

# Text Diffusion Model

2025.10.30 (목)

홍성태

ghdchlwl123@korea.ac.kr

---

## Large Language Diffusion Models

---

Shen Nie<sup>1,2,3\*</sup>† Fengqi Zhu<sup>1,2,3\*</sup>† Zebin You<sup>1,2,3†</sup> Xiaolu Zhang<sup>4†</sup> Jingyang Ou<sup>1,2,3</sup>  
Jun Hu<sup>4†</sup> Jun Zhou<sup>4</sup> Yankai Lin<sup>1,2,3‡</sup> Ji-Rong Wen<sup>1,2,3</sup> Chongxuan Li<sup>1,2,3‡§</sup>

<sup>1</sup> Gaoling School of Artificial Intelligence, Renmin University of China

<sup>2</sup> Beijing Key Laboratory of Research on Large Models and Intelligent Governance

<sup>3</sup> Engineering Research Center of Next-Generation Intelligent Search and Recommendation, MOE

<sup>4</sup> Ant Group

{nieshen,fengqizhu,chongxuanli}@ruc.edu.cn



---

## LLaDA-MoE: A Sparse MoE Diffusion Language Model

---

Fengqi Zhu<sup>1,2,\*</sup>, Zebin You<sup>1,2,\*</sup>, Yipeng Xing<sup>2,\*</sup>, Zenan Huang<sup>2,\*</sup>, Lin Liu<sup>2,\*</sup>, Yihong Zhuang<sup>2,\*</sup>, Guoshan Lu<sup>2,\*</sup>, Kangyu Wang<sup>2,3</sup>, Xudong Wang<sup>2</sup>, Lanning Wei<sup>2</sup>, Hongrui Guo<sup>2</sup>, Jiaqi Hu<sup>2,4</sup>, Wentao Ye<sup>2,4</sup>, Tieyuan Chen<sup>2,3</sup>, Chenchen Li<sup>2</sup>, Chengfu Tang<sup>2</sup>, Haibo Feng<sup>2</sup>, Jun Hu<sup>2</sup>, Jun Zhou<sup>2</sup>, Xiaolu Zhang<sup>2,†</sup>, Zhenzhong Lan<sup>2,‡</sup>, Junbo Zhao<sup>2,4,‡</sup>, Da Zheng<sup>2,‡</sup>, Chongxuan Li<sup>1,†</sup>, Jianguo Li<sup>2,†</sup>, Ji-Rong Wen<sup>1,†</sup>

<sup>1</sup>Renmin University of China, <sup>2</sup>Ant Group, <sup>3</sup>Shanghai Jiao Tong University, <sup>4</sup>Zhejiang University

---

# Large Language Diffusion Models

---

**Shen Nie**<sup>1,2,3\*</sup> **Fengqi Zhu**<sup>1,2,3\*</sup> **Zebin You**<sup>1,2,3†</sup> **Xiaolu Zhang**<sup>4‡</sup> **Jingyang Ou**<sup>1,2,3</sup>  
**Jun Hu**<sup>4‡</sup> **Jun Zhou**<sup>4</sup> **Yankai Lin**<sup>1,2,3‡</sup> **Ji-Rong Wen**<sup>1,2,3</sup> **Chongxuan Li**<sup>1,2,3‡§</sup>

<sup>1</sup> Gaoling School of Artificial Intelligence, Renmin University of China

<sup>2</sup> Beijing Key Laboratory of Research on Large Models and Intelligent Governance

<sup>3</sup> Engineering Research Center of Next-Generation Intelligent Search and Recommendation, MOE

<sup>4</sup> Ant Group

{nieshen, fengqizhu, chongxuanli}@ruc.edu.cn

Prompt: Explain what artificial intelligence is.



# Introduction

## LLM의 현주소: Autoregressive Model (ARM)

현존하는 대부분의 LLM(GPT, LLaMA 등)은 자기회귀 모델(ARM), 즉 'Causal Language Modeling' 기반으로 수행

Question: "LLM의 핵심 역량은 오직 'Auto-Regressive Modeling' 패러다임을 통해서만 달성할 수 있는가?"

Answer: "아니다."

LLM의 핵심 속성은 ARM 고유의 것이 아니라, 더 상위 개념인 Generative Modeling Principles 비롯

: 트랜스포머 아키텍처, 데이터/모델 크기, 피셔 일관성(Fisher consistency) 등의 상호작용 결과임

: ICL, 지시 사항 준수 등은 ARM만의 전유물이 아님

ARM 패러다임의 내재적 한계 – Reversal Curse (Reversal Reasoning 작업에는 구조적으로 취약)

# Introduction

## LLaDA – Diffusion 모델을 통한 새로운 접근

목표: ARM이 아닌 생성 모델링 원칙(확산 모델)을 통해 LLM의 핵심 역량이 발현될 수 있음을 증명하고자 함

### LLaDA의 동작 원리

- Forward Process (Data Masking): 원본 데이터(문장)에 점진적으로 마스크(noise)를 추가
- Reverse Process (Generation): 트랜스포머 기반의 Mask Predictor가 마스킹된 토큰을 예측(복원)하도록 학습

### 주요 특징:

1. Bidirectional Dependencies를 자연스럽게 모델링
2. Variational Lower Bound, VLB을 최적화하는 원칙적인(principled) 생성 접근 방식을 따름

Training

## | LLaDA

## Overview

(a) Mask all tokens independently



↓

Mask predictor



Mask token ↓ Remask

Non-mask token ↓ Random mask

(b)

Prompt Response



↓

Mask predictor



↓

↓

(c)

