2026 대학수학능력시험 수학 영역에서의 대규모 언어모델 평가 : 데이터 누출 제로 환경에서의 수학 능력 측정

Goun Pyeon[*], Inbum Heo[*], Jeesu Jung[*], Taewook Hwang[*], Hyuk Namgoong, Hyein Seo, Yerim Han, Eunbin Kim, Hyeonseok Kang, Sangkeun Jung[†]
Department of Computer Science & Engineering
Chungnam National University
{vusrhdns714, inbum10222, jisu.jung5, taewook5295, hyuk199, hyenee97, namu.rim2, eunbinkim777, dnfldjaak11, hugmanskj}@gmail.com

ABSTRACT

본 연구는 2026학년도 대학수학능력시험 수학 영역을 활용하여 데이터 누출이 완전히 배제된 환경에서 대규모 언어모델(LLM)의 수학 추론 능력을 체계적으로 평가하였다. 기존 벤치마크의 데이터 오염 문제를 해결하기 위해, 시험 문제 공개 직후 2시간 이내에 전체 46문항(공통과목 22문항, 선택과목 24문항)을 디지털화하여 평가를 수행함으로써 모델 학습 데이터 포함 가능성을 원천 차단하였다. 24개의 최신 LLM을 대상으로 입력 모달리티(텍스트, 이미지, 텍스트+도형)와 프롬프트 언어(한국어, 영어)를 체계적으로 변화시키며 다각도 평가를 실시하였다. 실험 결과, GPT-5 계열 모델은 일부 특정 입력 모달리티-프롬프트 언어 조합에서 만점(100점)을 기록했으며, Grok 4, Qwen 3 235B, Gemini 2.5 Pro 등 여러 모델도 97점 이상을 기록하였다. 특히 gpt-oss-20B는 상대적으로 작은 모델 크기에도 95.7점을 기록하여 높은 비용 효율성을 입증하였다. 문제 특성별 분석 결과, 미적분 영역의 평균 성능이 가장 낮았으며, 특히 4점짜리 고난도 문항에서 뚜렷한 성능 저하가 관찰되었다. 입력 조건별로는 텍스트 입력이 이미지 입력 대비 높은 성능을 보였으며, 프롬프트 언어의 영향은 모델 규모에 따라 상이한 양상을 나타냈다. GPT-5 계열의 추론(Reasoning) 강화 실험에서는 추론 강도를 높일수록 성능은 향상되었으나(82.6점→100점), 토큰 사용량이 4-5배 증가하고 효율성이 급격히 저하되어 실용적 관점에서 적은 추론을 하는 모델이 더 합리적인 선택일 수 있음을 확인하였다. 본 연구는 (1) 완전한 비노출 평가 환경의 구현, (2) 수능 시험지를 LLM 평가용 데이터로 표준화하여 변환하는 디지털 처리 파이프라인의 구축, (3) 성능 · 비용 · 시간을 종합적으로 고려한 실용적 평가 관점의 제시라는 세 가지 기여를 제공한다. 본 연구의 상세한 결과와 각 모델별 성능 비교는 2026학년도 한국 대학수학능력시험 LLM 평가 리더보드(https://isoft.cnu.ac.kr/csat2026/)에서 확인할 수 있다.

***K*eywords** 대규모 언어모델(LLM) · 모델의 수학적 추론 능력 및 효율성 · 프롬프팅 전략 · 비노출 수학 벤치마크

1 Introduction

대규모 언어 모델(Large Language Model, LLM)의 수학 추론 능력은 모델의 논리적 사고와 문제 해결 능력을 평가하는 핵심 지표로 자리 잡아왔다. 수학 문제는 명확한 정답과 구조적 논리를 요구하기 때문에, 모델의 실제 추론 능력을 평가하는 데 적합한 벤치마크 중 하나로 널리 활용되고 있다. 그러나 최근 모델들의 급격한 성능 향상과 더불어, 기존 평가 방식만으로는 LLM의 실질적인 수학 능력을 정확하게 식별하기 어렵다는 문제가 부각되고 있다.

특히, 광범위한 웹 기반 데이터로 학습되는 LLM의 특성상, 공개된 벤치마크 데이터 혹은 그와 유사한 형태의 자료가 훈련 과정에 노출되었는지를 확인하기 어렵다 [Min et al., 2022, Dodge et al., 2021]. 또한 평가용 벤치마크가 모델의 학습에 포함되지 않았더라도, 유사한 문제를 재서술(paraphrasing)하거나 합성(synthetic) 및 변형한 데이터가 학습 및 추론 과정에 사용되었을 가능성도 배제할 수 없다.

[*] These authors contributed equally.
[†] Corresponding author.

이러한 평가 벤치마크 데이터의 잠재적 노출은 모델의 실질적 성능을 왜곡하고, 모델이 일반화된 수학적 능력을 기반으로 문제를 해결한 것인지, 아니면 훈련 과정에서 노출된 패턴을 단순히 암기하여 답을 생성한 것인지 구분하기 어렵게 만든다. 즉, 특정 공개된 벤치마크에서 점수를 높이도록 LLM이 편향된 방식으로 학습되었을 가능성도 배제할 수 없다. 실제로 최근 연구들은 GPT-4, Claude 등 주요 LLM의 학습 데이터에 기존 벤치마크 문제가 포함되었을 가능성을 지적하고 있으며, 보고된 높은 성능이 순수한 추론 능력이 아닌 *암기 또는 패턴 학습의 결과*일 수 있음을 보인다 [Balloccu et al., 2024, Deng et al., 2024]. 따라서 진정한 수학 이해 및 풀이 능력의 검증을 위해서는 데이터 누출 가능성이 원천적으로 차단된 평가 데이터 세트가 필요하다.

이러한 맥락에서, 한국의 대학수학능력시험(Korean College Scholastic Ability Test, 이하 수능) 수학 영역 문제는 데이터 누출 제로 환경을 제공한다. 수능은 매년 국가 차원에서 출제되는 문제로 구성되어 있으며, 시험 직전까지 문제가 외부에 공개되지 않기 때문에, 시험 공개 이후 단시간 안에 모든 평가가 마무리된다면, 어떠한 LLM도 유사 문제를 학습 데이터에 포함할 수 없는 완전한 비노출 평가 환경을 보장한다. 또한 수능 수학은 공통과목 및 선택과목으로 구성된 총 46개 문항을 통해 확률과 통계, 미적분, 기하 등 다양한 수학 영역을 포괄하고 있어, 실제 수학 교육과정 전반에 대한 모델의 실질적 수학 능력을 폭넓게 측정할 수 있다.

본 연구는 데이터 오염(data contamination)이 완전히 배제된 환경에서 최신 LLM의 실질적 수학 추론 능력을 체계적으로 검증하고, 다양한 실험 조건에 따른 모델의 수학 문제 해결 특성을 다각도로 분석하기 위해 2026학년도 대학수학능력시험 수학 영역을 활용한 새로운 평가 프레임워크를 구축하였다. 시험 문제 공개 직후 2시간 이내에 원본 데이터를 수집 및 정제하여 평가를 수행함으로써, 어떠한 모델의 학습 과정에도 포함될 수 없는 *비노출 (non-exposure) 수능 벤치마크*를 구현하였다. 또한 LLM의 단순 정답률 비교를 넘어, 입력 모달리티, 프롬프트 언어, reasoning 설정, 풀이 시간 등 다양한 조건을 통제하여 LLM이 실제 시험 문항을 어떻게 이해하고 처리하는지를 다각도로 분석할 수 있도록 설계되었다.

본 연구는 다음 4가지 연구 질문(Research Question, RQ)에 초점을 맞춘다.

- **RQ1. 2026년 현재 LLM의 수학 문제 풀이 능력은 어떠한가?**
- **RQ2. LLM은 어떠한 유형의 수능 수학 문제에 가장 취약한가?**
- **RQ3. 입력 조건에 따라 LLM의 수학 성능은 어떻게 달라지는가?**
- **RQ4. Reasoning 강도의 변화가 LLM의 성능에 미치는 영향은 무엇인가?**

본 연구 결과, GPT-5 계열의 모델이 유일하게 만점을 달성하는 등 최신 LLM들이 수능 수학에서 90점 이상의 높은 성능을 보였으나, 대부분의 모델에서 기하 영역과 4점 고난도 문항 그중에서도 4점 단답형 문항에서 성능이 현저히 낮았다. 입력 조건별로는 텍스트 입력이 이미지 입력보다 우수했으며, GPT-5의 추론(Reasoning) 강화 실험에서는 성능이 82.6점에서 100점으로 향상되었으나 토큰 사용량이 4-5배로 증가하여 효율성이 급격히 저하되었다. 특히 소규모 모델인 gpt-oss-20B가 95.7점의 높은 성능과 최저 비용($0.01)으로 압도적인 비용 효율성을 달성한 점은 주목할 만하며, 이는 모델 규모가 수학 성능의 절대적 요인이 아님을 시사한다.

