용기의 소리를 재는 시스템 제작 9

가. 용기의 공명 특성을 얻기 위한 실험 장비 설정 9

나. 전달함수 계산 프로그램 - 사인 스윕과 디컨볼루션 제작 13

3. 학습 데이터 확보 - 형상으로부터 소리를 만드는 시뮬레이터 제작 14

가. 전달행렬법(TMM)의 물리적 조건 설정 및 전달함수 도출 방식 14

나. 전달행렬법은 정말로 믿을만 할까? - 물리적 계산, 실측과의 정합성 비교 15

4. 소리로부터 형상을 만드는 딥러닝 모델 제작 17

가. 10만 개 가상 컵에 대한 학습 데이터 확보 및 증강 17

나. 모델의 입출력 및 하이퍼파라미터 개수 설정 18

다. 형상 추정에 최적인 모델 선정 및 튜닝 - 시소 현상의 극복 19

라. 시뮬레이션 데이터에 대한 추정 결과 20

5. 소리로 형상을 복원하다 - 실측 자료를 통한 추정 21

가. 1차 실측 투입과 모델의 붕괴 원인 규명 21

나. 2차 실측 - 원인 분석과 극복 24

Ⅴ. 결론 및 연구 가치, 추가 개발 계획 27

1. 탐구 결론 27

2. 향후 탐구 계획 28

Ⅵ. 참고문헌 30

<표 차례>

표 1. 측정 장비 사진 10
표 2. 사용 장비 품명 및 FFT 11
표 3. 형상 제작 링 규격 12
표 4. 실측 spectrogram 측정 방법 12
표 5. 실측 spectrogram 측정 방법 13
표 6. TMM의 제원 16
표 7. 해석해가 존재하는 형상과 TMM과의 비교 건수 17
표 8. TMM에서의 딥 주파수와 해석해에서의 딥 주파수 비교 17
표 9. TMM에서의 딥 주파수와 실측에서 딥 주파수 비교 17
표 10. 생성 형상 정보 18
표 11. 증강학습 정보 18
표 12. 인공 신경망의 입출력 19
표 13. 인공 신경망의 구성요소 19
표 14. 최종적으로 선정된 모델 결합의 세부사항 21
표 15. 역할 분담 모델의 높이 MAE와 반지름 MAE 21
표 16. 시뮬레이션에 대한 추정 결과 22
표 17. 컵 별 형상 참값과 예측값 및 오차 23
표 18. 증강 이전 모델의 추정 결과 23
표 19. 증강학습에 대한 세부사항 24
표 20. 증강학습 이후 실측 추정 결과 25
표 21. 증강학습 이후 실측 추정 결과 25

<그림 차례>

그림 1. 소리로 형상을 유추할 수 있을까? 1
그림 2. 탐구 개요 2
그림 3. 기주에서의 정상파 조건 3
그림 4. 헬름홀츠 공명이 일어나는 병 3
그림 5. spectrogram 4
그림 6. 선행 발명 연구 6
그림 7. 선행 연구 포스터 6
그림 8. 선행 연구 7
그림 9. 스펙트로그램 생성 원리 8
그림 10. 링을 이용한 형상 제작 모식도 9
그림 11. 링을 이용해 형상을 제작한 모습 9
그림 12. 측정 장비 구조도 9
그림 13. 측정 장비 10
그림 14. openscad 모델링 정면도 10
그림 15. openscad 모델링 측면도 10
그림 16. openscad 모델링(왼쪽 위에서) 10
그림 17. 임의의 형상 제작을 위한 도넛 링 11
그림 18. 레퍼런스 측정 세팅 11
그림 19. 링을 넣어 형상을 만드는 장면 11
그림 20. 녹음 앱의 레퍼런스 측정 화면 11
그림 21. 녹음 앱을 이용해 구한 빈 컵에 대한 전달함수 11
그림 22. 물을 채운 후 전달함수를 구하는 장면 12
그림 23. 녹음 앱을 이용해 구한 두 번째 스텝의 전달함수 12
그림 24. 물을 3cm 남긴 모습 12
그림 25. 최종적으로 구한 스펙트로그램과 추정 결과 12
그림 26. TMM의 설계도 14
그림 27 가상, 실측 실험 세팅 17
그림 28. 채택된 모델의 학습 곡선 29
그림 29. 시소 현상의 발견 20
그림 30. 가로줄에 의해 오염된 스펙트로그램 23

I 탐구 동기 및 목적

1. 탐구 동기

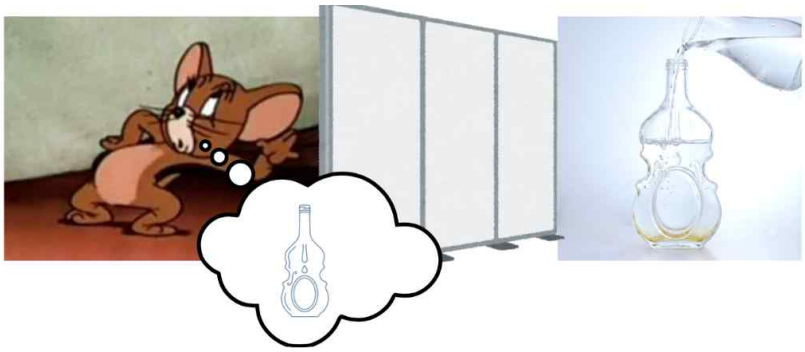

그림 1. 소리로 형상을 유추할 수 있을까?

컵에 물을 따르는 소리는 물이 채워져 갈수록 '또르륵'에서 '띠리릭'으로 변한다. 기주 공명 이론에 따르면 수위가 증가하면서 컵 속 공기 기둥의 길이가 짧아지면서 공명 주파수가 변하고, 특정 배음이 강해지면서 음색이 달라지게 된다. 이는 물을 따르면서 발생하는 소리가 용기 내부의 정보를 담고 있는 신호임을 의미한다. 우리는 여기서 **물을 따르는 소리로부터보이지 않는 공동의 물리적 정보를 얻을 수 있다는 점**에 주목하였다.

이 과정에서 우리는 물이 차오를수록 변하는 공명음을 이용해 수위를 판단하는 선행 연구를 접하게 되었다. 공명 주파수와 기주의 길이 사이에 수학적 관계가 존재한다는 점에서, 음향 분석이 단순히 소리를 인식하는 것을 넘어 공간적인 정보를 제공할 수 있다는 것이다. 물을 따를 때, 유량의 정보를 알고, 수위의 변화를 안다면 그 순간의 단면적을 수학적으로 계산할 수 있다. **그렇다면 소리만으로 높이 별로 병의 모양을 알 수 있는 것, 즉 병의 형상을 복원해내는 것은 가능할까?**

공동의 공명 구조를 통해 형상을 복원해내는 문제는 학계에서 활발히 논의되어 왔다. Kac의 연구에 의하면[1] "북의 소리만 듣고 북 모양을 알 수 있을까?"에 대한 답은 '일반적으로 불가능하다.' 였다. 수학적으로 모양이 다르지만 같은 소리, 즉 공명 구조를 가지는 두 북이 존재하기 때문이다. 소리를 한 번 듣고 맞히는 것은 원리적으로 답이 비유일한 문제이다.

우리는 **물을 따르는 것에서 이를 해결할 아이디어를 얻을 수 있었다.** 물의 표면은 소리에 대해 강체처럼 행동하기 때문에, 물을 붓고 공명 구조를 파악하는 것은 바닥의 위치를 끌어올려 새로운 공명 구조를 측정하는 것과 같다. 물을 붓는 횟수에 따라 새로운 정보를 계속해서 얻을 수 있는 것이다. 우리는 이것이 문제의 답의 비유일성을 해결할 수 있는 실마리가 될 수 있을 것이라고 판단하였다.

이에 우리는 임의의 모양을 가진 빈 공동에 **물을 채우면서 얻은 공명 정보만을 가지고 형상을 추정하는 연구를 진행하고자 하였다.** 이전까지 공명 구조를 이용하여 형상의 정보를 얻은 연구들은 수위만을 추정하거나, 원기둥 가정을 통하여 이를 이루고자 하였다. **우리의 연구는 소리 정보만을 통해 자유 형상을 역추정하는 첫 시도이다.** 자유 형상에서는 기주 가정이 성립하지 않고, 헬름홀츠 공명과 같은 다양한 유형의 공명과 비해석적인 공명이 존재할 수 있기 때문에, 단순 알고리즘만으로는 이러한 추정이 불가능하다는 것을 알 수 있다. 우리는 이를 해결하기 위해 인공 신경망을 도입하였다.

2. 탐구 목적

본 탐구는 빈 공동의 공명 특성으로부터 형상을 역추적하는 것이 목적이다. 이를 위해 물리 기반 시뮬레이션으로부터 인공 신경망 학습 데이터를 획득하고, 형상을 추정하는 인공 신경망을 제작하고자 한다. 이를 통해 물리 시뮬레이션과 인공 신경망의 결합으로 비정형 용기의 3 차원 형상을 추정하는 하나의 시스템을 구축하는데 목적을 둔다. 이 과정에서 존재할 수 있는 물리적 해의 비유일성 문제를 해결하기 위해, 일상적 과정인 물 채우기로부터 영감을 얻어, 물을 일정량씩 부어가는 주사 과정에서의 공명 특성을 파악하는 방법을 도입하고자 한다.

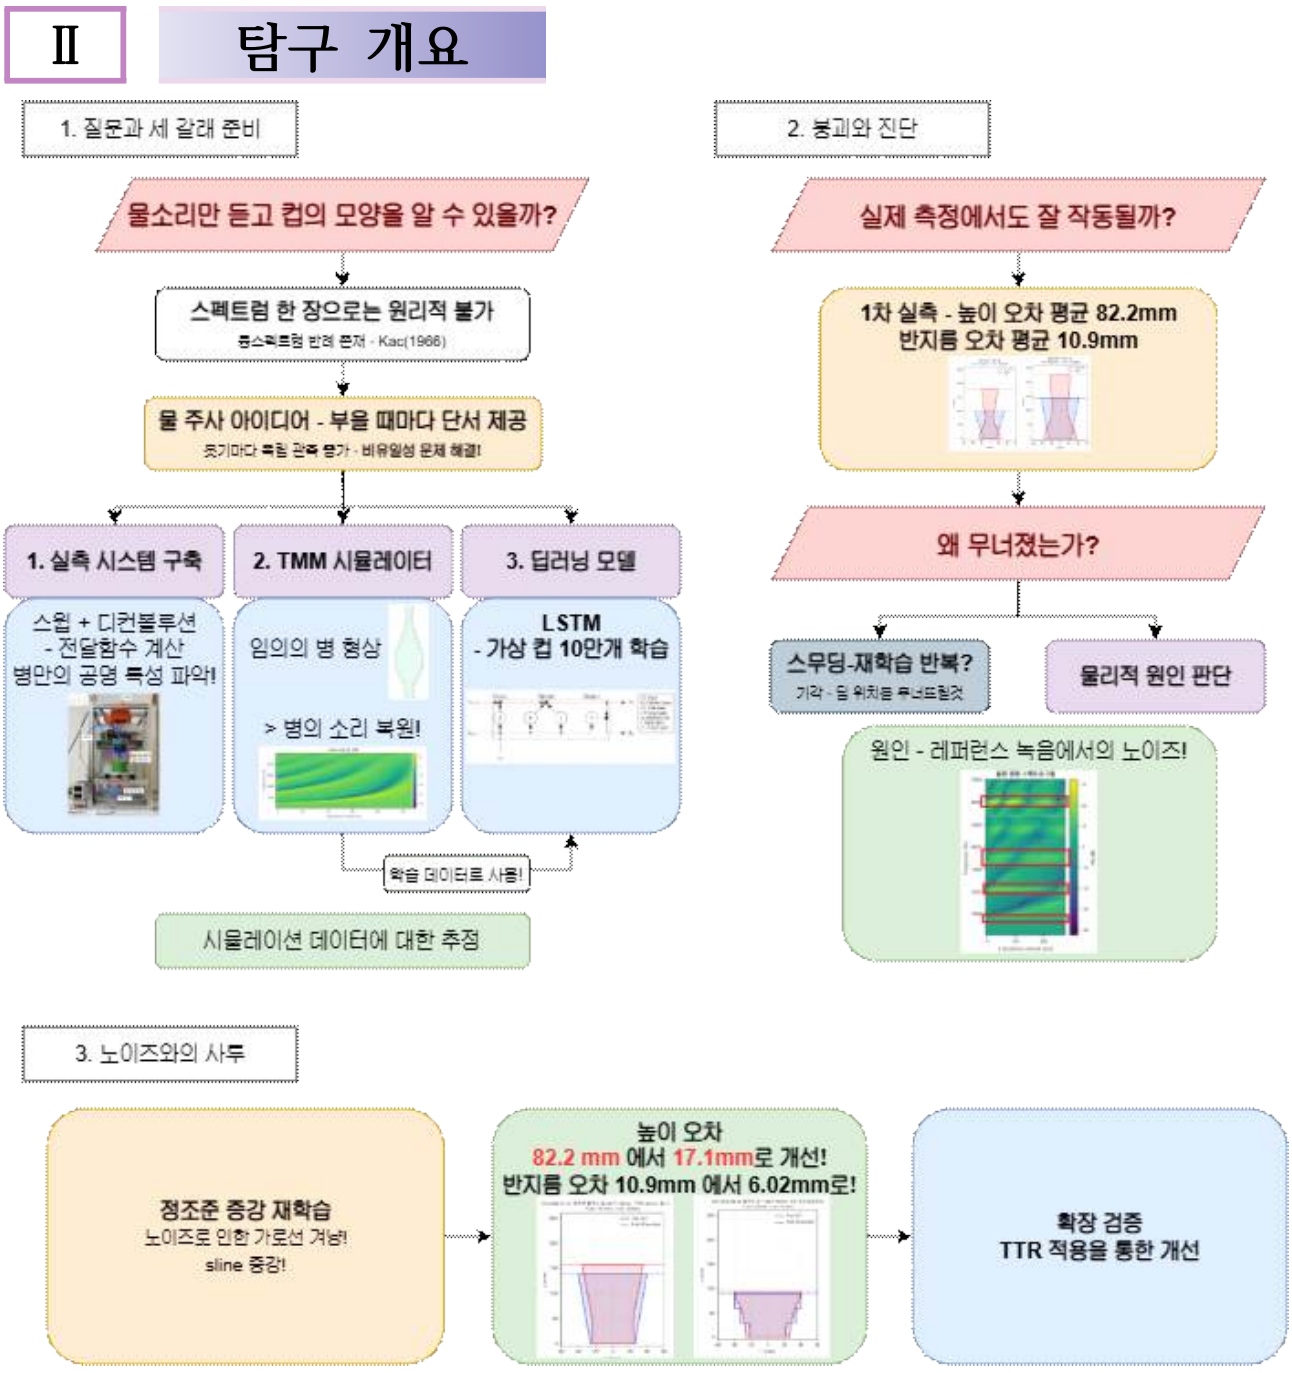

그림 2. 탐구 개요

III 이론적 배경 및 선행 연구 조사

1. 이론적 배경

가. 음향학 이론

1) 기주 공명, 헬름홀츠 공명

(가) 기주 공명

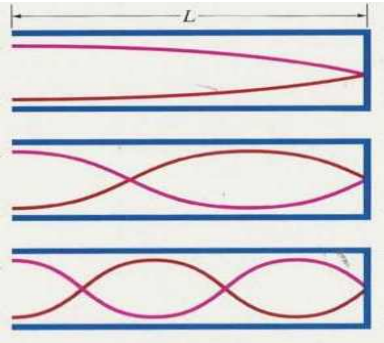

그림 3. 기주에서의 정상파 조건

음파가 관 내부를 진행하다 경계면에서 고정단반사가 일어나면 반사파와 입사파와 중첩되어 정상파가 형성되고, 열린 끝에서 음압 변화가 작은 압력 마디가 된다. 이 조건은 L=(2n-1)λ/4이며 이를 만족시키지 못하는 진동수에서는 입사파와 반사파가 서로 중첩되며 정상파를 형성하지 못한다. 이와 같이 관 내부의 공기 기둥에서 발생하는 공명을 기주 공명이라 하며, 한 쪽이 닫힌 기주에서의 1배 진동의 공식은 $f = \frac{c}{4L}$과 같다. (f: 진동수, c: 소리 속력, L: 기주 길이)

컵에 물을 따르면 물끼리 서로 충돌하며 넓은 음역대의 소리가 발생하게 된다. 이들 중 기주 공명 조건에 맞지 않는 주파수대는 서로 상쇄되어 우리의 귀에 들리지 않고, 조건에 맞는 진동수만 남게 된다. 물을 따르면 소리가 '또르륵' 에서 띠리릭으로 변하는 이유도 기주 공명 주파수의 변화에 기인한 것이다.