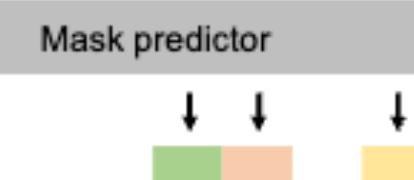
Prompt Response



$t = 1$

↓

Mask predictor



↓

↓

↓

Remask

↓

↓

↓

An intermediate step

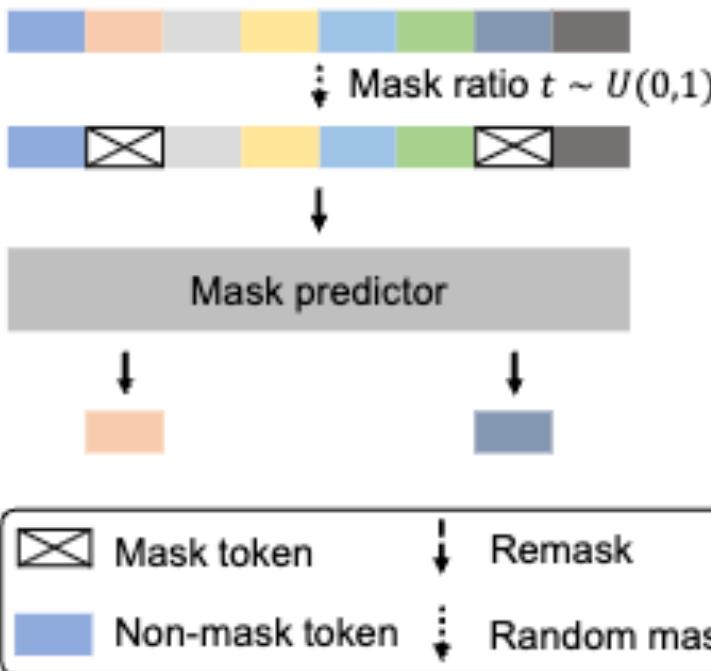
$t = 0$

↓

# Training

## Pre-training (1)

(a) Mask all tokens independently



## Transformer를 Mask Predictor로 쓰자

: Causal Mask → Non-Causal Mask

- 기존 ARM 모델과 달리, 예측 시 전체 입력을 참조

vs LLaMA3 8B

- LLaMA3: GQA / LLaDA: MHA (LLaDA는 KV Caching 호환 x)
- MHA사용으로 늘어난 파라미터는 FFN 차원 축소를 통해 사이즈 맞춤

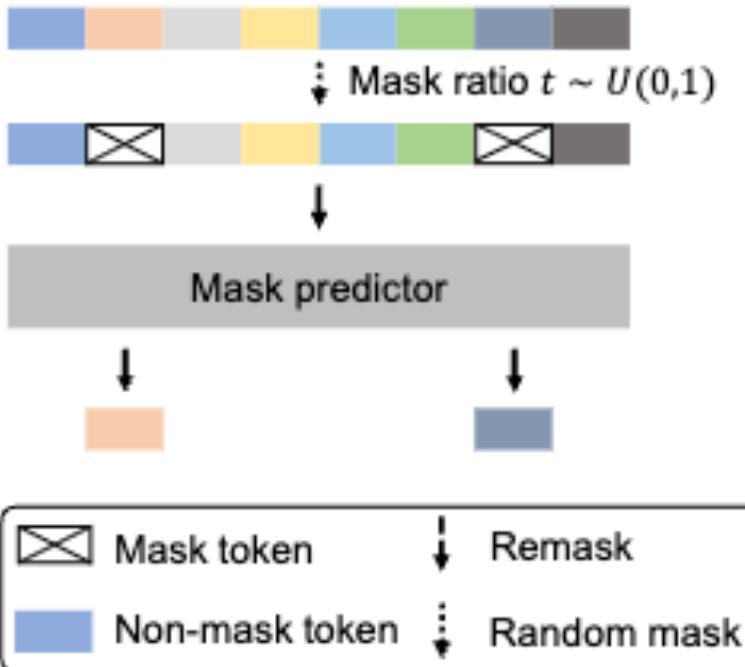
Data

- Online Corpora: 고품질 코드, 수학, 다국어 데이터 2.3T

# Training

## Pre-training (2)

(a) Mask all tokens independently



### Masking & Objective

- [0, 1] 범위에서 마스킹 확률  $t$ 를 무작위 샘플링
- 원본 시퀀스  $x_0$ 의 각 토큰을 독립적으로  $t$  확률로 마스킹하여  $x_t$  생성
- 고정 길이 (99%): 4096 토큰
- 가변 길이 (1%): [1, 4096] 범위에서 랜덤 샘플링

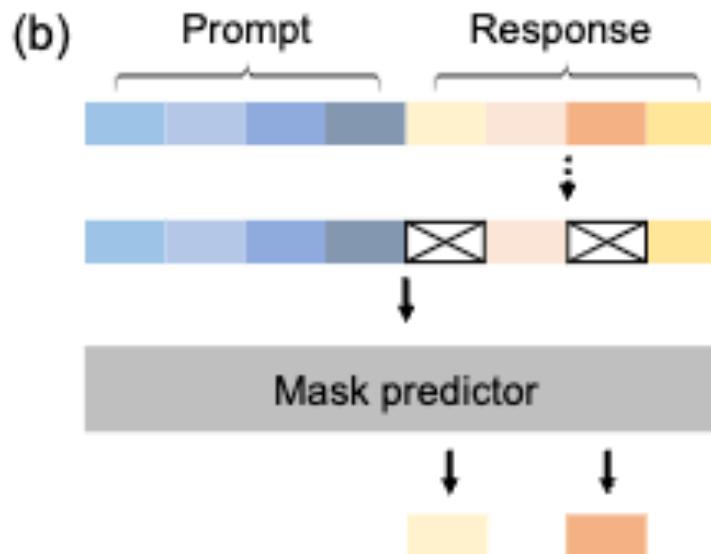
### Hyperparams

- AdamW (Weight Decay: 0.1)
- 배치 크기: 1280 (Global) / GPU당 4 (Local)
- Warmup-Stable-Decay

- Warmup (2k iter): 0  $\rightarrow$  4e-4
- Stable 1 (1.2T tok): 4e-4
- Decay 1 (0.8T tok): 1e-4
- Final Decay (0.3T tok): 1e-5