본 논문의 구성은 다음과 같다. 섹션 2에서는 수학 벤치마크 및 LLM 평가 관련 연구를 검토한다. 섹션 3에서는 2026학년도 수능 문항의 구조 분석과 함께, Korean CSAT-Math 기반 평가 프레임워크를 소개하고, 데이터 구축 파이프라인 및 프롬프트 설계 방식을 상세히 설명한다. 섹션 4에서는 평가 대상 모델 및 실험 환경을 제시한다. 섹션 5에서는 네 가지 연구 질문(RQ1–RQ4)에 기반한 실험 설계와 결과를 설명한다. 마지막으로 섹션 6에서는 주요 실험 결과와 그 해석을 논의한다. 섹션 7에서는 본 연구의 주요 한계점을 다루며, 섹션 8에서는 본 연구의 핵심 발견을 종합적으로 정리하고, 향후 연구 방향을 제시한다.

2 Related Work

2.1 LLM을 위한 수학 벤치마크 연구

최근 대규모 언어 모델(LLM)의 수학적 추론 능력을 검증하기 위해 다양한 평가 벤치마크가 제안됐으며, 이는 크게 **(1) LLM 성능 평가를 위해 별도로 구축된 벤치마크**와 **(2) 실제 시험 문항을 활용한 LLM 평가 벤치마크**로 구분된다.

첫 번째 유형인 LLM 전용 평가 벤치마크는 모델의 연산 · 추론 능력을 정밀하게 측정하도록 설계된 데이터셋이다. GSM8K [Cobbe et al., 2021]는 초–중등 난이도의 서술형 수학 문제를 통해 기본적인 수치 계산 및 짧은 chain-of-thought 추론 능력을 평가한다. CHAMP [Mao et al., 2024]는 힌트와 풀이 단계를 포함하여 모델이 외부 정보에 얼마나 의존하는지를 분석할 수 있도록 구성되었으며, GSM-Plus [Li et al., 2024]는 문제 재서술과 수치 교란을 활용하여 견고성과 분포 이동(robustness)을 측정한다. 최근에는 MathVista [Lu et al., 2024]와 MATH-Vision [Wang et al., 2024]처럼 시각 정보를 포함한 문제를 활용해 시각–언어 통합 기반의 추론 능력을 평가하려는 멀티모달 벤치마크가 제안되고 있다.

두 번째 유형은 실제 시험 문항을 기반으로 LLM의 수학 문제 해결 능력을 평가한다. SAT, GRE, AMC, AIME, IMO 등 국제 시험이 널리 활용되며, 대표적인 LLM 수학 능력 평가 벤치마크[3]는 AIME 시험 문제를 활용한다. 또한 MATH [Hendrycks et al., 2021], MathBench [Liu et al., 2024], OlymMATH [Sun et al., 2025], U-MATH [Chernyshev et al., 2024] 등은 실제 시험지에서 발췌한 문제를 포함하여 모델의 수학적 개념 이해와 논리 구조화를 평가한다. 이러한 연구들은 단순 정답률을 넘어 풀이 과정의 논리성, 설명의 명확성 등 질적 요소까지 평가 범위를 확장하고 있으나, 대부분 서구권 시험과 영어 기반 문제들에 편중되어 있다는 한계가 남아 있다.

이에 본 연구는 수능 수학 문제를 활용하여 비영어권 교육 환경에서 LLM의 수학적 문제 해결 능력을 체계적으로 평가하고자 한다. 수능은 한국의 대학 입시를 위한 국가 단위 시험으로, 매년 약 50만 명 이상이 응시하며, **전 국민적 표준 시험으로서 높은 공정성 · 신뢰도 · 난이도 균형을 갖춘 대표적 평가 체계**이다. 본 연구에서는 공통과목(22문항)과 선택과목(24문항)을 모두 포함한 총 46문항을 활용하여, 기하 · 미적분 · 확률과 통계 등 다양한 수학 영역을 포괄하는 **종합적 평가**를 수행한다.

2.2 LLM 평가에서의 데이터 누출 문제

LLM 성능 평가에서 **데이터 누출(data leakage)**은 모델 신뢰도에 중대한 영향을 미치는 핵심 문제로, 수학 및 언어 모델 벤치마크 연구 전반에서 활발히 논의되고 있다.

Xu et al. [2024]은 GSM8K, MATH 등 주요 수학 벤치마크가 최신 LLM의 학습 데이터에 실제 포함되었음을 확인하고, 31개 모델에서의 누출 사례를 체계적으로 보고하였다. 또한 Hidayat et al. [2025]은 MMLU와 HellaSwag 등 대규모 벤치마크에서 오염률을 정량화하였으며, Balunović et al. [2025]는 비공개 수학 경시대회 문제(MathArena)로 평가할 경우 기존 공개 벤치마크 대비 성능이 크게 하락함을 보여주었다. 이러한 결과는 기존 모델의 평가 벤치마크가 모델의 추론 능력을 순수하게 평가하지 못한다는 가능성을 보여준다.

이에 본 연구는 **2026학년도 수능 수학 문제가 공개된 직후** 데이터를 수집 및 가공하고 즉시 모델 평가를 수행함으로써, 어떤 LLM 모델의 학습 데이터에도 포함될 수 없는 완전한 비노출(non-exposure) 환경을 구현한다. 이 과정은 벤치마크 평가 데이터가 LLM 모델의 학습에 포함될 가능성을 원천적으로 차단하며, **사전 노출이 불가능한 실제 시험 문항을 활용함으로써 모델의 수학적 추론 능력을 보다 명확하고 신뢰성 있게 검증**할 수 있다.

2.3 모델의 입력 모달리티와 프롬프팅 언어에 관한 기존 연구

LLM의 성능은 모델 구조뿐 아니라 **입력 모달리티(input modality)**와 **프롬프팅 언어(prompting language)**에 의해 크게 영향받는 것으로 알려져 있다. 초기 LLM은 텍스트 기반 입력 처리에 최적화되어 있었으나, 최근에는 이미지 · 도표 · 수식 등 시각적 정보를 함께 처리하는 **멀티모달 LLM**이 등장하며, 시각 정보가 포함된 수학 문제에 대한 추론 능력을 분석하는 연구가 활발해지고 있다 [Lu et al., 2024, Wang et al., 2024].

프롬프팅 언어 역시 성능 변화의 중요한 요인으로 보고된다. 다국어 프롬프팅(multilingual prompting) 연구들은 동일한 문제라도 제시 언어에 따라 모델의 chain-of-thought 구조, 추론 경로, 해결 전략이 달라질 수 있음을 보여주었으며, 일반적으로 영어 프롬프트가 더 높은 안정성과 정확도를 보인다는 결과가 보고되고 있다 [Park et al., 2025, Zhou et al., 2025].

본 연구는 이러한 선행 연구를 바탕으로, 실제 시험 기반 환경에서 모델의 입력 모달리티와 프롬프팅 언어에 대한 모델의 성능 변화를 살펴본다. 수학 영역을 대상으로 입력 모달리티(텍스트, 이미지, 텍스트+시각 정보)와 프롬프팅 언어(한국어 · 영어)를 교차 구성하여 모델의 수학적 추론 능력을 다각도에서 평가 및 분석하였다.

2.4 모델의 추론(Reasoning) 방식과 추론 평가에 관한 기존 연구

LLM의 **Reasoning** 연구는 모델이 정답을 생성하기 전에 수행하는 **추론 과정(Reasoning Process)**을 어떻게 유도, 조절, 평가할 것인가에 초점을 맞춘다. Zero-shot Chain-of-Thought(CoT) [Kojima et al., 2022]는 별도의 미세조정 없이 "Let's think step by step"과 같은 간단한 문구만으로 단계적 추론을 유도할 수 있음을 보여주었다. [Wang et al., 2022]는 서로 다른 추론 경로를 병렬로 생성한 뒤 다수결 방식으로 최종 답을 선택하는 전략을 제안하며, 추론의 안정성과 일관성을 향상했다.

추론 강도를 조절하는 연구도 활발하다. Snell et al. [2024]는 추론량이나 깊이를 늘리는 **test-time scaling** 기법을 통해 더 깊은 추론을 수행하도록 유도할 수 있음을 보였으며, Zhou et al. [2025]는 다양한 추론 유형과 사고 경로를 시각화해 모델의 추론 품질을 질적으로 분석하였다. 이러한 연구들은 추론 길이와 성능 간의 관계가 단순 선형적이지 않으며, 과도하게 긴 추론 오히려 오류를 누적시킬 수 있다는 점을 공통적으로 지적한다.

본 연구는 이러한 기존 관찰을 실제 시험 기반 환경에서 정량적으로 검증한다. 동일한 수능 문항을 대상으로 추론 모드(예: `reasoning_effort`)를 체계적으로 조절하여, 추론 강도 변화가 모델의 성능과 비용 사이에서 어떤 *trade-off*를 형성하는지 분석한다.

[3] `https://artificialanalysis.ai/evaluations/aime-2025`

표 1: 수능 수학 영역 (CSAT-Math) 문항 구성 및 유형

		공통과목	선택과목			합
세부 과목		수학I + 수학II	확률과통계	미적분	기하	
총 문제 수		11 + 11개	8개	8개	8개	46개
문항 유형	5지선다형	15개	6개	6개	6개	33개
	단답형	7개	2개	2개	2개	13개
배점 구성	2점 문항	2개	1개	1개	1개	5개
	3점 문항	6개	4개	4개	4개	18개
	4점 문항	14개	3개	3개	3개	23개
총점		2*2 + 3*6 + 4*14 =74점	26점	26점	26점	152점

3 대학수학능력시험-수학 (Korean CSAT-Math) LLM 평가 프레임워크

3.1 수능 개요

한국의 대학수학능력시험(Korean College Scholastic Ability Test, 이하 수능)은 한국교육과정평가원(Korea Institute for Curriculum and Evaluation, KICE)에서 출제하는 국내에서 가장 높은 공신력을 갖는 국가 단위 평가로, 학생들이 대학 교육에 필요한 수학(受學) 능력을 갖추었는지 측정하기 위한 시험이다[4].

