

Estimation of Xenon Oscillation with Physics-informed Neural Network

2022.10.20

발표자 : 경희대학교 임준석

저자 : 경희대학교 임준석, 허균영

00 ABOUT SPEAKER

- 이름 : 임준석
- 소속 : 경희대학교 원자력공학과 석사 2기
- 연구 분야 : PINN을 이용한 원자력발전소 이상상태 진단
- email address : 2016101043@khu.ac.kr



00 CONTENTS

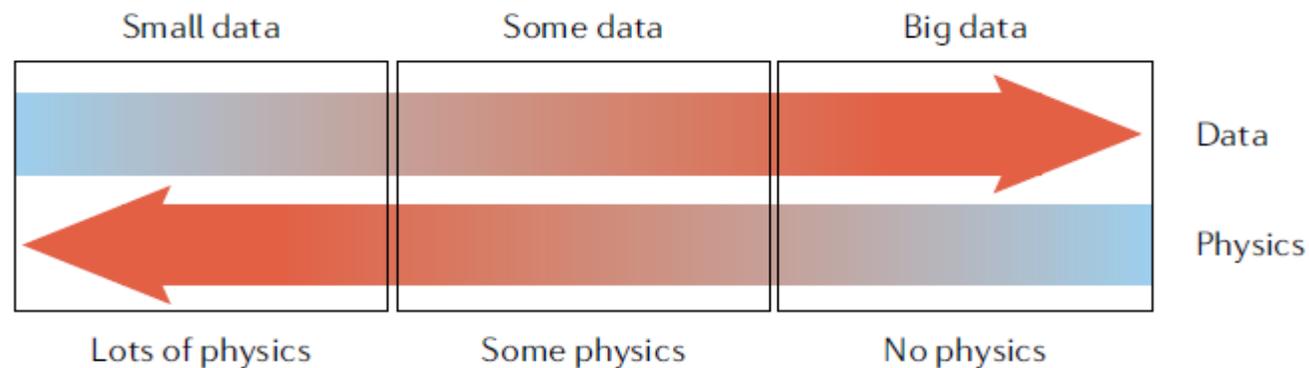
- Purpose
- About PINN
- About Xenon-135
- How to apply PINN to Xenon Oscillation
- Result
- Conclusions
- Q&A

01 PURPOSE

■ 연구 목적

- 과제명 : 원자력 비상대응 전략 시뮬레이션을 위한 행위자기반 플랫폼과 학습기반 최적화 방법 개발 연구
- 방사능 확산 및 주민 소개에 PINN 적용을 검토 중.
- PINN에 대한 이론 및 기술들을 획득 필요.
- 이번 연구는 위의 목적을 달성하기 위한 예시로 수행.

- 기존의 수치적 방법(유한 차분, 유한 요소, ...)
- 현실적인 문제를 풀려고 할수록 기하급수적으로 비용이 증가.
 - ✓ mesh 개수 증가.
 - ✓ 변수 개수 증가.
- 머신러닝
 - 데이터를 기반으로 하여 비교적 낮은 비용으로 방대한 공간을 탐색 가능.
 - ✓ 여러 사진들의 패턴을 학습.
 - 하지만 잘못된 일반화, 관찰 편향 등으로 인해 물리적으로 잘못된 예측을 할 가능성 있음.



■ PINN

- 2017년 Raissi, M. et.al 이 개발.
- 물리 법칙과 기존 데이터를 통합할 수 있는 신경망.
- 물리 법칙에 위배되는 솔루션은 즉각 폐기시키므로 hidden layer 개수, node 개수가 많지 않아도 충분.

■ 단점

- Multiscale, Multiphysics 문제를 한번에 풀 수 없음.
- 여러 항들을 갖는 손실함수는 non-convex인 경우가 많아 결론적으로 global minimum을 찾기 어려움.
- PINN은 경험적으로 성공했지만 그것의 능력과 한계가 이론적으로 엄밀히 증명되지 않았음.

- 활용사례 in 원자력
 - System Reliability Assessment
 - ✓ Zhou, T., Droguett, E. L., & Mosleh, A. (2021). Physics-Informed Deep Learning: A Promising Technique for System Reliability Assessment. arXiv preprint arXiv:2108.10828.
 - ✓ FT 정량화에 PINN을 적용하여 Top event 확률 계산.
 - Point Kinetics equation
 - ✓ Schiassi, E., De Florio, M., Ganapol, B. D., Picca, P., & Furfaro, R. (2022). Physics-informed neural networks for the point kinetics equations for nuclear reactor dynamics. Annals of Nuclear Energy, 167, 108833.
 - ✓ Temperature Feedback이 있을 경우 PKE를 PINN에 기반한 프레임워크로 솔루션 도출.
 - Radioactive Material Diffusion
 - ✓ Kim, G., & Heo, G. Radioactive Material Dispersion Modeling using Physics Informed Neural Network. KNS 2020.
 - ✓ Air Dispersion Equation을 가정 없이 풀기 위해 PINN을 활용.
 - etc.