# Training

## SFT

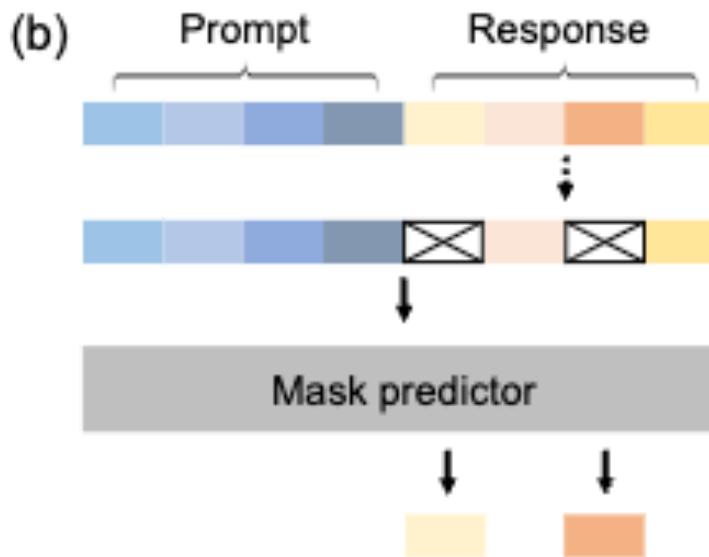


## Instruction Following

- : SFT를 사전 학습(PT)과 완벽하게 호환되는 방식으로 구현
- 프롬프트 ( $p_0$ ): 변경 없음 (마스킹 X)
- 응답 ( $r_0$ ): PT와 동일하게  $t$  확률로 독립적 토큰 마스킹
- 모델 입력:  $p_0$ 와  $r_t$ 를 연결 ( $[p_0, r_t]$ )
- Loss 계산:  $r_t$  부분의 마스킹된 토큰에 대해서만 계산

# Training

## SFT



### Data

- 450만 개의 쌍[Code, Mathematics, Instruction-following 등 다중 도메인]

### Batch & EOS

: prompt+response의 끝에 |EOS| 토큰을 추가하여 길이 통일

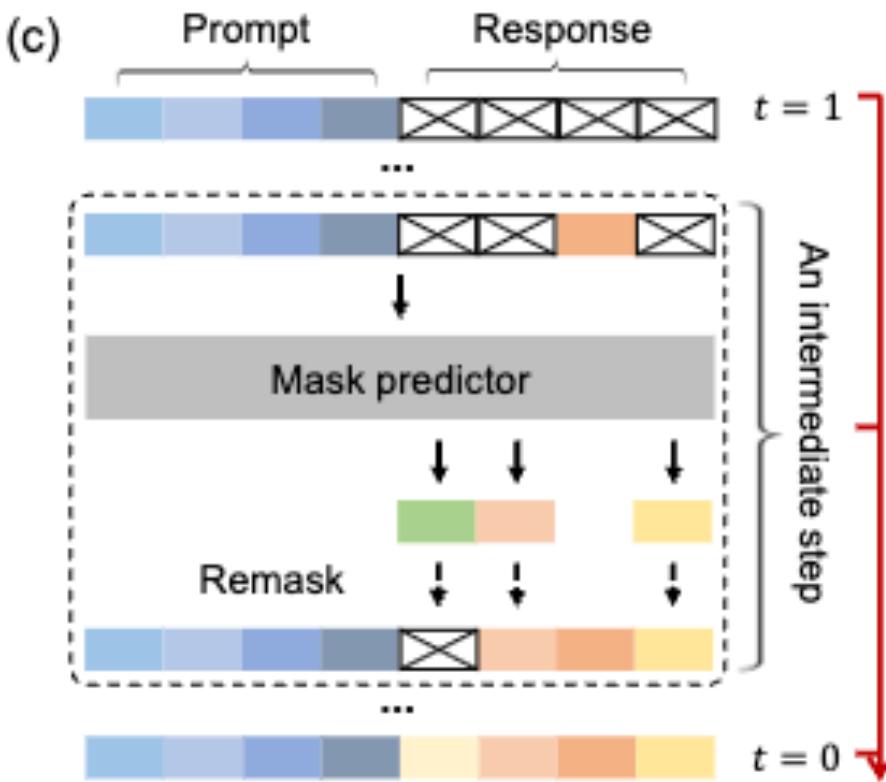
- 학습 시: 일반 토큰으로 취급하여 학습 (그냥 PAD 대신에 쓴다는 말ㅇㅇ)
- 추론 시: |EOS|를 샘플링하면 응답 생성 중단
- 모델이 응답 길이를 자동으로 제어하는 능력을 학습

### Hyperparams

- Epochs: 3
- LR: 2.5e-5 (Max) [Warm-up: 50 iter → 유지 → 마지막 10% 선형 감소]
- Weight Decay: 0.1
- Batch : 256 (Global) / GPU당 2 (Local)

# Inference

## Predicting (1)



## LLaDA의 추론 방식: Non-Autoregressive

- AR: left-to-right 한 토큰씩 순차적 생성
- LLaDA: 확산(Diffusion) 방식 채택 [동시 예측이 핵심]

추론 과정: Reverse Generation

시작 ( $T=1$ ): 프롬프트( $p_0$ ) + 완전히 마스킹된 응답  $[M]...[M]$

중간 ( $t \rightarrow s$ ):  $[p_0, r_t]$  (일부 마스킹된 응답)  $\rightarrow$  마스크 예측기로 모든  $[M]$  토큰 동시 예측

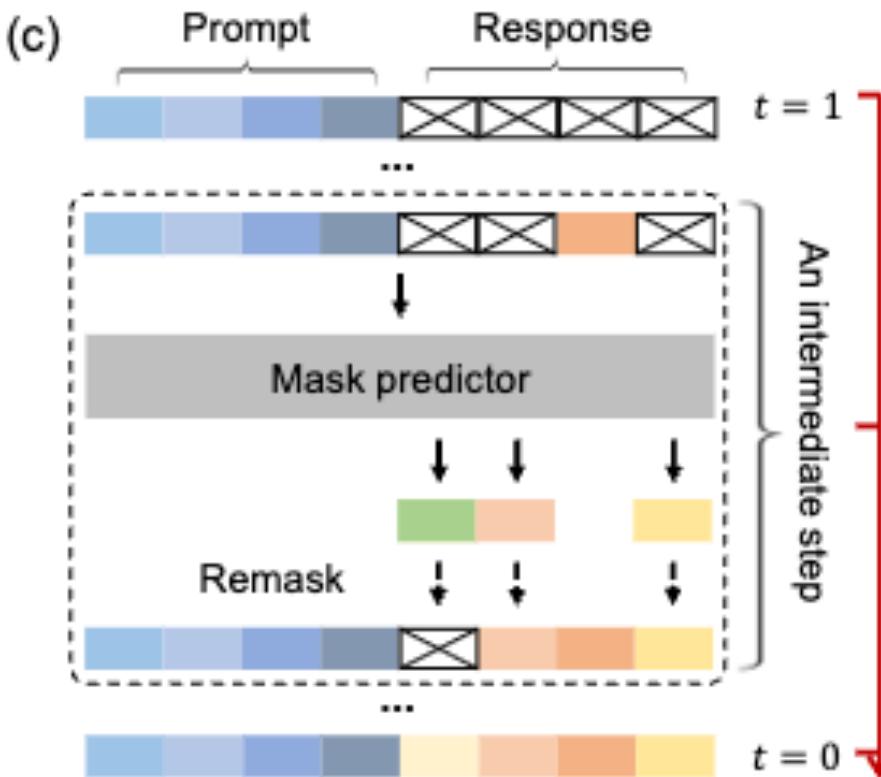
종료 ( $T=0$ ):  $[p_0, r_0]$  (완전한 응답)