(나) 헬름홀츠 공명

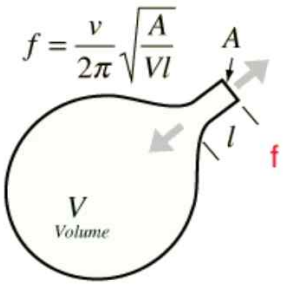

그림 4. 헬름홀츠 공명이 일어나는 병

헬름홀츠 공명은 병이나 플라스크처럼 입구가 좁고 내부 부피가 큰 용기에서 발생하는 역학적 공명 현상이다. 좁은 병목 내부의 공기는 일정한 질량을 가진 피스톤처럼 입구를 따라 왕복 운동을 하고, 내부 공간에 갇힌 공기는 피스톤의 움직임에 따라 압축과 팽창을 반복하며 원래 상태로 돌아가려는 복원력을 제공하는 용수철 역할을 한다. 외부에서 유입된 소리의 진동수가 이 계의 고유 진동수와 일치할 때 입구의 공기가 크게 왕복하며 강한 공명 소리가 발생한다. 헬름홀츠 공명의 진동수 공식은 $f = \frac{c}{2\pi}\sqrt{\frac{S}{VL}}$과 같다. (*f*: 진동수, *c*: 소리 속력, *S*: 병목 단면적, *V*: 내부 공간 부피, *L*: 병목 유효 길이)

(다) 관구 효과

관구 효과(End Correction)란, 한쪽 끝이 열린 관에서 공기 기둥이 실제 관 길이보다 $L_{eff} = L + kD$와 같이 더 길게 작용하는 현상을 말한다. (D: 기주의 지름, k≈0.3)

2) 푸리에 변환, spectrogram

(가) 푸리에 변환

푸리에 변환은 시간에 따라 변화하는 신호를 여러 주파수 성분 합으로 분해하는 수학적 방법이다. 일반적인 소리 신호는 시간에 따른 음압의 변화로 기록되기 때문에 파형만으로 주파수 성분을 파악하기 어렵지만, 푸리에 변환을 사용하면 시간 영역의 신호를 주파수 영역으로 바꾸어 주파수 성분을 분석할 수 있다. 음향 분석에서 FFT는 녹음된 소리 안에 어떤 주파수 성분이 강하게 존재하는지 확인하는 데 사용된다. 컵이나 병에 물을 따를 때 발생하는 소리를 녹음한 뒤 FFT를 적용하면, 특정 주파수에서 세기가 크게 나타나는 피크나 딥을 찾을 수 있다.

(나) Spectrogram

한 번의 FFT 결과로 x축이 주파수, y축이 세기인 주파수 스펙트럼을 얻을 수 있다. 그러나 이는 시간에 따른 주파수 성분의 변화를 알 수 없다. 스펙트로그램은 x축에 시간, y축에 주파수, 각 점의 색에 주파수 성분의 세기를 나타낸 그래프이다. 따라서 스펙트로그램을 이용하면 소리 속에 포함된 공명주파수가 시간에 따라 어떻게 이동하는지 확인할 수 있다. 본 연구에서는 음향 신호를 물리적으로 해석하고, 용기의 형상을 추정하기 위한 핵심 도루로서 스펙트로그램을 사용한다.

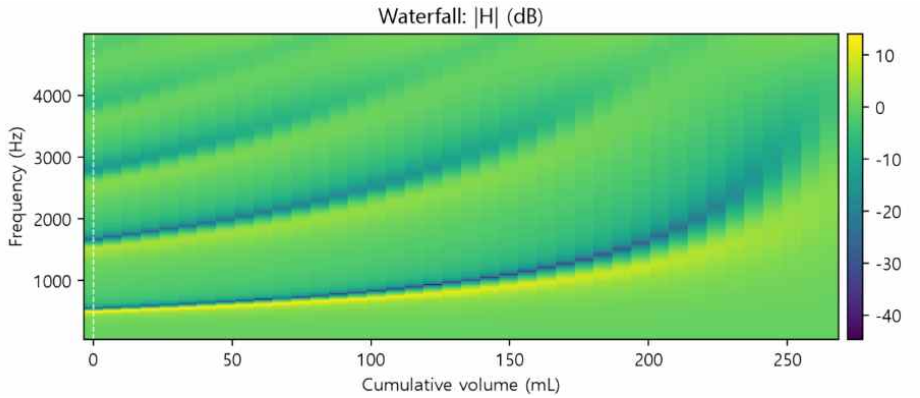

그림 5. spectrogram

3) 전달함수(Transfer Function)

전달 함수(Transfer Function)은 어떤 시스템에 입력된 신호가 출력 신호로 변환되는 과정에서 주파수별로 신호가 얼마나 증폭되거나 감쇠되는지를 나타내는 함수이다. 음향 실험에서는 스피커에서 발생한 소리가 공기 중을 지나 용기 내부에서 공명하고, 다시 마이크로 측정되는 과정을 하나의 시스템으로 볼 수 있다. 전달함수 H(f)는 출력 신호 Y(f)를 입력 신호 X(f)로 나누어 $H(f) = \frac{Y(f)}{X(f)}$와 같이 나타낼 수 있다. 음향 신호에는 용기 내부의 공명 특성 뿐만 아니라 스피커의 출력 특성, 마이크의 감도, 노이즈 등이 포함되기 때문에, 용기에 의한 영향만을 추출해내기 어렵다. 이러한 영향을 줄이고 용기의 공명 특성만을 추출하기 위해 전달 함수 개념을 적용한다.

나. TMM(Transfer Matrix Method, 전달행렬법)

전달행렬법은 음향학과 광학에서 복잡한 다층 구조나 연속된 시스템을 개별 요소의 행렬로 쪼개고, 순차적으로 곱하여 전체 거동과 특성을 해석하는 기법이다. 음파의 경우, 이를 통해 음파가 진행하는 공간에서 주파수 별 증폭과 감쇠 여부를 알 수 있게 된다. 음파가 공동을 진행하면서 공동의 모양, 즉 음향 임피던스에 따라 직접파와 방사파가 결합한 음압의 세기가 달라지게 되는데, TMM은 이러한 연속적인 변화를 파악하기 위해 병을 작은 조각(segment)로 쪼개어 이산화한다. 여기서 음파가 한 조각에서 다른 조각으로 전이할 때 변화를 수식적으로 서술하여 각 세그먼트에서의 유량과 음압의 관계를 행렬식으로 작성할 수 있으며, 이를 전달행렬이라고 한다. 일반적인 TMM에서는 공동의 입력 임피던스를 구하는 것이 목적이다. 그러나 우리 탐구는 공동이라는 음향학적 계에서, 우리가 구축한 축대칭 실측 시스템에서의 주파수 별 세기, 즉 전달함수를 아는 것이 목표이기 때문에 이를 수식적 전개와 물리적 상황 설정을 거쳐 전달함수를 도출해내도록 하였다. 지금까지의 음향학 연구에서는 보통 이를 물리적 상황을 가정하지 않고 2D FEM을 실시하여 구하였지만, 우리 연구는 상황을 가정하고 수식 전개를 함으로써, 이를 전달함수 도출에 직접 응용하는 새로운 방법론을 도입하였다.

다. 인공 신경망 모델

1) 인공 신경망 모델

인공 신경망은 사람의 뇌에서 뉴런들이 서로 연결되어 정보를 처리하는 방식을 모방한 계산 모델이다. 인공 신경망은 여러 개의 노드(node)로 구성되며, 각 노드는 입력값을 받아 가중치를 곱하고 편향을 더한 뒤 활성화 함수를 거쳐 출력값을 만든다. 이러한 노드들이 층을 이루며 연결되어 복잡한 입력과 출력 사이의 관계를 학습한다. 인공 신경망은 입력층, 은닉층, 출력층으로 구성된다. 입력층은 분석하고자 하는 데이터를 받는 층이고, 은닉층은 입력 데이터의 특징을 조합하고 변환하는 층이다. 출력층은 최종적으로 예측값을 내보낸다.

2) CNN(Convolutional Neural Network)

CNN은 이미지와 같이 공간적 구조를 가진 데이터를 분석하는 데 적합한 딥러닝 모델이다. 합성곱을 통해 이미지에서 선, 경계, 곡선 등 특징을 추출하고 여러 층을 거치며 더 복잡한 형태를 인식한다.

3) RNN(Recurrent Neural Network)

RNN은 시간에 따라 순서가 있는 데이터를 분석할 때 적합한 딥러닝 모델이다. 즉, RNN은 이전 시점의 정보를 다음 시점의 계산에 함께 반영해 현재 입력뿐만 아니라 과거에 입력된 데이터의 흐름을 기억하면서 전체적인 변화 양상을 학습할 수 있다.

4) LSTM(Long Short-Term Memory)

LSTM은 RNN의 한 종류로, 시계열 데이터에서 장기적인 변화 흐름을 학습하기 유용한 딥러닝 모델이다. RNN은 데이터 길이가 길어지면 앞부분의 중요한 정보가 약해질 수 있다. 하지만 LSTM은 게이트가 어떤 내용을 버릴지, 반영할지 조절하기 때문에 앞부분의 중요한 정보도 반영할 수 있다.

2. 선행 연구 조사

1. 제45회 전국학생과학발명품경진대회. (2024). 컵의 크기에 상관없이 가득 따라주는 똑똑한 AI 정수기

요약	 그림 6 선행 발명 연구 정수기에서 마이크로 물 떨어지는 소리를 녹음해, 기주공명의 원리를 적용하여 공기 기둥의 길이를 실시간으로 추적하고, 물이 일정 수위 도달하면 급수를 자동 차단하는 장치를 제작한 발명이다. LPC 기반의 포먼트 추출로 공명 주파수를 추적하는데 성공하였으며, 유량이 일정한 조건에서 1/f를 시간에 대해 선형적으로 근사하면 컵의 지름까지 역산할 수 있음을 실험적으로 보였다. 이 연구에서는 재질과 형태가 다른 컵 9개에서 자동 정지에 성공하였다.
의의	공명 주파수만으로 용기의 기하학적 정보인 남은 수위를 추정할 수 있음을 실물로 증명하였고, 후속 연구 주제로 정유량 조건에서 공명 변화율이 단면적에 대한 정보를 담을 것이라는 제안은 본 탐구 주제와 밀접한 연관이 있다. 이 발명은 용기를 원통으로 근사하고 높이 H와 지름 D 하나만을 수식적으로 역산하였다. 본 탐구는 이것을 전달행렬법과 딥러닝으로 확장해 자유 형상의 전체 반지름 분포를 mm 단위로 복원하려 한다는 점에서 차이가 있다.

2. Piyush Bagad, Makarand Tapaswi, Cees G. M. Snoek, Andrew Zisserman.(2024). The Sound of Water: Inferring Physical Properties from Pouring Liquids.

요약	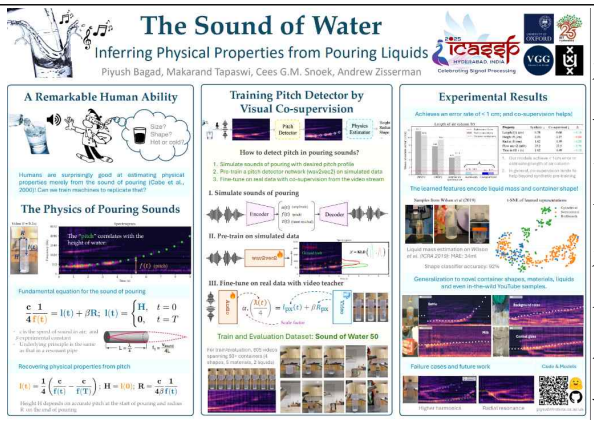 그림 7. 선행 연구 포스터 액체를 그릇에 따를 때 발생하는 낙수음의 기본주파수 변화를 이용해 원통 가정을 한 용기의 형태, 물의 높이, 부피, 유량 등의 물리적 성질을 추정하였다. wav2vec2 기반 오디오 인코더와 영상 데이터를 함께 활용하여 자기지도 학습 프레임워크를 제안하였으며, 실제 낙수음과 합성 낙수음 데이터셋 모두에서 이를 검증했다. 소리만으로 물리적 상태를 추정할 수 있음을 대규모 데이터와 최신 딥러닝 기법으로 입증한 연구이다.
의의	이 연구는 “낙수음으로 액체의 물리량을 추정한다”는 의식을 딥러닝 기반 대규모 프레임워크로 다뤘다는 점에서 본 탐구와 같은 문제의식을 공유하고 있으며, 이것이 학술적 가치를 가짐을 뒷받침하는 사례이다. 그러나 이 연구는 용기 형태를 원통으로 가정하고 신경망이 음향 신호에서 직접 물리량을 추정하는 데이터 중심 접근에 가깝다. 반면 본 탐구는 형태에 대한 사전 가정을 두지 않는다는 점, 물리 모델로 생성항 학습 데이터를 통해 실측에 적용하는 sim-to-real 과정을 적용하였다는 점에서 차별점을 가진다.

3. Mark Kac.(1966). Can One Hear the Shape of a Drum?

요약	북의 고유진동수만을 듣고 그 북의 모양을 알아낼 수 있는지를 수학적으로 정식화한 연구이다. 2차원 막의 파동방정식 문제를 다루며, 넓이와 둘레 같은 일부 기하 정보는 고유 진동수 스펙트럼만으로 복원 가능하지만 모양 전체를 복원할 수 있는지는 미해결 문제로 남겨두었다.
의의	이 논문은 소리만으로 형상을 알 수 있는가라는 질문을 수학적으로 엄밀하게 던진 연구로, 본 연구의 문제의식과 제목이 직접 잇닿아있는 근원이다. 이 질문은 1992년 Gordon-Webb-Wolpert의 스펙트럼이 같지만 모양이 다른 북에 대한 반례로 일반적인 경우에는 불가능함이 증명되었다. 본 탐구는 이 비유일성을 물을 채우는 과정을 통해 경계조건을 능동적으로 스캔한다는 점에서 해결하고자 한다.