- 물리 법칙

- 일반적인 미분방정식, $f = 0$
- $f = u(x, t) + N_x[u] = 0, x \in \Omega, t \in [0, T]$
 - ✓ $u(x, t)$: Latent (hidden) solution
 - ✓ $N_x[u]$: Nonlinear differential operator
 - ✓ Ω : x 범위 (파이프 길이, 직경 등)
 - ✓ $[0, T]$: 시간 범위
- 초기, 경계 조건
 - ✓ $f(x, 0) = 1$
 - ✓ $f(\infty, t) = 0$
 - ✓ etc.

- 이 논문의 물리 법칙

- $$f = \begin{cases} \frac{dI}{dt} - (\gamma_I \Sigma_f \phi_T - \lambda_I I) \\ \frac{dX}{dt} - (\gamma_X \Sigma_f \phi_T + \lambda_I I - \sigma_{a2}^X \phi_T X - \lambda_X X) \end{cases}$$

- 초기조건

- $I(0) = 10^{15} \text{ #/cm}^3, X(0) = 10^{14} \text{ #/cm}^3$

Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational physics*, 378, 686-707.



- Total loss function, L_{MSE}
 - $L_{MSE} = L_{MSE}^u + W \cdot L_{MSE}^f$, where, W is weight of L_{MSE}^f
- Loss function about initial or boundary condition, L_{MSE}^u
 - $L_{MSE}^u = \frac{1}{N_u} \sum_{i=1}^{N_u} [u_{NN}(t_u^i, x_u^i; \theta) - u^i]^2$
 - ✓ N_u : $u(x, t)$ 에 의해 생성된 point의 개수
 - ✓ $u_{NN}(t_u^i, x_u^i; \theta)$: 각 point(초기, 경계 조건)에 대해서 신경망이 예측한 값
 - ✓ u^i : 각 point(초기, 경계 조건)에 대한 참값
- Loss function about differential equation, L_{MSE}^f >> 물리법칙이 적용되는 부분
 - $L_{MSE}^f = \frac{1}{N_f} \sum_{i=1}^{N_f} [f(t_f^i, x_f^i)]^2 = \frac{1}{N_f} \sum_{i=1}^{N_f} [f(t_f^i, x_f^i) - 0]^2$
 - ✓ N_f : $f(t_f^i, x_f^i)$ 에 의해 생성된 point의 개수
 - ✓ $f(t_f^i, x_f^i)$: 각 point에 대해서 신경망이 예측한 값
 - ✓ 0 : 각 point에 대한 참값

Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational physics*, 378, 686-707.