Core Parameter

- 총 샘플링 단계 (Steps): 추론 속도(효율성) vs 샘플 품질 간의 트레이드오프 발생
- 생성 길이 (Length): 샘플링 시작 시 생성할  $[M]$ 의 개수 (예: 256, 512...)

# Inference

## Predicting (2)



### 핵심 전략: Remasking for Efficiency

- t시점에서 예측한 토큰을 s시점에 모두 믿어버리면(채워 넣으면), diffusion의 transition이 깨지고 샘플링이 불안정
- $t \rightarrow s$  단계로 이동 시
  1. t시점의 모든  $[M]$ 을 예측
  2. 예측된 토큰 중 일부 비율을 다시 마스킹하여  $r_s$ 를 생성

Low-Confidence

원칙적으로 순수하게 무작위로 다시 마스킹해야 함

But, annealing 기법에서 영감을 받아 Low-Confidence Remasking 수행

모델이 예측한 토큰들 중 confidence가 낮은 토큰을 골라 특정 비율만큼 우선적으로 리마스킹

# Inference

## Remasking Algorithm

### Algorithm 4 Random Remasking Strategy of LLaDA

**Require:** mask predictor  $p_\theta$ , prompt  $p_0$ , answer length  $L$ , sampling steps  $N$

```

1: Set  $r_1$  is a fully masked sequence of length  $L$ .
2: for  $t \leftarrow 1$  down to  $\frac{1}{N}$  step  $\frac{1}{N}$  do
3:    $s = t - \frac{1}{N}$ 
4:    $r_0 = \arg \max_{r_0} p_\theta(r_0 | p_0, r_t)$  # we employ greedy sampling when predicting masked tokens
5:   for  $i \leftarrow 1$  to  $L$  do
6:     if  $r_t^i \neq M$  then
7:        $r_0^i = r_t^i$ 
8:     else
9:       with probability  $\frac{s}{t}$ ,  $r_0^i$  is set to M
10:    end if
11:   end for
12:    $r_s = r_0$ 
13: end for
14: Return  $r_0$ 

```

$t$  (Time) = 현재 상태의 마스킹 비율

$s$  (Step) = 다음 단계의 목표 마스킹 비율

$N=4$ 로 정하면

–  $t$ 는  $1.0 \rightarrow 0.75 \rightarrow 0.5 \rightarrow 0.25 \rightarrow 0.0$

–  $s$ 는  $0.75 \rightarrow 0.5 \rightarrow 0.25 \rightarrow 0.0 \rightarrow$  완료

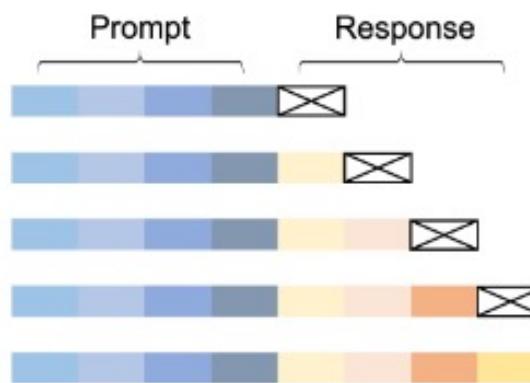
역과정은  $t=1$  (전부 마스크)에서 출발해  $t=0$  (최종응답)으로 가는 과정

실제로는 연속 시간을 여러 단계로 나눠서(discretize) 진행

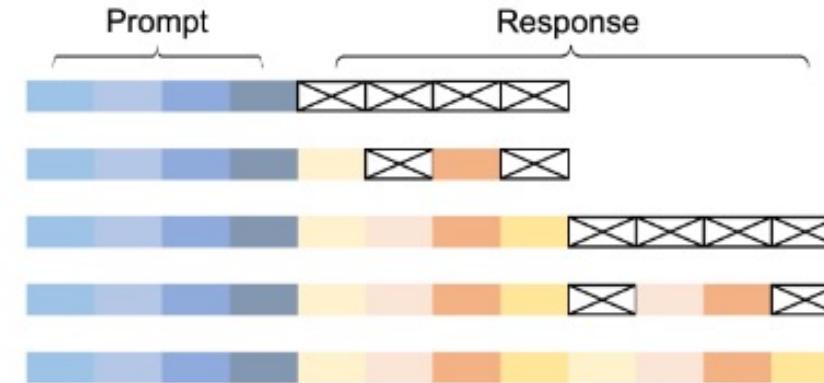
: 사용자가  $N$ 을 정하면, 1.0에서 0.0까지를  $N$ 개의 균일한 간격으로 나눔

# Inference

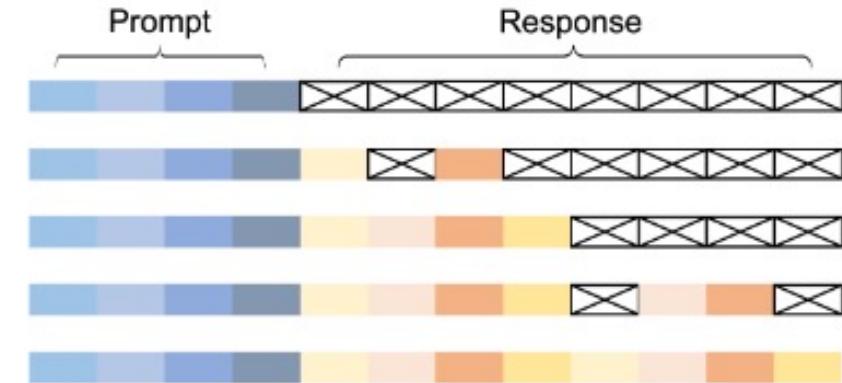
## Sampling Strategy for Flexibility



(a) Autoregressive.



