

LUT 포함 Qubit-Space 입력을 이용한 CNN-Transformer 기반 Rotated Surface Code 디코더

김지인¹, 오근영¹, 이길한¹, 박호성^{1,*}, 박성준²

전남대학교¹, 삼성전자²

jlib24555@gmail.com, ohky0529@naver.com, gilgilgil0214@naver.com, hpark1@jnu.ac.kr,*
joonpark2247@gmail.com

A CNN-Transformer-Based Decoder for Rotated Surface Codes Using LUT-Informed Qubit-Space Inputs

Jin Kim¹, Geun-yeong Oh¹, Gil Han Lee¹, Hosung Park^{1,*}, Seong-Joon Park²

Chonnam National Univ.¹, Samsung Electronics.²

요약

본 논문은 rotated surface code에서 논리 연산자 4클래스(I, X_L, Z_L, Y_L)를 예측하는 high-level 디코딩 기법을 채택하며, 큐비트별 신드롬 집계와 LUT 기반 오류 후보를 결합한 qubit-space 4채널 입력을 제안한다. 디코더는 CNN으로 국소 패턴을 추출하고, Transformer encoder로 전역 상관을 모델링하여 효율적인 학습을 수행한다. Depolarizing 잡음 환경에서 코드 거리 $d \geq 5$ 이상에서 제안 디코더는 LER이 개선되었으며, $d = 7$ 에서 MWPM 대비 약 35%, 기존 CNN 대비 약 20% 낮은 오류율을 달성하였다. 또한, 재학습 없이 pure-Y 잡음에 적용했을 때, $d = 7$, $p \approx 0.1$ 에서 MWPM 대비 약 73%, CNN 대비 약 41% 낮은 논리 오류율을 보여, 비교 기법 대비 성능 저하가 제한적임을 확인하며 잡음 분포 변화에 대한 강건성을 보였다.

I. 서론

대규모 양자 컴퓨팅에 필수적인 surface code에서 디코딩은 측정된 신드롬(syndrome)으로부터 복원 연산을 결정하는 과정이다. 동일한 신드롬에 대응하는 물리 오류 패턴은 다수 존재하므로, 디코딩의 목표는 물리 오류를 정확히 식별하는 것이 아니라 논리적 실패 확률을 최소화하는 복원 방법을 선택하는 데 있다. 본 연구는 이러한 관점에서 high-level decoding 기법을 채택하여, 신드롬으로부터 $\{I, X_L, Z_L, Y_L\}$ 네 가지 논리 오류 클래스 중 하나를 예측하는 문제로 디코딩을 다룬다.

최소 가중치 완전 매칭(minimum-weight perfect matching, MWPM) 기반 디코더는 surface code 구조를 활용해 널리 사용되지만, X형과 Z형 오류를 분리해 처리하는 특성으로 인해 결합 오류가 두드러지는 잡음 환경에서는 성능이 제한될 수 있다. 이를 보완하기 위해 신경망 기반 디코더가 제안되어 왔다.

한편 rotated surface code는 큐비트 효율이 높으나, 기하학적 배치로 인해 신드롬 정보를 학습 모델 입력으로 정렬하기 어렵다. 이러한 입력 표현과 코드 구조의 불일치는 학습 효율과 디코딩 성능을 저해할 수 있다. 이에 본 연구는 신드롬을 데이터 큐비트 공간에 정렬한 입력 표현을 기반으로 하는 학습 기반 디코딩 프레임워크를 제안한다.