■ 열전도 방정식

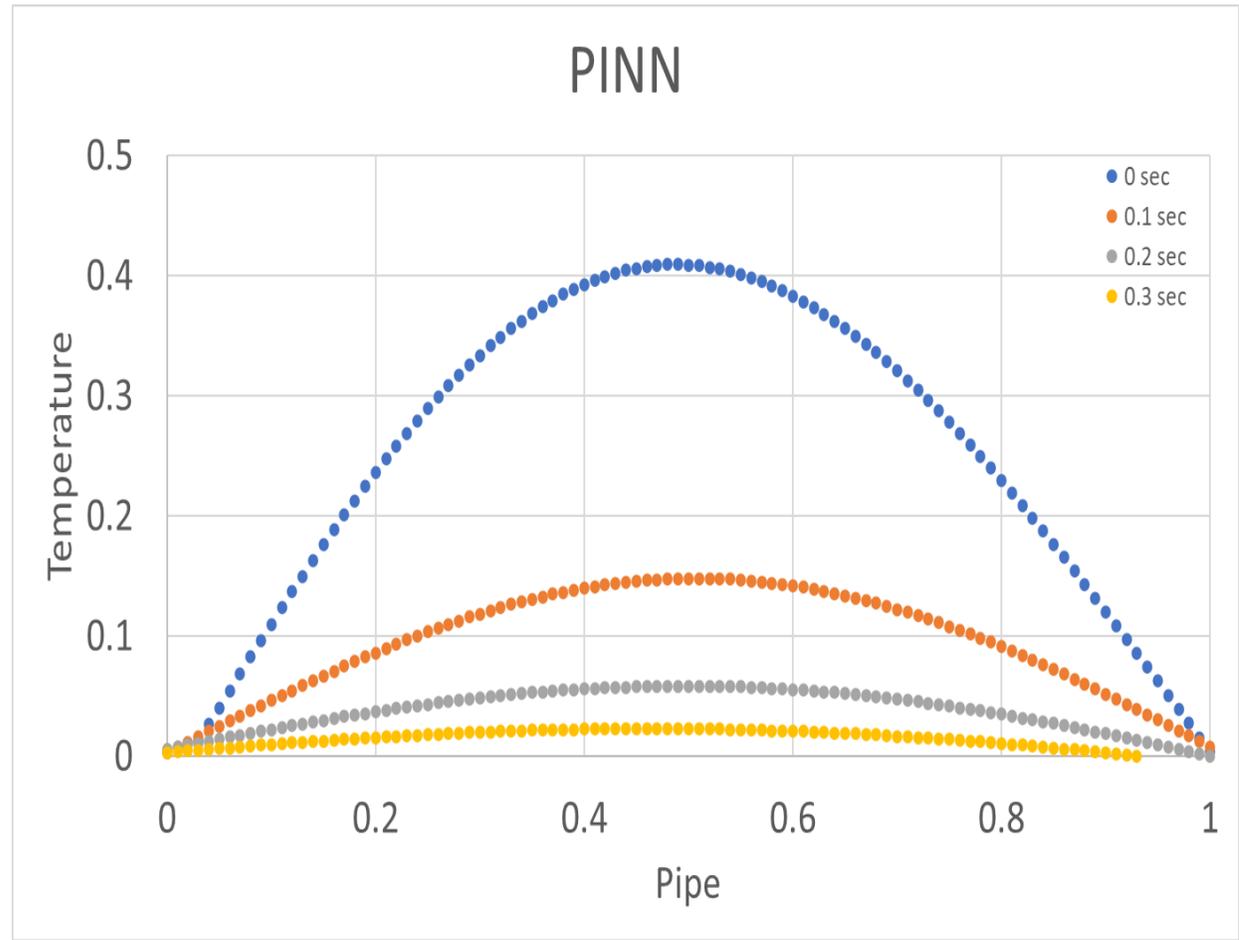
- $\frac{\partial u}{\partial t} = \alpha \frac{\partial^2 y}{\partial x^2}$, $\alpha = 1, L = 1$ 인 경우.

- 초기조건

$$\checkmark u(x, 0) = \begin{cases} x, & 0 < x < 0.5 \\ 1 - x, & 0.5 \leq x < 1 \end{cases}$$

- 경계조건

$$\checkmark u(0, t) = u(1, t) = 0$$



```

def physics_net(self, xt):
    x = xt[:, 0:1]
    t = xt[:, 1:2]

    with tf.GradientTape(persistent=True) as tape:
        tape.watch(t)
        tape.watch(x)
        xt_t = tf.concat([x,t], axis=1)
        u = self.nn(xt_t)
        u_x = tape.gradient(u, x)
        u_xx = tape.gradient(u_x, x)
        u_t = tape.gradient(u, t)
    del tape

    return u_t - u_xx

```

미분 term

물리법칙, $f = 0$

```

def learn(self, xt_col, xt_bnd, tu_bnd):
    with tf.GradientTape() as tape:
        f = self.physics_net(xt_col)
        loss_col = tf.reduce_mean(tf.square(f))
        tu_bnd_hat = self.nn(xt_bnd)
        loss_bnd = tf.reduce_mean(tf.square(tu_bnd_hat - tu_bnd))
        loss = loss_col + loss_bnd
    grads = tape.gradient(loss, self.nn.trainable_variables)
    self.opt.apply_gradients(zip(grads, self.nn.trainable_variables))

    return loss

