

---

# Overview of Physics-Informed Machine Learning

---



2026년 05월 15일

장성호

# 발표자 소개



## ❖ 장성호 (Seongho Jang)

- 고려대학교 산업경영공학과 박사과정 재학
- Data Mining & Quality Analytics Lab. (김성범 교수님)

## ❖ Research Interest

- Reinforcement learning
- Physics-informed machine learning
- Physical AI

## ❖ Contact

- [jsh01@korea.ac.kr](mailto:jsh01@korea.ac.kr)

# Content

## ❖ Background

## ❖ Physics-Informed Learning

- Physics-Informed Neural Networks (PINNs)
- Physics-Guided Neural Networks (PGNNs)

## ❖ Neural Operators

- Learning parametric PDE mappings

## ❖ Surrogate Modeling



- Replacing Computational Fluid Dynamics / Finite Element Method
- Advanced applications and future directions

# Background

## Physics-based simulation and surrogate modeling

### ❖ Why Physics-Based Simulation?

- 공학/과학 문제는 대부분 물리 법칙 기반으로 해석됨
  - CFD (computational fluid dynamics) / FEM (finite element method) / FEA (finite element analysis)
- 하지만 정밀 시뮬레이션의 비용은 매우 비쌘
- 설계 조건, 재료, 경계조건, 파라미터가 바뀔 때마다 반복 계산 필요




# Background

## Physics-based simulation and surrogate modeling

### ❖ Why Machine Learning?

- ML은 데이터로부터 빠른 예측 모델을 만들 수 있음
- 기존 시뮬레이터를 대체하거나 보조하는 surrogate model로 활용 가능
- Neural operator 계열은 PDE 하나가 아니라 여러 파라미터 조건의 solution mapping을 학습하는 방향으로 발전함




# Background

## Physics-based simulation and surrogate modeling

### ❖ Why Physics-Informed?

- 순수 data-driven 모델은 데이터가 부족하거나 OOD 조건에서 불안정할 수 있음
- 물리 법칙, 제약조건, 시뮬레이션 결과를 학습에 넣으면 일반화와 해석 가능성을 높일 수 있음
- PINN은 PDE residual을 loss에 반영하고, PGNN은 물리 모델 출력/물리 loss를 NN에 결합하는 더 유연한 방향으로 볼 수 있음



# Background

Physics-based simulation and surrogate modeling

## ❖ What is a Differential Equation?



- Differential Equation은 시스템의 상태가 어떻게 변화하는지를 설명하는 수학적 규칙
- 값 자체보다 변화율을 이용해 다음 상태를 설명하는 것
  - ODE (ordinary differential equation): 시간에 따른 변화
  - PDE (partial differential equation): 시간과 공간에 따른 변화

# Background

Physics-based simulation and surrogate modeling

## ❖ What is a Differential Equation?

- 자동차의 위치  $x(t)$ 를 예측하고 싶다고 가정
  - 속도  $v(t)$ 는 위치의 변화율
  - 가속도  $a(t)$ 는 속도의 변화율
- 현재 위치 + 속도  $\times$  시간 = 다음 위치





같은 속도 규칙  
→ 초기 위치  $x(0)$ 에 따라 결과가 달라짐  
→ 초기조건

# Background

Physics-based simulation and surrogate modeling

## ❖ What is a Differential Equation?

- 자동차의 위치  $x(t)$ 를 예측하고 싶다고 가정
  - 속도  $v(t)$ 는 위치의 변화율
  - 가속도  $a(t)$ 는 속도의 변화율
- 현재 위치 + 속도  $\times$  시간 = 다음 위치



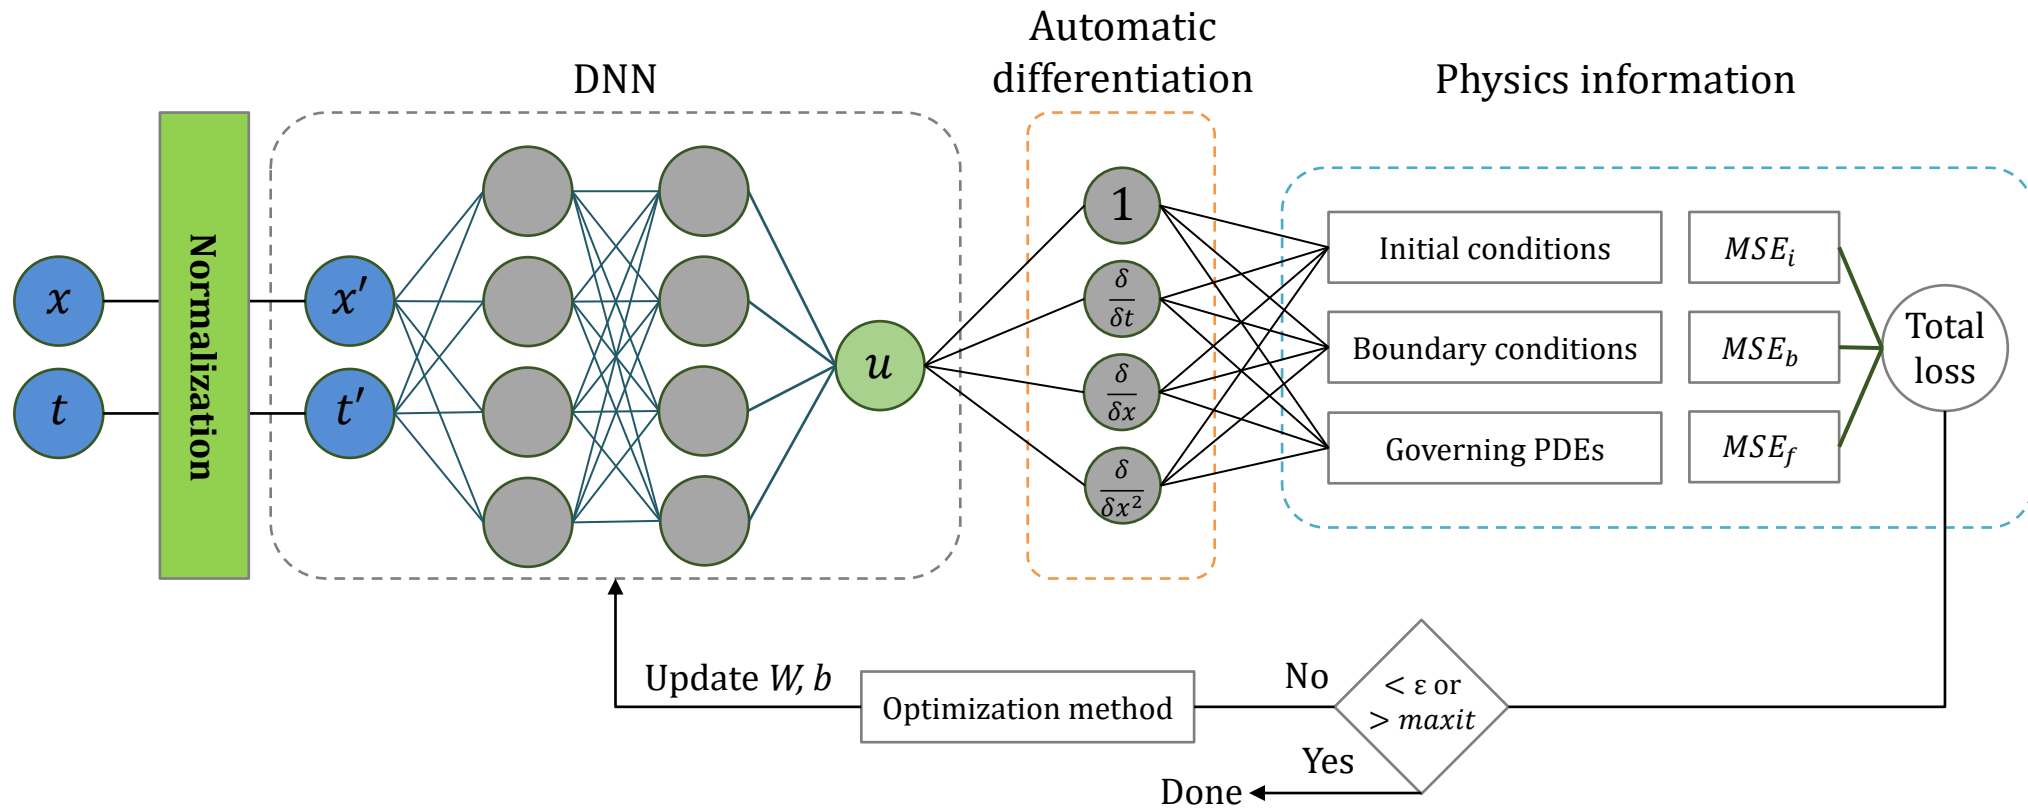
특정 위치에서 속도 값이 정해질 수 있음  
→ 특정 공간 위치에서 만족해야 하는 조건  
→ **경계조건**

# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

❖ **PINN (forward problem):** Journal of Computational Physics(2019, sites: 23,243)

- 신경망이 해  $u(x, t)$ 를 학습하면서 자동 미분을 통해 PDE를 만족하도록 학습됨
- 데이터뿐 아니라 물리 제약식(PDE, 초기/경계조건)을 함께 만족하도록 최적화

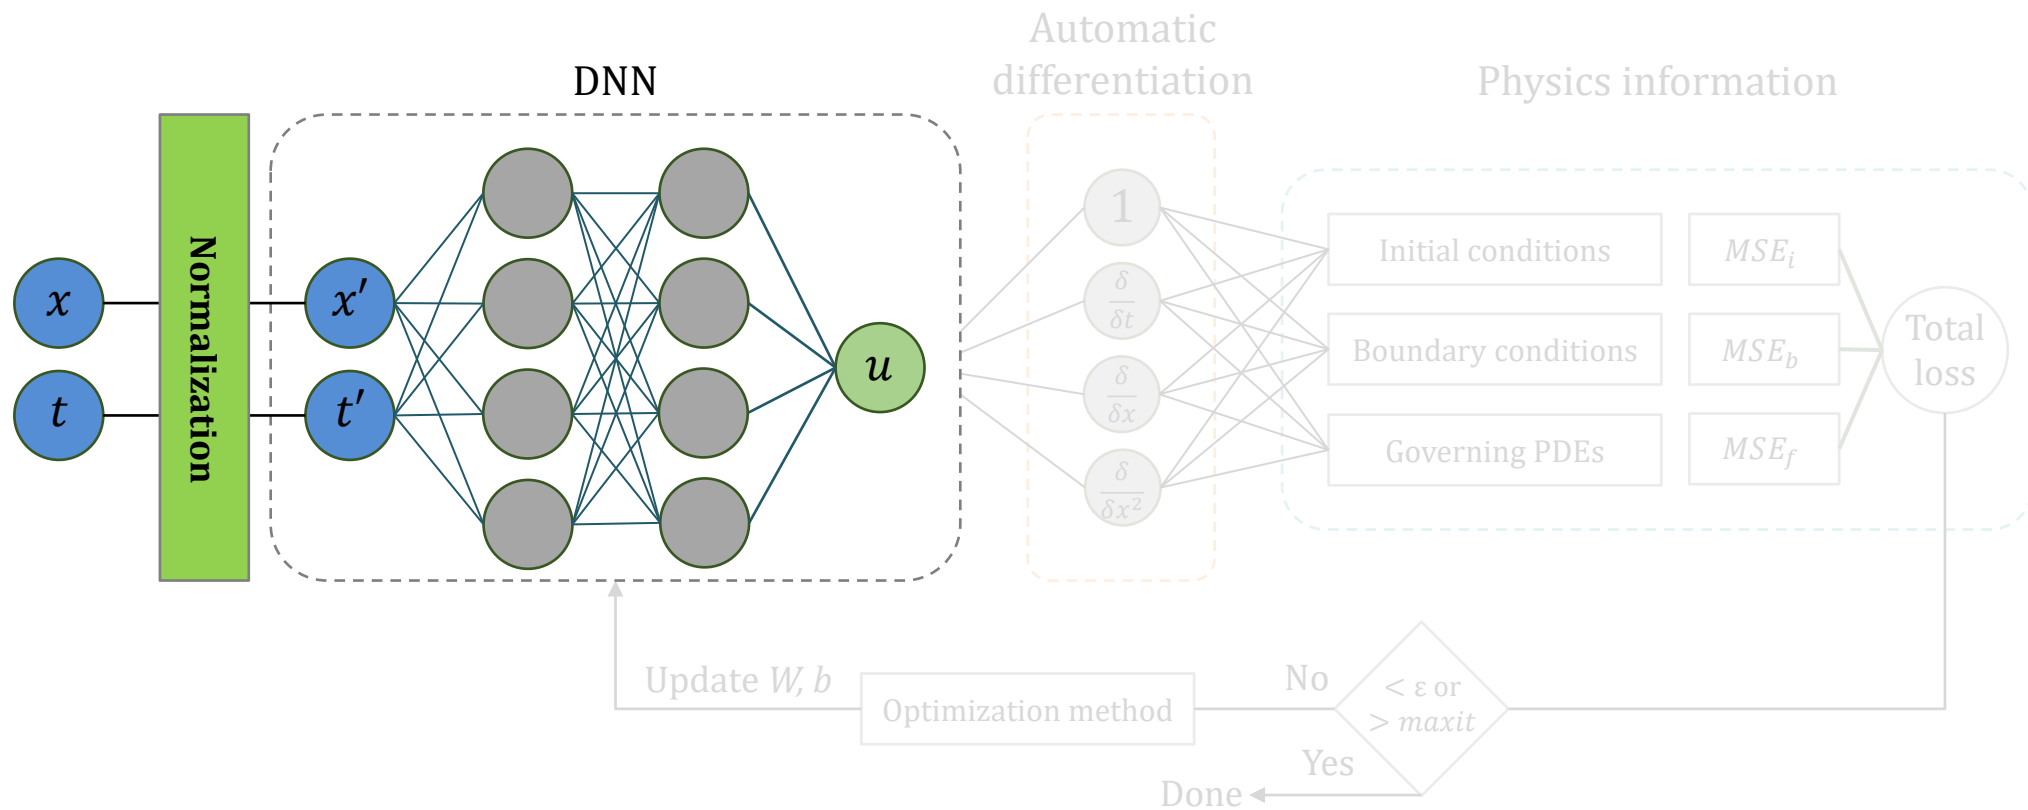


# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ PINN (forward problem)

- 특정 위치  $x$ 와 시간  $t$ 를 입력 받아 해당 지점의 물리량을 예측하는 함수로 신경망을 사용함
- 즉, 전체 시공간을 격자로 계산하는 대신, 위치와 시간을 넣으면 값을 바로 출력하는 연속 함수를 학습하는 것이 목표