II. 제안하는 방법

LUT 포함 qubit-space 입력 표현

Rotated surface code에서 관측 신드롬 s 와 LUT(Lookup Table) 기반 기준 보정(pure error) 후보를 동일한 데이터 큐비트 좌표계(qubit space, $d \times d$)에 정렬하여 CNN 입력으로 사용할 4채널 격자 텐서를 구성한다. 본 연구에서 사용하는 qubit space 격자는 rotated surface code의 데이터 큐비트 좌표를 재인덱싱하여 구성한 것으로, 새로운 좌표 변환이나 보간을 도입하지 않으며 물리적 인접 관계를 보존한다. 입력은 검사행렬 기반 신드롬 집계 특징과 LUT가 생성한 pure error로 이루어진다. 여기서 LUT

는 전체 신드롬을 키로 직접 조회하는 완전 테이블이 아니라, 활성 신드롬 비트들의 기여 패턴을 모듈로-2로 합산하여 후보를 생성하는 선형(XOR) LUT이다. LUT 후보가 데이터 큐비트 위치에 정의되므로 신드롬 특징 또한 qubit space로 정렬하며, 이를 통해 syndrome grid 방식에서 발생하는 채널별 빈 칸과 입력 희소성을 완화한다.

본 연구에서는 rotated surface code의 검사행렬 $H_X \in \{0,1\}^{n_x \times n_q}$, $H_Z \in \{0,1\}^{n_z \times n_q}$ 와 신드롬 $s_X \in \{0,1\}^{n_x}$, $s_Z \in \{0,1\}^{n_z}$ 로부터 데이터 큐비트별 집계 벡터 $r_X, r_Z \in R^{n_q}$ 를 $r_X = H_X^\top s_X$, $r_Z = H_Z^\top s_Z$ 로 정의 한다. 이때 $r_X(j)$, $r_Z(j)$ 는 각각 데이터 큐비트 j 에 인접한 안정자(stabilizer) 중 활성 신드롬의 개수를 나타낸다. Rotated 구조에서 타입별 최대 연결도가 2임을 반영하여 $\tilde{r}_X = r_X/2$, $\tilde{r}_Z = r_Z/2$ 로 정규화하고, \tilde{r}_X 와 \tilde{r}_Z 를 입력 채널로 사용한다.

본 디코더는 LUT로부터 신드롬에 대응하는 기준 보정값을 계산한 뒤, 그 이후에도 남는 잔차 오류의 논리 클래스만을 분류하는 high-level 디코딩 기법을 채택한다. 임의의 오류 E 는 $E = S \cdot T \cdot L$ 로 분해되며, 여기서 S 는 stabilizer 성분, T 는 신드롬으로부터 결정되는 pure error 성분(lookup table로 구현), L 은 논리 오류 클래스를 의미한다.

LUT 적용 이후 잔차에 포함된 stabilizer 성분은 논리 오류율에 영향을 주지 않으므로, 신경망은 잔차의 논리 클래스만 예측하도록 학습한다. 본 모델은 LUT가 산출한 pure error를 신경망의 추가 입력으로 제공함으로써, LUT의 결정 규칙을 다시 학습할 필요 없이 LUT 이후에 남는 논리적 분기만을 분류하도록 한다. 이는 입력과 출력의 정보 수준을 정합시켜 학습 난이도를 낮춘다.

\tilde{r}_X , \tilde{r}_Z 및 LUT로 산출된 pure error p_X , p_Z 는 모두 데이터 큐비트 인덱스 j 에 대해 정의되므로, 이를 동일한 $d \times d$ qubit-space 격자에 정렬한 뒤 채널 방향으로 결합하여 4채널 입력 텐서를 구성한다. 채널 0과 1은 \tilde{r}_X , \tilde{r}_Z , 채널 2와 3은 p_X , p_Z 를 담는다. 이러한 입력 구성은 rotated

surface code의 국소적 인접 구조와 전역 상관을 동시에 활용할 수 있도록 하며, 격자 내 빈 칸으로 인한 입력 희소성을 완화한다. syndrome grid 방식에서 발생하는 채널별 빈 칸과 입력 희소성을 완화한다.