수능은 매년 한 차례 시행되는 국가 단위의 대학 입시 시험으로, 수십만 명의 수험생이 이를 준비한다. 때문에 이 시험은 사회적 영향력도 매우 커, 2025년 11월 13일에 시행된 '2026학년도 수능' 의 경우, 아침에 등교하는 학생들을 위해 직장인들의 출근 시간이 미뤄지기도, 영어 듣기 평가 시 소음을 줄이기 위해 전국 모든 항공기의 이·착륙이 제한되기도 한다[5].

수능은 이처럼 중요도가 매우 높은 시험인 만큼, 문제 유출 방지에 큰 노력을 기울이고 있다. 모든 출제 위원과 점검 위원들은 수능 날짜 약 40일 전부터 비공개된 장소에 모여 외부와 단절된 공간에서 출제 및 검토를 수행한다[6]. 이와 같이 문제 출제 및 검토 과정, 나아가 문제지 인쇄 및 운송 전 과정이 엄격한 보안 관리가 이루어지고 있기 때문에 수능 문제는 사실상 **사전 유출이 거의 불가능한 시험**으로 여겨진다.

수능 시험 영역은 국어 영역, 수학 영역, 영어 영역, 한국사 영역, 탐구 영역(사회 탐구, 과학 탐구, 직업 탐구)으로 총 다섯 가지 영역으로 이루어진다. 본 연구에서는 이 중 **수학 영역**만을 대상으로 LLM을 평가하고자 하였다.

2022학년도 이후 수능 수학 영역(CSAT-Math)은 공통 과목(수학 I · 수학 II) 22문항과 선택 과목(확률과통계 · 미적분 · 기하) 중 하나를 선택하여 응시하는 8문항으로 총 30문항을 100분 동안 풀이하도록 설계되어 있다.

한편, 본 연구에서는 특정 선택 과목에 국한되지 않고 모델의 전반적인 수학 능력과 과목 간 추론 특성을 종합적으로 분석하기 위해, 공통 과목(22문항)과 3개의 선택 과목(각 8문항)을 모두 포함한 총 46문항을 사용하여 모델을 평가하였다.

표 1은 전체 문항 구성, 유형별 문항 수, 그리고 문항별 배점을 정리한 것으로, 각 항목은 다음과 같다:

- **공통 과목 (22문항)**: 모든 수험생이 필수로 응시하며, 수학 I(11문항)과 수학 II(11문항)로 구성된다.
- **선택 과목 (8문항)**: 수험생은 확률과통계, 미적분, 기하 중 하나를 선택하여 응시한다.
- **문항 유형**: 5지선다형과 단답형으로 구분된다.
  - **단답형**: 선택지가 제공되지 않고, 수험생이 직접 0-999 범위의 정수 내의 답을 도출해야 한다.
  - **5지선다형(객관식)**: 1-5번에 해당하는 보기 선택지가 제공되고, 그중 하나의 번호를 선택하여 답을 도출해야 한다.
- **배점 구성**: 문항별로 배당된 점수(2점, 3점, 4점)로, 문제의 요구 사고 수준 및 풀이 복잡도를 반영한다.

[4] https://suneung.re.kr/sub/info.do?m=0101&s=suneung

[5] https://www.yna.co.kr/view/AKR20251111058900003

[6] https://www.news1.kr/society/education/5973136

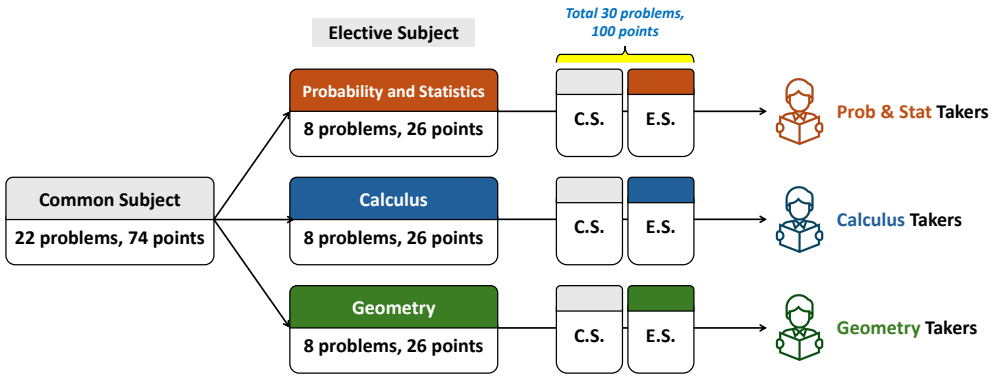

그림 1: 수능 수학 영역의 공통과목-선택과목 구조

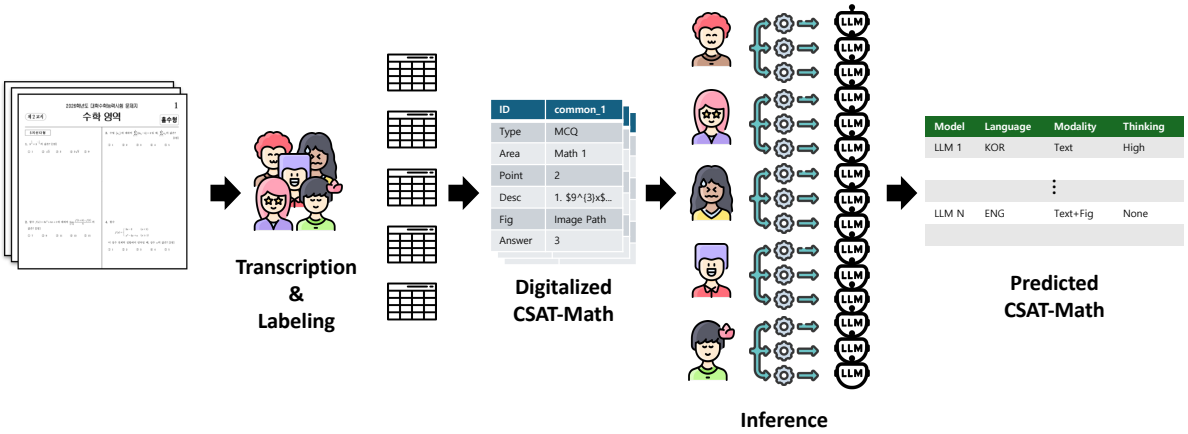

그림 2: 수동 평가 말뭉치 구축 (전사 및 라벨링 작업과 LLM 평가 파이프라인)

2026학년도 수능 학습 방법 안내[7]에 따르면, 각 과목은 다음과 같은 범위를 다룬다:

- **공통 과목**
  - **수학I**: 지수함수와 로그함수, 삼각함수, 수열
  - **수학II**: 함수의 극한과 연속, 미분, 적분
- **선택 과목**
  - **확률과 통계**: 경우의 수, 확률, 통계
  - **미적분**: 수열의 극한, 미분법, 적분법
  - **기하**: 이차곡선, 평면벡터, 공간도형과 공간좌표

수능 수학은 출제 범위와 문항 유형, 난이도가 체계적으로 설계되어 있어 LLM의 수학적 추론 능력을 평가하기에 적합한 구성을 가진다. 이러한 체계적 구성은 수험생에게 공통 과목에서 선택 과목으로 이어지는 응시 체계를 기반으로 하며, 그림 1는 이와 같은 수학 영역의 전체 출제 구성을 도식화한 것이다.

3.2 데이터 구축 파이프라인

본 평가 방법은 현 모델들의 사전 훈련 가능성 **완전 배제**를 목표로 설계되었다. 이를 위해 우리는 시험 문제가 공개된 직후 2시간 이내에 LLM 평가 데이터로 구축하고 평가를 시작하여 사전 데이터 유출 가능성을 최소화하였다. 총 7명의 연구진(작업자 6명, 검수자 1명)이 수동 평가 말뭉치 구축에 참여하였으며, 8명이 LLM 평가 및 모니터링 과정에 참여하였다. 그림 2은 시험 문제 공개 직후 진행된 전체 파이프라인을 보인다.

구체적인 데이터 구축 순서는 다음과 같다.

[7] https://www.suneung.re.kr/boardCnts/fileDown.do?fileSeq=ead4803d0df8cda516056b38fef4c7ae

1. 데이터 입력용 Digitalized CSAT-Math 양식 및 담당 문항을 작업자에게 배분
2. 문제지 및 정답 공개 직후[8] 각 인원이 할당받은 문항별로 정보 추출
3. 검수자 1인이 취합하여 오류 및 일관성 검토
4. 하나의 Digitalized CSAT Math 형식 데이터로 완성

3.3 2026학년도 수능 수학 문제지 구성

실제 수능 수험생들에게 배포되는 수능 수학 문제지는 다음과 같이 구성된다.