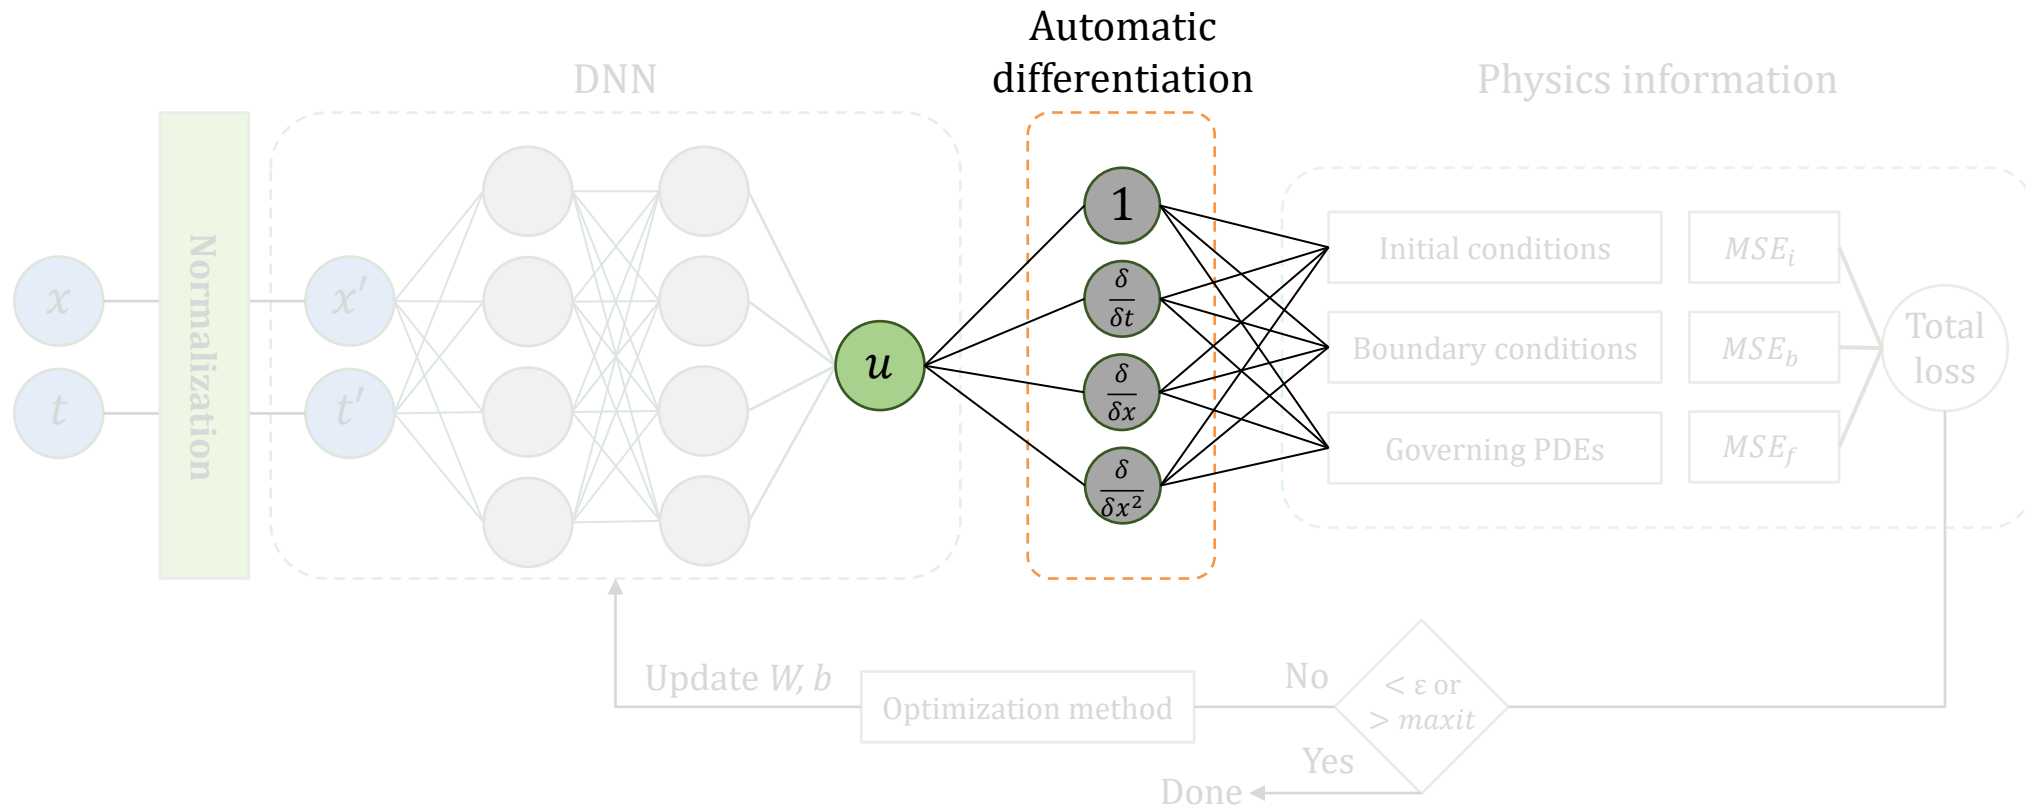


# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ PINN (forward problem)

- 물리 법칙은 값 자체뿐 아니라, 시간과 공간에 따라 얼마나 변화하는지(변화율)로 표현함
- 따라서 신경망의 출력값을 미분하여, 그 결과를 물리 방정식(PDE)에 대입하여 사용함

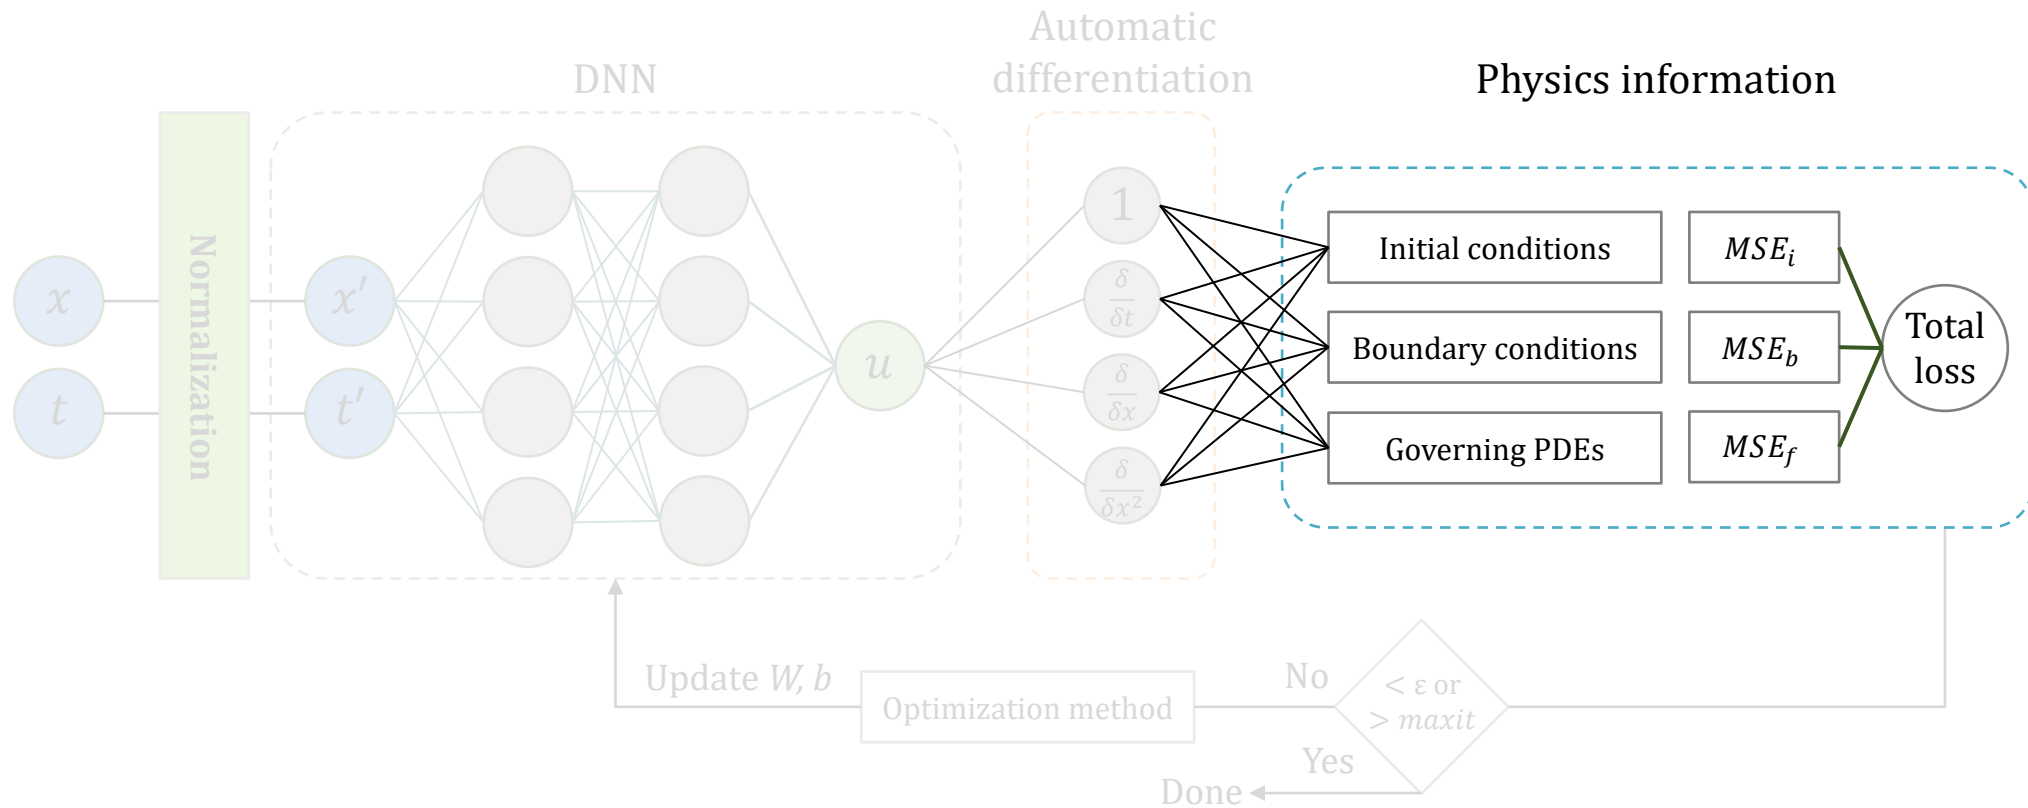


# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ PINN (forward problem)

- 모델이 예측한 값이 물리 법칙을 얼마나 위반했는지를 loss로 계산함
- 초기조건(처음 상태)과 경계조건(벽/경계에서의 조건)을 함께 만족하도록 학습

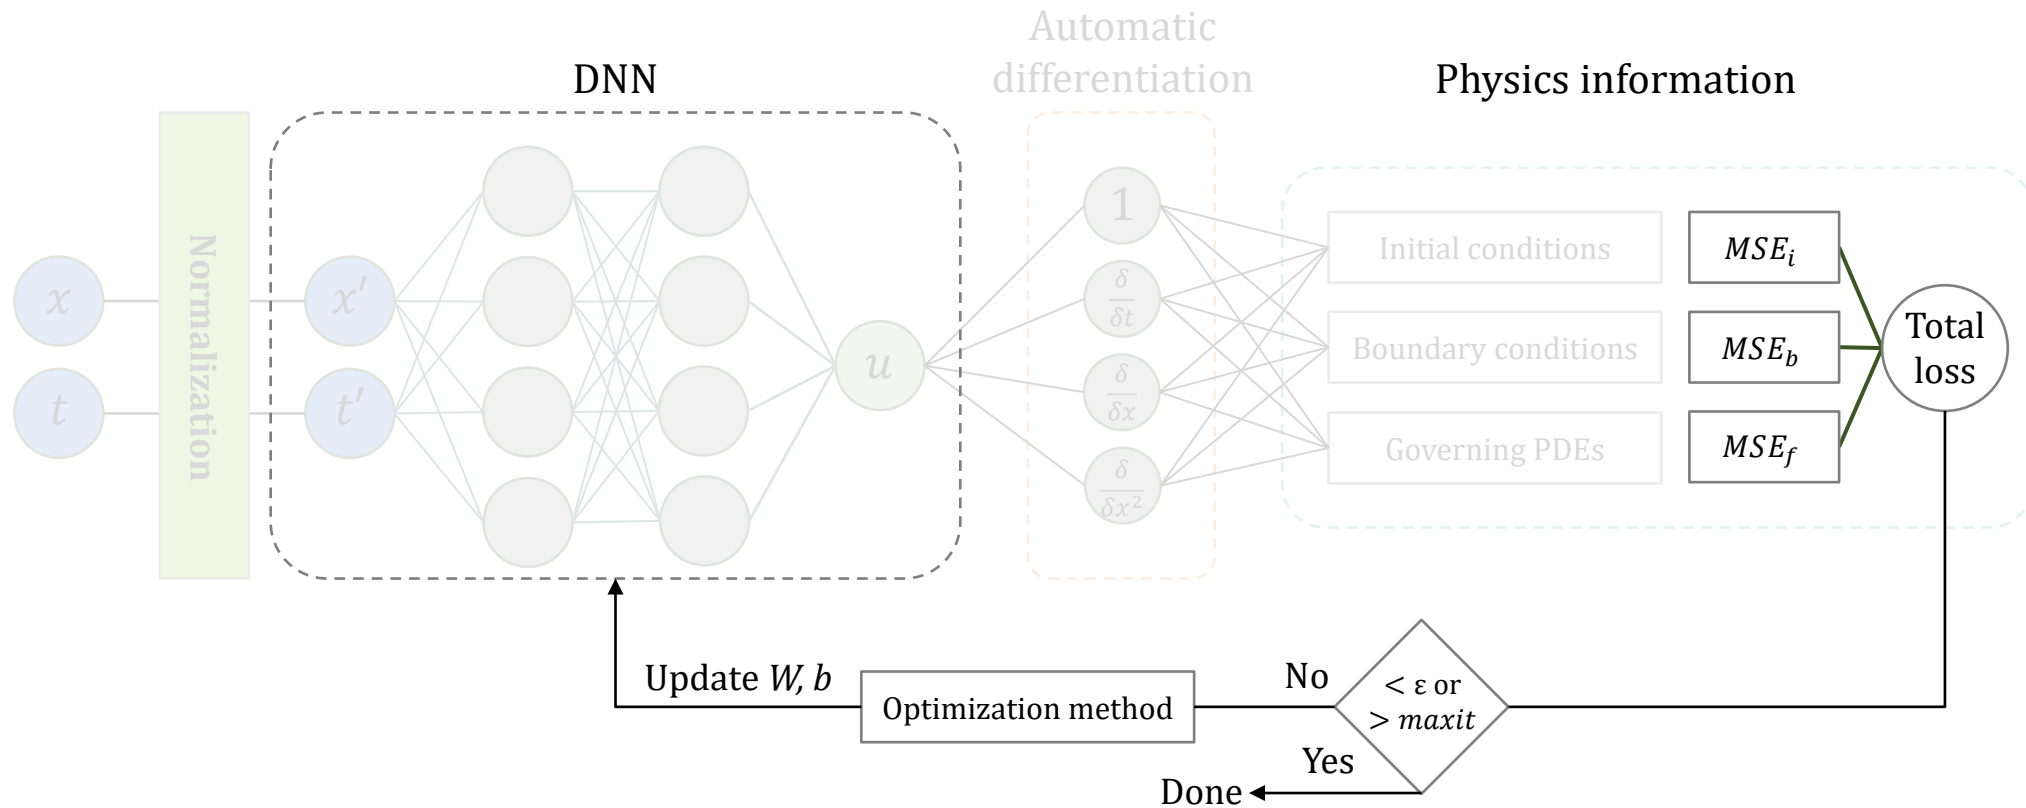


# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ PINN (forward problem)