```

$$L_{MSE}^f = \frac{1}{N_f} \sum_{i=1}^{N_f} [f(t_f^i)]^2$$

$$L_{MSE}^u = \frac{1}{N_u} \sum_{i=1}^{N_u} [u_{NN}(t_u^i; \theta) - u^i]^2$$

$$L_{MSE} = L_{MSE}^u + W \cdot L_{MSE}^f$$

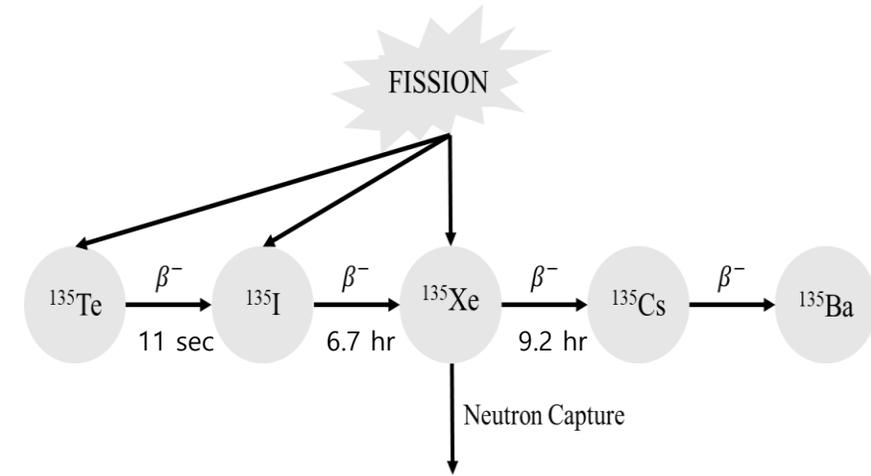
- Xenon-135 (^{135}Xe)
 - 원자로에 대표적인 **독 물질** 중 하나로서 큰 열중성자 흡수 단면적을 가지고 있음.
 - 이 때문에 원자로 운전, 정지 상태 모두 악영향을 끼침.
 - 증배계수 (K_{eff})가 1을 유지하기 어렵게 만들.
 - 원자로 정지 후 재가동 시, 누적된 ^{135}Xe 때문에 제어봉의 반응도보다 더 큰 부반응도가 생겨 재가동을 하지 못하게 함. >> Reactor Dead Time
 - etc.

Production of Xenon-135

- ^{135}Xe 의 **생성 경로**는 두 가지로 ^{135}I 가 β 붕괴 또는 ^{235}U 의 핵분열임.
- 그러므로 ^{135}I 의 양 또한 파악해야 함.
- ^{135}I 의 **생성 경로**는 엄밀하게는 두 가지로 ^{135}Te 의 β 붕괴 또는 ^{235}U 의 핵분열임. 하지만 ^{135}Te 의 반감기가 매우 짧기 때문에 ^{235}U 의 핵분열만으로 생성된다고 해도 무방함.
- ^{135}I 의 **소멸 경로**는 한 가지로 β 붕괴임.

Destruction of Xenon-135

- ^{135}Xe 의 **소멸 경로**는 두 가지로 중성자를 흡수하거나 β 붕괴하는 경우임.



$$\begin{cases} \frac{dI}{dt} = \gamma_I \Sigma_f \phi_T - \lambda_I I \\ \frac{dX}{dt} = \gamma_X \Sigma_f \phi_T + \lambda_I I - \sigma_{a2}^X \phi_T X - \lambda_X X \end{cases}$$

04 HOW TO APPLY PINN TO XENON OSCILLATION

▪ INPUT

- t_u^i : 초기 조건 $I(0) = 10^{15} \text{ #/cm}^3, X(0) = 10^{14} \text{ #/cm}^3$ 의 input인 0을 입력.
- u^i : 초기 조건의 output인 $10^{15} \text{ #/cm}^3, 10^{14} \text{ #/cm}^3$ 을 입력.
- t_f^i : 0~400 hour 범위에서 한 iteration 마다 랜덤(uniform distribution)으로 10,000 개씩 입력.
- $\phi_T = \begin{cases} 10^{14} \text{ #/cm}^2 \cdot h & : t < 200h \\ 0.5 \times 10^{14} \text{ #/cm}^2 \cdot h & : t \geq 200h \end{cases}$ 을 적용하기 위해 t에 따라 ϕ_T 를 다르게 입력.
- 기타 상수들을 입력.