(b) Block Diffusion.



(c) Block Diffusion LLaDA.

Default: 완전히 마스킹된 상태에서 시작 (parallel decoding)

(a) AR – LLaDA도 기존 LLM처럼 동작 가능

(b) Block Diffusion – 블록 간 Autoregressive

(c) Block Diffusion – Semi-autoregressive

# Experiments Results (1)

## Benchmark Results of Pre-trained LLMs.

	LLaDA 8B*	LLaMA3 8B*	LLaMA2 7B*	Qwen2 7B <sup>†</sup>	Qwen2.5 7B <sup>†</sup>	Mistral 7B <sup>†</sup>	Deepseek 7B <sup>†</sup>
Model Training tokens	Diffusion 2.3T	AR 15T	AR 2T	AR 7T	AR 18T	AR -	AR 2T
General Tasks							
MMLU	<b>65.9</b> (5)	65.4 (5)	45.9 (5)	70.3 (5)	74.2 (5)	64.2 (5)	48.2 (5)
BBH	49.7 (3)	<b>62.1</b> (3)	39.4 (3)	62.3 (3)	70.4 (3)	56.1 (3)	39.5 (3)
ARC-C	45.9 (0)	<b>53.1</b> (0)	46.3 (0)	60.6 (25)	63.7 (25)	60.0 (25)	48.1 (0)
Hellaswag	70.5 (0)	<b>79.1</b> (0)	76.0 (0)	80.7 (10)	80.2 (10)	83.3 (10)	75.4 (0)
TruthfulQA	<b>46.1</b> (0)	44.0 (0)	39.0 (0)	54.2 (0)	56.4 (0)	42.2 (0)	-
WinoGrande	74.8 (5)	<b>77.3</b> (5)	72.5 (5)	77.0 (5)	75.9 (5)	78.4 (5)	70.5 (0)
PIQA	73.6 (0)	<b>80.6</b> (0)	79.1 (0)	-	-	-	79.2 (0)
Mathematics & Science							
GSM8K	<b>70.3</b> (4)	48.7 (4)	13.1 (4)	80.2 (4)	85.4 (4)	36.2 (4)	17.4 (8)
Math	<b>31.4</b> (4)	16.0 (4)	4.3 (4)	43.5 (4)	49.8 (4)	10.2 (4)	6.0 (4)
GPQA	25.2 (5)	<b>25.9</b> (5)	25.7 (5)	30.8 (5)	36.4 (5)	24.7 (5)	-
Code							
HumanEval	<b>35.4</b> (0)	34.8 (0)	12.8 (0)	51.2 (0)	57.9 (0)	29.3 (0)	26.2 (0)
HumanEval-FIM	<b>73.8</b> (2)	73.3 (2)	26.9 (2)	-	-	-	-
MBPP	40.0 (4)	<b>48.8</b> (4)	23.2 (4)	64.2 (0)	74.9 (0)	51.1 (0)	39.0 (3)
Chinese							
CMMLU	<b>69.9</b> (5)	50.7 (5)	32.5 (5)	83.9 (5)	-	-	47.2 (5)
C-Eval	<b>70.5</b> (5)	51.7 (5)	34.0 (5)	83.2 (5)	-	-	45.0 (5)

# Experiments Results (2)

## Benchmark Results of Post-trained LLMs.

	LLaDA 8B*	LLaMA3 8B*	LLaMA2 7B*	Qwen2 7B <sup>†</sup>	Qwen2.5 7B <sup>†</sup>	Gemma2 9B <sup>†</sup>	Deepseek 7B <sup>†</sup>
Model	Diffusion	AR	AR	AR	AR	AR	AR
Training tokens	2.3T	15T	2T	7T	18T	8T	2T
Post-training							
Alignment pairs	SFT	SFT+RL	SFT+RL	SFT+RL	SFT+RL	SFT+RL	SFT+RL
	4.5M	-	-	0.5M + -	1M + 0.15M	-	1.5M + -
General Tasks							
MMLU	65.5 (5)	<b>68.4</b> (5)	44.1 (5)	-	-	-	49.4 (0)
MMLU-pro	37.0 (0)	<b>41.9</b> (0)	4.6 (0)	44.1 (5)	56.3 (5)	52.1 (5)	-
Hellaswag	74.6 (0)	<b>75.5</b> (0)	51.5 (0)	-	-	-	68.5 (-)
ARC-C	<b>88.5</b> (0)	82.4 (0)	57.3 (0)	-	-	-	49.4 (-)
Mathematics & Science							
GSM8K	69.4 (4)	<b>78.3</b> (4)	29.0 (4)	85.7 (0)	91.6 (0)	76.7 (0)	63.0 (0)
Math	<b>31.9</b> (0)	29.6 (0)	3.8 (0)	52.9 (0)	75.5 (0)	44.3 (0)	15.8 (0)
GPQA	<b>33.3</b> (5)	31.9 (5)	28.4 (5)	34.3 (0)	36.4 (0)	32.8 (0)	-
Code							
HumanEval	49.4 (0)	<b>59.8</b> (0)	16.5 (0)	79.9 (0)	84.8 (0)	68.9 (0)	48.2 (-)
MBPP	41.0 (4)	<b>57.6</b> (4)	20.6 (4)	67.2 (0)	79.2 (0)	74.9 (0)	35.2 (-)

# Reversal Reasoning and Analyses

## Reversal Curse

- : ARMs가 "A는 B이다"와 같은 사실을 학습할 때 "B는 A이다"라는 역방향 사실을 추론하는 데 어려움을 겪음
- : ARM은 L2R 방식으로 처리하고 생성하는 본질적인 특성으로, 입력 시퀀스의 방향성에 강한 inductive bias 가짐

### 평가 프로토콜 (Poem Completion Task)

- : LLaDA의 Reversal Reasoning 능력을 정량적으로 평가하기 위해 Allen-Zhu and Li [35]의 프로토콜을 차용
- : 496쌍의 유명한 중국 시 문장으로 구성된 데이터셋을 구축

Forward Task: 다음 줄을 생성. Reversal Task: 이전 줄을 생성

LLaDA

# Reversal Reasoning and Analyses

Table 4: Comparison on the Poem Completion task.