- 물리 방정식을 잘 만족하지 못하면  $\text{loss}(\text{PDE residual})$ 가 커지고, 이를 줄이도록 신경망을 반복적으로 업데이트
- 즉, PINN은 어떤 위치와 시간에서도 물리 법칙을 만족하는 값을 예측하도록 설계함

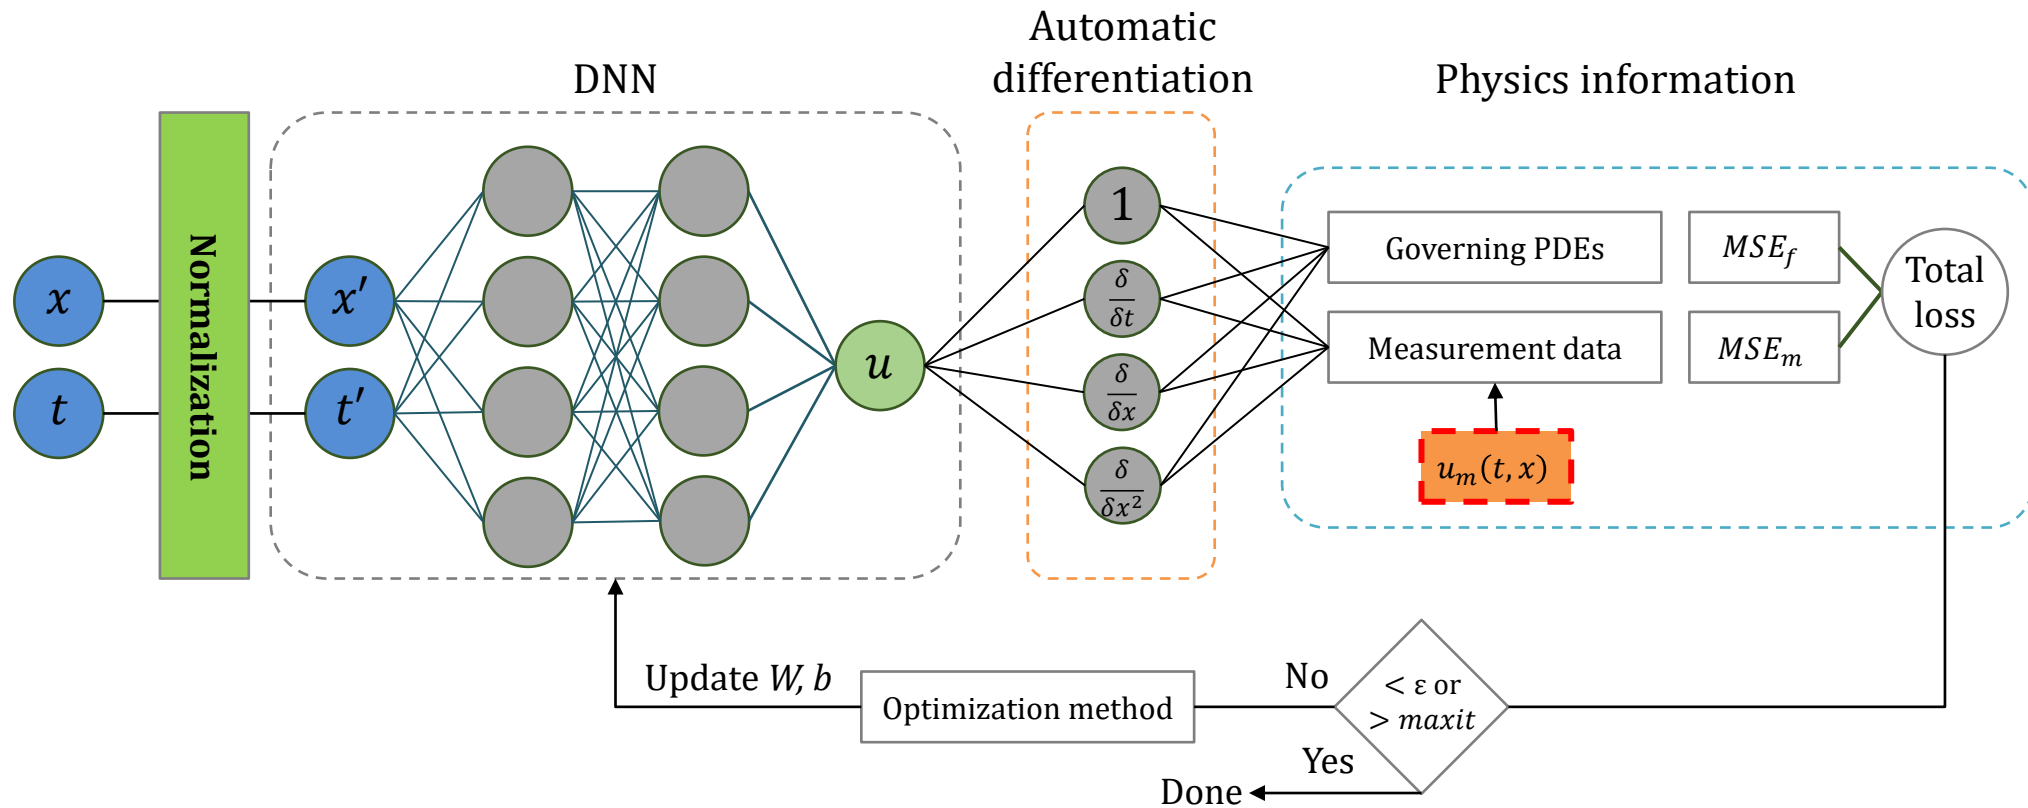


# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ Inverse PINN (Inverse problem)

- 일부 관측 데이터가 주어졌을 때, PDE 내부의 미지 물리 파라미터  $\lambda$ 를 신경망과 함께 학습함
- 즉, 데이터와 물리 방정식을 동시에 만족하도록 학습하여 시스템의 숨겨진 물리 특성을 추정함



# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ Forward vs Inverse Problems (PINN)


- Forward 문제는 물리 파라미터가 주어졌을 때, 시스템의 응답  $y(t)$  를 계산하는 문제
- Inverse 문제는 관측된 데이터  $y(t)$  와 물리 방정식을 이용해 미지의 물리 파라미터  $(m, \mu, k)$  를 추정하는 문제

$$(m, \mu, k) \rightarrow my'' + \mu y' + ky = 0 \rightarrow y(t)$$

$m, \mu, k$   
(mass  $m$ , damping  $\mu$ , stiffness  $k$ )

$$m \frac{d^2y}{dt^2} + \mu \frac{dy}{dt} + ky = 0$$


forward  
➔



Output:  $y(t)$


Forward PINN

$$\text{Data } y(t) + (my'' + \mu y' + ky = 0) \rightarrow (m, \mu, k)$$



$y(t)$

inverse  
➔



PINN  
( $m, \mu, k$  estimate)

Inverse PINN

# Physics-Informed Learning

## Physics-Informed Neural Networks (PINNs)

### ❖ Forward vs Inverse Problems (PINN)

- Forward 문제는 물리 파라미터가 주어졌을 때, 시스템의 응답  $y(t)$  를 계산하는 문제
- Inverse 문제는 관측된 데이터  $y(t)$  와 물리 방정식을 이용해 미지의 물리 파라미터  $(m, \mu, k)$  를 추정하는 문제

$(m, \mu, k) \rightarrow my'' + \mu y' + ky = 0 \rightarrow y(t)$       PINN은 PDE residual, IC, BC를 loss로 직접 사용       $Data\ y(t) + (my'' + \mu y' + ky = 0) \rightarrow (m, \mu, k)$

➔ 지배방정식이 비교적 잘 알려져 있고 미분 가능한 형태로 쓸 수 있을 때 강점

$m, \mu, k$   
(mass  $m$ , damping  $\mu$ , stiffness  $k$ )

$$m \frac{d^2 y}{dt^2} + \mu \frac{dy}{dt} + ky = 0$$

forward



실제 문제에서는 물리식이 불완전, 일부 현상만 알려져 있음

➔ 물리식을 직접 강제하지 않고 유연하게 결합하자

inverse



PINN  
( $m, \mu, k$  estimate)

Forward PINN

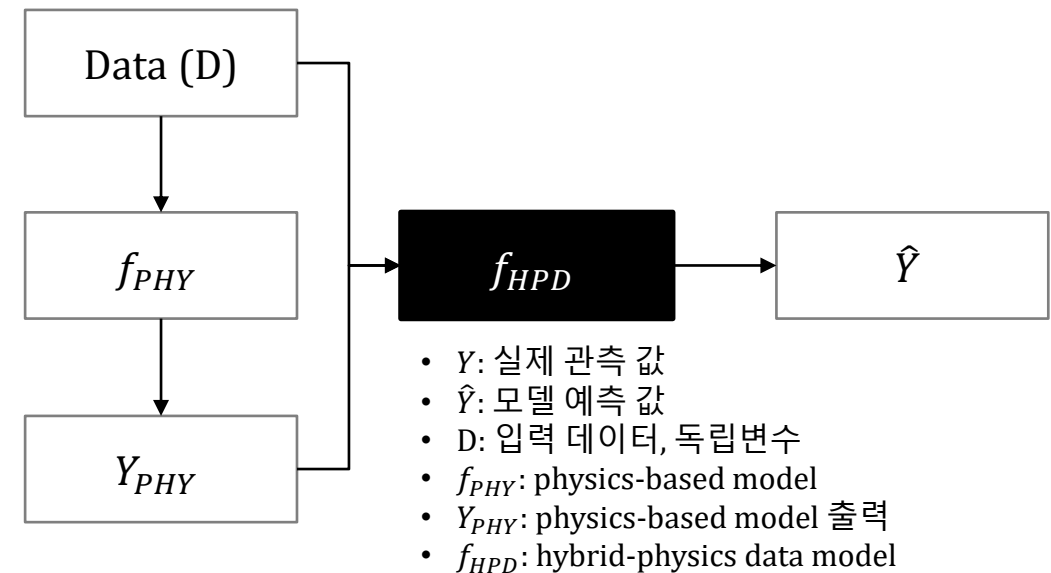
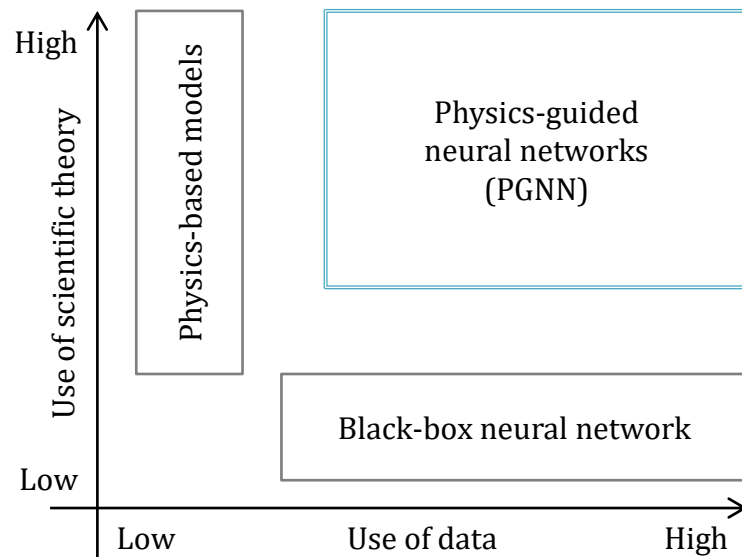
Inverse PINN

# Physics-Informed Learning

## Physics-Guided Neural Networks (PGNNs)

### ❖ Physics-guided Neural Networks (PGNN): An Application in Lake Temperature Modeling (2021, sites: 1098)

- 물리 기반 모델은 상대적으로 정확하지만 유연성이 부족하고, 순수 데이터 기반 모델은 데이터에 의존적
- PGNN은 두 모델을 결합하여 물리 지식과 데이터를 함께 활용하는 hybrid 모델

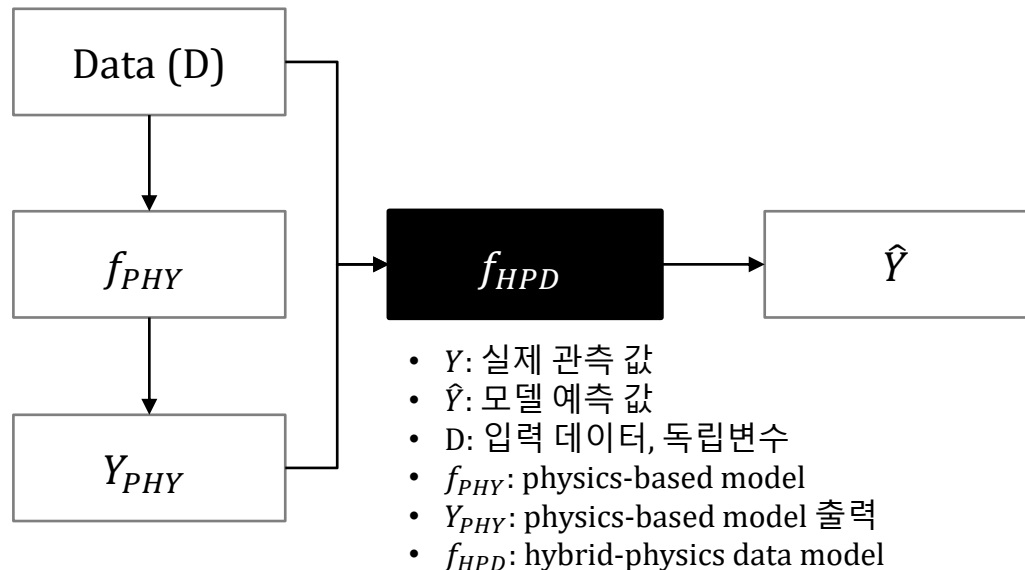


# Physics-Informed Learning

## Physics-Guided Neural Networks (PGNNs)

### ❖ How to incorporate physics (PGNN)

- Physics as input (Feature)
  - 물리 모델의 출력이나 물리적으로 의미가 있는 변수를 입력 feature로 함께 사용함
- Physics as loss (constraint)
  - 모델 예측이 물리 법칙을 얼마나 위배하는지를 loss로 정의하여 학습에 반영함
  - 데이터뿐 아니라 물리 방정식도 같이 만족하도록 모델 학습



$$f_{HPD}: X = [D, Y_{PHY}] \rightarrow Y$$

물리 정보를 입력 feature으로 활용

# Physics-Informed Learning

## Physics-Guided Neural Networks (PGNNs)

### ❖ How to incorporate physics (PGNN)

- Physics as input (feature)
  - 물리 모델의 출력이나 물리적으로 의미가 있는 변수를 입력 feature로 함께 사용함
- Physics as loss (constraint)
  - 모델 예측이 물리 법칙을 얼마나 위배하는지를 loss로 정의하여 학습에 반영함
  - 데이터뿐 아니라 물리 방정식도 같이 만족하도록 모델 학습

$$\arg \min_f \text{Loss}(\hat{Y}, Y) + \lambda R(f)$$

$$\begin{aligned} \mathcal{G}(Y, Z) &= 0, \\ \mathcal{H}(Y, Z) &= 0 \end{aligned}$$

$$\text{Loss. PHY}(\hat{Y}) = \|\mathcal{G}(\hat{Y}, Z)\|^2 + \text{ReLU}(\mathcal{H}(\hat{Y}, Z))$$


$$\arg \min_f \text{Loss}(\hat{Y}, Y) + \lambda R(f) + \lambda_{PHY} \text{Loss. PHY}(\hat{Y})$$