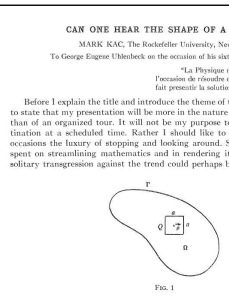

CAN ONE HEAR THE SHAPE OF A DRUM?

MARK KAC, The Rockefeller University, New York

To George Eugene Uhlenbeck on the occasion of his sixty-fifth birthday

"La Physique ne nous donne pas seulement l'occasion de résoudre des problèmes . . . , elle nous fait pressentir la solution." H. POINCARÉ.

Before I explain the title and introduce the theme of the lecture I should like to state that my presentation will be more in the nature of a leisurely excursion than of an organized tour. It will not be my purpose to reach a specified destination at a scheduled time. Rather I should like to allow myself on many occasions the luxury of stopping and looking around. So much effort is being spent on streamlining mathematics and in rendering it more efficient, that a solitary transgression against the trend could perhaps be forgiven.

FIG. 1

그림 8. 선행 연구

4. M. R. Schroeder.(1967). Determination of the Geometry of the Human Vocal Tract by Acoustic Measurements

요약	사람의 성도 형상을 순수 음향 측정만으로 추정하는 방법을 제시한 연구이다. 성도의 고유진동수를 측정하는 방법과 입술에서의 음향 임피던스를 측정하는 방법을 다루며 두 측정 모두 단면적 함수를 푸리에 급수로 나타냈을 때 계수를 결정할 수 있음을 보였다. 측정된 고유진동수의 개수가 늘어날수록 복원되는 형상의 공간 해상도가 높아진다는 것 또한 이론적으로 정립한 연구이다.
의의	이 연구는 속이 빈 공동의 공명 구조를 통해 형상을 복원한다는 이론적 가설을 세운 연구로, 본 연구가 풀고자 하는 문제와 수학적인 구조가 유사하다. 다만 이 연구는 사람이 발화 중 만들어내는 고유 진동수를 관측하지만, 본 연구에서는 물을 채우는 과정 자체를 경계조건을 바꾸며 주사하는 과정으로 재해석해, 한번의 정적 측정으로 얻을 수 없는 관측을 확보함으로써 단일 고유 진동수 측정의 한계를 극복하고자 하였다.

IV 탐구 내용

1. 물과 소리로 어떻게 형상을 알아낼까? - 물 주사를 통한 유일성 복원

가. 물 주사를 통해 공명 특성을 얻는 기본적 원리

탐구를 시작하기에 앞서, 소리로 형상을 복원하는 것이 가능한지 확인하기 위해서는 하나의 소리가 하나의 형상 정보를 담는지 확인하여야 한다. 즉 동일한 공명 특성을 가진 서로 다른 두 개의 형상이 존재하는지 알아보아야 한다. 하지만 선행연구 분석을 통해, 빈 공동의 공명 정보 한 장만을 가지고 형상을 복원하는 것은 원리적으로 불가함을 확인할 수 있었다. 서로 다른 모양임에도 불구하고, 완전히 같은 공명 스펙트럼을 가지는 두 입체도형 쌍이 실존한다는 것이다. 그러나, 또 다른 선행연구에서는 물을 따름에 따라 공명 주파수가 이동하는 것을 이용해 수위를 파악하는 정수기를 개발하였는데, 우리는 이로부터 이 문제의 해의 비유일성을 해결할 수 있는 실마리를 찾게 되었다. 음파에 대해 물은 강체처럼 행동하기 때문에, 물을 채우면서 공명 특성을 측정하는 것은 하나의 수학적 정보를 주는 것만이 아니라, 경계조건이 계속 바뀌는 여러 번의 측정이 되어 더 많은 정보를 주는 것이다. 이는 형상을 표현하는 높이 별 반지름, 즉 미지수의 개수는 그대로이지만, 독립적인 방정식이 되는 관측 정보는 관측 횟수만큼 늘어나는 셈이기 때문에, 이러한 해의 비유일성 문제를 깰 수 있다.

이를 측정하기 위해, 측정하고자 하는 공동과 스피커, 마이크를 통해 공명 특성을 파악한다. 물을 일정량 채운 뒤, 스피커로 스윕 신호를 재생하여 50~8000Hz 대역의 주파수가 모두 공동 안을 진동하게 한다. 이 신호를 마이크로 받으면, 물을 채운 순간에서의 공동에 대한 공명 정보, 즉 주파수 별 전달함수를 얻어낼 수 있다. 이러한 스펙트럼 정보를 물을 따른 횟수(스텝)에 따라 모두 수집하고, 이를 스펙트로그램의 형태로 저장하면, 물이 채워지면서 달라지는 공명 특성을 얻을 수 있다. 우리 연구는 이러한 측정을 기반으로 형상을 추정하고자 한다. 측정에 대한 상세한 설명은 4. 절의 실측 장치 제작에 기술하였다.

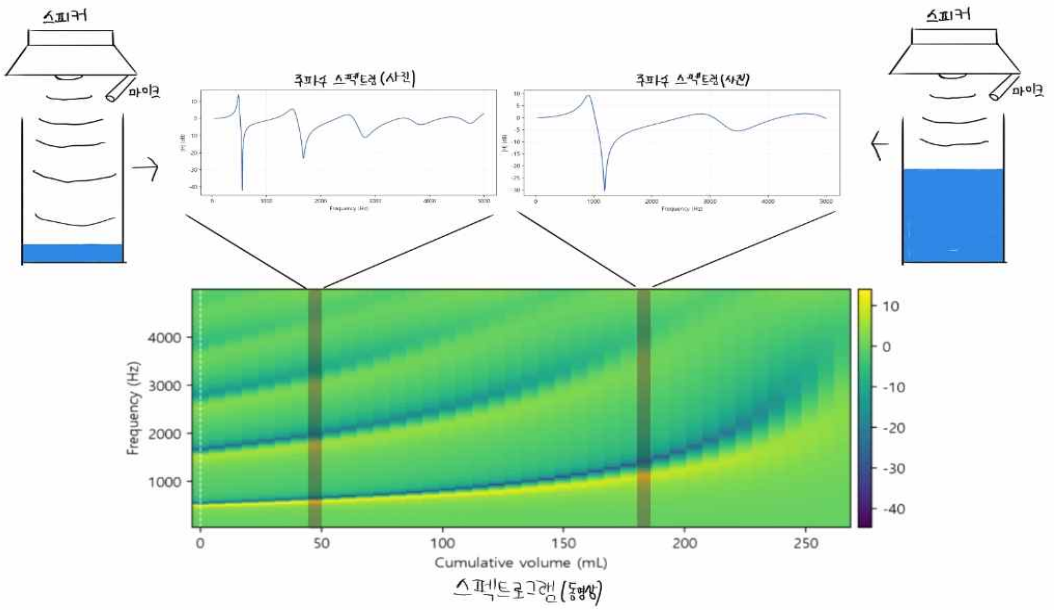

그림 9. 스펙트로그램 생성 원리

2. 컵의 소리에 귀를 기울이다 - 실제 용기의 소리를 재는 시스템 구축

가. 용기의 공명 특성을 얻기 위한 실험 장비 설정

실측을 통해 우리가 용기의 스펙트럼을 얻고, 스펙트로그램을 얻기 위해서는 실제 녹음 환경에서 용기에 의한 효과를 분리해낼 수 있어야 한다. 우리는 이를 얻기 위해 **비율 전달함수의 개념을 도입하고, 다음과 같이 장비를 설계 및 제작하였다.** 다양한 형상의 용기를 제작하기 위해, 내경이 서로 다른 링을 쌓아 형상을 만드는 방식을 고안하였다.

(가) 측정하고자 하는 값

용기의 효과를 분리하기 위한 비율 전달함수는 다음과 같이 정의된다.

$$H(f) = \frac{p_{ref}(f) + p_{scat}(f)}{p_{ref}(f)}$$

여기서 레퍼런스 음압인 $p_{ref}(f)$는 컵이 없는 기준면에서 음압, $p_{scat}(f)$는 컵이 산란시키는 음압, $p_{ref}(f)+p_{scat}(f)$는 컵이 존재할 때 총 음압이다. 이러한 비율 전달함수를 통해, 실측 실험시 주변 소음 또는 마이크 특성, 공간 특성이 제외된 컵의 영향을 추출해낼 수 있다. 물을 따르는 한 시점에서, 이 전달 함수를 스펙트럼의 형태로 그릴 수 있고, 이를 물을 따르는 단계인 스텝(step) 별로 쌓아 스펙트로그램을 만들 수 있다. 우리는 이렇게 얻은 스펙트로그램을 통해 용기의 형상에 대한 정보를 얻을 수 있는 것이다. 하지만 실측에서는 직접적인 음압을 구할 수 없으므로, 출력인 사인 스윕을 내보내고 난 뒤 입력에 대해 **디컨볼루션 값의 비율을 계산하여 전달함수를 구하였다.**

(나) 장비와 측정 방식 설명

표 1. 측정 장비 사진

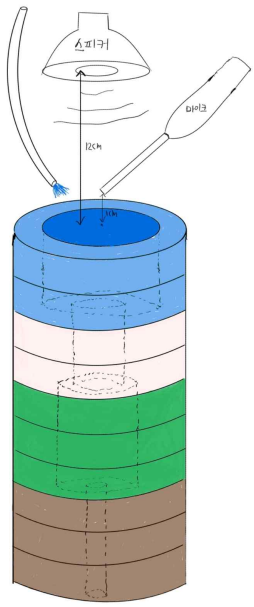

그림 10. 링을 이용한 형상 제작 모식도



그림 11. 링을 이용해 형상을 제작한 모습

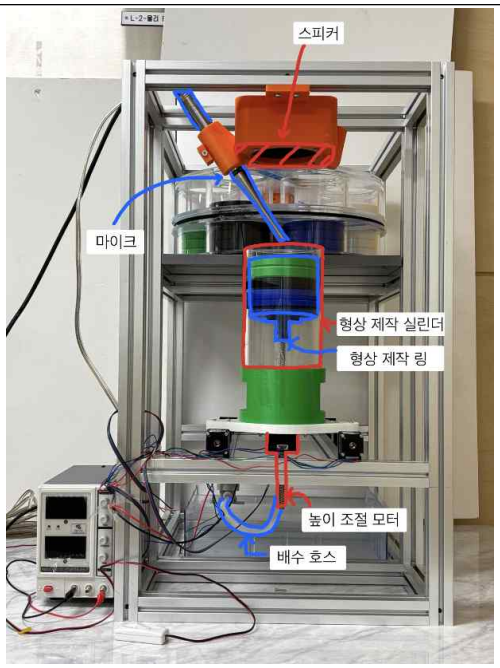

그림 12. 측정 장비 구조도

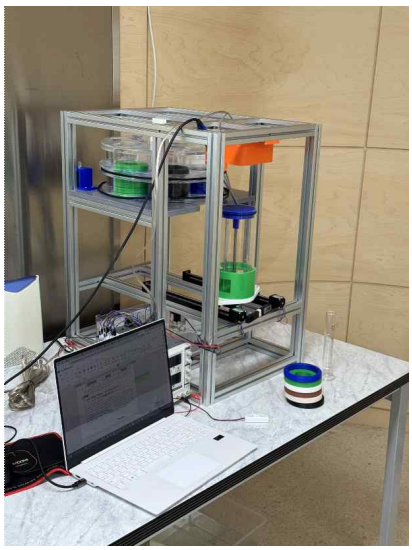

그림 13. 측정 장비

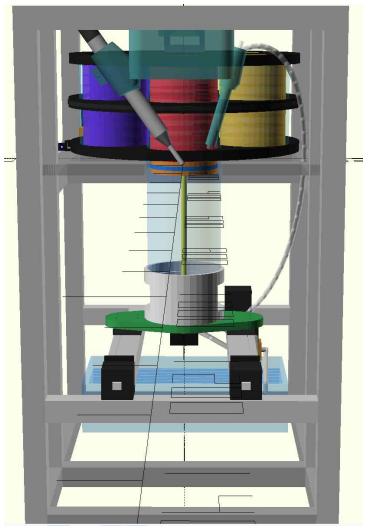

그림 14. openscad 모델링 정면도

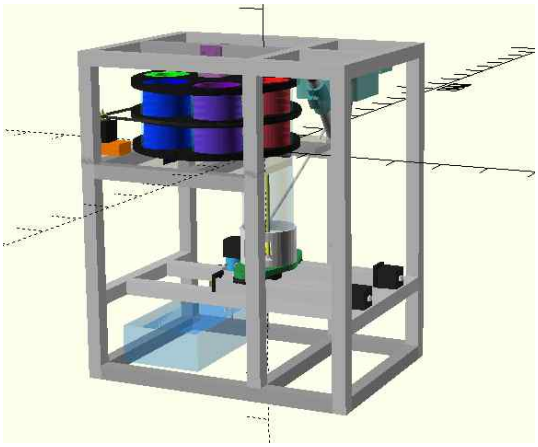

그림 15. openscad 모델링 측면도

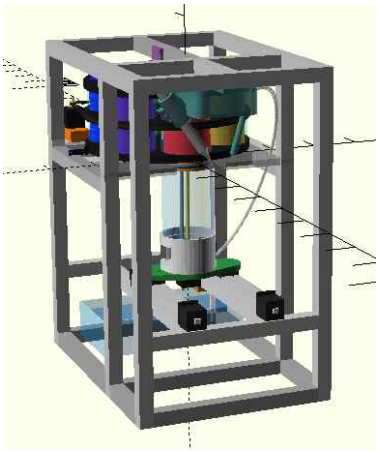

그림 16. openscad 모델링(왼쪽 위에서)

사진을 통해 알 수 있듯, 장비는 우리가 직접음을 투입할 수 있는 스피커, 직접음이 컵을 거쳐 나오는 것을 측정하기 위한 마이크, 그리고 형상을 놓을 수 있는 피스톤 받침대로 구성되어 있으며, 피스톤 위에는 형상을 제작할 수 있는 도넛 링들을 제작하였다. 사용한 장치들과 세부 사항은 다음 <표>와 같다.

표 2. 사용 장비 품명 및 FFT

사항	사용된 것	비고
마이크	Eerthworks M50	**무지향성 마이크,** **주파수 응답 범위** **3Hz ~ 50kHz** (±1dB 범위 내)
스피커	**삼미(SAMMI) CW-100B25**	소구경 저음용(Woofer) 스피커 유닛
직접 음원	**스윕 사운드**	**50~8000 Hz 대역 사인파 사용,** 로그 스윕
FFT	**Hanning 함수 사용**	해상도 2048
실린더	아크릴로 제작	높이 150mm, 반지름 50mm

도넛 링들의 실제 크기와 모습은 다음과 같다.



그림 17. 임의의 형상 제작을 위한 도넛 링

표 3. 형상 제작 링 규격

도넛 링	내경(안반지름)	외경(바깥반지름)	높이
청색	40mm	50mm	15mm
흑색	34mm		
백색	28mm		
녹색	22mm		
살구색	16mm		
갈색	10mm		

도넛 링을 사용하여 형상을 제작할 때, 그리고 실제 컵을 사용하여 측정을 진행할 때는 각각 다음과 같은 방식으로 측정을 진행한다.