- 과목: 공통과목과 선택과목(확률과통계, 미적분, 기하)으로 구분된다.
- 문제 유형: 문제에 대한 유형 설명으로, 해당 유형이 시작되는 문제의 상단에 표기되어있다.
- 문제 지문: 문제에 대한 설명으로, 문제 번호 및 배점과 함께 표기된다.
- 배점: 문제별로 배당된 점수를 뜻한다. 2점, 3점, 4점 세 가지로 나뉜다.
- 문제 시각 자료: 문제 지문과 더불어 제공되는 도형이나 그래프 또는 그림 자료이다.
- 표: 일부 소수의 문제에서 제공되는 표. (주로 확률과통계 과목에서 z-score 표로 등장한다.)
- 선택지: 5지선다형 문제에서 정답 후보 항목들. (1부터 5까지 원 문자와 함께 실제 답이 제공된다.)

3.3.1 Digitalized CSAT-Math 데이터 구조

평가 말뭉치 작업 인원은 각자 부여된 문항에 대해서 문제지를 분석하여 아래의 Digitalized CSAT-Math에 데이터를 입력한다.

- `prob_id`: 문제 고유 번호. 예를 들어, `2026_odd_common_11`은 2026학년도 수능 수학의 홀수형 시험지 중 공통과목 부분 11번 문제를 뜻하고, `2026_odd_probability_30`은 2026학년도 수능 수학의 홀수형 시험지 중 확률과통계 부분 30번 문제를 뜻한다.
- `prob_type`: 문제 유형. 5지선다형 또는 단답형 중 하나이다.
- `prob_area`: 과목. 공통과목을 세분화한 수학1, 수학2와 확률과통계, 미적분, 기하 다섯 가지로 이루어진다.
- `prob_point`: 배점. 2점, 3점, 4점 세 가지로 구성된다.
- `prob_desc`: Markdown + LaTeX으로 변환된 문제 본문.
- `prob_img_path`: 문제 전체를 잘라낸 이미지 경로.
- `prob_fig_img_path`: 문제 시각 자료만 잘라낸 이미지 경로.
- `answer`: 정답 (5지선다형은 1-5, 단답형은 0-999 범위 정수)

`prob_id`, `prob_type`, `prob_point`의 세 정보는 2022학년도 수능부터 이번 2026학년도 수능까지 모두 고정값을 갖는다. 예를 들어, `prob_id`(문제 번호)는 1번부터 22번까지 공통과목 문제로 고정, 23번부터 30번까지는 확률과통계·미적분·기하의 총 세 개 세트로 고정된다. 또 `prob_type` 및 `prob_point` 또한 2022학년도 수능부터 2026학년도 수능까지 동일한 문항 번호에 대해 서로 같은 값을 유지한다. 따라서, 수동 평가 말뭉치 구축 인원은 고정된 몇몇 값을 제외하고 `prob_area`, `prob_desc`, `prob_img_path`, `prob_fig_img_path`, `answer`의 다섯 가지 정보를 입력하도록 안내받았다.

3.4 Digitalized CSAT-Math 데이터 구축 방법

본 연구의 데이터 구축 과정의 목적은 (1) **원본 문제지의 구조와 수학적 표현을 최대한 그대로 보존**하면서도, (2) 이후 **LLM 입력으로 바로 사용할 수 있을 만큼 일관된 형식으로 표준화**하는 것이다.

Digitalized CSAT-Math데이터를 구축하는 데에는 총 7명이 참여하였다. 전체 46문항에 대해 4명은 각각 9문항씩, 1명은 10문항을 담당하여 `prob_desc`, `answer`, `prob_area` 태깅을 수행하였으며, 별도로 1명이 문제 이미지 및 도형 이미지 추출 작업을 전담하였다.

[8] 한국교육과정평가원 사이트(`https://cdn2.kice.re.kr/suneung-26/index.html`를 통해 오후 2시 10분에 대중에 공개됨

3.4.1 문항별 텍스트 데이터 구축

본 연구에서는 PDF 형태의 수능 수학 문제를 LLM 모델 입력으로 활용하기 위해, 모든 문항을 텍스트로 전사하였다. 이를 위해 각 문제의 지문과 선지, 배점, 보기, 표, 수식 정보를 Digitalized CSAT-Math 형식의 `prob_desc` 필드에 기록하였다. `prob_desc`는 각 문항의 "사람이 읽는 문제지"를 텍스트만으로 재현한 정보이다.

Markdown을 활용한 문제 정보 추출 Markdown은 복잡한 문서 구조를 텍스트만으로 간단하게 표현할 수 있게 만든 규칙이다. 예를 들어, '>'는 인용구(박스), '| a | b |'와 같은 형식은 표를 나타낸다. 이러한 규칙은 HTML이나 PDF처럼 복잡한 형식을 쓰지 않고도, 텍스트 파일만으로 문서의 구조를 쉽게 표현할 수 있다.

수능 수학 문제에서는 <보기> 박스(그림 3의 f, i), 선지(①–⑤)(그림 3의 b, d), 표(그림 3의 k) 등 다양한 구조적 요소가 등장한다. 이를 일반 텍스트로만 옮기면 구조가 무너지거나 의미가 불명확해지는 경우가 많다. 반면 Markdown을 사용하면 PDF 상에서 <보기> 상자, 표 등으로 표현되던 구조적 요소가 정보 손실 없이 자연스럽게 표현된다.

예를 들어, 일반 문단은 평문으로(그림 3의 a, c, h), 인용 상자 형태의 <보기>는 인용구 기호(>)를 사용하여 나타냈다(그림 3의 f, i). 이와 같이 Markdown을 사용하면, 텍스트만으로도 문제의 레이아웃과 구조를 원본과 유사하게 재현할 수 있으며, 이후 마크다운 편집기를 통해 실제 문제지와 거의 동일한 형태로 시각화할 수 있다.

LaTeX문법을 이용한 수식 표현 본 실험에서는 모든 수식을 LaTeX문법으로 변환하여 사용하였다. 이는 LaTeX이 수학적 기호와 구조를 표현할 수 있는 형식이며, LLM이 문장과 수식의 경계를 명확하게 인식하도록 돕기 위함이다. 문장 중간에 등장하는 짧은 수식은 인라인 수식(`$...$`)으로(그림 3의 f, g, j), 한 줄 전체를 차지하는 주요 수식이나 계산 과정은 블록 수식(`$$...$$`)으로 구분하여 표기하였다(그림 3의 e).

LaTeX수식은 실제 수능 문제지에 인쇄된 수식과 최대한 유사하게 작성하였다. 점을 나타내는 기호는 `\mathrm{P}`처럼 `\mathrm{}` 명령어를 사용하여 이탤릭체가 아닌 일반 서체로 표기하였고(그림 3의 c), 벡터와 선분 길이는 각각 `\vec{AB}`, `\overline{AB}`와 같은 LaTeX명령어로 표현하였다. 극한(`\lim`)이나 시그마(`\sum`) 기호의 위아래에 지수가 붙을 때는 `\limits`를 명시하여, 실제 문제지에서와 같이 위/아래에 범위가 표시되도록 조정하였다(그림 3의 f).

문제 구성 요소(번호, 배점, 선지) 표현 각 문항의 문제 번호, 배점(예: [4점]), 선지(5지선다형의 경우 ①–⑤), 단답형 여부 등은 모두 원문을 그대로 반영하여 텍스트로 옮겼다. 예를 들어, 문항 시작 부분의 "11."과 끝부분의"[3점]" 표기는 그대로 전사하고(그림 3의 a, c 등), 선택형 선지는 "① 2 ② 3 ③ 4 ④ 5 ⑤ 6"과 같이 원문자(①②③④⑤)를 포함한 형태로 기록하였다(그림 3의 b, d).

3.4.2 문항별 메타데이터 구축

본 연구에서는 LLM이 문제를 풀이할 때 직접적으로 인식할 수 없는, 즉 시험지에 명시되어 있지 않지만 평가 분석에 필요한 정보를 **메타데이터**로 정의하였다. 이러한 메타데이터에는 문항의 실제 출제 영역(수학I/수학II/선택과목)과 정답이 포함된다.

문항별 실제 출제 영역 섹션 3.1에서 설명한 것과 같이, LLM에 직접 입력되지는 않더라도 수능 문제는 크게 공통과목과 선택 과목으로 이루어진다. 공통 과목은 수학I과 수학II 두 가지 과목에서 각각 11문제씩 총 22문제가 출제된다. 이때 22개 문항은 시험마다 동일한 순서로 배치되지 않는다. 따라서 문항 번호만으로는 해당 문제가 수학I에서 출제된 것인지, 혹은 수학II에서 출제된 것인지 알 수 없다. 반면 배점($2 \cdot 3 \cdot 4$점)이나 문제 유형(단답형 $\cdot$ 5지선다형)은 문항별로 고정된다.

또한, 공통 과목(1–22번)에 대해서는 각 문항의 실제 출제 범위(`prob_area`)를 사람이 직접 확인하는 절차가 필요하였다. 특히, 해당 정보는 공식적으로 제공되지 않기 때문에, 본 연구에서는 해당 구간의 모든 문항에 대해 수학I 또는 수학II 중 어느 과목에서 출제되었는지 일일이 식별하고 이를 데이터로 구축하였다.