# Physics-Informed Learning

## Limitation of PINN and PGNN

### ❖ Difficulty in handling multiple physical parameters

- PINN은 주어진 PDE와 **특정 초기/경계조건**에 대해 해를 찾는 방식
  - 물리 파라미터나 조건이 바뀌면 새로운 문제로 다시 학습해야 함
- PGNN은 물리 모델 출력이나 physics-based loss를 활용
  - 여러 물리 파라미터.조건이 섞인 데이터에서는 어떤 물리 정보를 어떻게 반영해야 하는지 설계가 어려움

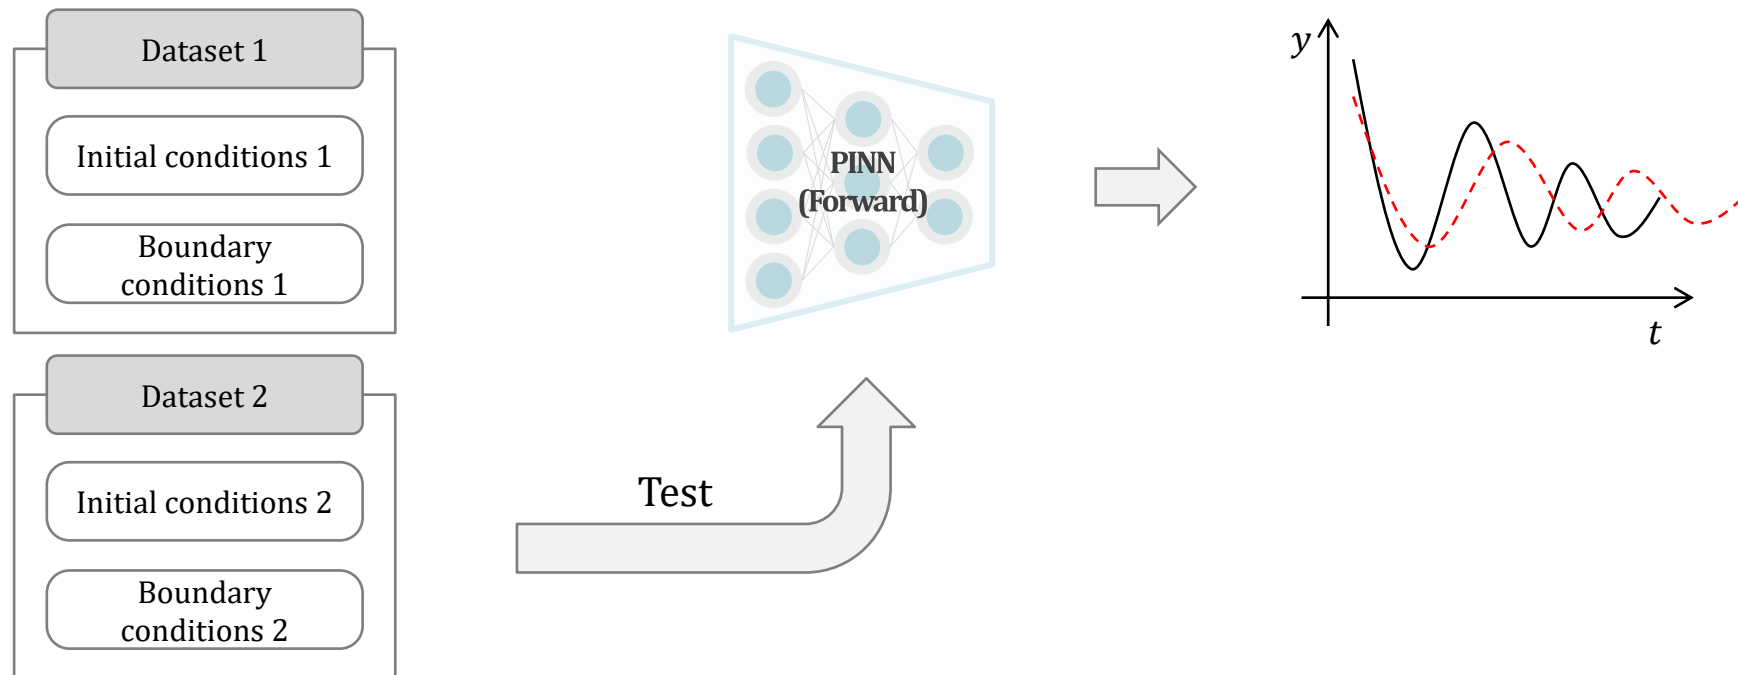


# Physics-Informed Learning

## Limitation of PINN and PGNN

### ❖ Difficulty in handling multiple physical parameters

- PINN은 주어진 PDE와 **특정 초기/경계조건**에 대해 해를 찾는 방식
  - 물리 파라미터나 조건이 바뀌면 새로운 문제로 다시 학습해야 함
- PGNN은 물리 모델 출력이나 physics-based loss를 활용
  - 여러 물리 파라미터.조건이 섞인 데이터에서는 어떤 물리 정보를 어떻게 반영해야 하는지 설계가 어려움



# Neural Operators

Learning parametric PDE mappings

## ❖ What Does Neural Operator Learn?

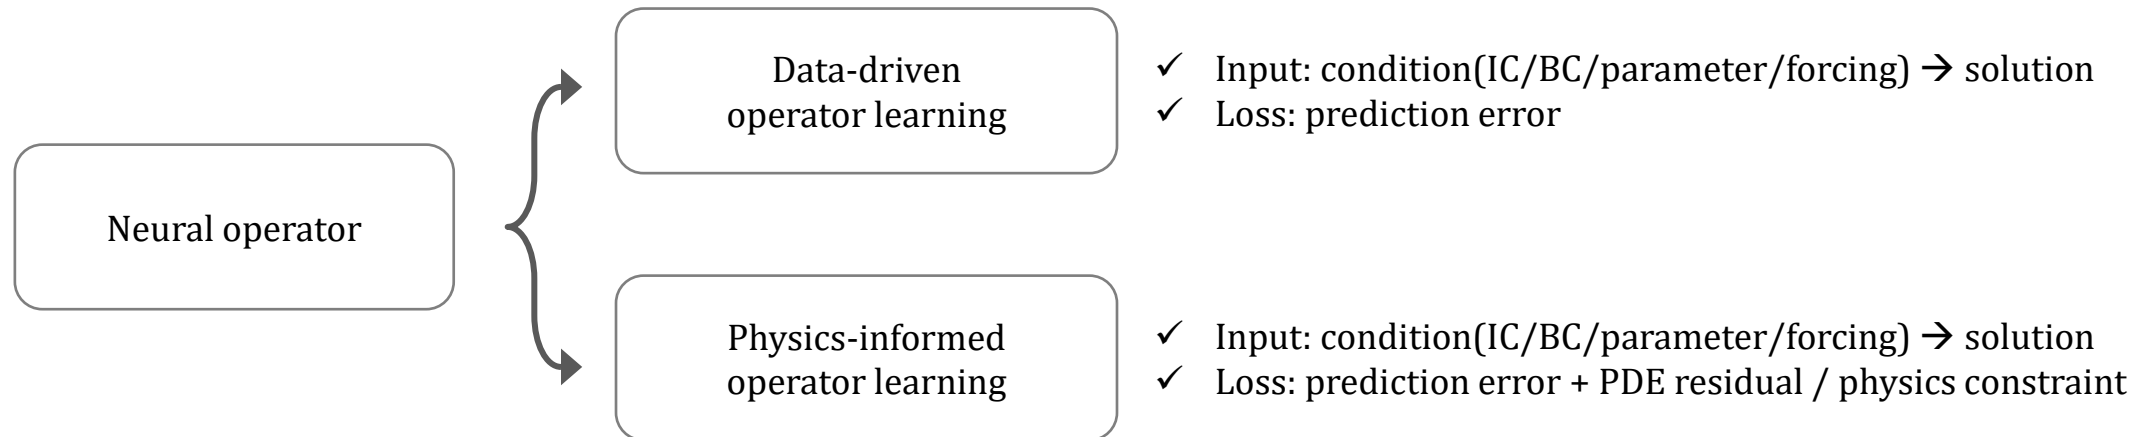
- Operator은 다양한 초기/경계조건, 물리 파라미터에 대한 해의 변화를 한 번에 예측
- DeepONet/FNO는 여러 시뮬레이션 데이터로부터 입력 함수/조건  $(\lambda, u_0, BC)$ 와 해  $u(x, t)$ 사이의 mapping을 학습
- 따라서 기본 형태는 data-driven surrogate이지만, 학습 대상은 하나의 값이 아니라 함수 전체를 변환하는 operator

# Neural Operators

Learning parametric PDE mappings

## ❖ Can Neural Operators Use Physics?

- 기본 Neural operator는 시뮬레이션 데이터 기반으로 학습하지만, PDE residual이나 boundary condition loss를 추가하면 physics-informed operator
- 즉, Neural operator는 physics-free model이 아니라, data-driven과 physics-informed를 모두 포함할 수 있는 surrogate modeling framework

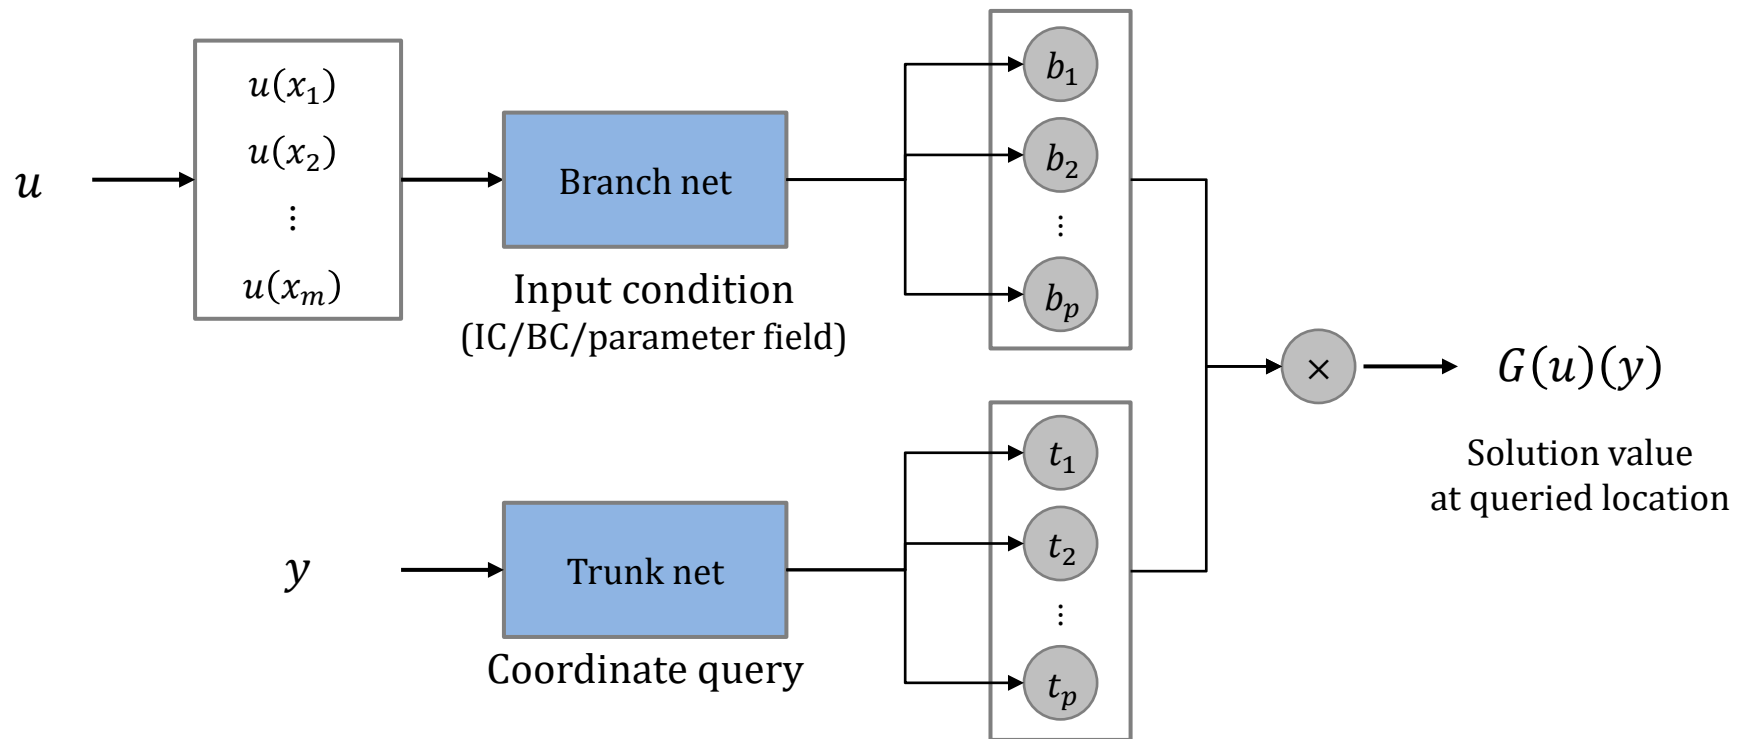


# Neural Operators

## Learning parametric PDE mappings

❖ **DeepONet** (deep operator network): nature machine intelligence, (2021, sites: 4,485)

- DeepONet은 PDE parameter, 초기/경계조건과 같은 문제 설정과 좌표 정보를 분리하여 학습하는 operator learning 모델
- Branch network는 문제 조건을 표현하고, Trunk network는 좌표별 해 표현을 생성하며, 두 정보를 결합하여 최종 해를 예측



# Neural Operators

Learning parametric PDE mappings

## ❖ DeepONet: Branch network

- Branch network는 PDE parameter, 초기조건, 경계조건과 같은 문제 설정 정보를 입력으로 받음
- 이를 통해 현재 문제의 전체적인 해 특성을 표현하는 coefficient vector를 생성