표 4. 실측 spectrogram 측정 방법

(1) 레퍼런스 측정	(2) 링을 이용 형상 제작 / 빈컵 전달함수 측정

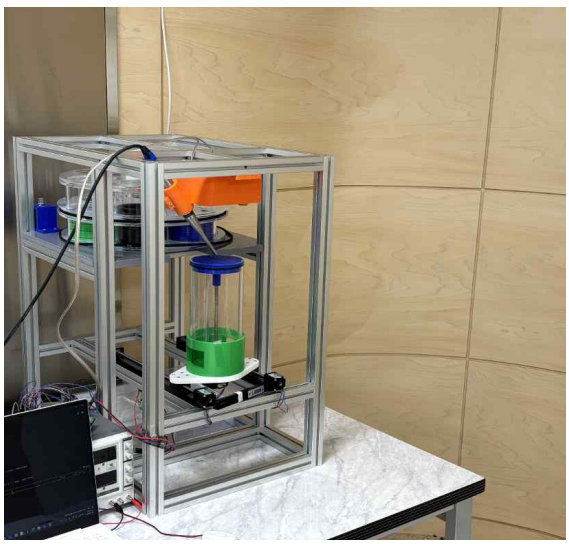

그림 18. 레퍼런스 측정 세팅

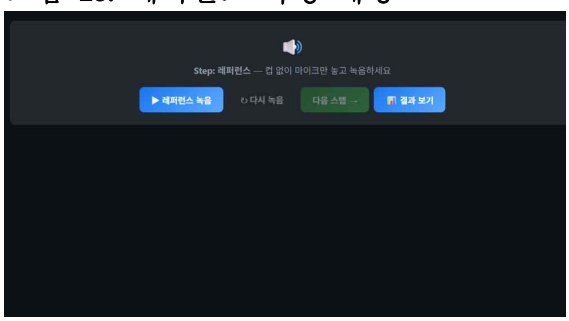

그림 19. 녹음 앱의 레퍼런스 측정 화면

->

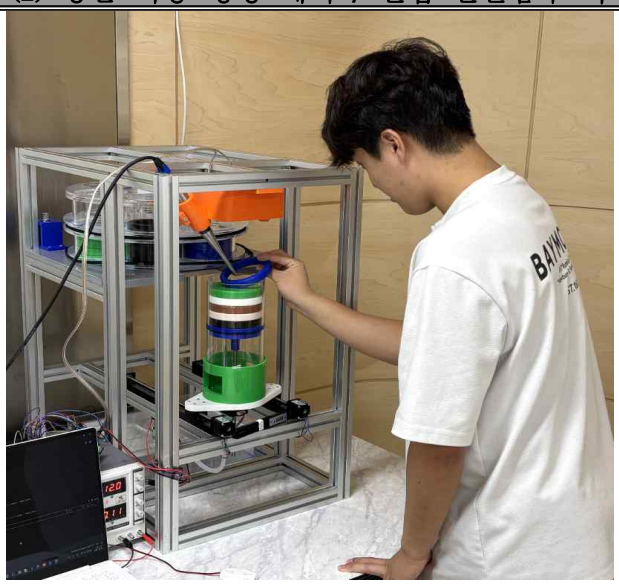

그림 20. 링을 넣어 형상을 만드는 장면



그림 21. 녹음 앱을 이용해 구한 빈 컵에 대한 전달함수

(1) 레퍼런스 측정

컵이 없는 상태, 즉 레퍼런스를 녹음하는 경우, 컵의 내부 형상 뿐만 아니라 측정하고자 하는 장치의 외부 형상 또한 공명 특성에 영향을 줄 수 있다. 따라서 비율 전달함수에 의해 이 효과가 상쇄돼기 위해서는 왼쪽 그림과 같이 피스톤을 끝까지 밀어올려 측정하도록 한다. 레퍼런스에서 큰 잡음이 들리게 되면 스펙트로그램에 큰 오염이 생길 수 있다. 따라서 레퍼런스 녹음에서는 스윕을 5번 쏜 후 디컨볼루션 한 bin 값의 중앙값을 취함으로써 레퍼런스에서의 잡음을 줄였다.

(2) 링을 이용한 형상 제작 및 빈컵 전달함수 측정

링을 쌓아 형상을 제작한 후 빈 컵에 대한 전달함수를 측정한다. 이 경우 스윕을 3번 쏜 후 디컨볼루션 한 bin 값의 중앙값을 취한다.

표 5. 실측 spectrogram 측정 방법

3. 이산 물채움 측정	4. 측정 완료
	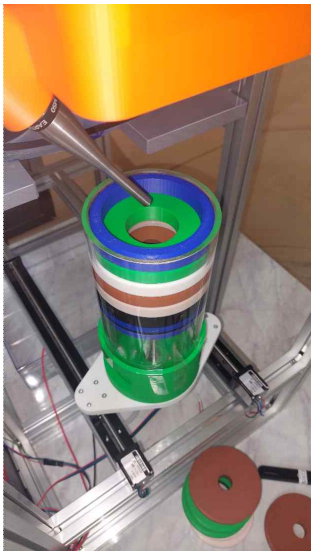 -> 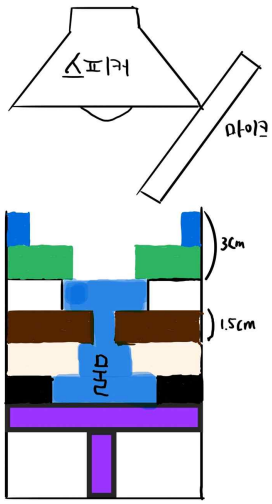
그림 22. 물을 채운 후 전달함수를 구하는 장면	그림 24. 물을 3cm 남긴 모습
	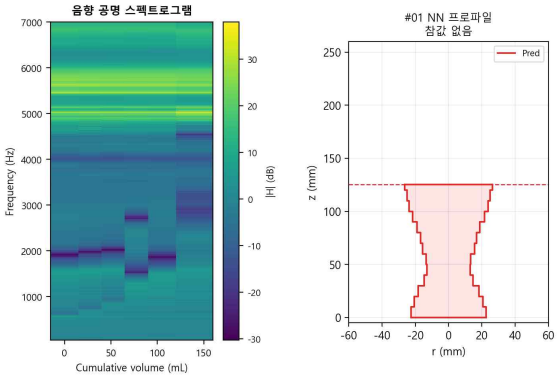
그림 23. 녹음 앱을 이용해 구한 두 번째 스텝의 전달함수	그림 25. 최종적으로 구한 스펙트로그램과 추정 결과

(3) 이산 물채움 측정

물을 먼저 채운 후 스윕을 쏘아 전달함수를 구한다. 특정 수위에서의 컵의 전달함수를 구한 것을 한 '스텝' 이라고 칭한다. 이를 물이 채울 때 마다 반복하여 여러 스텝에서의 전달함수를 구한다.

(4) 측정 완료

입구에서부터 3cm 까지 물이 차오르면 측정을 종료한다. 그 후 여러 전달 함수를 수위가 낮은 스텝부터 높은 스텝까지 차례대로 쌓아 스펙트로그램을 추출한다.

나. 전달함수 계산 프로그램 - 사인 스윕과 디컨볼루션

우리는 컵의 영향을 파악하기 위해 비율 전달함수 $H(f)=\frac{p_{ref}(f)+p_{scat}(f)}{p_{ref}(f)}$를 알아야 한다. 하지만, 마이크는 실제로 측정한 음압 p를 제공하지 않는다. 우리의 녹음에는 스윕의 파형, 스피커와 마이크 응답, 공간 특성이 모두 섞여있기 때문에, 순수한 음압을 알 수 없는 것이다. 따라서, 우리는 마이크 녹음으로부터 전달함수 H(f)를 구하는 방식을 고안하였다.

수학적으로, 녹음은 입력된 스윕이 측정계의 임펄스 응답, 즉 모든 주파수에 대한 응답과 합성곱된 결과다. 이를 수식으로 나타내면 $Y(f)=X(f)\cdot G(f)$이다. 따라서 측정계의 임펄스 응답$G(f)$는 원리적으로 역합성곱을 취하여 $G(f)=\frac{Y(f)}{X(f)}$로 나타낼 수 있다.

하지만 역합성곱을 취하기 위해 단수 나눗셈을 진행하면 $X(f)\approx 0$인 조건에서 잡음의 영향을 폭증시킬 수 있다. 따라서 이를 방지하기 위해 정칙화항 ϵ을 넣은 Wiener 역합성곱 $\hat{G}(f)=\frac{Y(f)X(f)}{(X(f))^2+\epsilon}$을 사용한다. 이렇게 얻은 $\hat{G}(f)$는 아직 스피커, 마이크 등 기계적 특성을 포함하고 있다. 식으로 나타내면 $G_{ref}=S(f)\cdot p_{ref}(f)$, $G_{cup}(f)=S(f)\cdot(p_{ref}(f)+p_{scat}(f))$이다. 여기서 $S(f)$는 주파수에 대한 스피커와 마이크의 특성이다. 이가 공통적으로 곱해지므로, 전달함수는

$$H(f)=\frac{p_{ref}(f)+p_{scat}(f)}{p_{ref}(f)}=\frac{S(f)(p_{ref}(f)+p_{scat}(f))}{S(f)(p_{ref})}=\frac{G_{cup}(f)}{G_{ref}(f)}$$

로 나타낼 수 있으므로, 컵에 의한 효과만을 담을 수 있다. 즉, 음압을 재지 않고, 디컨볼루션만으로 음압의 비를 얻을 수 있다,

노이즈를 제거하기 위해 컵이 없을 때 상태인 레퍼런스 녹음은 5회 진행하고 이것에 대해 대해 주파수 빈 별로 중앙값을 취하였다. 초기에는 이를 평균하는 것으로 정하였으나, 노이즈가 발생한 case에 대해 평균을 진행하면 다른 데이터들이 오염되어 평균을 하는 의의가 줄어들기 때문에 주파수 빈 별로 중앙값을 취하기로 한 것이다.

이를 각 스텝에서 측정하는 공명 특성, 즉 용기가 있는 상황에서 $p_{ref}(f)+p_{scat}(f)$를 측정하기 위해서는 시간적 효율성을 위해 측정을 3회로 줄여 동일한 방법을 실시한다. 이렇게 얻은 $p_{ref}(f)$, $p_{ref}(f)+p_{scat}(f)$에 대해 $H(f)=\frac{p_{ref}(f)+p_{scat}(f)}{p_{ref}(f)}$를 측정하면 원하는 출력값인 전달함수를 얻을 수 있다.

3. 학습 데이터 확보 - 형상으로부터 소리를 만드는 시뮬레이터 제작

가. 전달행렬법(TMM)의 물리적 조건 설정 및 계산

소리로부터 형상을 추정하는 딥러닝 모델을 만들기 위해서는 학습 데이터가 필요하다. 이러한 학습 데이터를 얻기 위해서는 실제로 다양한 형상의 컵을 가지고 녹음을 진행해 공명 특성을 얻어낼 수 있다. 하지만 우리 연구는 자유 형상에 대한 추정 시스템 구축을 목표로 하고 있기 때문에, 방대한 양의 데이터를 직접 실험을 통해 얻는 것은 시간적•공간적 한계가 있을 것이라고 판단했다. 따라서 우리는 물리 기반 시뮬레이션 중 하나인 **전달행렬법을 통해 학습 데이터를 확보하고자 하였다.**

본 탐구에서는 컵을 한쪽이 막힌 공동으로 모델링하고, 입구 위에서 스피커로 소리를 쏘고 마이크로 응답을 잰다. 이때 {컵이 있을 때의 음압/컵이 없을 때의 음압}의 압력 비율을 전달함수로 정의하고 관측량으로 삼는다. 이러한 물리적 설정을 바탕으로, TMM을 설계하였다.

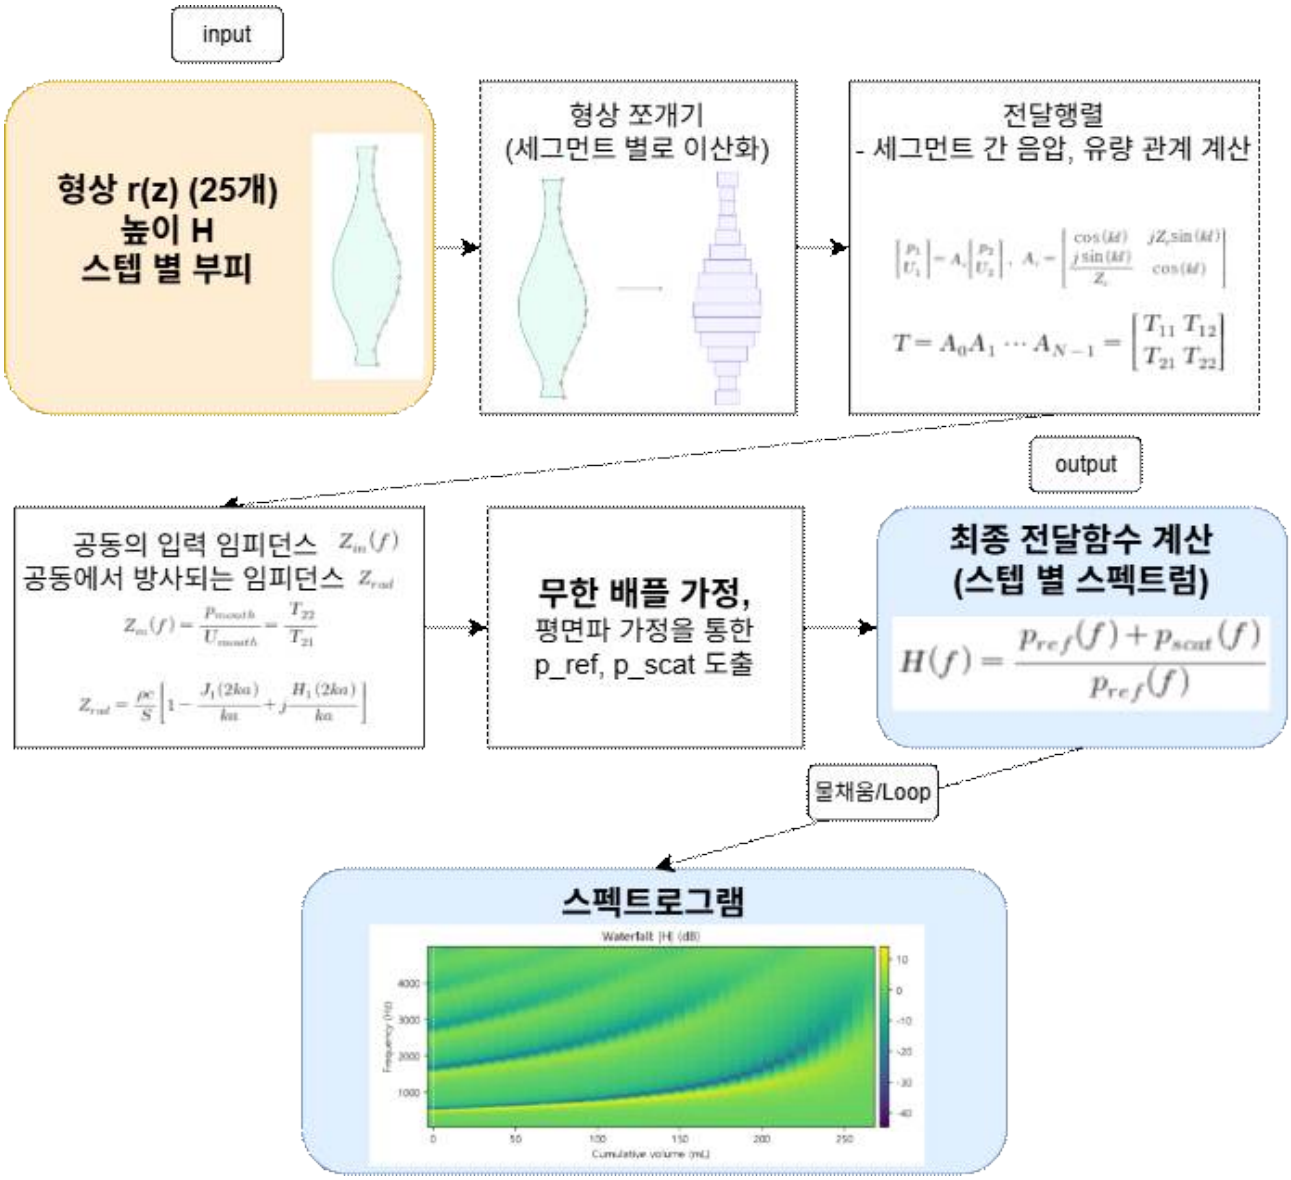

그림 26. TMM의 설계도

보통의 TMM에서는, 세그먼트로 이산화 한 후 입구의 입력 임피던스를 알아내는데 그치지만 우리 탐구에서는 공동의 형상이 축대칭이며 **마이크가 그 축 위에 위치한다는 점, 입구 공동 근처의 공간을 무한 배플로 근사할 수 있다는 점에서 임피던스로부터 주파수 별 음압을 계산하고, 그 전달함수를 직접 도출하는 시뮬레이션을 제작할 수 있었다.**

다음은 탐구에서 사용한 TMM의 제원을 표로 나타낸 것이다.