문항별 실제 정답 `answer` 필드는 각 문항의 정답을 위한 필드이다. 선택형 문항의 경우, 원문에서는 선지가 ①–⑤와 같은 원문자로 제시되지만, `answer`에는 해당 선지 번호를 정수로 변환하여 기록하였다(예: ① $\rightarrow$ 1, ⑤ $\rightarrow$ 5). 단답형 문항의 경우, 문제지에 제시된 정답을 그대로 정수(또는 필요한 경우 정수 표현)로 입력하였다. 이와 같이 모든 정답을 일관된 정수 형태로 표현함으로써, 서로 다른 문제 유형(5지선다형, 단답형)에 대해 동일한 형식의 정답 비교 및 채점 규칙을 적용할 수 있도록 설계하였다.

3.4.3 이미지 데이터 구축

이미지 추출 실제 수능 수학에는 줄글로 된 문제와 더불어 도형이나 그림 등의 시각적 요소가 문제에 포함된다. 2026학년도 기준으로 46개의 문항 중 8문제에 **시각적 요소가 존재**한다. 이러한 시각 자료는 학생들이 문제를 더 쉽게 이해하도록 돕는다. 본 연구에서는 시각 자료가 LLM의 수학 문제 풀이에 어떠한 영향을 미치는지 확인하기 위해 문제 원본 PDF로부터 두 종류의 이미지를 추출한다.