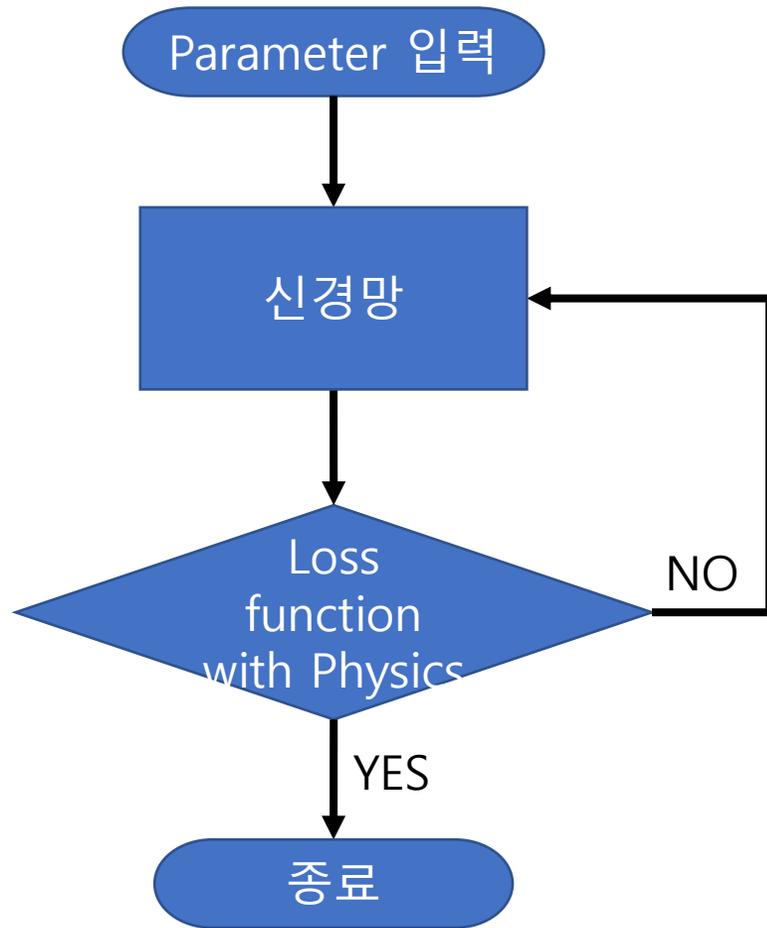
■ OUTPUT

- $u_{NN}(t_u^i; \theta)$: 각 point(초기, 경계 조건)에 대해서 신경망이 예측한 값
- $f(t_f^i)$: 각 point에 대해서 신경망이 예측한 값을 미분방정식에 대입한 값

$$\checkmark \begin{cases} \frac{dI}{dt} - (\gamma_I \Sigma_f \phi_T - \lambda_I I) \\ \frac{dX}{dt} - (\gamma_X \Sigma_f \phi_T + \lambda_I I - \sigma_{a2}^X \phi_T X - \lambda_X X) \end{cases}$$

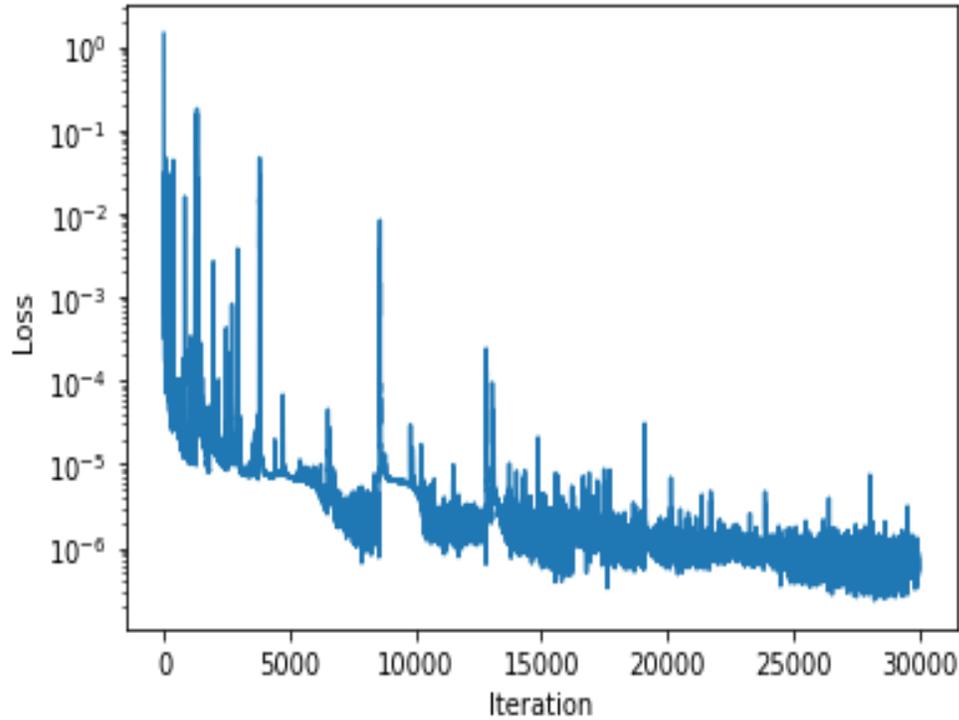
■ 신경망

- Hidden layer 4개로 구성되며 각 layer는 node 50개를 갖고 Activation function은 'ReLU' 사용.
- 30,000번 iteration
- ADAM optimizer