	Forward	Reversal
GPT-4o (2024-08-06)	<b>82.7</b>	34.3
Qwen2.5-7B Instruct	75.9	38.0
LLaDA-8B Instruct	51.8	<b>45.6</b>

LLaDA는 ....

- Forward 성능은 ARM들보다 낮지만 Reversal 성능에서 큰 우위 → 전체적으로 더 균형 잡힌 처리 가능
- masked diffusion의 훈련으로 토큰을 균등하게 취급하여 방향성 편향이 적음

# Conclusion

8B 규모의 Diffusion 언어 모델을 최초로 제안

기존 ARM의 한계를 극복하고 언어 모델링의 새로운 패러다임 제시

Bidirectional Modeling & Enhanced Robustness (e.g., Reversal Curse)

## Limitations

- 강화 학습을 통한 정렬 과정을 거치지 않음
- 확산 샘플링 알고리즘이 아직 예비 단계
- 계산 제약으로 ARM과 동일한 데이터/규모로 직접 비교 X

## Future Work

- 모델 및 데이터 확장: SOTA ARM 모델 규모로 확장 필요
- 다중 모드 (Multi-modal) 데이터 처리 능력 탐구
- RL 기반 정렬 적용을 통한 성능 및 인간 의도 일치성 개선



---

# LLaDA-MoE: A Sparse MoE Diffusion Language Model

---

Fengqi Zhu<sup>1,2,\*</sup>, Zebin You<sup>1,2,\*</sup>, Yipeng Xing<sup>2,\*</sup>, Zenan Huang<sup>2,\*</sup>, Lin Liu<sup>2,\*</sup>, Yihong Zhuang<sup>2,\*</sup>, Guoshan Lu<sup>2,\*</sup>, Kangyu Wang<sup>2,3</sup>, Xudong Wang<sup>2</sup>, Lanning Wei<sup>2</sup>, Hongrui Guo<sup>2</sup>, Jiaqi Hu<sup>2,4</sup>, Wentao Ye<sup>2,4</sup>, Tieyuan Chen<sup>2,3</sup>, Chenchen Li<sup>2</sup>, Chengfu Tang<sup>2</sup>, Haibo Feng<sup>2</sup>, Jun Hu<sup>2</sup>, Jun Zhou<sup>2</sup>, Xiaolu Zhang<sup>2,†</sup>, Zhenzhong Lan<sup>2,†</sup>, Junbo Zhao<sup>2,4,†</sup>, Da Zheng<sup>2,†</sup>, Chongxuan Li<sup>1,†</sup>, Jianguo Li<sup>2,†</sup>, Ji-Rong Wen<sup>1,†</sup>

<sup>1</sup>Renmin University of China, <sup>2</sup>Ant Group, <sup>3</sup>Shanghai Jiao Tong University, <sup>4</sup>Zhejiang University

# Introduction

## 기존 MDM의 아키텍처 한계

- 현재까지의 MDM 연구는 대부분 Dense한 트랜스포머 백본에 의존
- 대조적으로, AR 모델 분야에서는 Sparse Mixture-of-Experts 아키텍처가 널리 검증됨