표 6. TMM의 제원

항목	값	비고
세그먼트 기본 길이	5 mm	연속 반지름을 균일 원통 조각으로 계단 근사
최소 세그먼트 수	30 개	
주파수 생성 대역	50~7000 Hz	
주파수 빈 수	700 개	1 빈 당 약 9.9 Hz
학습 입력 crop	5000 Hz	498 빈
기준 온도	$20\,^{\circ}\mathrm{C}$	
음속	$331.3 + 0.606\,T \approx 343\ \mathrm{m/s}$	
밀도	$101325/(287.05 \cdot (273.15 + T)) \approx 1.204\ \mathrm{kg/m^3}$	이상기체 가정
점성계수	$1.81 \times 10^{-5}\ \mathrm{Pa \cdot s}$	
비열비	1.4	
Prandtl 수	0.71	
최대 스텝 수	128	

이상적인 환경을 가정했을 때 딥이 되는 주파수의 음압은 0이 되므로 이론적으로 음의 무한대로 수렴한다. 하지만, 실제 환경에서는 유체의 점성이 존재하고, 열전도가 일어나기 때문에 유체 속도가 0으로 떨어지지 않는 감쇠가 일어난다. 이러한 감쇠를 모델링하기 위해 kirchhoff 감쇠식을 적용하였으며 이것은 다음과 같다. alpha = kirchhoff 계수이다.

$$\alpha(f,r) = \frac{1}{rc}\sqrt{\frac{\mu\omega}{2\rho}}\left(1 + \frac{\gamma - 1}{\sqrt{\mathrm{Pr}}}\right),\ \omega = 2\pi f,\ (\mu: \text{점성계수},\ \rho: \text{밀도},\ c: \text{음속},\ \gamma: \text{비열비},\ \mathrm{Pr}: \text{Prandtl 수})$$

이러한 감쇠 효과에 의해 복소 파수 k는 원래 파수 k_0로부터 다음과 같이 이동하는 것으로 근사 가능하다.

$$k = k_0 - (1-j) \cdot \alpha(f, r_i) = \frac{\omega}{c} - (1-j) \cdot \alpha(f, r_i)$$

우리 연구에서는 이러한 감쇠 효과를 TMM에 반영하여 보다 현실에 가까운 공명 특성을 복원해내고자 하였다.

나. 전달행렬법은 정말 믿을만 할까? - 물리적 계산 및 실측 정합성

우리는 딥러닝의 학습 데이터로 정말로 TMM을 사용해도 되는지 파악하기 위해 TMM에서의 딥 주파수 - 이론적인 해가 존재하는 것의 공명 주파수 - 실측에서 측정한 딥 주파수 세 개를 서로 비교 검증하기로 하였다. 검증 결과는 다음과 같다.

(가) TMM과 이론 정합성

딥러닝의 학습 데이터로 전달행렬법을 사용해도 되는가를 확인하기 위해서는 전달행렬법이 실제 물리적 이론과 맞는지 확인하여야 한다. 이를 확인하기 위해서 해석적으로 공명주파수를 구할 수 있는 형상에 대해 TMM을 실시하여 딥 주파수를 파악하고, 이가 해석적 해와 물리적으로 맞아떨어지는지 대조해야 한다. 전달행렬을 사용하지 않고 물리적으로 해석적 해를 통해 공명진동수를 구할 수 있는 용기의 유형과 그 공명 조건은 다음 표와 같고, 그에 해당하는 랜덤 형상을 생성하여 TMM과 물리 공식에서 나타내는 딥 주파수의 상관관계를 파악했다.

표 7. 해석해가 존재하는 형상과 TMM과의 비교 건수

용기	해석적 공명 조건	용기 개수	비교 건수 (공명주파수)
개-폐 균일 원통	$Z_c \cdot \cot(kL) = X_{rad}(f,a)$	132	489
헬름홀츠 공명기	$f = \frac{c}{2\pi}\sqrt{\frac{S_n}{V \cdot L_{eff}}}$	72	72
2단 계단관	$Z_{c2}[Z_{c_2}s_1s_2 - Z_{c_1}c_1c_2] + X_{rad}[Z_{c_2}s_1c_2 + Z_{c_1}s_1s_2] = 0$	36	243
원뿔관	$\theta_2 = \arctan(kx_1) \pm kL$	48	144

표 8. TMM에서의 딥 주파수와 해석해에서의 딥 주파수 비교

용기	Pearson 상관계수	최대 오차(%)
개-폐 원통	0.989753	2.85e-09%
헬름홀츠 공명기	0.99949624	3.47e-06%
2단 계단관	0.99997575	1.69e-06%
원뿔관	0.99999974	7.36e-04%

이처럼 학습 데이터를 얻는데 사용할 물리 기반 시뮬레이션인 TMM이 실제 물리 이론과 매우 높은 정합성을 보이고, 이를 형상 역추정의 학습 데이터로 사용할 수 있다는 것을 확인할 수 있었다. 하지만 이 검증은 우리가 가정하는 1차원 평면파 대역에서 유효하며, TMM과 해석해 모두 무한 배플 방사 가정을 하였기 때문에 둘의 이론적 가정은 동일하다는 점에서, 이가 실측과의 정합성은 보장하지 않는다는 점에 유의해야 한다.

(나) TMM과 실측 정합성

링으로 직접 제작한 형상에 대하여. 실측에서의 원시 스펙트럼에서 발견되는 딥 주파수와 TMM의 예측을 비교하였다.

이에 대한 피어슨 상관계수를 구한 결과는 다음 표와 같다.

표 9. TMM에서의 딥 주파수와 실측에서 딥 주파수 비교

상관계수 대상	Pearson r 상관계수	R^2 상관계수	비교 건수
TMM 예측 딥 주파수 /실측 딥 주파수	0.963	0.927	47개 스펙트럼 형상 7개

이를 통해, TMM의 예측이 실측에서도 높은 정합성을 보임을 알 수 있었다. 그러나 일부 경우에 대해서는 TMM의 예측된 공명주파수와 실측 주파수가 약간의 차이를 보였는데, 이는 실험실 환경에 의한 것으로 추정된다.

4. 소리로부터 형상을 만드는 딥러닝 모델 제작

가. 10만 개 가상 컵에 대한 학습 데이터 확보 및 증강

입력이 스펙트로그램, 출력이 정답 형상인 딥러닝 모델을 개발하기 위해 앞서 만든 TMM 전달행렬법 시뮬레이션을 이용해 학습 데이터를 확보하였다.

표 10. 생성 형상 정보

형상	데이터 비율	형상 자유변수
원기둥	20%	높이와 반지름
원뿔대	20%	높이와 입구, 바닥 반지름
호리병	25%	목의 높이와 목 반지름, 몸통 반지름, 목과 몸통 사이의 기울기
자유(랜덤)형상	35%	높이를 4~10등분한 지점에서 반지름을 랜덤으로 설정

TMM 시뮬레이션에 입력할 병의 형상을 위의 표와 같이 일반적인 컵의 형상과 랜덤 형상에 대하여 학습할 수 있도록 했다. 또한 반지름은 5~50mm, 높이는 30~250mm의 제한 조건을 걸어 일반적인 컵의 형상에 크게 벗어나는 이상치를 학습에 포함하지 않도록 설정했다.

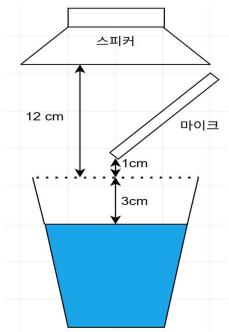

그림 27 - 가상, 실측 실험 세팅

그 다음 이 데이터를 TMM에 입력하여 모델의 입력 데이터인 스펙트로그램을 확보하고자 하였다. 시뮬레이션과 실측 실험 환경을 통일했을 때의 스펙트로그램 데이터를 확보하기 위해, 왼쪽 사진과 같이 마이크와 스피커 위치를 설정하였다.

시뮬레이션에서 생성한 데이터는 노이즈가 없는 상태로 마이크 위치에서의 오차와 온도에 의한 오차, 잡음에 대한 오차가 반영되어있지 않다. 따라서 같은 컵에 대하여 교란을 추가하는 방법으로 시뮬레이션에 현실을 반영하여 증강 학습을 진행하였다.

표 11. 증강학습 정보

증강 항목	증강 범위	설명
온도	15~30 ° C	온도 따른 딥 주파수 이동 고려
기하 오차	마이크 오차 위치 부여	마이크 위치에 따른 딥 주파수 이동 고려
신호 왜곡	게인 지터 ±0.05 기울기 지터 ±0.03	스피커, 마이크 개체차 대비 주파수 응답 기울기 오차 대비
배경잡음	신호 대 잡음비 10~40 dB	환경 소음 대비
부피 불규칙성	10mL 간격 스텝 중 랜덤 추출	사용자가 일정하게 붓지 않는 상황 대비

나. 모델의 입출력 및 하이퍼파라미터 개수 설정

인공신경망의 입력은 배치 B개, 최대 S번의 붓기 스텝, 스텝마다 498개 주파수 빈(bin)의 스펙트럼(log10(H(f))를 포함하는 X = (B, S, F=498)과, 스텝별로 누적해서 부은 부피인 V = (B, S), 마스킹 용 스텝 step_mask (B, S)이다. 입력은 5000Hz 이하의 주파수를 498빈으로 분할하였으며, 음압에 대한 Z-score 정규화를 실시하고, V를 리터 단위로 스케일을 맞추어 전처리하였다. 인공신경망의 출력은 컵의 형상을 나타내는 두 종류의 파라미터로 구성된다. 첫째는 컵 전체의 높이 H(스칼라, mm 단위) 이고, 둘째는 컵의 반지름 분포를 나타내는 r(z) 프로파일로, 바닥부터 10mm 간격으로 나눈 25개 구간 각각에 대한 반지름 값의 벡터이다. 이 두 형상 파라미터는 뒤에서 비교하는 1D CNN과 RNN 모델에 공통으로 적용되는 출력 형식이다. 이 입력 데이터와 출력 데이터를 표로 나타내면 다음과 같다.

표 12. 인공 신경망의 입출력

구분	항목	이름	텐서	단위	설명
입력	스펙트럼	X	(B, S, F)	log10(H(f)) (무차원)	스텝마다 498개 주파수 빈 존재. (50~5000Hz 대역을 498등분)
	누적 부피	V	(B, S)	리터(L)	스텝별 누적으로 부은 물의 양.
	스텝 마스크	step_mask	(B, S)	{0,1}	실제 스텝 = 1, 마스킹 했을 경우 0
출력	높이	head_h	(B, 1)	mm	Linear(256 -> 64) + ReLU + Linear(64 -> 1)의 과정을 거쳐 출력.
	반지름 프로파일	head_r	(B, 25)	mm	Linear(256 -> 64)의 과정을 거쳐 출력. 25슬롯, 슬롯당 10mm의 높이 구간.

형상을 추정하는 인공신경망으로는 1D CNN과 RNN을 사용하였다. CNN과 RNN의 구성 요소와 이에 따른 층의 개수, 구성 요소는 다음과 같다.

표 13. 인공 신경망의 구성요소

구성 요소	1D CNN	RNN(LSTM)
StepEncoder	Conv1d * 4 + Linear * 1 = 5층	동일 = 5층
v_emb	Linear * 2 = 2층	동일 = 2층
step_mix	Linear * 1 = 1층	동일 = 1층
스텝 간 연결	(없음)	LSTM 1층(순환)
trunk	Linear * 2 = 2층	동일 = 2층
head_r	Linear * 1 = 1층	동일 = 1층
head_h	Linear * 1 = 1층	Linear * 2 = 2(64차원 은닉)
합계	12층(합성곱 4층 + Linear 8층, 순환구조 없음)	14층(합성곱 4 + LSTM 1 + Linear 9)
파라미터 수	445,178개	922,234개(d = 256, bi 기준)

각 구성 요소의 역할은 다음과 같다.

StepEncoder : 합성곱을 통해 스펙트럼 신호의 특징을 파악하고, 입력된 498차원의 스펙트럼

신호를 d차원으로 압축한다.

v_emb : 스텝별 누적 부피를 32차원으로 임베딩하여 학습에 사용한다.

step_mix : d차원의 스펙트럼 특징과 32차원의 부피 임베딩을 다시 d차원으로 압축하여, 하나의 스텝에서 알아낼 수 있는 정보를 최종적으로 산출한다.

스텝 간 연결 : 매 스텝을 순서대로 밟으며 직전 스텝까지의 기억, 즉 스펙트럼 정보를 이어받아 현재 스텝 정보로 갱신한다. RNN에만 적용되며, 정방향, 역방향, 양방향의 순서로 스펙트럼 정보를 읽고 기억하게 할 수 있다. 이 여부를 다르게 해가며, 형상 추정에 최적인 모델을 찾는다.

trunk : 각 스텝에서 얻은 정보들을 하나로 합쳐 정리한 다음, 이 정리된 정보를 이후의 두 갈래(전체 높이/반지름 분포) 예측이 공통으로 사용할 특징으로 만든다.

head_r : trunk에서 정리된 특징을 받아, 컵의 반지름 분포(바닥부터 10mm씩 나눈 25개 구간 각각의 반지름 값)를 예측한다.

head_h : trunk에서 정리된 특징을 받아 컵의 전체 높이를 예측한다. 이 예측이 trunk의 학습에 영향을 줄 수 있으므로, 따로 detach하여 학습한다. 이는 추후 모델 학습에서 나타난 시소 현상을 해결하기 위한 문제이다.

다. 형상 추정에 최적인 모델 선정 및 튜닝 - 시소 현상의 발견과 극복

(가) 1차 모델 학습 및 시소 현상의 발견

나. 절의 공통된 구조를 기반으로, 학습하는 방식에 여러가지 변화를 주어 모델들을 설계하고, 시뮬레이션을 기반으로 형상과 추정 형상 간의 높이 오차 및 반지름 오차를 분석하였다. 설계한 모델들은 총 17개이고, 각각의 기능과 성능은 다음과 같다.

최종적으로 선택된 모델의 loss curve는 다음과 같다.