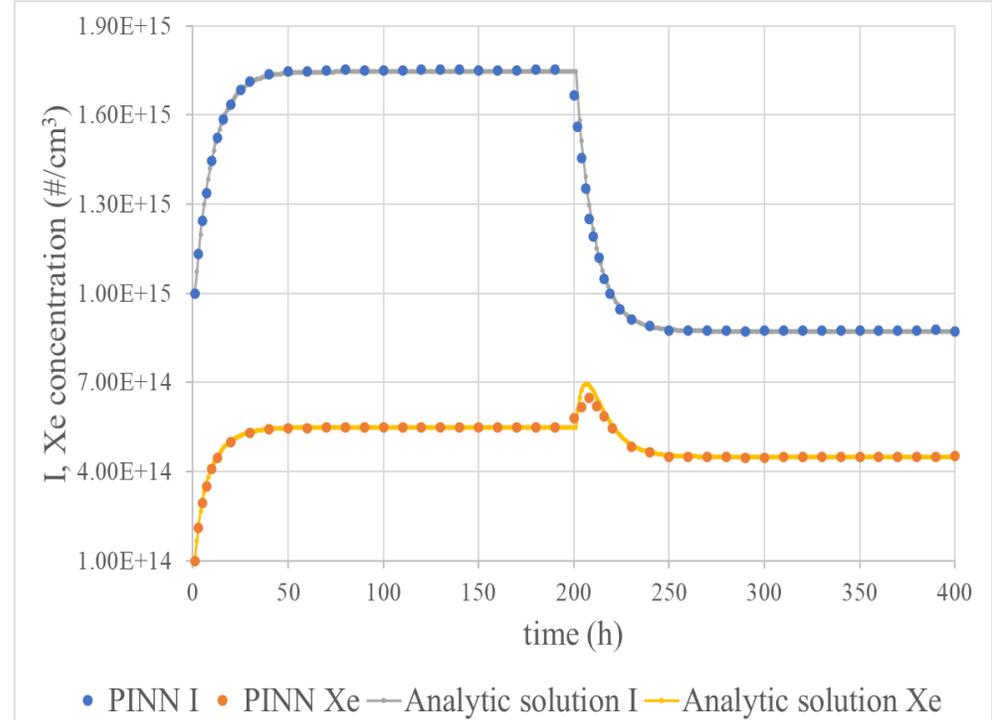


- Parameter 입력
 - 미분방정식 및 초기, 경계 조건 등을 입력.
- 신경망
 - 점점 Loss 값이 감소하는 방향 (optimizer)으로 예측 값을 도출.
- Loss function
 - 물리 법칙이 적용된 loss 값이 도출되고 이 수준이 사용자가 판단한 수준 이하라면 종료.

05 RESULT



- 30,000번 반복 후, Loss 값이 10^{-6} 수준으로 감소. Peak 또한 높이가 이전보다 감소.



- Analytic solution과 비교하였을 때, 출력이 변하는 상황에서도 비슷하게 예측.

06 CONCLUSIONS

- PINN을 Xe Oscillation 문제에 적용하여 PINN에 대한 기본적인 이론 및 적용 방법을 학습.
- PINN은 기존의 미분방정식 solver와 크게 다르지 않은 값을 예측함.
- 관측 데이터는 일종의 경계 조건이기 때문에 이는 경계 조건의 손실함수(L_{MSE}^u)에 추가할 수 있고 이를 통해 더 현실적인 문제를 해결할 수 있음.

- $L_{MSE}^u = \frac{1}{N_u} \sum_{i=1}^{N_u} [u_{NN}(t_u^i; \theta) - u^i]^2$ 에서 경계 조건의 input은 t_u^i , output은 u^i 에 입력

- EX) $I(100) = 50 \text{ \#/cm}^3, X(100) = 30 \text{ \#/cm}^3 \rightarrow t_u^i = \begin{bmatrix} 0 \\ 100 \end{bmatrix}, u^i = \begin{bmatrix} 10^{15} & 10^{14} \\ 50 & 30 \end{bmatrix}$

Q&A

감사합니다.