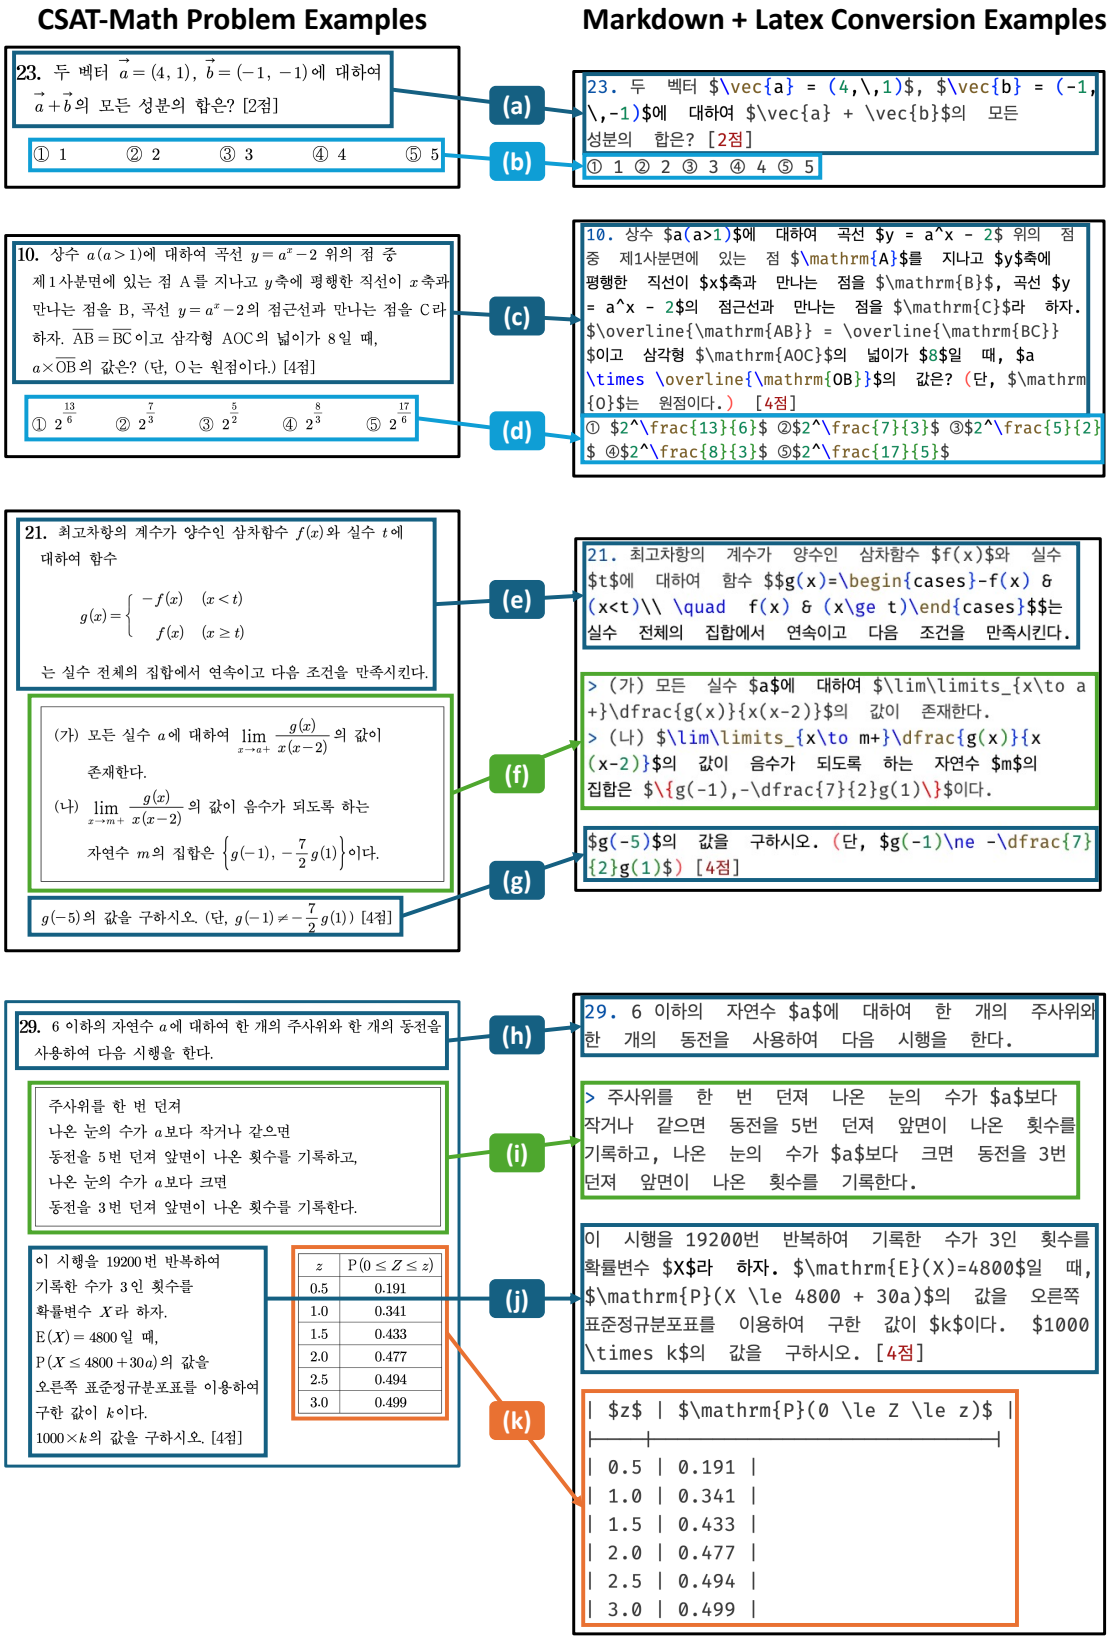

그림 3: 실제 수능 문제와 Digitalized CSAT-MAth 텍스트 변환 예제

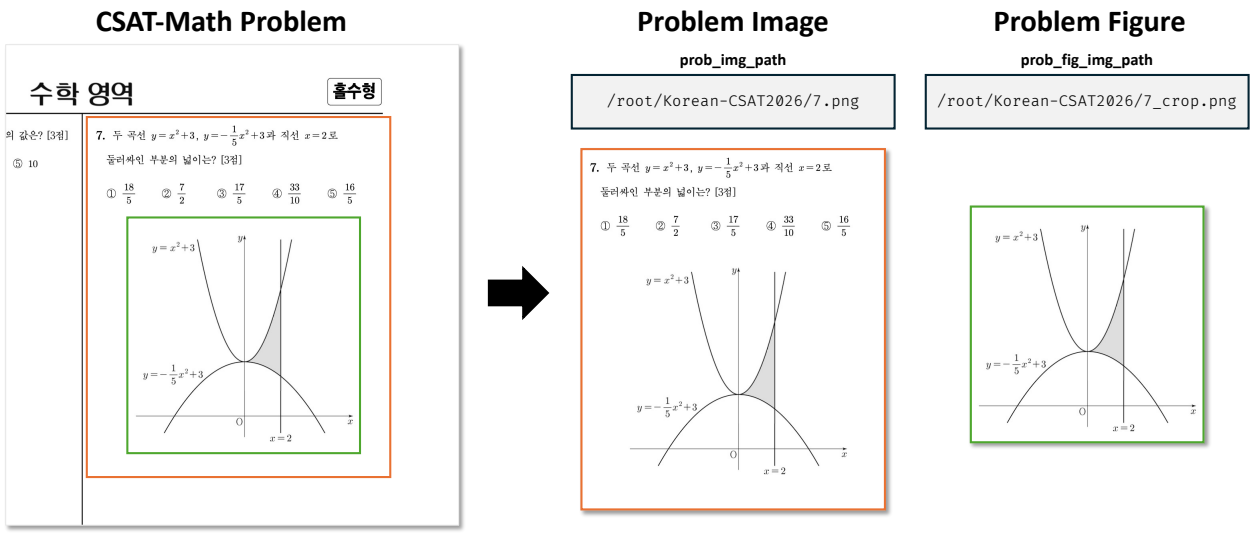

그림 4: 수능 수학 문제지에서 이미지 추출 예제

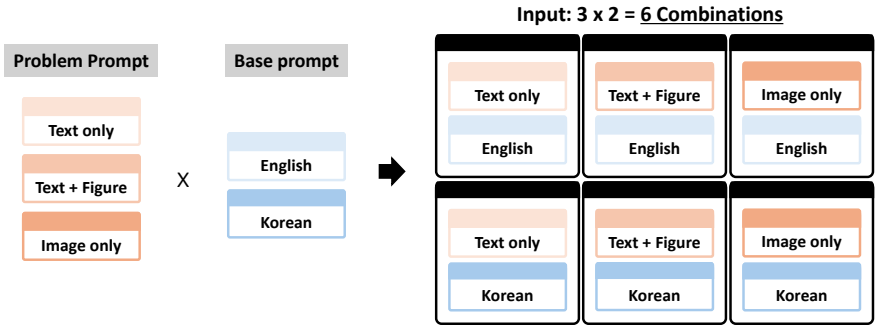

그림 5: 프롬프트 조합 예시

- Problem Image: 문제 전체 이미지 (`prob_img_path`)
- Problem Figure: 문제 내에 포함된 도형이나 그림 등 시각 자료 이미지 (`prob_fig_img_path`)

그림 4은 실제 태깅 과정에서 추출된 이미지 단위들을 예시로 보인다.

3.4.4 데이터 검수

작업자와 검수자 전원은 Markdown 편집기(Obsidian[9] 또는 StackEdit[10])를 활용하여 직접 문항별 정보를 렌더링하여 수능 수학 문제지와 직접 태깅한 텍스트가 시각적으로 일치하는지 1차로 검증하였다. 특히 Markdown+LaTeX 문법으로 작성된 수식, 텍스트, 이미지가 실제 모델 입력 형태와 동일하게 표시되는지 확인하였으며, 수식 표현의 정확성, 줄 바꿈 · 기호 · 레이아웃 등 시각적 요소가 실제 문제 정보와 일관되게 반영되었는지 검토하였다. 이후 관리 · 감독자(1명)이 전체 태깅 결과를 2차로 검수하여 데이터의 일관성과 정확성을 확보하였다.

3.5 문제 풀이 Prompt 템플릿

LLM에 입력되는 프롬프트 구성은 크게 '문제' 와 '풀이 지시문' 으로 이루어진다. '문제'는 수능 수학 문제를 입력해 주는 부분이고, '풀이 지시문' 은 수능 배경에 맞추어 수능에 맞게 LLM이 문제를 풀도록 지시하는 부분이다.

본 연구에서는 LLM의 멀티모달 처리 능력과 다국어 성능을 평가하기 위해, '문제' 입력 방식과 '풀이 지시문' 언어를 다양한 조합으로 구성하여 실험을 수행하였다. LLM에 입력되는 '문제' 입력 방식(입력 모달리티)은 3가지, '풀이 지시문' 입력 방식(언어)은 2가지로, 총 6가지 조합의 다양한 입력 방식을 이용하였다. 그림 5는 이러한 조합으로 총 6가지의 프롬프트를 구성하는 예제를 보인다.

[9] `https://obsidian.md/`
[10] `https://stackedit.io/`

Input Modality

Problem Prompt – Text only

26. 그림과 같이 곡선 $y = \sqrt{x + x\ln x}$와 x축 및 두 직선 $x = 1$, $x = 2$로 둘러싸인 부분을 밑면으로 하는 입체도형이 있다. 이 입체도형을 x축에 수직인 평면으로 자른 단면이 모두 정삼각형일 때, 이 입체도형의 부피는? [3점]

① $\displaystyle \frac{\sqrt{3}(3 + 8\ln 2)}{16}$ ② $\displaystyle \frac{\sqrt{3}(5 + 12\ln 2)}{24}$ ③ $\displaystyle \frac{\sqrt{3}(1 + 12\ln 2)}{16}$ ④ $\displaystyle \frac{\sqrt{3}(1 + 2\ln 2)}{4}$ ⑤ $\displaystyle \frac{\sqrt{3}(1 + 9\ln 2)}{12}$

Problem Prompt – Image only

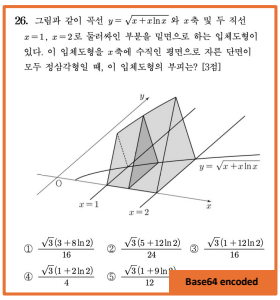

Problem Prompt – Text + Figure

26. 그림과 같이 곡선 $y = \sqrt{x + x\ln x}$와 x축 및 두 직선 $x = 1$, $x = 2$로 둘러싸인 부분을 밑면으로 하는 입체도형이 있다. 이 입체도형을 x축에 수직인 평면으로 자른 단면이 모두 정삼각형일 때, 이 입체도형의 부피는? [3점]

① $\displaystyle \frac{\sqrt{3}(3 + 8\ln 2)}{16}$ ② $\displaystyle \frac{\sqrt{3}(5 + 12\ln 2)}{24}$ ③ $\displaystyle \frac{\sqrt{3}(1 + 12\ln 2)}{16}$ ④ $\displaystyle \frac{\sqrt{3}(1 + 2\ln 2)}{4}$ ⑤ $\displaystyle \frac{\sqrt{3}(1 + 9\ln 2)}{12}$

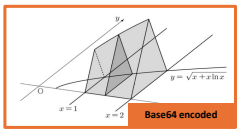

Prompt Language

Base Prompt – English

Solve this question.

Do these steps and SHOW your work:
1) Translate the problem into English.
2) Solve the problem with clear reasoning and calculations.
3) State the final answer.

MANDATORY: Write the FINAL answer on the LAST line in this exact format:
\\ boxed{answer}
Nothing after the boxed answer.

Type-specific output rules:
- Multiple-choice (five options): answer MUST be ONLY an integer 1–5.
- Short-answer: answer MUST be ONLY an integer in [0, 999], no units, no leading zeros.

Examples:
- MCQ → \\ boxed{3}
- Short-answer → \\ boxed{256}

Problem type: 5지선다형
Problem ID: 2026_odd_common_11

Base Prompt – Korean

다음 수학 문제를 풀어주세요.

아래 순서로, 과정을 반드시 보여주며 작성하세요:
1) 문제를 한국어로 정확히 이해하고 핵심 조건을 정리합니다.
2) 논리적 추론과 계산 과정을 단계별로 서술해 풀이합니다.
3) 최종 정답을 제시합니다.

필수: 마지막 줄에 아래 형식으로 '딱 한 줄'만 출력하세요:
\\boxed{{answer}}
박스 이후에는 아무 내용도 쓰지 않습니다.

문항 유형별 규칙:
- 객관식(5지선다): 정답은 1~5 중 하나의 '정수'만.
- 단답형: 정답은 0~999 범위의 '정수'만(단위/불필요한 0 금지).

예시:
- 객관식 → \\boxed{3}
- 단답형 → \\boxed{256}

Problem type: 5지선다형
Problem ID: 2026_odd_common_11

Example 1

Problem prompt: Text+Figure

Base prompt: Korean

Prompt

26. 그림과 같이 곡선 $y = \sqrt{x + x\ln x}$와 x축 및 두 직선 $x = 1$, $x = 2$로 둘러싸인 부분을 밑면으로 하는 입체도형이 있다. 이 입체도형을 x축에 수직인 평면으로 자른 단면이 모두 정삼각형일 때, 이 입체도형의 부피는? [3점]

① $\displaystyle \frac{\sqrt{3}(3 + 8\ln 2)}{16}$ ② $\displaystyle \frac{\sqrt{3}(5 + 12\ln 2)}{24}$ ③ $\displaystyle \frac{\sqrt{3}(1 + 12\ln 2)}{16}$ ④ $\displaystyle \frac{\sqrt{3}(1 + 2\ln 2)}{4}$ ⑤ $\displaystyle \frac{\sqrt{3}(1 + 9\ln 2)}{12}$

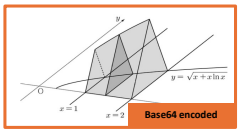

다음 수학 문제를 풀어주세요.

아래 순서로, 과정을 반드시 보여주며 작성하세요:
1) 문제를 한국어로 정확히 이해하고 핵심 조건을 정리합니다.
2) 논리적 추론과 계산 과정을 단계별로 서술해 풀이합니다.
3) 최종 정답을 제시합니다.

필수: 마지막 줄에 아래 형식으로 '딱 한 줄'만 출력하세요:
\\boxed{{answer}}
박스 이후에는 아무 내용도 쓰지 않습니다.

문항 유형별 규칙:
- 객관식(5지선다): 정답은 1~5 중 하나의 '정수'만.
- 단답형: 정답은 0~999 범위의 '정수'만(단위/불필요한 0 금지).