그림 28. 채택된 모델의 학습 곡선

시뮬레이션 데이터를 통한 모델의 테스트 결과, H_MAE와 r_MAE가 (최대최소)의 범위를 보였으며, 이를 통해 최대 오차범위 (최대최소) 이내의 형상 추정이 가능하다는 것을 파악하였다.

그런데 위와 같이 컵의 높이와 반지름 프로파일을 하나의 공유 몸통(trunk)에서 동시에 예측하는 다중과제(multi-task) 구조로 CNN, RNN을 학습한 결과 **H의 예측 성능이 개선되는 부분에서는 반지름 r에 대한 예측 성능이 저하되고, 그 반대의 경우도 마찬가지**로 작용한다는 것을 알 수 있었다. 우리는 이러한 시소 현상을 해결할 방안을 탐색하고자 하였다.

우리는 이의 주된 원인이 인공 신경망의 학습에서 역전파를 이용한 하이퍼파라미터 조절 과정에서, 높이를 추정하고자 하는 것의 역전파가 반지름을 추정하는 파라미터에 영향을 주었기 때문으로 분석하였다. 이를 해결하기 위해 구조적으로 head_h의 경사 즉, 그래디언트가 trunk 부분의 하이퍼파라미터에 영향을 주지 않도록 분리(gradient detach) 방식을 도입하고자 하였다. 그리고 이 분리 옵션을 켠 경우와 끈 경우를 비교하여 효과를 검증하고자 하였다.



그림 29. 시소 현상의 발견

또한 이러한 점으로부터, NN의 H 추정 정확도가 높은 모델이 존재하고, r 추정 정확도가 높은 모델이 존재하므로 시소 현상을 해결하기 위해 H와 r을 각각 다른 모델에 역할 분담시켜 결합할 수 있다. 이러한 역할분담형 결합 구조를 활용하면, H와 r에서의 시소 문제를 해결하고 각각의 정확도를 동시에 높일 수 있을 것이라 생각했다.

이 결과 흥미롭게도 H 단독 과제에서는 오히려 detach를 하지 않은 모델(rnn_ratio_nodetach_bestH)이 최적의 성능을 보였으며, r 전문가는 단방향 어블레이션을 적용하고, detach를 적용한 모델(rnn_uni)이 최적의 성능을 보이는 것을 확인할 수 있었다.

라. 시뮬레이션 데이터에 대한 추정 결과

다. 절에서 선정된 최적의 모델 결합에 대한 총 하이퍼파라미터 수, H_MAE, R_MAE는 다음 표와 같으며, 임의로 추출한 테스트 데이터에 대한 추정 결과는 다음과 같다.

표 14. 최종적으로 선정된 모델 결합의 세부사항

구성요소	모델명	구조	학습 epoch 수	파라미터 수
H 역할 분담	rnn_sline_nodetach_bestH.pt	Bi-LSTM, detach 안함	16	922,234
r 역할 분담	rnn_sline_uni.pt	Uni-LSTM detach 함	24	1,053,306
결합 모델	CombinedPredictor	-	-	1,975,540

표 15. 역할 분담 모델의 높이 MAE와 반지름 MAE

모델	평가 조건	H_MAE	r_MAE
역할 분담 모델	동일	3.87	2.55

표 16. 시뮬레이션에 대한 추정 결과 (빨간색: 추정 형상, 파란색: 정답 형상)

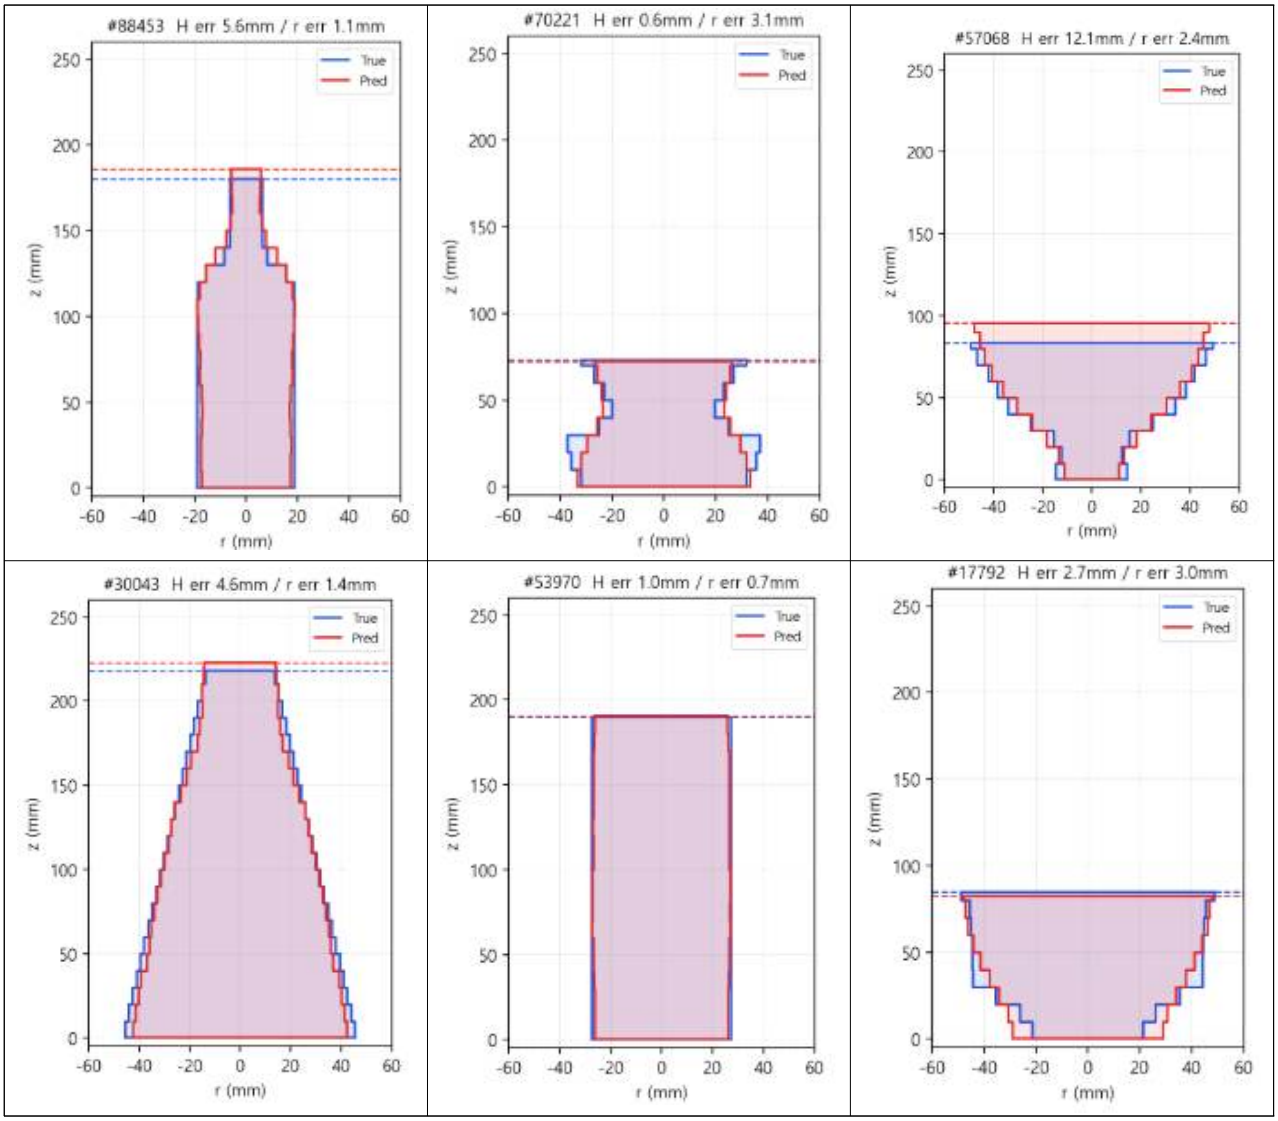

이를 통해, 시뮬레이션 데이터에서 테스트 시 평균 높이 오차 3.87 mm, 평균 반지름 오차 2.55 mm의 수준으로 추정할 수 있음을 확인하였다.

5. 소리로 형상을 복원하다 - 실측 자료를 통한 추정

가. 1차 실측 투입과 모델의 붕괴 원인 규명

(가) 1차 실측 진행과 모델의 붕괴

3.절에서의 시뮬레이션 연구로 최적 구성(역할분담형 결합 구조 - H: 양방향, nodetach, 선형 보정 RNN, r: 단방향, detach, LSTM)을 확정할 수 있었다. 이를 통해 시뮬레이션 테스트 데이터 1만 개 샘플에서 H_MAE 4.07mm/ r_MAE 1.56mm를 달성하였다. 우리는 이가 실측에서 잘 들어맞는지 확인하기 위해 10개의 형상을 가진 컵에 대해 실측 데이터를 얻고, 형상 추정을

실시하였다. 그러나 시뮬레이션에서 작은 오차를 보였던 인공신경망이 실제 측정에서 70% 이상의 오차를 보이는 것을 확인하였다. 참 높이가 82~180mm인 컵 전부를, 166~228mm의 대역으로 과대 추정한 것을 확인하였다. 다음은 추정 결과이다.]

표 17. 컵 별 형상 참값과 예측값 및 오차

컵	참 H	참 입구 r	예측 H	예측 입구 r	H오차	r오차
1	100	35	181.5	18.8	81.5	46.4
2	144	42	224.2	21.8	55.7	48.1
3	82	27	168.3	14.4	105.2	46.6
4	100	25	188.2	20	88.2	20
5	180	11	228	8.4	26.7	23.3
6	115	38	213.7	16.8	85.8	55.7
7	83	40	166	18.2	100.1	54.4
8	138	40	200	33.1	44.9	17.2
9	90	34	196.7	18.9	118.6	44.5
10	152	29	203.9	26.3	34.2	9.2
평균					**82.2**	**10.9**

표 18. 증강 이전 모델의 추정 결과 (빨간색: 추정 형상, 파란색: 정답 형상)

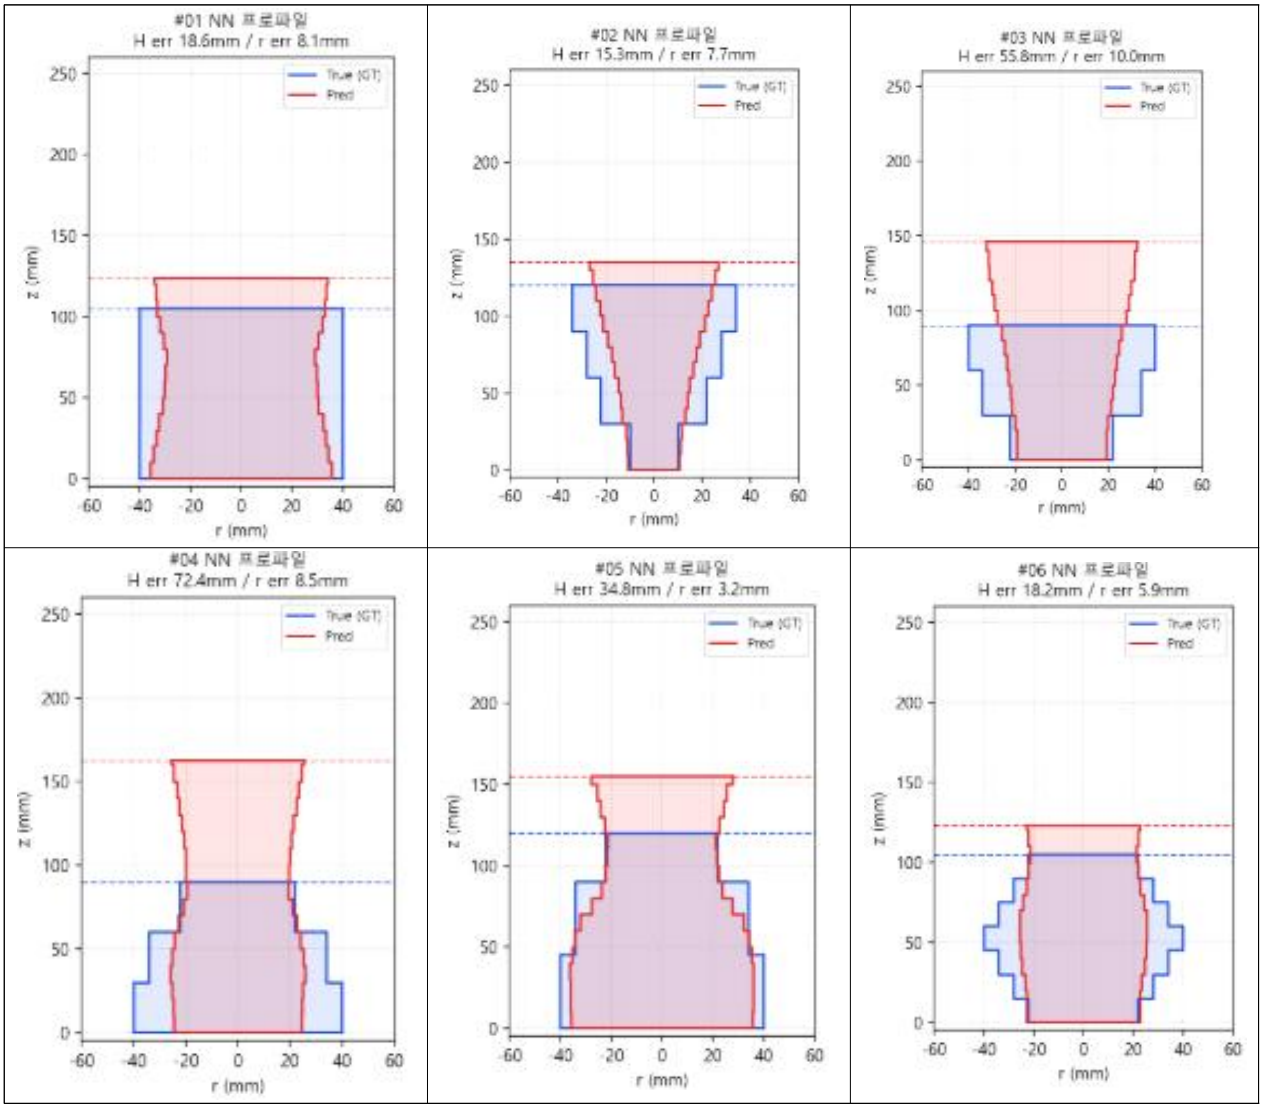

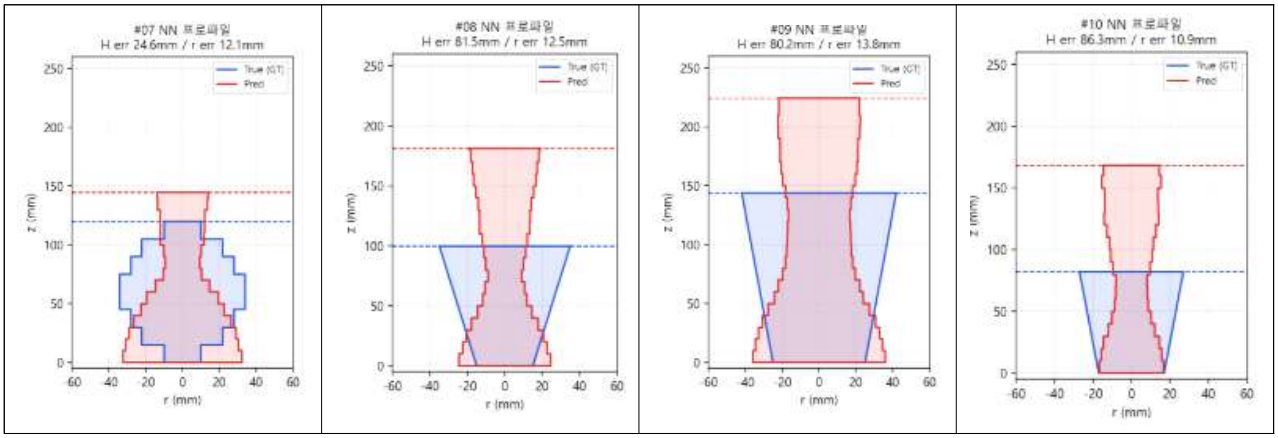

모든 컵에 대해 높이가 과대추정되었으며, 최악의 경우 높이가 115 mm인 형상에 대해 213.7mm로 약 85%의 오차가 발생하였다. 또한 공통적으로 추정이 잘못된 경우 가운데가 오목하고 밑 반지름이 큰 형상으로 추정되었다는 것을 확인할 수 있었다. 우리는 이러한 오차의 경향성이 보이는 것을 바탕으로, 스펙트로그램에서 공통된 특징, 즉, 실측에서 딥러닝 모델을 붕괴시키는 특징이 있을 것이라고 판단했다.