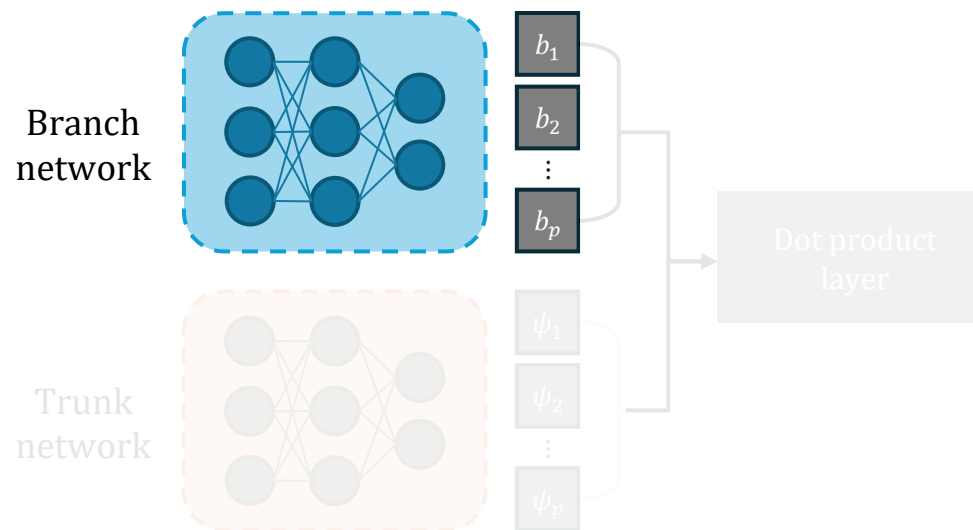

Branch network inputs

parameter:

$k, A, \mu_1, \mu_2$

BC:

domain geometry:



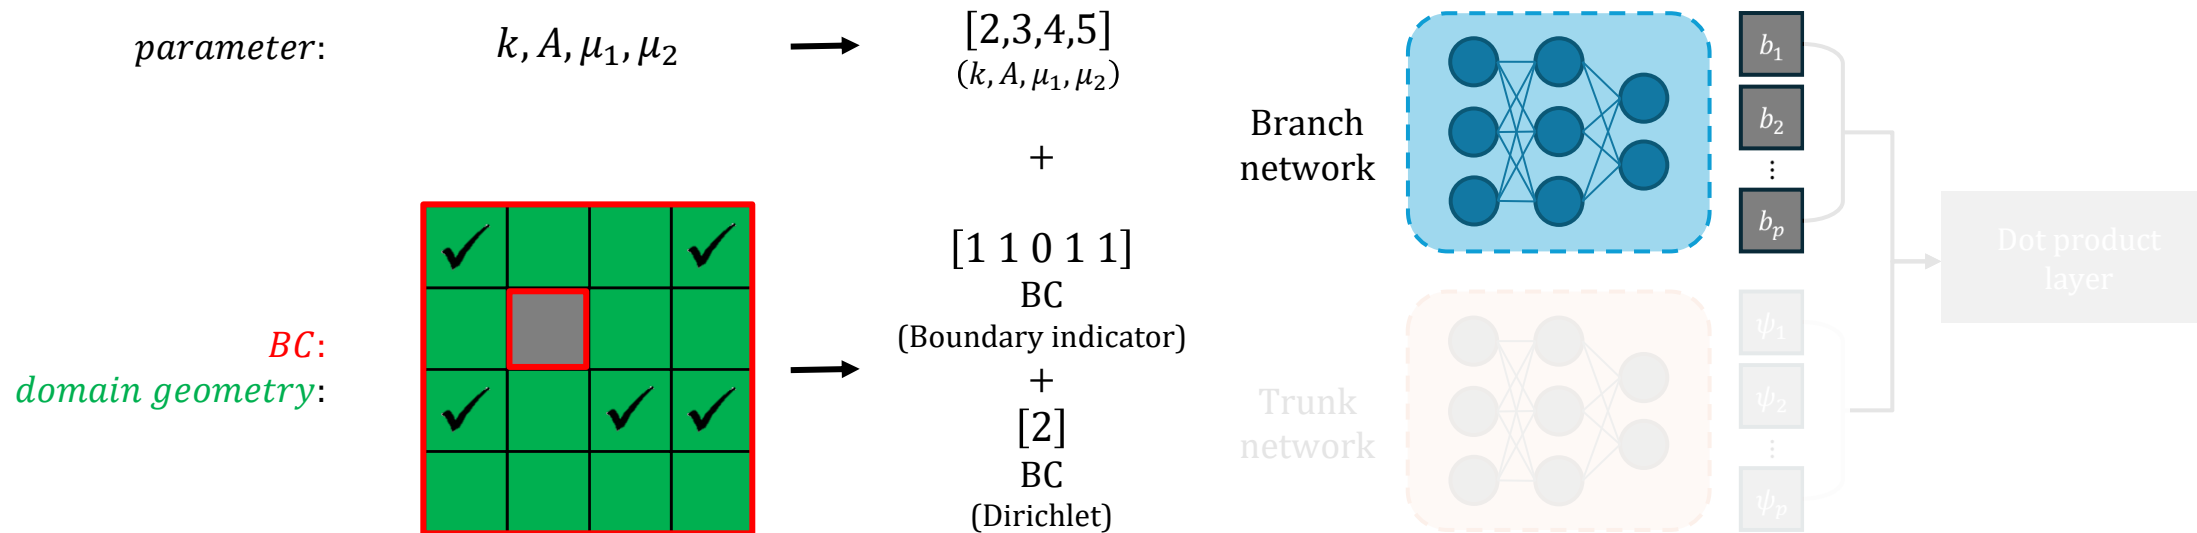
# Neural Operators

Learning parametric PDE mappings

## ❖ DeepONet: Branch network

- Branch network는 PDE parameter, 초기조건, 경계조건과 같은 문제 설정 정보를 입력으로 받음
- 이를 통해 현재 문제의 전체적인 해 특성을 표현하는 coefficient vector를 생성

Branch network inputs



# Neural Operators


Learning parametric PDE mappings

## ❖ DeepONet: Trunk network

- Trunk network는 특정 위치  $(x, y, t)$ 와 같은 coordinate query를 입력으로 받음
- 이를 통해 각 좌표 위치에서의 해 표현(spatial basis representation)을 생성함

Trunk network inputs

✓ (1, 4)	(2, 4)	✓ (3, 4)	(4, 4)
(1, 3)		(3, 3)	(4, 3)
✓ (1, 2)	(2, 2)	(3, 2)	✓ (4, 2)
(1, 1)	(2, 1)	✓ (3, 1)	✓ (4, 1)



# Neural Operators

Learning parametric PDE mappings


## ❖ DeepONet: Trunk network

- Trunk network는 특정 위치  $(x, y, t)$ 와 같은 coordinate query를 입력으로 받음
- 이를 통해 각 좌표 위치에서의 해 표현(spatial basis representation)을 생성함

Trunk network inputs

✓ (1, 4)	(2, 4)	✓ (3, 4)	(4, 4)
(1, 3)		(3, 3)	(4, 3)
✓ (1, 2)	(2, 2)	(3, 2)	✓ (4, 2)
(1, 1)	(2, 1)	✓ (3, 1)	✓ (4, 1)

$[(1,2), (1,4), (3,1), (3,4), (4,1), (4,2)]$



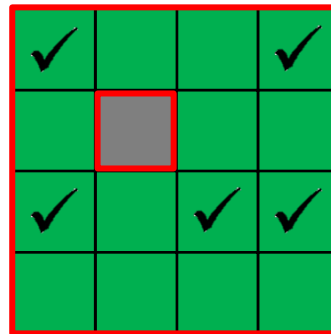
# Neural Operators

Learning parametric PDE mappings


## ❖ DeepONet Summary: Universal Approximation of Operators

- DeepONet은 입력 함수/조건  $a$ 가 주어졌을 때 해 함수  $u$ 를 생성하는 operator  $\mathcal{G}: a \rightarrow u$ 를 근사함
- Branch network은 입력 함수/조건을 sensor point에서 관측하여 문제 특성을 요약
- Trunk network는 임의의 좌표 query에서 해를 평가할 수 있도록 하여 grid-free prediction이 가능


Branch network input sampling  
→ 입력 함수/조건을 요약



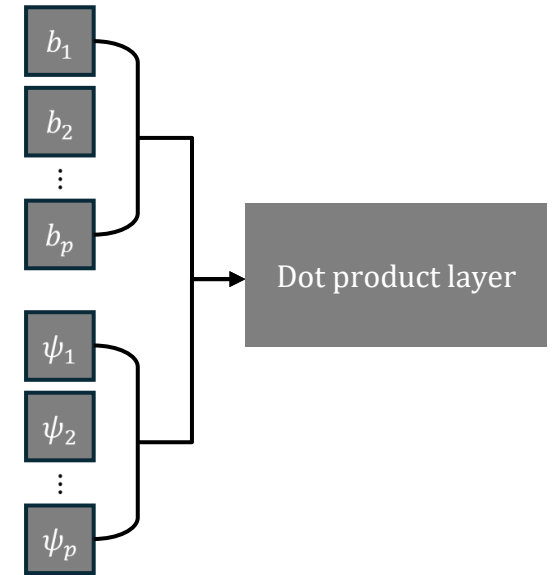

Trunk network input sampling  
→ 해 예측과 loss 계산을 위한 query points



Branch network



Trunk network




# Surrogate Modeling

Replacing Computational Fluid Dynamics / Finite Element Method

## ❖ Why Surrogate Modeling?

- CFD, FEM, FEA와 같은 시뮬레이션은 형상, 재료 특성, 초기/경계조건을 입력으로 받아 물리 현상을 계산함
- 입력 조건이 바뀔 때마다 시뮬레이션을 처음부터 다시 수행해야 하므로 많은 계산 시간이 필요함
- Surrogate modeling은 이러한 입력과 결과의 관계를 학습하여 새로운 조건에서도 결과를 빠르게 예측하는 방법

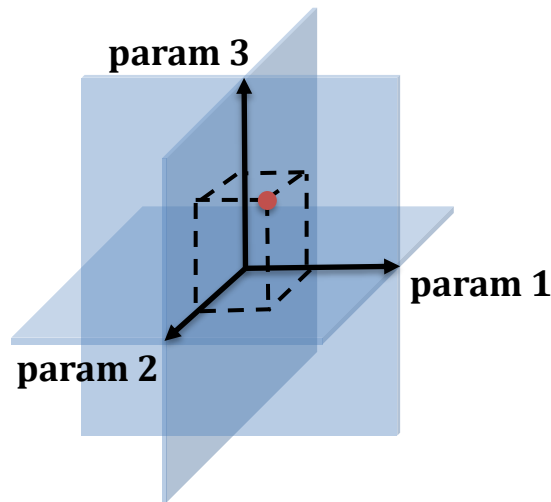


# Surrogate Modeling


Replacing Computational Fluid Dynamics / Finite Element Method

## ❖ Research Directions in Surrogate Modeling


- Surrogate modeling 목표는 시뮬레이션 결과를 정확하고 빠르게 예측하는 것
- 이를 위해 어떤 조건에서 데이터를 생성할지, 어떤 해상도로 계산할지, 어떤 모델 구조를 사용할지 함께 고려함
  - 어떤 조건에서 데이터를 생성할 것인가? (Sequential sampling / DoE)
  - 어디를 더 정밀하게 계산할 것인가? (Adaptive mesh refinement)
  - 어떤 모델 구조를 사용할 것인가? (Neural operators, MoE, Foundation models)



Data sampling strategy



Adaptive mesh refinement



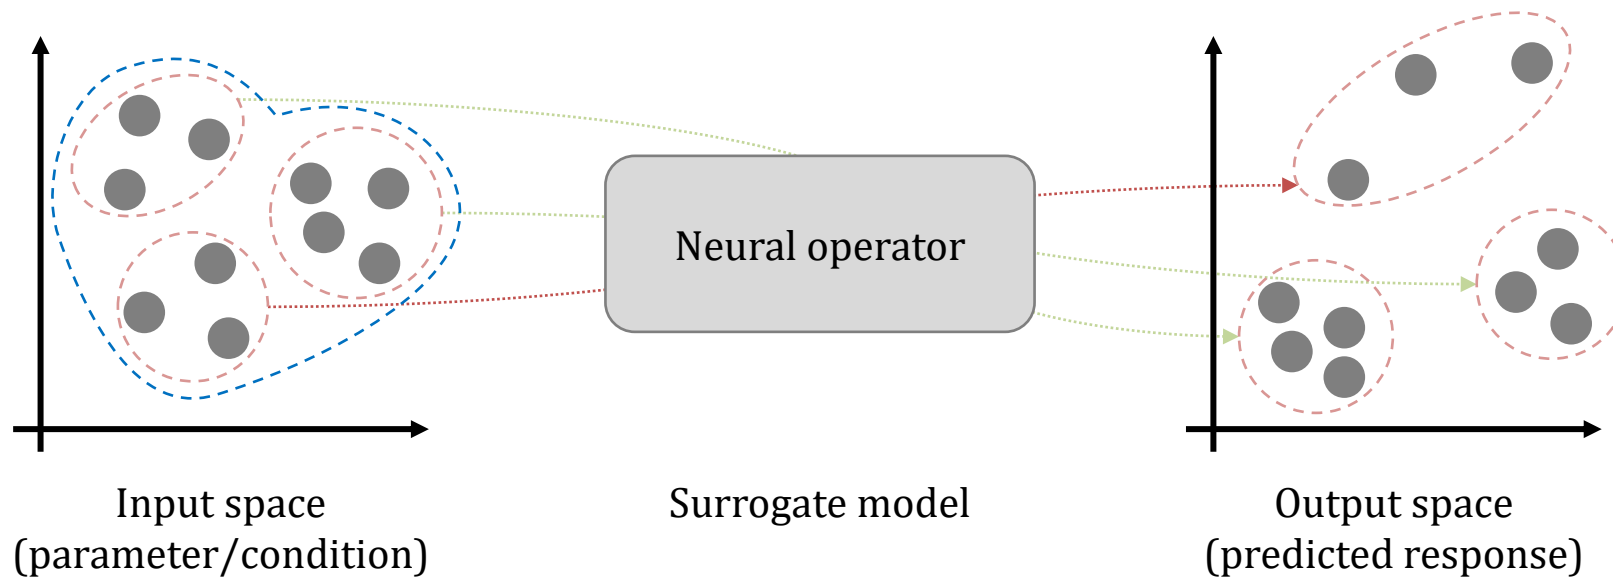
Model architecture design (MoE)

# Surrogate Modeling

## Data Sampling Strategy

### ❖ Thompson Sampling in Function Spaces via Neural Operators: NeurIPS (2025)

- CFD, FEM, climate simulation과 같은 고정밀 시뮬레이션은 한 번 수행하는 데 많은 시간이 필요함
- 따라서 가능한 모든 조건을 계산하는 대신, 가장 informative한 조건을 선택하여 데이터를 생성함
- Thompson sampling은 현재 surrogate가 가장 유망하다고 판단하는 조건을 선택하여 exploration과 exploitation을 동시에 수행함




# Surrogate Modeling

## Data Sampling Strategy

### ❖ Thompson Sampling in Function Spaces via Neural Operators

- CFD, FEM, climate simulation과 같은 고정밀 시뮬레이션은 한 번 수행하는 데 많은 시간이 필요함
- 따라서 가능한 모든 조건을 계산하는 대신, 가장 informative한 조건을 선택하여 데이터를 생성함
- Thompson sampling은 현재 surrogate가 가장 유망하다고 판단하는 조건을 선택하여 exploration과 exploitation을 동시에 수행함