CNN - Transformer 기반 디코더

제안 디코더는 4채널 qubit-grid 입력으로부터 논리 연산자 클래스를 예측하도록 설계되며, CNN 기반 임베딩 모듈과 Transformer encoder를 결합한다. 먼저 다층 합성곱 계층을 통해 국소 영역에서 syndrome count와 LUT 후보 사이의 상호작용을 특징으로 추출하고, 1×1 합성곱을 통해 d_{model} 차원의 임베딩으로 변환한다. 이후 격자 위치별 임베딩을 토큰 시퀀스로 펼쳐 Transformer encoder에 입력한다. Transformer의 self-attention은 격자 전역의 상관관계를 학습하여, 오류 누적 패턴 및 논리 연산자 방향성과 관련된 장거리 구조를 반영한다. 최종적으로 분류 헤드가 네 가지 논리 연산자 클래스에 대한 확률을 출력한다.

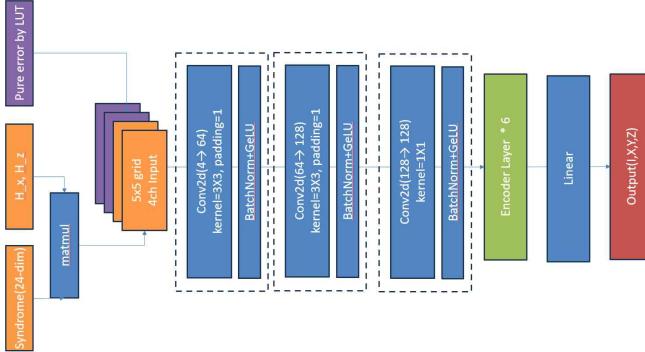


그림 1. 제안한 LUT 포함 입력 CNN - Transformer 디코더 구조.

III. 실험 설정 및 결과

본 연구는 rotated surface code에서 코드 거리 $d=3,5,7$ 에 대해 디코딩 성능을 평가하였다. 물리 잡음은 depolarizing 모델을 기본으로 사용하며, 단일 큐비트 오류율을 p 라 할 때 각 데이터 큐비트에 I, X_L, Z_L, Y_L 오류가 각각 $1-p, p/3, p/3, p/3$ 의 확률로 독립적으로 적용된다고 가정한다. 각 샷에서 관측된 신드롬으로부터 검사행렬 기반 합계 특징과 LUT 기준 후보를 결합한 4채널 입력을 구성하고, 모델의 논리 클래스 예측에 따라 보정을 적용한 뒤 논리 실패 여부를 판정하였다.

성능 지표로는 논리 오류율(logical error rate, LER)을 사용하며, 이는 물리 오류율 p 에서 디코딩 실패가 발생할 확률로 정의한다. 또한 pseudo-threshold p 는 LER(p)와 p 가 교차하는 지점으로 정의한다. 본 연구에서는 이산적으로 측정된 데이터에서 LER(p) - p 의 부호가 변하는 인접 구간을 찾고, 해당 구간에서 선형 보간을 통해 pseudo-threshold를 추정하였다. 비교 기준으로는 MWPM 디코더[1]와 CNN 기반 디코더[2]를 사용하였다.

Depolarizing 잡음 환경에서 제안 디코더는 코드 거리 $d \geq 5$ 에서 MWPM [1] 및 CNN[2] 대비 더 낮은 논리 오류율을 보였으며, 대표적인 물리 오류율($p \approx 0.1$)에서 $d=7$ 기준 MWPM[1] 대비 약 35%, CNN[2] 대비 약 20% 낮은 논리 오류율을 달성하였다. 이에 따라 pseudo-threshold 또한 일관되게 개선되었으며 각 코드 거리에서의 비교 결과는 표 1에 정리하였다.