이 시점에서 우리는 두 가지 해결방안을 놓고 고민하게 되었다. 하나는 스펙트로그램의 전처리를 추가하는 것이고, 다른 하나는 실측 붕괴의 원인을 찾아서 그에 대한 정조준 증강 학습(sline 증강 학습)을 실시하는 것이다. 본 연구에서는 후자를 택하였다. 이를 위해 실측 스펙트로그램 사진을 분석하였다.

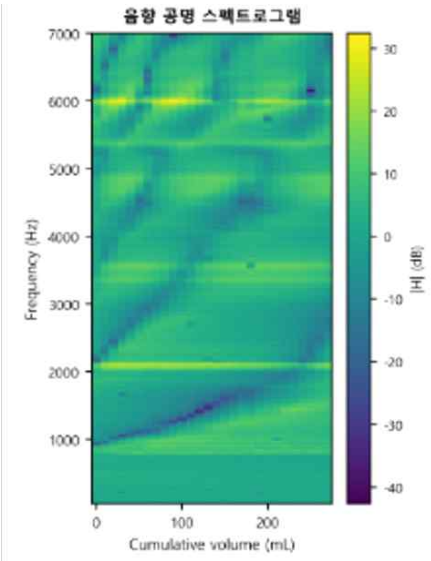

스펙트로그램에서 볼 수 있듯, 일부 녹음본에서 긴 가로줄, 즉 공통된 주파수에서 증폭된 신호를 파악할 수 있었다. 만약 레퍼런스 녹음에서 어떠한 노이즈로 인해 스펙트럼 값이 0에 가까운 지점이 있으면 스펙트로그램 상에서 계속 노이즈가 증폭되거나 값이 크게 나타나는 곳이 있을 것이고, 반대로 스펙트럼 값이 큰 경우 전달함수 값은 일관되게 작은 값을 띌 것이다. 이로부터, 레퍼런스 녹음이 잘못되어 노이즈가 발생하는 경우 스펙트로그램에 큰 영향을 준다는 것을 알 수 있다.

이를 예방하기 위해, 증강 학습에 잘못된 가로줄, 즉 레퍼런스에 노이즈가 발생했을 경우를 더욱 강화하고 추가하여 학습하였다. 증강학습에 대한 세부사항은 다음과 같다.

그림 30. 가로줄에 의해 오염된 스펙트로그램

표 19. 증강학습에 대한 세부사항

항목	기존	확장
대역	4000~7000 Hz	80~7000Hz 전 대역
개수	1~2개	3~10개
방향	딥만	딥 65% + 피크 35%
폭/진폭	30~150Hz / 0.2~1.0	10~150 Hz / 0.05~1.0
스텝별 깊이	고정	+- 25% 변동

나. 증강학습을 통한 회복 및 결과 분석

(가) 추정 결과

증강학습을 진행하고 난 2차 실측의 결과는 다음과 같다. 총 20개 형상에 대해 추정을 진행하였으며, 평균적으로 H_MAE 17.1 mm, R_MAE 6.2 mm 정도의 오차를 보였다. 아래 그림은 실제 형상과 추정한 형상을 나타낸 그림이다.

표 20. 증강학습 이후 실측 추정 결과

No.	실측 대상 용기	참값 H(mm)	예측 H(mm)	H 오차(mm)	r 오차(mm)	스텝(s)
01	일자형 컵	105.0	103.5	1.5	3.6	9
02	벌어진 컵	120.0	102.4	17.6	4.5	4
03	벌어진 컵	90.0	102.3	12.3	7.1	5
04	오므라드는 컵	90.0	113.3	23.3	2.5	7
05	오므라드는 컵	120.0	140.8	20.8	4.5	10
06	중앙이 볼록한 컵	105.0	98.8	6.2	5.2	6
07	중앙이 볼록한 컵	120.0	96.0	24.0	11.2	6
08	벌어진 컵	100.0	106.1	6.1	8.1	13
09	유리 벌어진 컵	144.0	160.0	16.0	8.7	40
10	유리 벌어진 컵	82.0	112.1	30.1	6.6	9s
11	3D프린터 일자 컵	100.0	148.0	48.0	6.5	15
12	매스실린더	180.0	181.4	1.4	0.8	7
13	고무 벌어진 컵	115.0	140.9	25.9	6.2	28
14	유리 벌어진 컵	83.0	101.9	18.9	7.9	13
15	텀블러 벌어진 컵	138.0	157.7	19.7	5.9	39
16	유리 오므라진 컵	90.0	93.7	3.7	5.5	33
17	유리 일자 컵	152.0	153.0	1.0	4.8	26
18	일자 컵	150.0	154.3	4.3	3.0	14
19	일자 컵	150.0	157.9	7.9	6.2	20
20	벌어진 컵 1	90.0	95.0	5.0	4.1	5
평균				17.1	6.2	

표 21. 증강학습 이후 실측 추정 결과 (빨간색: 추정 형상, 파란색: 정답 형상)

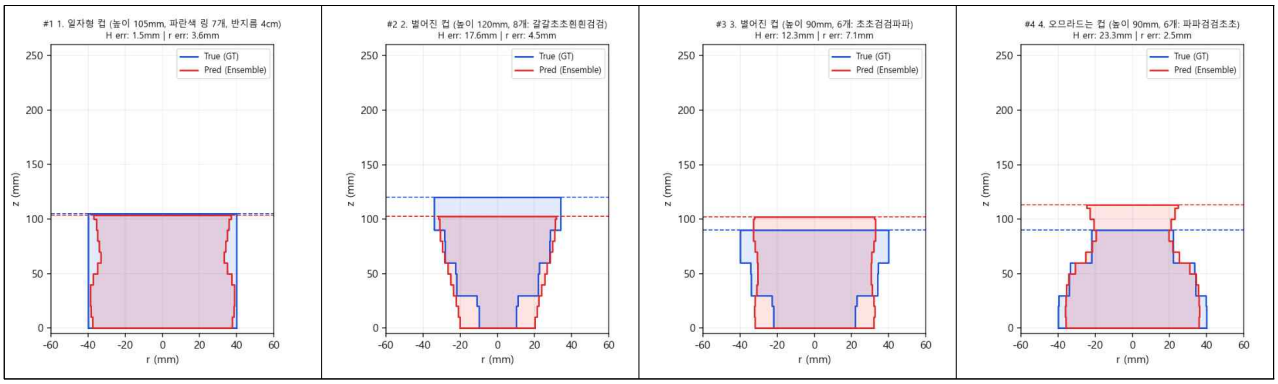

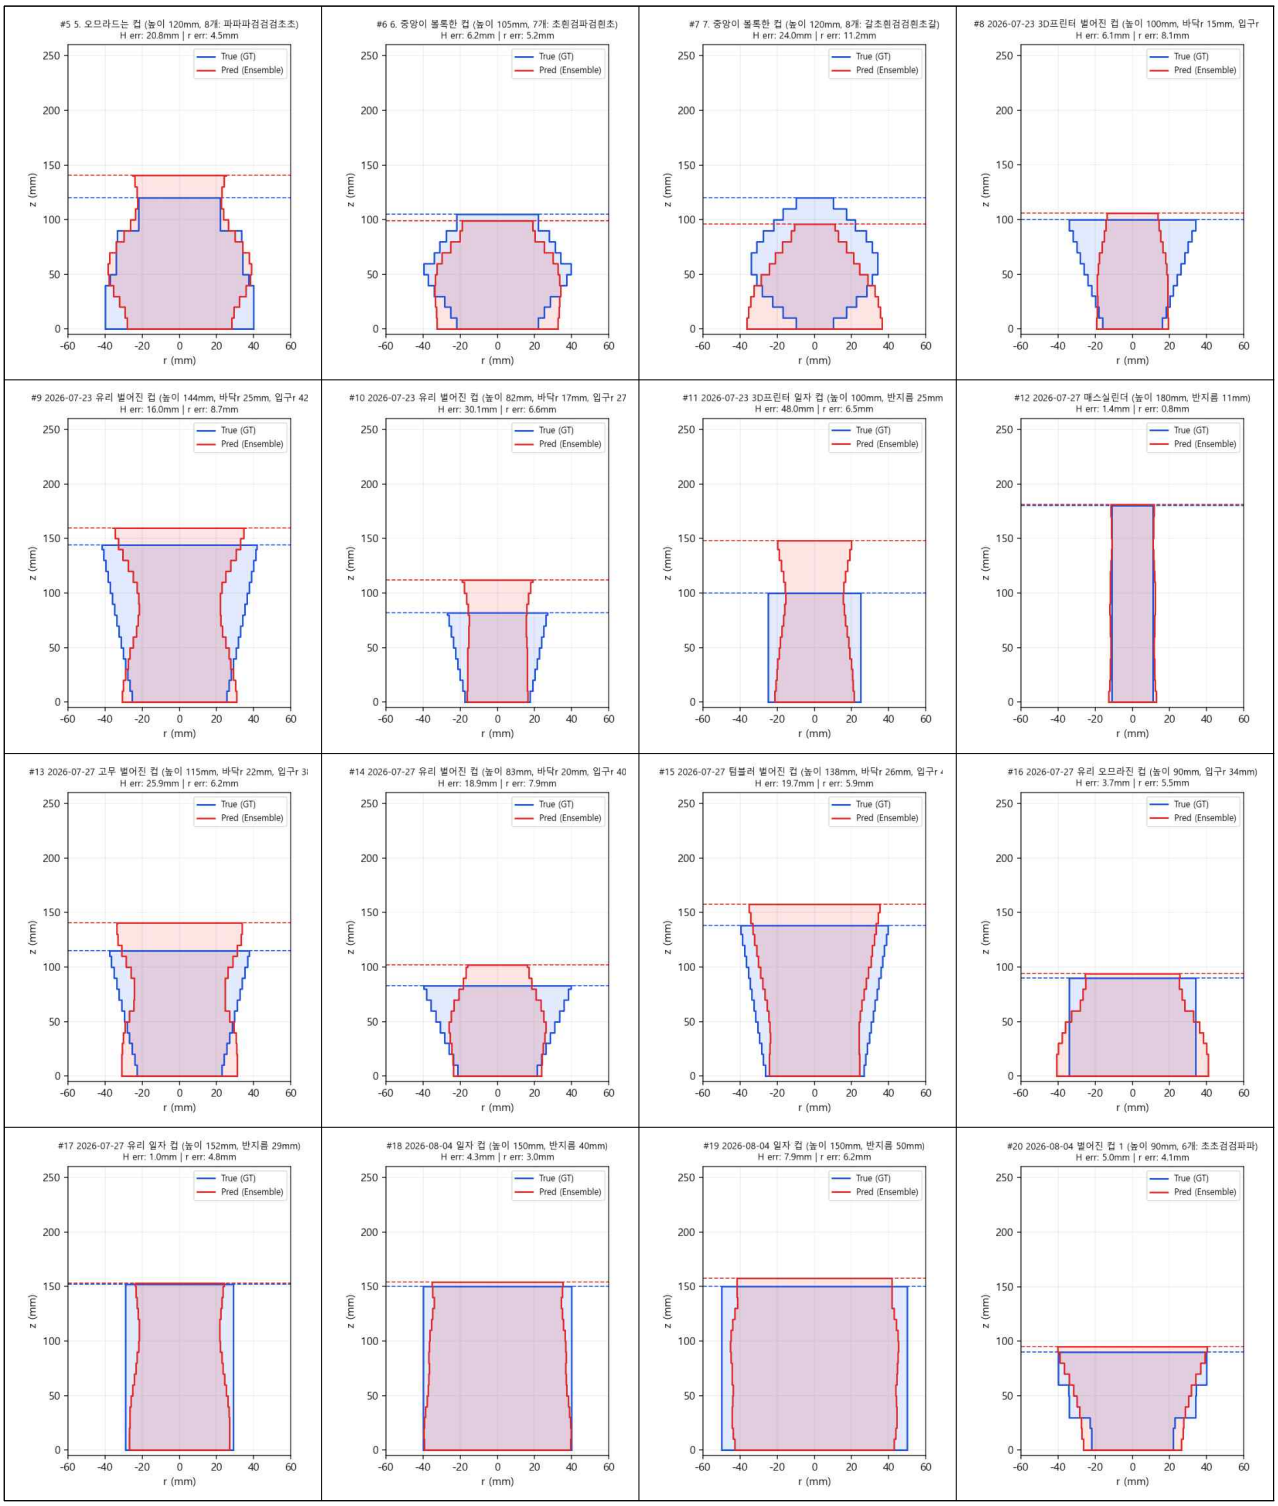
#5 5. 오므라드는 컵 (높이 120mm, 8개: 파파파검검초초)
H err: 20.8mm | r err: 4.5mm
#6 6. 중앙이 볼록한 컵 (높이 105mm, 7개: 초원검파검원초)
H err: 6.2mm | r err: 5.2mm
#7 7. 중앙이 볼록한 컵 (높이 120mm, 8개: 갈초원검검원초갈)
H err: 24.0mm | r err: 11.2mm
#8 2026-07-23 3D프린터 벌어진 컵 (높이 100mm, 바닥r 15mm, 입구r
H err: 6.1mm | r err: 8.1mm
#9 2026-07-23 유리 벌어진 컵 (높이 144mm, 바닥r 25mm, 입구r 42
H err: 16.0mm | r err: 8.7mm
#10 2026-07-23 유리 벌어진 컵 (높이 82mm, 바닥r 17mm, 입구r 27
H err: 30.1mm | r err: 6.6mm
#11 2026-07-23 3D프린터 일자 컵 (높이 100mm, 반지름 25mm
H err: 48.0mm | r err: 6.5mm
#12 2026-07-27 매스실린더 (높이 180mm, 반지름 11mm)
H err: 1.4mm | r err: 0.8mm
#13 2026-07-27 고무 벌어진 컵 (높이 115mm, 바닥r 22mm, 입구r 3
H err: 25.9mm | r err: 6.2mm
#14 2026-07-27 유리 벌어진 컵 (높이 83mm, 바닥r 20mm, 입구r 40
H err: 18.9mm | r err: 7.9mm
#15 2026-07-27 텀블러 벌어진 컵 (높이 138mm, 바닥r 26mm, 입구r
H err: 19.7mm | r err: 5.9mm
#16 2026-07-27 유리 오므라진 컵 (높이 90mm, 입구r 34mm)
H err: 3.7mm | r err: 5.5mm
#17 2026-07-27 유리 일자 컵 (높이 152mm, 반지름 29mm)
H err: 1.0mm | r err: 4.8mm
#18 2026-08-04 일자 컵 (높이 150mm, 반지름 40mm)
H err: 4.3mm | r err: 3.0mm
#19 2026-08-04 일자 컵 (높이 150mm, 반지름 50mm)
H err: 7.9mm | r err: 6.2mm
#20 2026-08-04 벌어진 컵 1 (높이 90mm, 6개: 초초검검파파)
H err: 5.0mm | r err: 4.1mm
True (GT)
Pred (Ensemble)
z (mm)
r (mm)

(나) 결과 분석

(1) sline 증강으로 인한 개선

sline 증강으로 재학습한 결합 모델을, 붕괴를 확인했던 동일 조건의 실측 데이터에 다시 투입하였다. 이 결과 1차 실측에서 **82.2mm였던 높이 평균 오차는 17.1mm**로, 약 5분의 1로 감소하였다. 이는 증강을 통해 설정했던 원인인 레퍼런스 노이즈에 대한 증강으로 이를 극복했다는 점에서, 이것은 우리의 원인 탐색이 옳았다고 확인하는 증거가 될 수 있다.