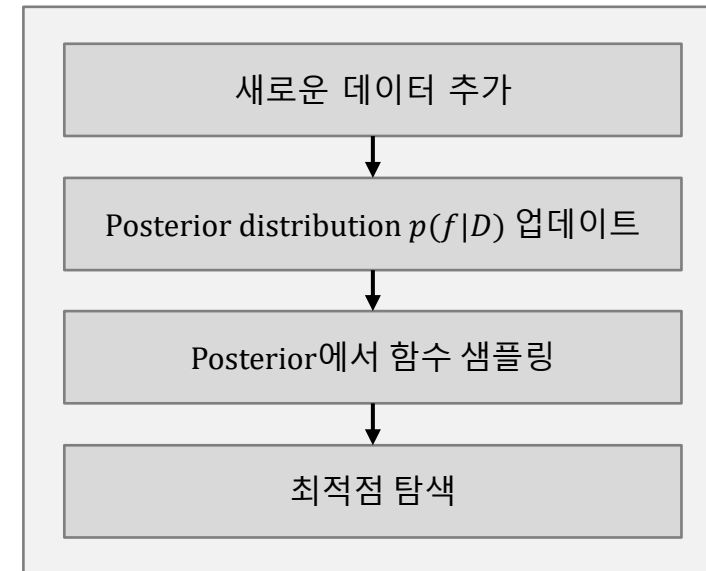



# Surrogate Modeling

## Data Sampling Strategy

### ❖ Thompson Sampling in Function Spaces via Neural Operators

- 기존 Gaussian process 기반 Thompson sampling
  - 관측 데이터를 이용하여 가능한 함수들의 posterior distribution을 추정
  - Posterior에서 하나의 함수를 샘플링하고, 그 함수가 가장 좋은 값을 가지는 입력 조건을 선택



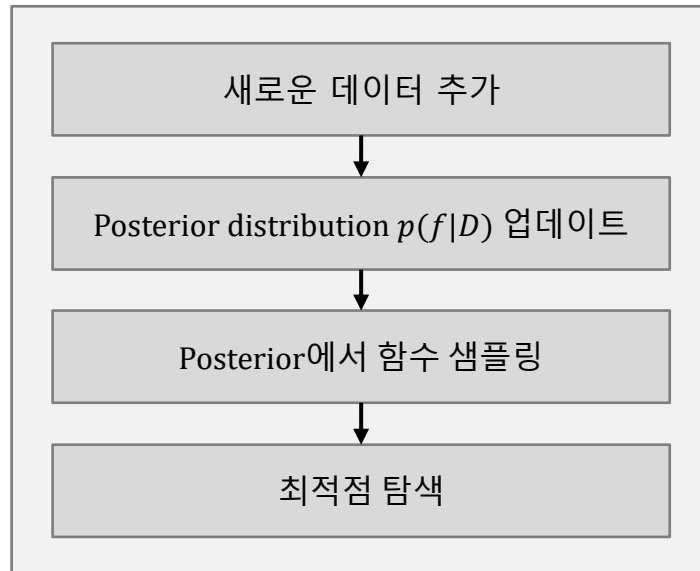
기존 방식  
(Gaussian process)

# Surrogate Modeling

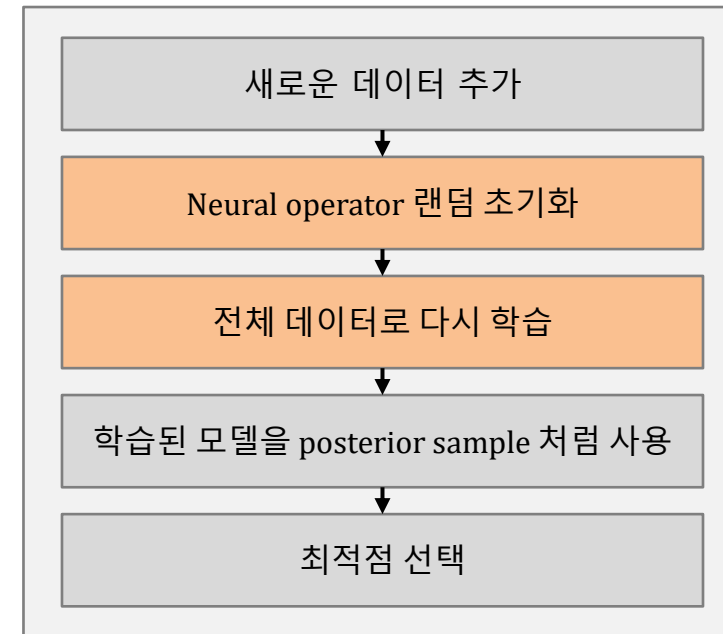
## Data Sampling Strategy

### ❖ Thompson Sampling in Function Spaces via Neural Operators

- Neural Operator Thompson Sampling(NOTS)
  - Gaussian process의 posterior distribution을 직접 계산하는 대신, neural operator를 랜덤 초기화한 뒤 현재까지의 데이터로 다시 학습
  - 학습된 neural operator 하나를 posterior sample의 근사로 활용하여 해당 operator의 arg max 조건을 기반으로 새로운 simulation 수행



기존 방식  
(Gaussian process)




제안 방식  
(NOTS)

# Surrogate Modeling

## Adaptive Discretization

### ❖ Learning Mesh-Based Simulation with Graph Networks: ICLR(2021, sites: 1706)

- CFD/FEM에서는 전체 영역을 고해상도로 계산하면 계산 비용이 급격히 증가
- 따라서 변화가 큰 영역이나 물리적으로 중요한 영역에 mesh를 더 조밀하게 배치
- Adaptive mesh refinement(AMR)는 동일한 계산 예산에서 더 높은 정확도를 얻기 위한 전략

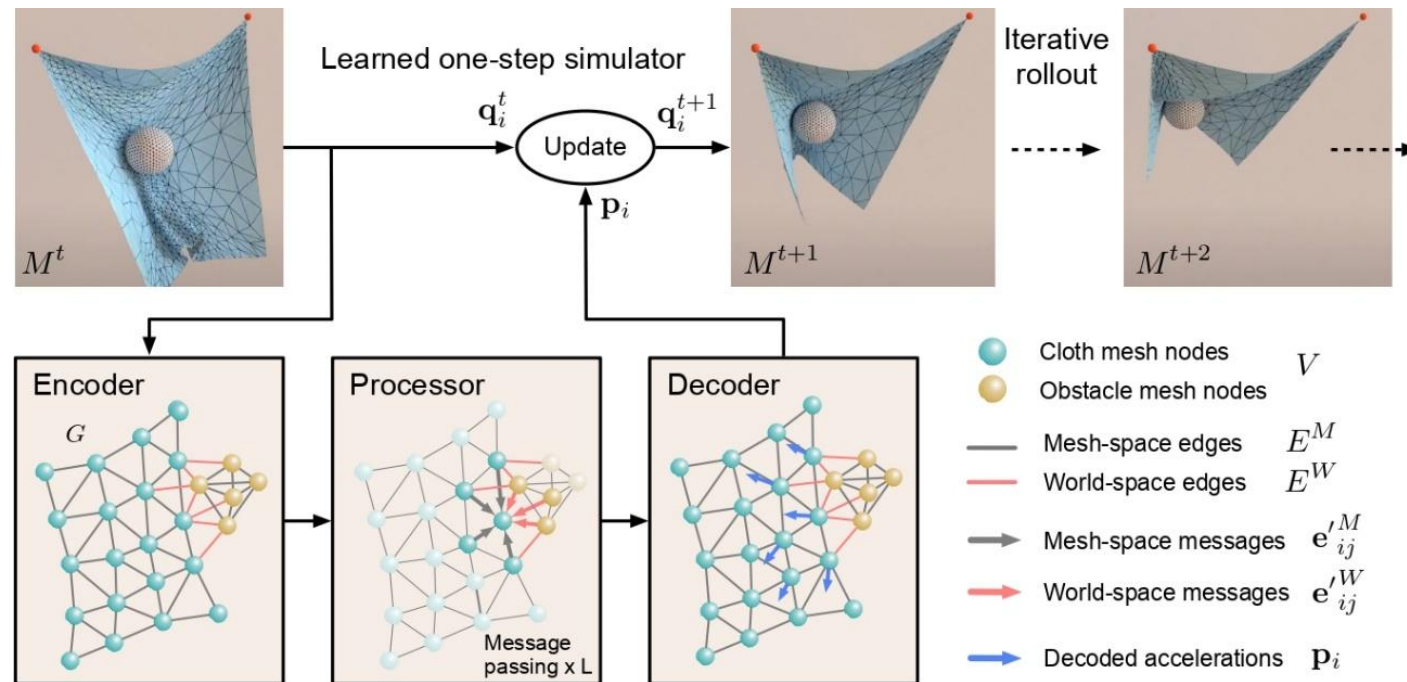


# Surrogate Modeling

## Adaptive Discretization

### ❖ Learning Mesh-Based Simulation with Graph Networks

- Mesh의 node와 edge를 그래프로 표현하고, 각 node의 위치·속도·물리량을 입력으로 사용하여 latent representation으로 변환
- Processor에서 message passing을 반복 수행하여 인접 node 간의 물리적 상호작용을 계산하고 시스템의 동역학 정보를 통합함
- Decoder가 각 node의 acceleration 또는 state update를 예측하고, 이를 적용하여 다음 time step의 mesh state를 생성함

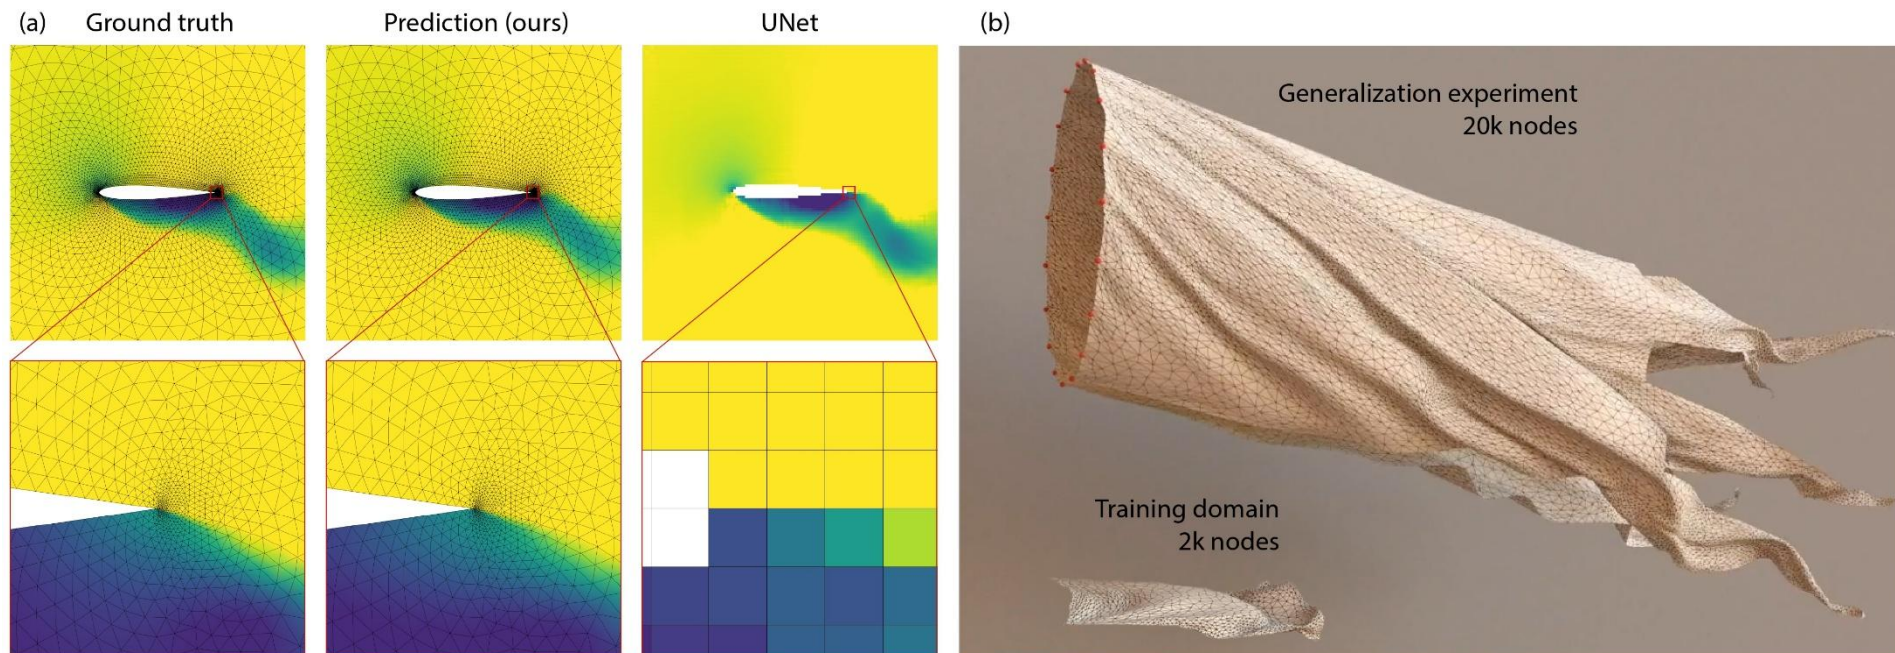


# Surrogate Modeling

## Adaptive Discretization

### ❖ Learning Mesh-Based Simulation with Graph Networks

- Ground truth는 고정밀 CFD 시뮬레이터가 계산한 해이며, 예측 결과를 비교하기 위한 기준으로 사용됨
- 제안모델은 irregular triangular mesh를 직접 처리할 수 있어 wake region과 같은 복잡한 유동 구조를 보다 정밀하게 예측함
- 낮은 해상도로 학습한 모델을 더 높은 해상도에도 그대로 적용할 수 있어, 서로 다른 해상도에 대해 우수한 일반화 성능을 보임