잡음 분포 변화에 대한 강건성을 평가하기 위해 pure-Y 잡음(Y 100%) 조건에서도 동일한 절차로 실험을 수행하였다. Depolarizing 잡음에서 학습한 모델을 재학습 없이 pure-Y 조건에 적용했을 때, 제안 디코더는 비교 기법 대비 성능 저하가 제한적으로 나타나 잡음 분포 변화에 대한 강

성을 보였다. 특히 코드 거리 $d=7, p=0.10$ 에서 MWPM[1] 대비 약 73%, CNN[2] 기반 디코더 대비 약 41% 낮은 논리 오류율을 기록하였다.

표 1. MWPM[1], CNN[2], 제안 기법의 pseudo-threshold 비교 (Depolarizing; $d=3,5,7$) 및 Y-only 테스트($d=7$).

Model	$d=3$	$d=5$	$d=7$ (Depolarizing)	$d=7$ (Y 100%)
MWPM	0.0830	0.1034	0.1136	0.0618
CNN[2]	0.0964	0.1242	0.1263	0.0991
Proposed	0.0962	0.1281	0.1382	0.1231

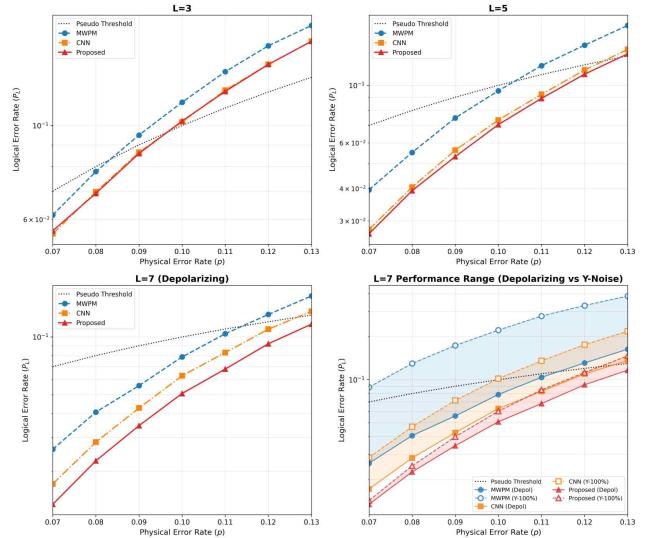


그림 2. $d=3,5,7$ 에서 물리 오류율 대비 논리 오류율 비교 및 $d=7$ 잡음 조건 변화(Depolarizing/Pure-Y) 성능 범위.

IV. 결론

본 논문은 rotated surface code 디코딩을 논리 연산자 클래스 예측 문제로 다루고, 신드롬 합계와 LUT 기준 후보를 결합한 qubit-space 입력 표현을 제안하였다. 제안 디코더는 depolarizing 잡음에서 MWPM 및 기존 CNN 기반 기법 대비 향상된 논리 오류율 및 pseudo-threshold를 보였으며, pure-Y 잡음에서도 재학습 없이 제한적인 성능 저하만을 보여 잡음 분포 변화에 대한 일반화 가능성을 확인하였다. 향후에는 더 큰 코드 거리와 현실적인 잡음 모델로의 확장을 검증할 예정이다.

ACKNOWLEDGMENT

본 연구는 2025년도 정부(교육부) 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(RS-2025-25398164) 및 첨단분야 혁신융합대학사업(차세대통신)의 연구이자, 과학기술정보통신부 및 정보통신기획평가원의 학석사연계ICT핵심인재양성사업(RS-2022-00156385)의 연구 성과임.

참 고 문 현

- [1] O. Higgott and C. Gidney, "Sparse Blossom: correcting a million errors per decoding round with local decoding," IEEE Transactions on Quantum Engineering, vol. 4, pp. 1 - 16, 2023.
- [2] H. Jung, I. Ali, and J. Ha, "Convolutional Neural Decoder for Surface Codes," IEEE Transactions on Quantum Engineering, vol. 5, pp. 1-13, Art. no. 3102513, Jun. 2024. DOI: 10.1109/TQE.2024.3419773.