일자형 컵에서는 대부분 높이 오차와 반지름 오차가 5mm 이하로 도출되었으며, 가장 좋은 사례인 10에서는 높이 오차 1.5mm, 반지름 오차 3.6mm로, 시뮬레이션 성능에 준하는 정확도가 실측에서도 재현되었다. 또한 20의 벌어지는 컵에서도 예측한 높이와 출구 반지름이 정답 형상과 거의 유사하게 나온 것을 확인할 수 있다.

(2) 보완점

반면 오므라드는 형상인 04에서는 높이 오차 23.3mm로 남았는데, 이는 이러한 형상에서 물을 부어도 공명 정보가 적게 드러나는, 즉 관측 정보량 자체가 부족한 형상이라는 특징을 가진다. 또한 벌어지는 형상에서는 대부분 높이가 높게 과대 추정된 것을 알 수 있었는데, 이는 TMM에서 적용한 무한 배플 가정이 실측 과정에서는 스피커-마이크 세트로 인하여 유효하지 않음으로 인한 것으로 추정된다. 현재는 추정의 정확도를 높이기 위해 NN을 초깃값으로 사용한 이후 형상을 그래디언트로 미세 조정하는 테스트타임 정제를 적용하는 단계에 있다. 또한 향후 TMM의 가정을 실측에 맞게 수정하여 높이 추정의 오차를 줄이고자 한다.

V 결론 및 향후 계획

1. 탐구 결론

본 탐구는 컵에 물을 따를 때 소리가 변하는 것을 보고, 소리의 변화를 추적했을 때 형상 정보를 얻어낼 수 있다는 사실로부터 빈 공동에 물을 채워가며 공동의 공명 특성을 파악하면 역으로 형상을 추정해낼 수 있을 것이라는 아이디어로부터 시작되었다. 자유 형상에 대해서는, 기주 공명 뿐만 아니라 헬름홀츠 공명, 단면적의 모양에 따른 공명 등이 개입될 수 있으므로 단순 알고리즘을 통해 형상을 추정하기 어렵다. 따라서 본 탐구는 이를 해결하기 위해 인공 신경망을 사용하는 방식을 채택하였으며 이를 학습하기 위한 물리 시뮬레이터를 제작하고자 하였다. 결론적으로, 물을 채워가며 얻은 공명음을 시뮬레이터를 통해 학습한 인공신경망으로 분석하므로써 형상을 추정하는 하나의 시스템을 구축하는 것이 본 연구의 목적이었다.

본 탐구는 이를 실현하기 위해 총 네 갈래의 탐구 과제를 해결하고 추정을 위한 절차를 마련하였다.

1) 실측 시스템 구축

공동의 공명음으로부터 형상 정보를 얻기 위해, 공명 특성을 측정하는 장비를 스피커와 마이크, 임의의 형상을 만들 수 있는 도넛 링 등으로 구성해 제작했다. 직접 음원으로 스윕을 사용하고, 마이크로 입력된 소리를 디컨볼루션하여 컵이 소리에 미치는 영향인 전달함수를 계산, 이를 물을 채워가면서 반복하며 컵의 공명 구조를 담은 스펙트로그램을 얻는데 성공하였다.

2) TMM 시뮬레이터 구축

딥러닝의 학습 데이터를 생성하기 위해 실제 측정을 대신할 수 있는 시뮬레이터를 제작하고자 하였다. 이를 위해 유한요소해석법의 일종인 전달행렬법을 사용하여, 마이크를 용기 입구 위 1cm에 가져다 대었을 때, 스윕을 발사하고 돌아오는 주파수 응답에 대한 전달함수를 계산, 이를 누적하여 스펙트로그램을 얻는 시뮬레이터를 제작하였다. 시뮬레이터를 통해 생성한 데이터가 학습에 적절한지 판단하기 위해 물리적인 해석해가 존재하는 288개의 용기에 대하여 시뮬레이터의 공명진동수와 수식적 해의 공명진동수를 비교하였으며, pearson 상관계수 $r >= 0.99$ 임을 확인하였다. 또한 실측 공명 진동수와의 비교에서도 상관계수 $r >= 0.95$임을 확인하여 학습에 시뮬레이터를 사용할 수 있다는 타당성을 확보하였다.

3) 딥러닝 모델

TMM 시뮬레이터를 통해 생성한 가상 컵 10만 개에 대해 학습을 진행하였으며, CNN과 RNN에 대해 손실방정식, 학습 체크포인트, LSTM 가중치 방향 등을 다르게 하여 형상을 추적하는데 최적의 모델을 찾고자하였다. 이 과정에서 H와 r에 대한 손실함수가 서로 트레이드오프 관계를 보이는 시소 현상을 발견하였으며 이를 해결하기 위해 자체적인 역할 분담 모델을 제작하여 둘의 손실함수가 최소가 되도록 하였다. 이 과정을 거쳐 시뮬레이션 데이터에서 H 평균 절대값 오차 3.87mm, r 평균 절대값 오차 2.55mm를 확보하였다.

4) 실측에서의 추정

이렇게 학습된 모델을 가지고 실측 데이터에 대한 추정을 진행하였으나 H에 대한 평균 절대값 오차가 82.2mm로 평균적으로 과대추정되는 문제가 발생하였다. 본 연구에서는 이를 해결하기 위해 스펙트로그램을 다시 분석하였으며, 레퍼런스 녹음에서 노이즈가 발생할 경우 스펙트로그램에 정적인 세로 줄이 발생하는 사례들을 발견하였다. 이가 스펙트로그램에 변하지 않는 특성으로 도출됨에 따라 높이가 과대추정 되었을 것이라고 판단하였다. 이 문제를 해결하기 위해, 본 탐구에서는 레퍼런스의 노이즈에 대한 sline 증강학습을 실시하였으며 이 결과 H 오차가 평균 17.1 mm까지, 즉 개선 이전의 약 5배까지 줄어드는 것을 확인할 수 있었다.

2. 향후 탐구 계획 및 활용성

(1) 향후 탐구 계획

본 탐구에서는 높이 오차 ~ mm 이내, 반지름 오차 ~ mm 이내로 형상을 추정해내는데 성공하였다. 하지만 형상 추정 결과에서 보이는 몇몇 경향을 해소할 수 있는 방법과, 형상 추정의 정확도를 높일 수 있는 몇 가지 방법이 존재한다.

가. 실측 자동화 기계를 통한 다량의 실측 데이터 수집 및 모델 학습

본 탐구의 탐구 목적을 실현하는데 있어 가장 중요한 부분 중 하나는 시뮬레이션으로 학습한 모델이 실제에서도 뛰어난 성능을 보이게 하는 것인 sim-to-real 과정에 있다. 초기에 실측에서 큰 오차가 발생하였고, 이를 실측 데이터 분석을 통해 원인을 특정한 뒤 증강학습을 진행한 결과 추정 정확도를 대폭 향상할 수 있었다. 이렇듯, sim-to-real 에서는 실측 데이터를 바탕으로 모델을 수정하는 작업이 필요하다. 하지만 탐구 초기에 제시하였던 문제와 같이 실제 데이터를 학습할 만큼 다량의 데이터를 모으는 작업은 시간적, 공간적으로 매우 어려우므로 이를 자동화하는 장치를 제작해야 한다. 본 탐구에서는 이를 실제로 일부 적용하였으며, 조금의 수정을 거치면 이를 자동화하여 더 많은 데이터를 수집하는 것이 가능할 것으로 판단된다. 이를 통해 최종적으로 실측에서의 높이 오차와 반지름 오차를 줄일 수 있을 것으로 기대된다.

나. 연속 물채움을 통한 형상 추정

본 탐구에서 처음 영감을 얻은 공명 진동수 파악을 통한 정수기 출수 멈춤 기능 탐구에서는 연속으로 물을 따를 때 공명 진동수를 추적하고, 여기서 형상 추정 가능성을 확인하였다. 하지만 본 연구는 이산적으로 물을 채우고 공명 특성을 반복해서 측정함으로써 형상을 추정하고자 하였다. 본 연구에 반영된 실측 기법 중 스윕과 디컨볼루션에, 유량에 따른 높이 변화율을 반영하면 연속적인 물채움에 있어서 형상을 추정할 수 있는 스펙트로그램을 얻을 수 있을 것으로 기대된다. 추후 이를 보완하여, 연속적으로 물을 따르면서 공명 특성을 얻고, 더 나아가 물의 타격음, 즉 ‘또르륵’에서 ‘띠리릭’으로 변하는 소리를 감지하여 자유 형상을 추정하는 탐구를 진행할 것이다.

다. TMM과 실측 간극 줄이기

우리가 사용한 TMM은 무한 배플 가정을 통해 컵이 없을 때의 음압인 레퍼런스 음압과 컵이 있을 때의 음압을 계산하여 전달함수를 도출한다. 그러나 실측 환경은 마이크 위가 모두 개방되어 있는 무한 배플이 아니라, 스피커의 단면적이 이를 막고 있는 형태로, 마이크와 스피커의 거리가 충분히 가까워 딥 주파수 이동에 영향을 줄 수 있다. 이는 벌어진 컵에서 높이 추정에 영향을 미칠 수 있으므로, TMM의 가정을 실측의 사정에 맞게 스피커 위치를 반영하여 변경하면 이러한 문제를 해결할 수 있을 것으로 예상된다.

(2) 활용 방안

본 탐구에서 개발한 '음향 기반 3차원 형상 추정 기술'은 일상적인 컵부터 지름이 10~300mm에 이르는 소형 및 중형 산업용 용기에서 가장 높은 정밀도를 발휘한다. 특히 빛이 통하지 않아 내부를 눈으로 볼 수 없고, 함부로 열어볼 수 없는 위험한 밀폐 용기나 배관 내부를 소리만으로 분해 없이(비파괴) 진단할 수 있어, 다음과 같이 산업 현장의 고질적인 문제를 해결하는 데 큰 가치를 가진다.

가. 센서 내장형 용기를 통한 가스 잔량 및 찌꺼기 실시간 진단

반도체 공정 등에는 매우 비싸고 위험한 특수 액체나 가스가 완벽히 밀폐된 불투명 금속제 탱크에 담겨 공급된다. 현재는 내부를 볼 수 없어 공정 도중 화학 물질이 끊기는 사고를 막기 위해, 아직 10~15%가량 넉넉히 남아 있음에도 용기를 미리 교체하고 남은 용액은 버리는 실정이다. 본 기술을 활용하여, 이러한 특수 용기를 제조할 때 뚜껑이나 상단 밸브 쪽에 소형 음향 측정 장치(스피커와 마이크)를 내장할 수 있다면, 공정이 진행되는 동안 미세한 소리를 발생시켜 내부 상태를 실시간으로 모니터링할 수 있다. 이를 통해 뚜껑을 열지 않고도 남아있는 액체의 정확한 수위는 물론, 벽면에 굳어있는 찌꺼기의 양과 위치까지 3차원으로 파악할 수 있어 고가의 화학 물질 낭비를 획기적으로 막을 수 있을 것으로 예상된다.

나. 공장 배관 내부의 막힘(슬래그) 위치 정밀 탐지

산업 현장의 수많은 배관 내부에는 공정 후 발생하는 고체 부산물(슬래그)이 쌓여 점차 관을 막게 된다. 현재 산업계에서는 배관 내부의 어디가 얼만큼 막혔는지 정확히 알 방법이 없어, 안전을 위해 막히지도 않은 멀쩡한 배관들까지 통째로 자주 교체하고 있다. 이로 인해 부품 낭비는 물론 공장 가동을 멈춰야 하는 막대한 손실이 발생한다. 본 기술을 활용하여 배관에 주기적으로 소리 신호를 흘려보내면, 배관 내부 깊이에 따라 관이 얼만큼 좁아졌는지 그 단면적의 변화를 밀리미터(mm) 단위로 정확히 찾아낼 수 있다. 배관 전체를 교체할 필요 없이 막힌 부분만 정확히 찾아 조치할 수 있어, 부품 교체 주기를 늘리고 유지보수 비용을 크게 절감할 수 있을 것으로 예상된다.

VI 참고문헌

[1] Mark Kac. (1966). Can One Hear the Shape of a Drum? American Mathematical Monthly.

[2] M. R. Schroeder. (1967). Determination of the Geometry of the Human Vocal Tract by Acoustic Measurements. Journal of the Acoustical Society of America.

[3] Piyush Bagad, Makarand Tapaswi, Cees G. M. Snoek, Andrew Zisserman. (2024). The Sound of Water: Inferring Physical Properties from Pouring Liquids.

[4] 제45회 전국학생과학발명품경진대회. (2024). 컵의 크기에 상관없이 가득 따라주는 똑똑한 AI 정수기.

[5] G. Kirchhoff. (1868). Ueber den Einfluss der Wärmeleitung in einem Gase auf die Schallbewegung. Annalen der Physik, 210(6), 177-193.

[6] Kinsler, L. E., Frey, A. R., Coppens, A. B., & Sanders, J. V. (2000). Fundamentals of Acoustics (4th ed.). John Wiley & Sons. (Chapter 10: Pipes, Resonators, and Filters)

[7] Helmholtz, H. von. (1863). Die Lehre von den Tonempfindungen als physiologische Grundlage für die Theorie der Musik. Braunschweig: Friedrich Vieweg und Sohn.

[8] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.

[9] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735-1780.

[10] AI 활용에 관하여: 본 탐구는 여러 가지 AI 도구를 적극적으로 활용하였다. 자료 조사 뿐만 아니라 이론 공부, 공식 유도, 그래프 작성, 실험 결과 분석 등 탐구 전반에 걸쳐 매우 적극적으로 ai를 활용하였고 필요한 도구를 ai 코딩 에이전트의 도움을 받아 제작하여 활용하였다. 최종 문서 작성에 있어서도 초안 작성과 필요한 그림 생성에 ai를 활용하였다. 그러나 이 모든 작업은 탐구자의 주도적인 요구로 이루어졌으며 ai가 제공한 결과물을 검증하고 신뢰성을 판단하고 선택해서 사용하고 우리탐구의 맥락에 맞게 수정을 요구하는 등 일련의 행동은 탐구자의 몫이었다.