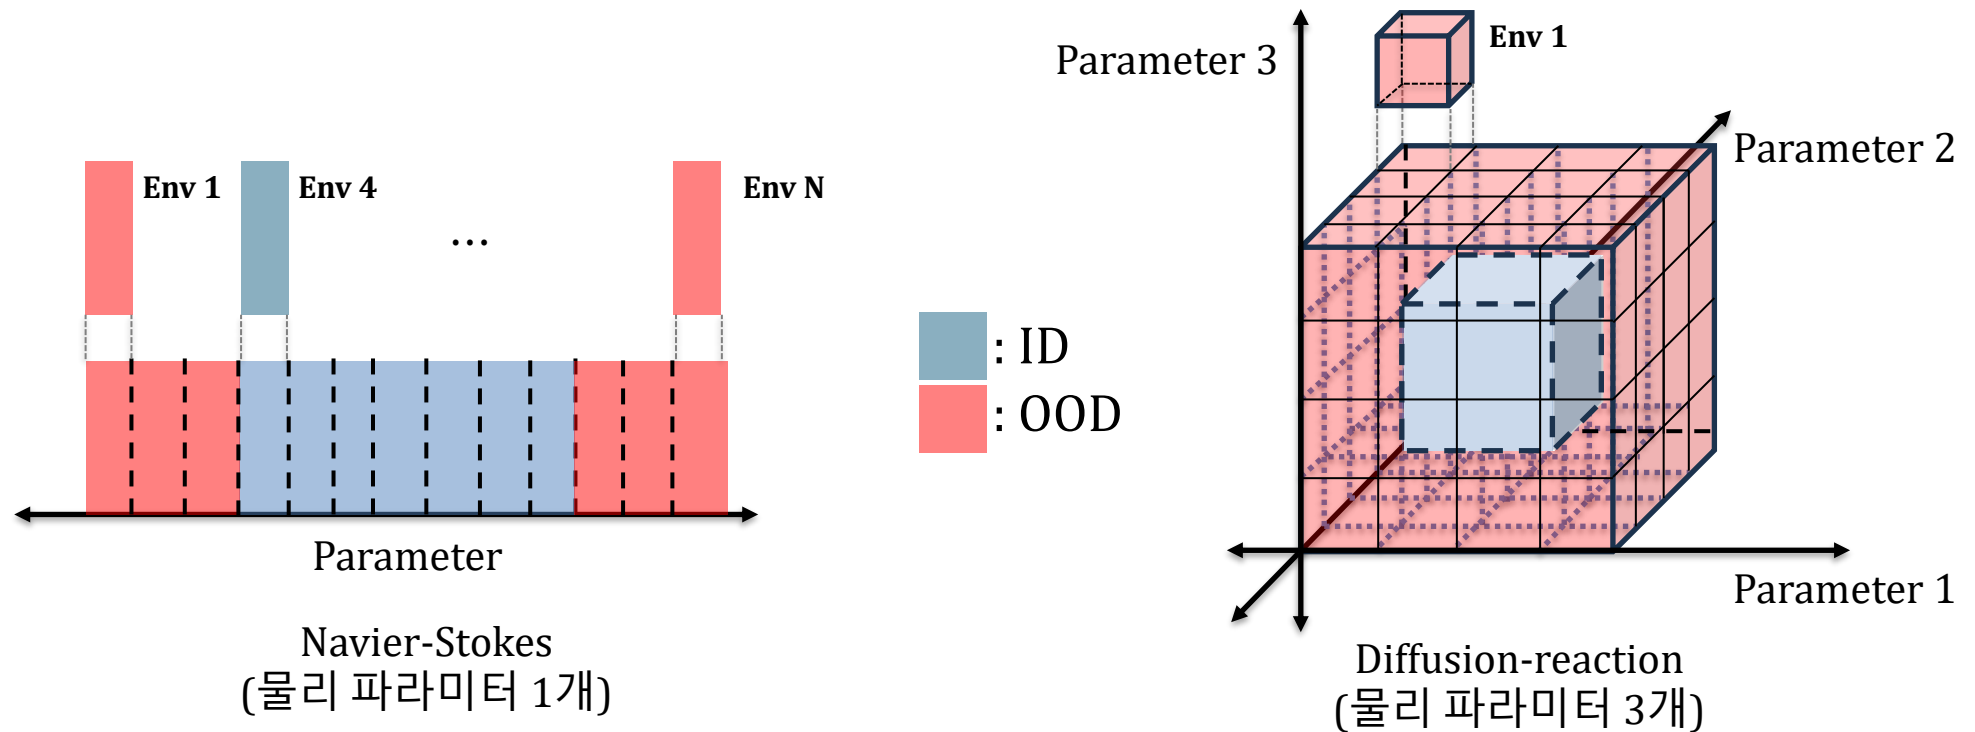


# Surrogate Modeling

## Model Architecture Design

### ❖ Towards Generalizable PDE Dynamics Forecasting Via Physics-Guided Invariant Learning: ICLR (2026, sites: 2)

- PDE surrogate modeling에서는 물리 파라미터 조합에 따라 서로 다른 동역학 환경이 형성
- 학습 중 보지 못한 새로운 parameter 조합(OOD)에서 생성된 데이터에 대한 예측 오차가 크게 증가할 수 있음

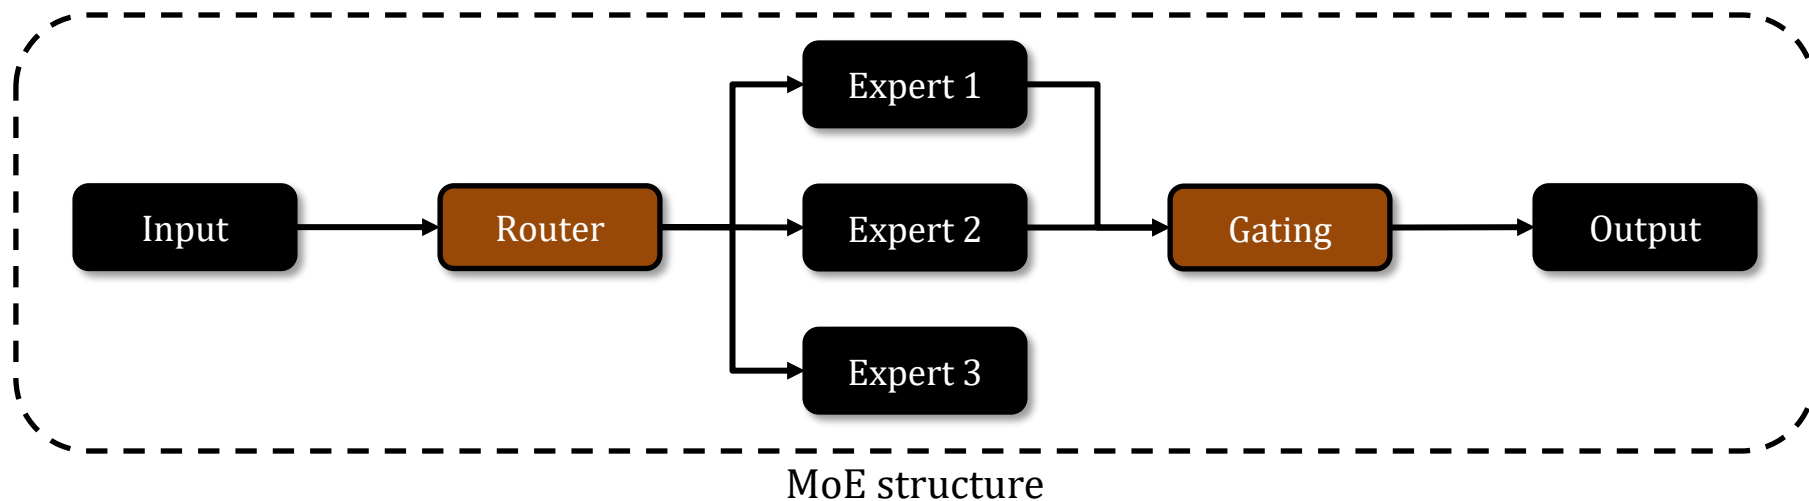


# Surrogate Modeling

## Model Architecture Design

### ❖ Towards Generalizable PDE Dynamics Forecasting Via Physics-Guided Invariant Learning

- MoE(mixture-of-experts)는 여러 expert model을 두고, 입력 조건이나 상황에 따라 일부 expert를 선택하거나 가중 결합하여 예측
- 일반적으로 expert는 서로 다른 데이터 분포, task, modality에 특화되도록 설계
- 해당 논문에서는 동일한 PDE stage를 서로 다른 물리 관점으로 변환하여 expert에 입력
  - State view:  $u$
  - Gradient view:  $\nabla u$
  - Diffusion / Curvature view:  $\nabla^2 u$

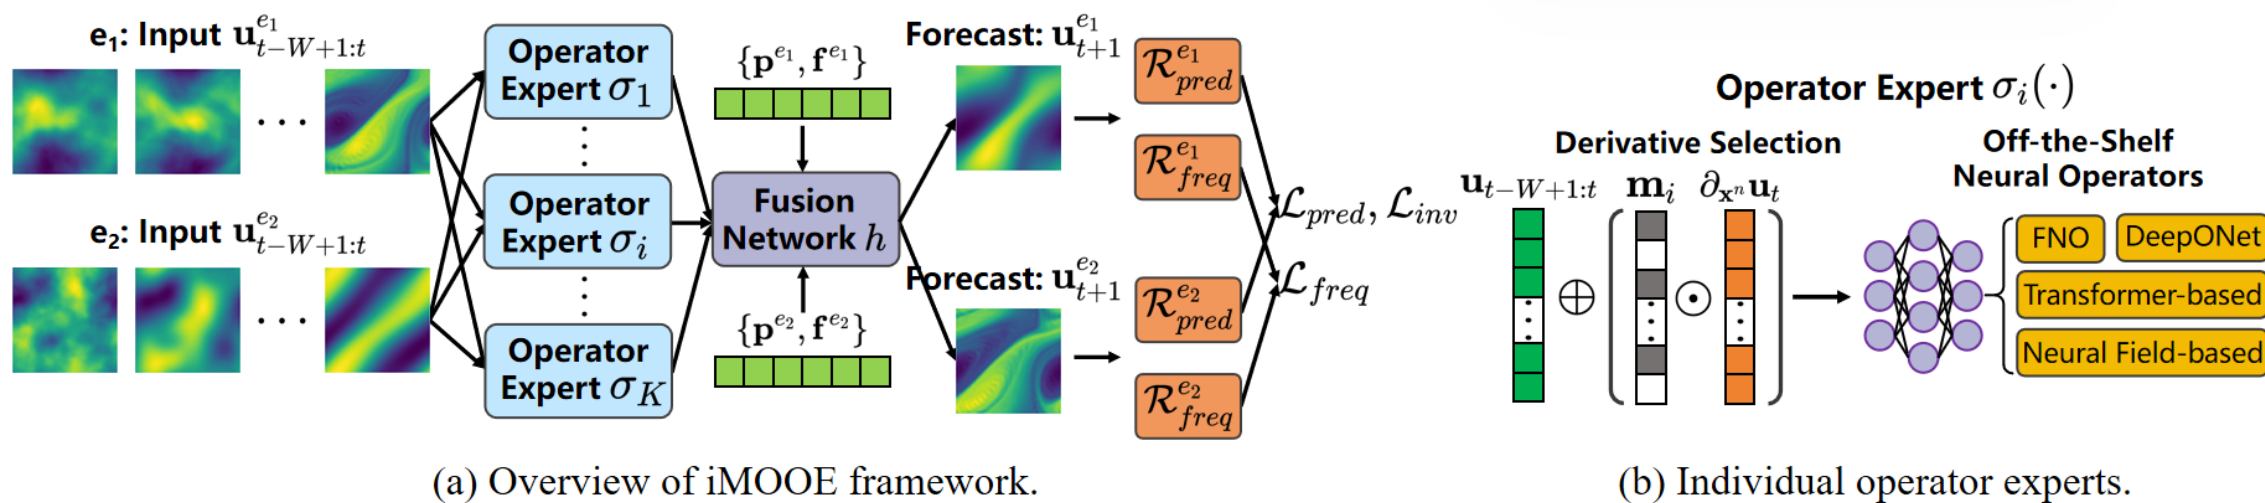


# Surrogate Modeling

## Model Architecture Design

### ❖ Towards Generalizable PDE Dynamics Forecasting Via Physics-Guided Invariant Learning

- 각 물리 파라미터 조합은 서로 다른 environment(domain)으로 간주됨
- Domain generalization은 모든 environment에서 공통적으로 유지되는 invariant pattern을 학습하는 것을 목표로 함
- V-REx는 environment별 loss의 분산을 최소화하여 특정 domain에 과적합되는 것을 방지함



(a) Overview of iMOOE framework.

(b) Individual operator experts.

# Surrogate Modeling

## Model Architecture Design

### ❖ Towards Generalizable PDE Dynamics Forecasting Via Physics-Guided Invariant Learning

- 각 물리 파라미터 조합은 서로 다른 environment(domain)으로 간주됨
- Domain generalization은 모든 environment에서 공통적으로 유지되는 invariant pattern을 학습하는 것을 목표로 함
- V-REx는 environment별 loss의 분산을 최소화하여 특정 domain에 과적합되는 것을 방지함

Operator compatibility study on DR data with various OOD contexts

Operators	Variants	Env1	Env2	Env3	Env4	Env5
FNO	Naive	6.78e-2	8.80e-2	6.70e-2	6.00e-2	3.14e-2
	+MOOE	3.40e-2	6.00e-2	3.88e-2	3.28e-2	1.88e-2
	+iMOOE	3.19e-2	5.20e-2	3.12e-2	3.05e-2	1.41e-2
Operators	Variants	Env6	Env7	Env8	Mean	Std
FNO	Naive	6.77e-2	7.47e-2	5.31e-2	5.75e-2	1.01e-2
	+MOOE	4.78e-2	6.60e-2	5.03e-2	4.96e-2	7.12e-3
	+iMOOE	3.47e-2	3.65e-2	5.09e-2	<b>4.34e-2</b>	<b>6.18e-3</b>