MDM을 Sparse MoE 아키텍처로 scratch부터 사전 학습시킨 선행 연구가 부재 → 효율성과 성능을 모두 잡자

어떻게? 약 20T(조) 토큰 데이터로 학습된 MDM과 Sparse MoE 아키텍처를 가진 모델 학습

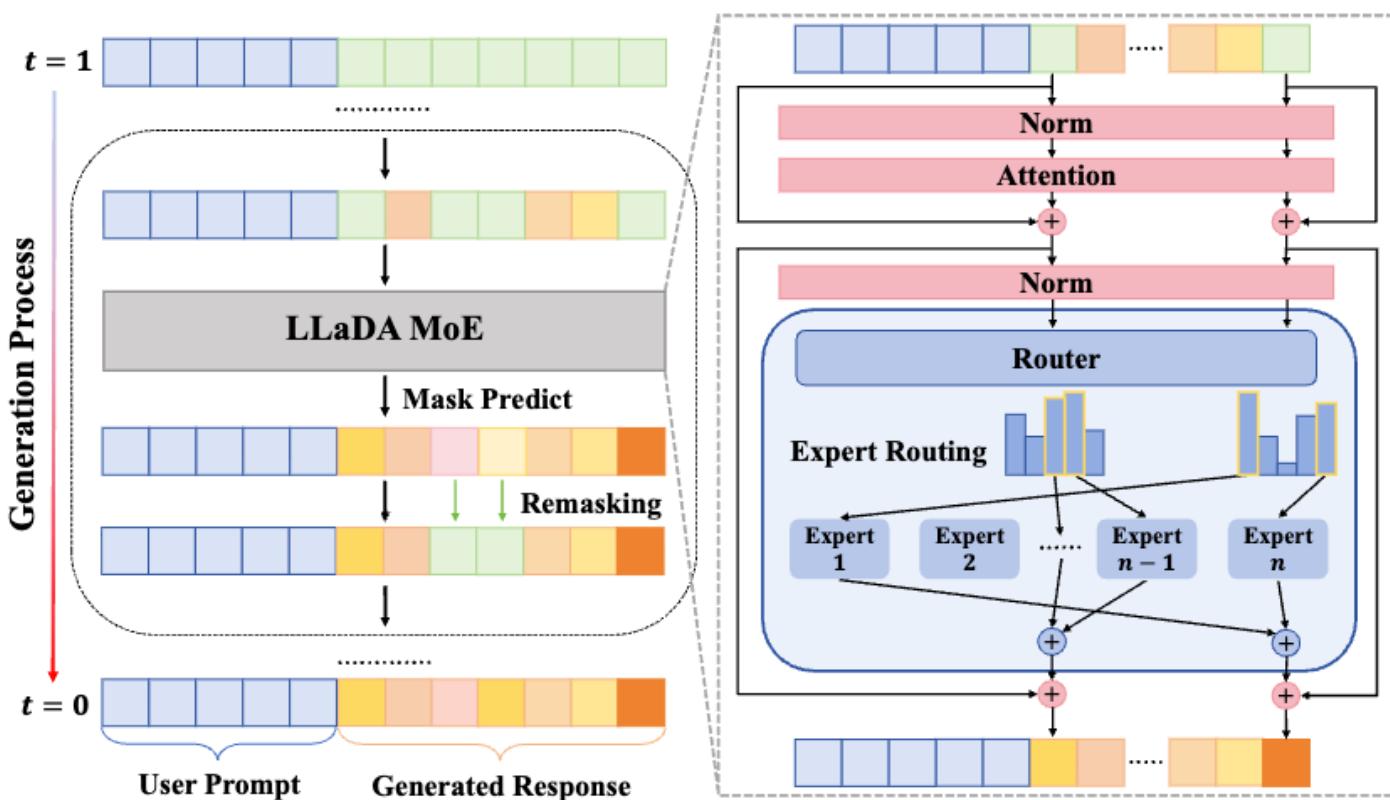
### 1. 확산 언어 모델(MDM) 중 SOTA 달성

: 총 7B 파라미터 중 단 1.4B 개의 활성 파라미터만 사용, 적은 추론 비용으로도 이전의 8B Dense MDM 의 성능을 능가

### 2. 타 모델과의 경쟁력 입증

# Architecture

## Overview



LLaDA-MoE는 정규화를 위해 아래 항목 사용

1. RMSNorm
2. Activation Func: SwiGLU
3. ROPE
4. MHA 내에 QK-layernorm

Layers	16
Hidden Dimension	2048
Attention Heads	16
Total Experts	64
Activated Experts	8
Expert Dimension	1024
RoPE Base	50,000
Active Parameters	1.4B
Non-embedding Parameters	7B

# Architecture

## MoE Routing.

- 현재까지의 MDM 연구는 대부분 Dense한 트랜스포머 백본에 의존
- 대조적으로, AR 모델 분야에서는 Sparse Mixture-of-Experts 아키텍처가 널리 검증됨

## Auxiliary Losses.

- 1) Load-Balancing Loss: Expertes가 공평하게 나누어 받도록 보장

$$\mathcal{L}_{LB} = N \sum_{i=1}^N f_i P_i$$

N. 전문가의 수  
 f\_i. i번째 전문가가 모든 토큰에 걸쳐 선택된 빈도  
 P\_i. i번째 전문가에게 할당된 평균 라우팅 확률

- 2) Z-Loss: 라우터가 출력하는 로짓( $z_t$ ) 값 자체가 너무 커지는 것을 방지하여 학습을 안정화

$$\mathcal{L}_Z = \frac{1}{T} \sum_{t=1}^T \left( \log \sum_{j=1}^N e^{z_{t,j}} \right)^2$$

T: number of tokens  
 $z_{\{t,j\}}$ : Router( $h_t$ ) 가  $t$ 번째 토큰에 대해  $j$ 번째 E에게 부여한 logit

# Training Pipeline

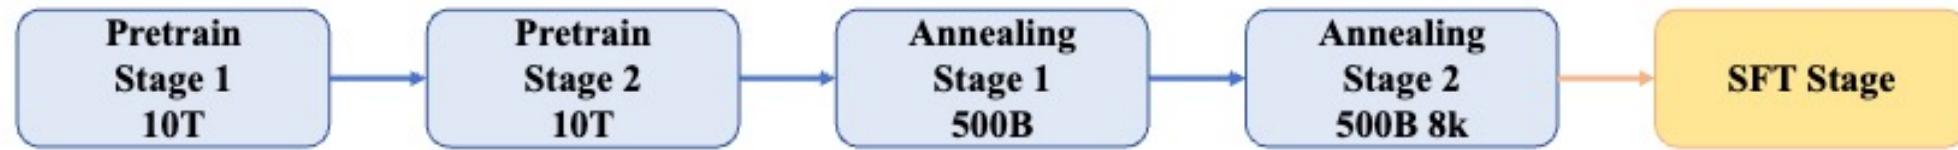


Figure 3: **Training pipeline.** LLaDA-MoE is trained through Pretrain stage 1 (10T tokens), pretrain stage 2 (10T tokens), annealing stage 1 (500B tokens), annealing stage 2 (500B tokens with 8k context length), followed by SFT on curated prompt–answer pairs.

## Pretrain Stage

### PT Stage 1

- 대규모 혼합 텍스트 코퍼스 (10T Tokens)

### PT Stage 2

- sampling reweighted to increase the fraction of mathematics and code (+10T)

# ■ Pipeline

## Annealing Stage

### Annealing Stage 1

- 500B tokens of high-quality text
- 사전 학습 2단계의 최고 성능 체크포인트 사용

### Annealing Stage 2

- 500B토큰
- RoPE Base 10,000에서 50,000으로 증가
- 컨텍스트 길이 4k에서 8k로 확장

## SFT Stage

- high-quality question–answer pairs
- 다중 턴 대화(multi-turn dialogs)의 경우, 특정 턴의 응답에만 마스킹 커널을 적용
- SFT 중 샘플은 대부분 4k보다 짧아 최대 4k 토큰으로 제한하여 학습 (불필요한 |EOS| 토큰 생성 방지)

# Training Pipeline

## Forward Process

: 마스크가 추가된 입력  $y_t$ 를 보고 원본 토큰  $y^i$ 를 예측하도록 모델을 학습 (LLaDA와 동일)

## Train-Test Discrepancy

- 실제 테스트 시에는 4k보다 훨씬 짧거나 다양한 길이의 입력이 들어옴

## Variable-Length Training

- 99%: 기존과 동일하게 고정된 4k 컨텍스트 사용
- 1%의 8에서 4096 사이의 무작위 길이를 샘플링하여, 입력을 해당 길이로 truncate