예시:
- 객관식 → \\boxed{3}
- 단답형 → \\boxed{256}

Problem type: 5지선다형
Problem ID: 2026_odd_common_11

Example 2

Problem prompt: Text+Figure

Base prompt: English

Prompt

26. 그림과 같이 곡선 $y = \sqrt{x + x\ln x}$와 x축 및 두 직선 $x = 1$, $x = 2$로 둘러싸인 부분을 밑면으로 하는 입체도형이 있다. 이 입체도형을 x축에 수직인 평면으로 자른 단면이 모두 정삼각형일 때, 이 입체도형의 부피는? [3점]

① $\displaystyle \frac{\sqrt{3}(3 + 8\ln 2)}{16}$ ② $\displaystyle \frac{\sqrt{3}(5 + 12\ln 2)}{24}$ ③ $\displaystyle \frac{\sqrt{3}(1 + 12\ln 2)}{16}$ ④ $\displaystyle \frac{\sqrt{3}(1 + 2\ln 2)}{4}$ ⑤ $\displaystyle \frac{\sqrt{3}(1 + 9\ln 2)}{12}$

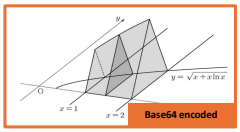

Solve this question.

Do these steps and SHOW your work:
1) Translate the problem into English.
2) Solve the problem with clear reasoning and calculations.
3) State the final answer.

MANDATORY: Write the FINAL answer on the LAST line in this exact format:
\\ boxed{answer}
Nothing after the boxed answer.

Type-specific output rules:
- Multiple-choice (five options): answer MUST be ONLY an integer 1–5.
- Short-answer: answer MUST be ONLY an integer in [0, 999], no units, no leading zeros.

Examples:
- MCQ → \\ boxed{3}
- Short-answer → \\ boxed{256}

Problem type: 5지선다형
Problem ID: 2026_odd_common_11

그림 6: 전체 프롬프트 예시

입력 모달리티 수능 수학 문제는 줄글로 된 설명뿐 아니라, 도형 또는 그래프 등 시각적 요소가 포함되는 경우가 있다. 따라서 본 연구에서는 다음 세 가지 입력 형태를 고려하였다:

- **텍스트(Text only)**: 문제를 순수 텍스트(prob_desc)로만 변환하여 입력한다. 섹션 3.4.1에서 설명한 방식으로 변환된 텍스트를 그대로 이용한다. 문제에 도형이나 그래프가 포함된 경우 해당 시각 정보는 제외된다. 이 조건은 모든 모델에서 기본적으로 수행된다.
- **이미지(Image only)**: 문제 영역 전체를 이미지(Problem Image)로 추출하여 입력한다. '문제'는 문제 번호, 지문, 선택지를 포함한 전체 문항이 하나의 이미지로 입력되며, '풀이 지시문' 함께 제공된다. 이 조건은 실제 시험지를 받아보는 수험생의 상황과 가장 유사하며, 모델의 텍스트 인식 능력과 이미지 이해에 기반한 수학 문제 풀이 능력을 평가한다. 이미지 입력이 불가능한 텍스트 전용 모델의 경우 평가에서 제외된다.
- **텍스트+도형(Text+Figure)**: 문제의 글자 영역은 텍스트(prob_desc) 입력과 동일하게 제공되나, 도형 또는 그래프 등의 시각적 요소(Problem Figure)는 별도 이미지로 함께 제공한다. 하이브리드 입력 방식으로, 텍스트 이해와 시각 정보 해석을 모두 요구하며 텍스트 전용 모델의 경우 평가에서 제외된다.

프롬프트 언어 LLM의 다국어 성능을 평가하기 위해, 동일한 문제에 대해 한국어와 영어 두 가지 언어로 '풀이 지시문' 프롬프트를 구성하였다:

- **한국어(Korean)**: '문제'와 '풀이 지시문'을 모두 한국어로 제공한다.
- **영어(English)**: '문제'는 한국어로 번역 없이 제공하나, '풀이 지시문'을 영어로 제공한다.

입력 모달리티와 언어를 조합하면 총 $3 \times 2 = 6$가지 조건이 생성되나, 모델의 이미지 입력 지원 여부에 따라 실제 실험에서는 일부 조건만 적용되기도 한다. 예를 들어, 텍스트 전용 모델은 (텍스트, 한국어), (텍스트, 영어) 조건에서만 평가되며, 멀티모달 모델은 6가지 조건에서 모두 평가된다. 사용된 전체 프롬프트 템플릿과 세부 조건에 대한 구성 예제는 그림 6에서 보인다.

4 CSAT-Math LLM 실험 설계

본 절에서는 전반적인 실험 설계를 제시한다. 구체적으로, (1) 평가에 사용된 LLM 목록 및 실행 환경을 기술하며, (2) 네 가지 핵심 연구 질문(RQ)에 따라 설계된 실험 목적과 절차를 설명한다.

4.1 모델 목록

수능 수준의 수학 추론을 다룰 수 있는 상위권 LLM을 대상으로 하되, 실제 서비스 환경에서의 활용 가능성을 고려하여 다음 기준을 만족하는 모델만 선정하여 평가하였다.

- **성능 기준**: 수학 능력을 사전 검증하기 위해 2025년 10월 5일을 기준으로 AIME 2025 벤치마크[11] 홈 화면에 선별 표시된 24개 모델만을 후보로 포함하였다. 이는 난이도가 높은 경쟁적 수학 벤치마크에서 기본적인 정답 생산 능력 및 인지도를 확보한 모델을 대상으로 수능 환경에서의 세부 특성을 비교하기 위함이다.
- **접근성**: 실험 과정의 편의성과 재현성을 높이기 위해, 본 연구에서는 2025년 10월 5일을 기점으로 OpenRouter를 통해 즉시 사용 가능한 모델만을 평가 대상으로 선정하였다. 이는 서로 다른 모델을 하나의 통일된 방식으로 호출함으로써 실험 구성을 간소화하고, 향후 동일한 실험을 재현하거나 확장하려는 연구자들이 동일한 인터페이스를 그대로 활용할 수 있도록 하기 위함이다.
- **배포 시점 기준**: 데이터 비누출(zero-leakage) 환경에서 평가하기 위해, 본 연구에서는 **2026학년도 수능(2025년 11월 13일) 직전까지 공개**된 모델만을 평가 대상으로 선정하였다. 즉, 수능 당일 이후에 출시되거나 업데이트된 모델은, 잠재적 학습 데이터 포함 가능성을 고려하여 제외하였다.
- **다양성**: 모델 종류가 편향되지 않도록, **상용 모델** (예: GPT 계열, Claude 계열, Gemini 계열 등)과 **오픈소스 모델** (예: Qwen, Llama, DeepSeek 계열 등)을 균형 있게 포함하였다. 또한 파라미터 규모(수십억 수천억 단위)와 아키텍처(전통적 LLM vs 추론 특화 모델)가 다른 모델들을 함께 평가함으로써, 같은 환경에서 모델 계열 · 규모에 따른 성능 차이를 분석할 수 있도록 하였다.

최종적으로 선정된 모델 목록과 각 모델의 공급사, 모델 사용 비용, 파라미터 규모, 추론 기능 지원 여부 등은 표 2에 정리하였다.

[11] `https://artificialanalysis.ai/evaluations/aime-2025`

표 2: LLM 모델 목록, 공급사, 가격, 규모, 및 Reasoning/Thinking 지원 여부. 1M Input은 OpenRouter 상에서 해당 모델의 공급사 기준 1 Million input token 당 가격, 1M Output은 1 Million output token 당 가격을 의미한다. 규모는 모두 활성 파라미터를 기준으로 하며, 규모가 공개되지 않은 경우 기존 성능 및 문서를 기반으로 추정하였다(∼* 표기). 추론 기능 지원 표기는 해당 모델이 지원할 경우 ✓, 미지원할 경우 –로 표기하였다.