OOD forecasting results on irregular spatial domains

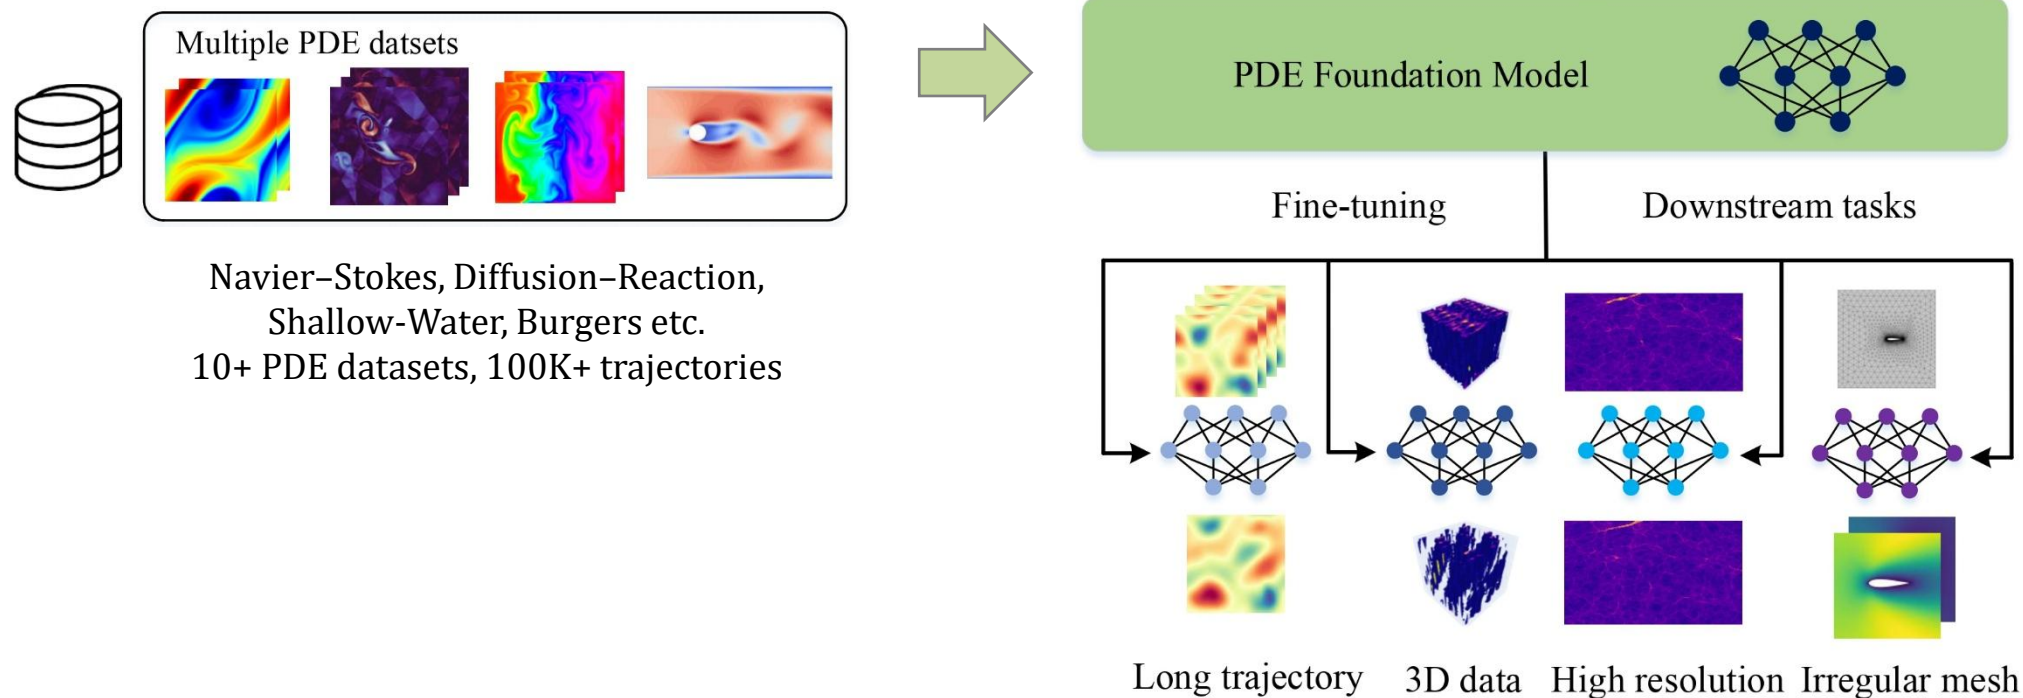
Operators	Variants	nMSE	RMSE
VCNeF	Naive	$5.45 \times 10^{-2}$	$2.22 \times 10^{-1}$
	+iMOOE	<b><math>5.08 \times 10^{-2}</math></b>	<b><math>1.98 \times 10^{-1}</math></b>
Geo-FNO	Naive	$5.15 \times 10^{-2}$	$2.16 \times 10^{-1}$
	+iMOOE	<b><math>4.35 \times 10^{-2}</math></b>	<b><math>1.88 \times 10^{-1}</math></b>
OFormer	Naive	$4.95 \times 10^{-2}$	$2.04 \times 10^{-1}$
	+iMOOE	<b><math>4.14 \times 10^{-2}</math></b>	<b><math>1.79 \times 10^{-1}</math></b>

# Surrogate Modeling

## Model Architecture Design

### ❖ DPOT: Auto-Regressive Denoising Operator Transformer for Large-Scale PDE Pre-Training: ICML (2024, sites:132)

- 다양한 PDE 데이터를 통합하여 하나의 PDE foundation model을 대규모로 사전 학습함
- 사전학습된 모델은 fine-tuning을 통해 long trajectory, 3D data, high resolution, irregular mesh 등 다양한 downstream PDE 문제 적용



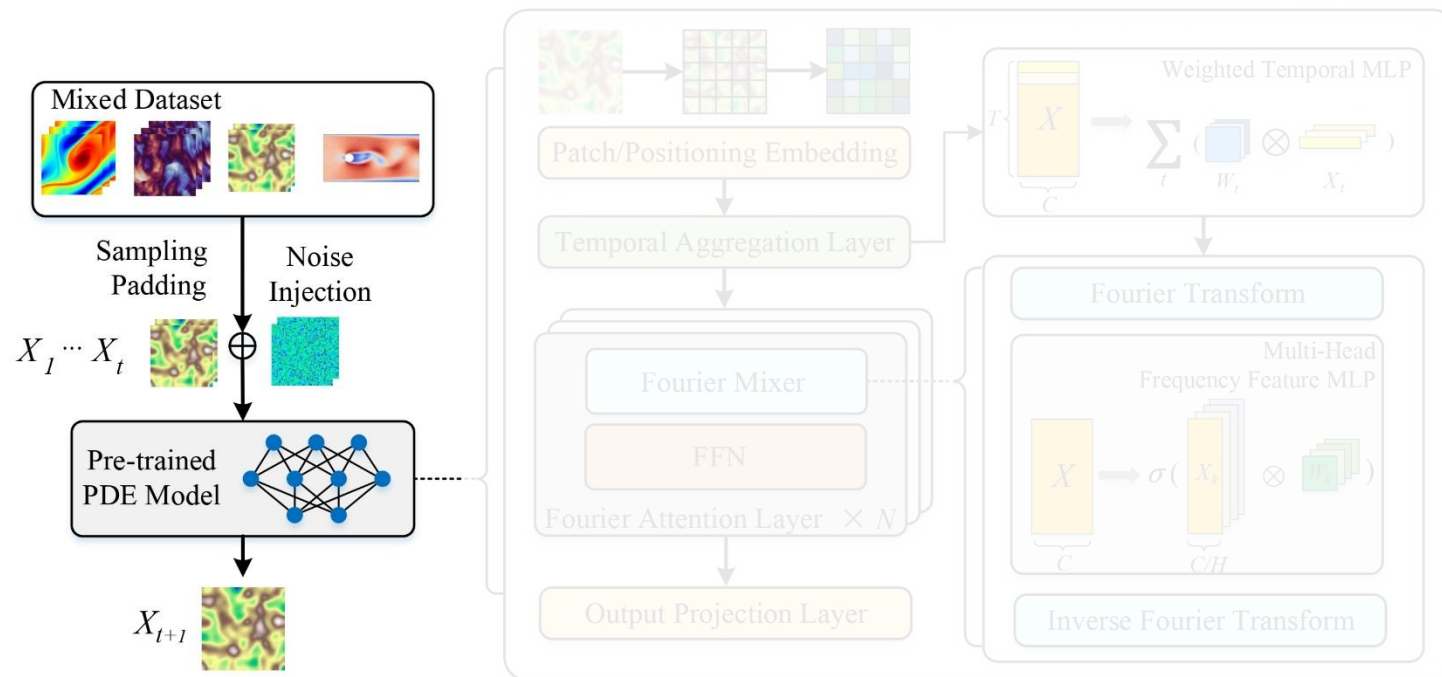
# Surrogate Modeling

## Model Architecture Design

### ❖ DPOT: Auto-Regressive Denoising Operator Transformer for Large-Scale PDE Pre-Training

- Noise Injection and Denoising Training

- 현재 상태  $X_t$ 에 Gaussian noise를 추가하여 corrupted input을 생성 이후, 모델은 noisy input으로부터 다음 시점  $X_{t+1}$ 을 예측함
- 다양한 오차 상황을 학습하여 장기 rollout의 안정성을 향상함

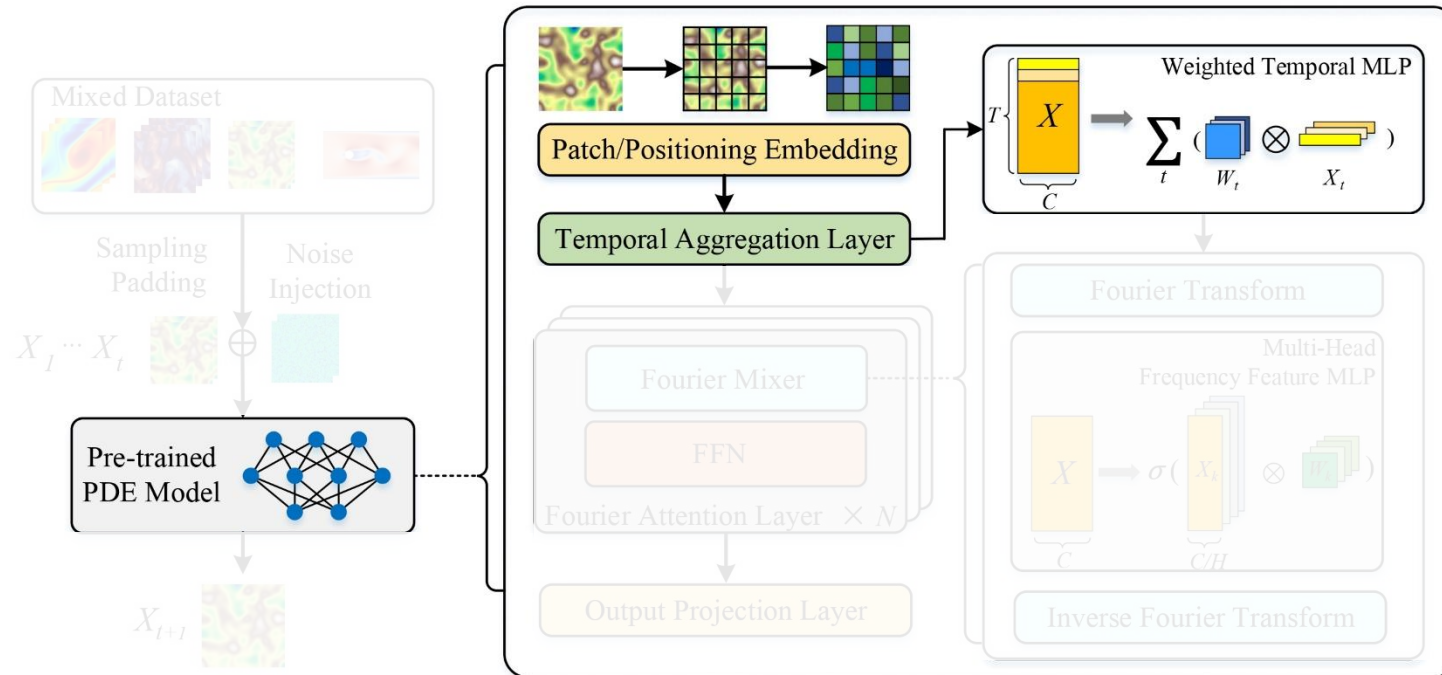


# Surrogate Modeling

## Model Architecture Design

### ❖ DPOT: Auto-Regressive Denoising Operator Transformer for Large-Scale PDE Pre-Training

- Temporal Aggregation Layer
  - 입력 sequence의 각 time step을 patch embedding으로 변환함
  - 학습 가능한 weight를 이용해 시간 정보를 통합 → 더 중요한 시점에 더 큰 가중치

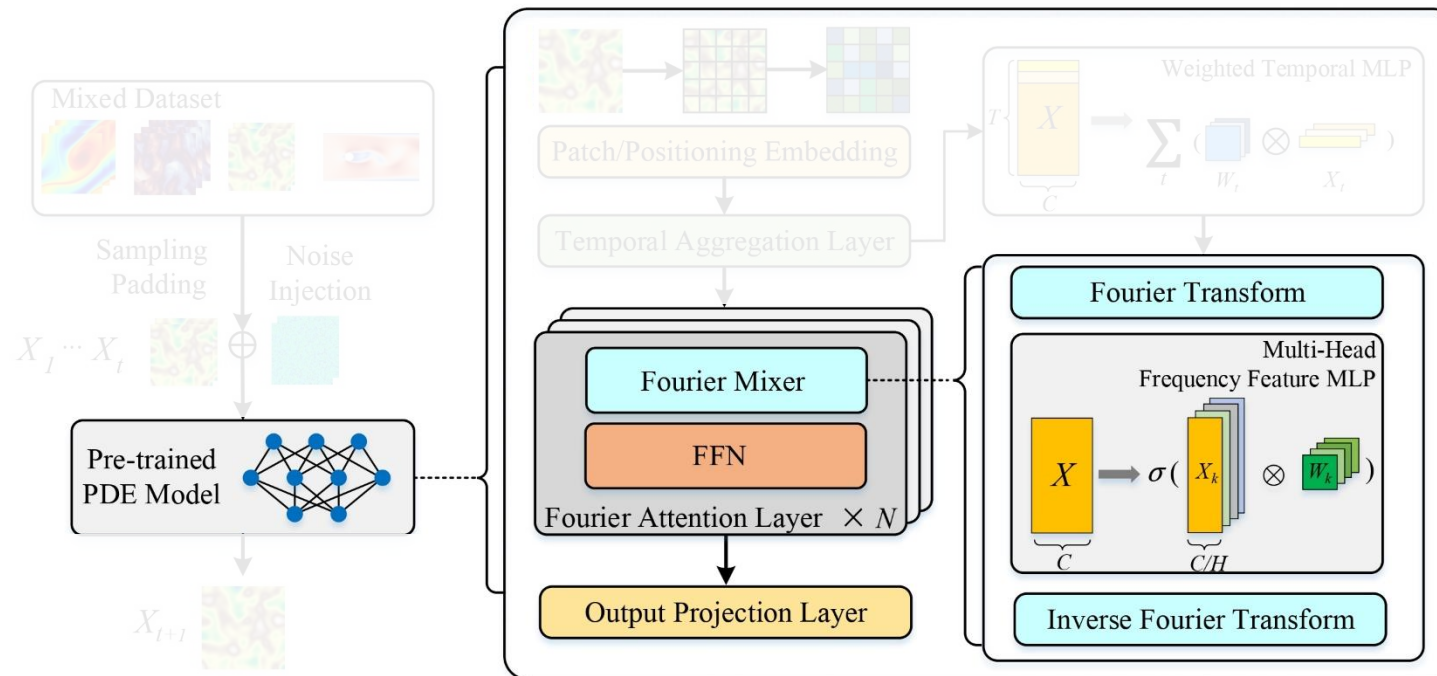


# Surrogate Modeling

## Model Architecture Design

### ❖ DPOT: Auto-Regressive Denoising Operator Transformer for Large-Scale PDE Pre-Training

- Fourier Mixer / Fourier Attention
  - 주파수 변환을 통해 spatial field를 frequency domain으로 변환하고, 각 frequency band에 대해 learnable weighting multi-scale spatial pattern 학습
  - Inverse Fourier transform과 output projection을 통해 처리된 주파수 정보를 다시 공간 영역으로 변환하여 다음 PDE state를 생성함



# Conclusion

- Physics-based simulation은 높은 정확도를 제공하지만 반복 계산으로 인해 계산 비용이 매우 큼
- 이를 대체하기 위해 simulation 결과를 빠르게 근사하는 surrogate model 개념이 등장함
- 순수 data-driven surrogate model은 물리 법칙을 충분히 반영하지 못해 물리적으로 일관되지 않은 결과를 생성할 수 있음
- PINN은 PDE residual, 초기조건, 경계조건을 loss에 직접 반영하여 물리 법칙을 만족하도록 학습함
- PGNN은 물리 모델과 데이터를 보다 유연하게 결합하여, 불완전한 물리식이나 관측 노이즈가 존재하는 상황에도 적용 가능함
- 다양한 초기/경계조건, 물리 파라미터가 함께 작용하는 복잡한 시스템을 효율적으로 반영할 수 있는 보다 일반적인 모델이 필요함
- Neural operator는 다양한 조건에 대한 solution mapping을 학습하여 surrogate model을 구축함
- 최근에는 DoE, Foundation Models, Mixture of Experts, Reinforcement Learning과 결합되어 발전

# Thank you