# Training Pipeline

## Supervised Fine-tuning

: 답변 부분만 확률  $t$ 에 따라 마스킹하여, 원본 토큰  $y^i$ 를 예측하도록 모델을 학습 (LLaDA와 동일)

## |EOS| 토큰 학습

: 문장 끝을 알리는 |EOS| 토큰도 답변의 일부로 취급하여 함께 마스킹하고 손실 계산에 포함

## 다중 턴 대화

:  $[q_1, a_1, q_2]$ 까지를 입력으로 보고,  $a_2$ 를 답변으로 취급하여 동일하게 학습

## 4k 컨텍스트 제한

: 어닐링 2단계 (Annealing Stage 2) 동안 4k에서 8k로 확장되지만, SFT는 4k로 제한

# Inference

추론은 모델이 완전히 마스크된 상태([M][M]...[M])에서 시작하여 점차 [M]을 실제 토큰으로 채워 나감

## Train–Test Discrepancy

- 실제 테스트 시에는 4k보다 훨씬 짧거나 다양한 길이의 입력이 들어옴

## Generation Strategy

: LLaDA와 동일한 전략 사용 가능

# Experiments Results (base)

Knowledge, Reasoning, Coding, Math, Agent 등에 대한 벤치마크 평가 수행

- : Semi-Autoregressive로 평가
- : Generation length 1024
- : block size 64

	LLaDA-MoE-7B-A1B-Base	LLaDA-8B-Base	Dream-v0-Base-7B	Qwen2.5-3B-Base
Architecture				
Model	MoE	Dense	Dense	Dense
Method	Diffusion	Diffusion	Diffusion	AR
# Total Params	7B	8B	7B	3B
# Activated Params	1B	8B	7B	3B
<i>General Tasks</i>				
MMLU	64.59	65.90	<b>69.50</b>	<u>67.98</u>
MMLU-Pro	39.16	<u>41.80</u>	<b>48.15</b>	35.50
CEval	65.56	<u>70.50</u>	59.18	<b>75.00</b>
CMMLU	65.65	<u>69.90</u>	60.87	<b>73.65</b>
RACE	84.96	<u>88.37</u>	44.70	<u>87.88</u>
<i>Reasoning Tasks</i>				
BBH	52.71	49.80	<b>57.90</b>	<u>56.50</u>
Drop	65.86	<u>72.93</u>	<b>75.16</b>	<u>51.61</u>
KorBench	31.20	<u>33.68</u>	<b>37.44</b>	27.44
<i>Math Tasks</i>				
GSM8K	66.41	70.70	<b>77.79</b>	<u>78.17</u>
MATH	36.10	27.30	<u>39.60</u>	<b>40.94</b>
OlympiadBench	<u>10.07</u>	6.85	<b>10.22</b>	9.33
<i>Coding Tasks</i>				
CRUX-O	<b>39.00</b>	31.00	<u>37.75</u>	35.62
MBPP	52.40	38.20	<u>56.20</u>	<b>69.56</b>
MultiPL-E	<b>41.13</b>	23.61	27.60	<u>40.80</u>
HumanEval	45.73	33.50	<u>57.90</u>	<b>57.93</b>
LiveCodeBench v6	<u>16.18</u>	2.53	14.87	<b>16.99</b>
BigCodeBench-Full	<u>21.23</u>	13.42	18.33	<u>30.88</u>
Avg	<u>46.94</u>	43.53	46.66	<b>50.34</b>

# Experiments Results (Instruct)

Knowledge, Reasoning, Coding, Math, Agent 등에 대한 벤치마크 평가 수행

- : Semi-Autoregressive로 평가
- : Generation length 1024
- : block size 64

	LLaDA-MoE-7B-A1B-Instruct	LLaDA-8B-Instruct	LLaDA-1.5	Dream-v0-Instruct-7B	Qwen2.5-3B-Instruct
Architecture	MoE	Dense	Dense	Dense	Dense
Model	Diffusion	Diffusion	Diffusion	Diffusion	AR
Method	Pretrain + SFT	Pretrain + SFT	Pretrain + SFT + DPO	Continue Pretrain + SFT	Pretrain + SFT + RL
# Total Params	7B	8B	8B	7B	3B
# Activated Params	1B	8B	8B	7B	3B
<i>General Tasks</i>					
MMLU	<u>67.18</u>	65.50	66.00	67.00	<b>69.11</b>
MMLU-Pro	<b>44.64</b>	37.00	35.70	43.30	<u>44.13</u>
CMMLU	<u>64.30</u>	55.21	58.72	58.82	<b>65.62</b>
CEval	<u>63.93</u>	54.48	58.41	57.98	<b>68.20</b>
<i>Reasoning Tasks</i>					
Drop	79.77	<u>83.09</u>	<b>84.89</b>	76.25	68.56
KorBench	<b>38.40</b>	33.68	<u>37.20</u>	32.56	36.88
<i>Math Tasks</i>					
GSM8K	82.41	78.60	<u>83.30</u>	81.00	<b>86.28</b>
MATH	<u>58.68</u>	42.20	42.60	39.20	<b>67.02</b>
OlympiadBench	<u>21.04</u>	10.52	10.96	10.44	<b>30.41</b>
<i>Coding Tasks</i>					
CRUX-O	<u>42.38</u>	28.50	29.12	40.12	<b>46.75</b>
MBPP	<b>70.02</b>	41.00	42.80	58.80	<u>65.81</u>
MultiPL-E	<u>52.53</u>	29.08	29.04	29.86	<b>54.92</b>
HumanEval	<b>61.59</b>	49.40	52.40	55.50	<u>60.37</u>
LiveCodeBench v6	<u>13.27</u>	6.66	6.94	5.23	<u>9.20</u>
BigCodeBench-Full	<u>20.44</u>	11.32	11.93	19.04	<b>27.81</b>
<i>Agent &amp; Alignment Tasks</i>					
IFEval Strict Prompt	<u>59.33</u>	51.39	58.23	<b>62.50</b>	58.20
BPCL-Live	<u>63.09</u>	47.47	<b>66.20</b>	53.03	50.40
Avg	<u>53.12</u>	42.65	45.56	46.51	<b>53.51</b>

# Q & A