유형		모델명	모델 공급사	1M Input	1M Output	규모	추론 기능 지원
Closed	GPT	GPT-5 Codex	openai	$1.25	$10.00	∼635B*	–
		GPT-5	openai	$1.25	$10.00	∼330B*	✓
		GPT-5-mini	openai	$0.25	$2.00	∼27B*	✓
		GPT-5-nano	openai	$0.05	$0.40	∼15B*	✓
	Grok	Grok 4	xai	$6.00	$30.00	∼213B*	✓
		Grok 4 Fast	xai	$0.40	$1.00	∼40B*	–
	Claude	Claude 4.5 Sonnet	anthropic	$6.00	$22.50	∼100B*	✓
		Claude 4.5 Haiku	anthropic	$1.00	$5.00	∼30B*	✓
		Claude 4.1 Opus	anthropic	$15.00	$75.00	∼400B*	✓
	Gemini	Gemini 2.5 Pro	google-vertex/global	$2.50	$15.00	∼128B*	✓
		Gemini 2.5 Flash	google-vertex/global	$0.30	2.50	∼27B*	–
Open	GPT	gpt-oss 20B	hyperbolic	$0.04	$0.04	3.6B	✓
	Qwen	Qwen3 235B A22B	siliconflow/fp8	$0.30	$1.50	22B	–
		Qwen3 235B A22B Thinking 2507	siliconflow/fp8	$0.45	$3.50	22B	✓
	Deepseek	Deepseek R1 0528	novita/fp8	$0.27	$0.41	∼37B*	✓
		Deepseek V3.2 Exp	novita/fp8	$0.70	$2.50	∼37B*	–
	GLM	GLM 4.6	z-ai	$0.60	$2.20	32B	–
	Magistral	Magistral Medium 2506	mistral	$2.00	$5.00	45B	–
		Magistral Medium 2506 Thinking	mistral	$2.00	$5.00	45B	✓
	MiniMax	MiniMax M2	minimax	$0.30	$1.20	∼10B*	–
	Llama	Llama 4 Maverick	friendli	$0.20	$0.60	17B	–
		Llama 3.3 Nemotron Super 49B V1.5	deepinfra/fp8	$0.10	$0.40	49B	–
	Kimi	Kimi K2 0905	moonshotai	$0.60	$2.50	32B	–
		Kimi K2 0905 Thinking	moonshotai	$0.60	$2.50	32B	✓

4.2 모델의 추론 능력 설정

최근 대규모 언어 모델은 단순한 패턴 매칭 기반 응답 생성에서 벗어나, 문제 구조를 분석하고 중간 사고 단계를 구성하는 추론(Reasoning) 기능을 점차 내장하고 있다. 본 연구에서는 Reasoning을 **"모델이 최종 답변을 생성하기 전에 내부적으로 수행하는 사고(thinking) 또는 단계적 추론 절차"**로 가정한다. 일반적으로 Reasoning 과정은 출력 텍스트와 독립적으로 Reasoning token을 소모한다.

최근 상용 · 오픈소스 모델들도 일부 추론 기능을 제공하기 시작했으나, 대부분은 전용 추론 모델을 별도로 두거나 제한된 수준의 옵션만을 지원한다. 즉, 사용자가 추론 강도를 세밀하게 조절할 수 있는 경우는 많지 않다. 이에 본 연구는 다양한 추론 설정을 체계적으로 비교하기 위해, 추론 강도와 설명 길이를 모두 조절할 수 있는 GPT-5 모델에 대해서만 별도의 Reasoning 실험을 수행하였다.

GPT-5는 추론 과정과 응답을 제어하기 위한 두 가지 설정을 제공한다: (1) `Reasoning_Effort`: 내부 추론 강도(생성되는 Reasoning token의 양), (2) `Text_Verbosity`: 최종 출력의 설명 길이. 두 설정값은 서로 독립적으로 작동하여, 같은 추론 강도에서 짧게 말할 수도 있고(high effort + low verbosity), 적은 추론을 하면서도 길게 설명할 수도 있다(minimal effort + high verbosity).

Reasoning_Effort GPT-5는 내부 추론 양을 다음의 네 가지 설정으로 구분한다.

- `minimal`: Reasoning token 사용 최소화, 가장 빠른 응답
- `low`: 기본적인 추론 수행, 간단한 문제 해결에 적합
- `medium`(기본값): 균형 잡힌 추론, 일반적인 수학 문제에 안정적
- `high`: 깊이 있는 추론, 어렵고 복잡한 문제 해결에 적합

Text_Verbosity LLM의 최종 출력 길이를 제어하는 기능으로, `Reasoning_Effort`와 독립적으로 설정된다.

- `low`: 간결한 답변, 풀이 과정 생략 가능
- `medium`(기본값): 일반적인 설명 수준
- `high`: 상세한 설명

표 3: GPT-5의 Reasoning Effort × Text Verbosity 조합별 특성

Effort	Verbosity	특징
minimal	low	최소 Reasoning × 짧은 출력
	medium	최소 Reasoning × 중간 길이 출력
	high	최소 Reasoning × 긴 출력
low	low	낮은 Reasoning × 짧은 출력
	medium	낮은 Reasoning × 중간 길이 출력
	high	낮은 Reasoning × 긴 출력
medium	low	중간 Reasoning × 짧은 출력
	medium	중간 Reasoning × 중간 길이 출력 (기본값)
	high	중간 Reasoning × 긴 출력
high	low	높은 Reasoning × 짧은 출력
	medium	높은 Reasoning × 중간 길이 출력
	high	높은 Reasoning × 긴 출력

`Reasoning_Effort` × `Text_Verbosity` **조합** GPT-5는 `Reasoning_Effort` 4단계와 `Text_Verbosity` 3단계를 독립적으로 결합하여 총 12개 조합을 구성한다. 표 3는 `Reasoning_Effort`와 `Text_Verbosity`의 각 단계 조합에 따른 응답 특징과, 활용 가능성에 관해 설명한다. 본 연구는 이 모든 조합을 별도의 실험 조건으로 설정하여, 수능 환경에서 각 설정 변화가 모델에 미치는 영향을 체계적으로 비교하였다.

4.3 API 및 서버 환경

모든 실험은 OpenRouter API[12]를 통해 수행되었으며, 일관된 평가를 위해 다음과 같은 하이퍼파라미터를 고정하였다:

- **Temperature**: 0.0
  Temperature는 모델이 답변을 생성할 때 얼마나 무작위성을 허용할지 조절하는 파라미터이다. 값이 높을수록 다양한 단어를 시도하며 출력이 달라질 가능성이 커지고, 값이 0에 가까울수록 항상 가장 가능성이 높은 단어만 선택하므로 답변의 일관성이 높아진다. 본 연구에서는 입력 모달리티(Text-only, Image-only, Text+Figure)와 프롬프트 언어(Korean, English)를 변화시키며 모델의 성능 차이를 분석하는 것이 핵심 목표이므로, Temperature를 0.0으로 고정하여 모델 응답의 무작위성에 의한 영향을 최소화하고자 하였다.
- **Top-p**: 0.0
  Top-p는 모델이 다음 단어를 선택할 때 고려하는 후보 범위(확률 누적 상위 p%)를 의미한다. Top-p 값을 높이면 더 다양한 후보를 고려하여 출력이 변할 가능성이 커지고, 0에 가까울수록 가장 확률이 높은 단어만 선택하게 되어 출력이 안정적이다. 본 연구에서는 sampling에 따른 변동성을 제거하기 위해 Top-p 역시 0.0으로 설정하여, 결정적(deterministic)인 출력을 얻도록 하였다.
- **Max tokens**: 제한 없음(모델의 최대 설정값)
- **재시도 정책**: API 오류가 발생하면 최대 5회까지 재시도하며, 재시도 간격은 지수 백오프(exponential backoff)[13] 전략을 적용하였다. 지수 백오프는 첫 번째 재시도는 짧은 시간 후에 수행하고, 이후 재시도할 때마다 대기 시간을 점진적으로 증가시키는 방식이다 (예: 5초 → 10초 → 20초 → 40초 . . .). 본 연구에서는 대규모 실험 환경에서도 안정적인 응답을 확보하기 위해 지수 백오프 기반의 재시도 전략을 적용하였다.
- **타임아웃**: 없음

실험은 총 8명의 연구진이 참여했으며, 개인 PC 또는 서버에서 수행되었다. 환경은 다음과 같다:

- **OS**: Ubuntu 22.04 LTS 또는 Window 10
- **언어 및 런타임**: Python 3.10
- **주요 라이브러리**:
  - `openai==2.8.0`: OpenRouter 호환 API 호출 및 응답 관리
  - `pandas==2.3.3` 실험 결과 구조화 및 리더보드 생성

[12] `https://openrouter.ai`
[13] `https://en.wikipedia.org/wiki/Exponential_backoff`

- **병렬화**: 최대 16개의 프로세스를 병렬 실행하였다. 각 프로세스는 python 명령어 한 줄로, 하나의 모델에 대해 지정된 입력 조합에 대해 1번 문항부터 46번 문항까지 차례대로 풀도록 하고 쉘 스크립트로 자동화된 방식으로 실행한다.

4.4 LLM 모델 응답 기록과 Preidcted CSAT Math 형식

문제 풀이 스크립트는 모든 호출을 문항 단위로 정보를 자동 기록한다. 기록되는 정보는 다음과 같다:

- API 요청 전문
- 모델 생성 응답 전문
- 정답 추출 결과
- 실제 응답 시간 (latency per problem, KST 기준)
- API 토큰 사용량(input / output / total)
- 오류 발생 시 오류 종류 및 재시도 횟수

Preidcted CSAT Math 형식은 아래와 같다:

- `prob_id`: 문제 고유 번호.
- `prob_type`: 문제 유형. [5지선다형 또는 단답형]
- `prob_area`: 문항 출제 범위. [수학1, 수학2, 확률과통계, 미적분, 기하]
- `answer`: 실제 문항 정답. [5지선다형은 1-5, 단답형은 0-999 범위 정수]
- `model_index`: 사용할 모델의 고유 인덱스.
- `model_id`: OpenRouter에 요청을 보내기 위한 모델 이름. (예: `openai/gpt-5-codex`)
- `provider`: 모델을 서빙할 공급사. 공급사별로 모델을 다르게 양자화하고 가격도 각각 다르기 때문에 일관된 실험을 위해 고정하여 사용한다. (예: `novita/fp8`)
- `content_mode`: 입력 모달리티. [`text_only` 또는 `image_only` 또는 `text_fig`]
- `language`: 프롬프트 언어. `ko`(한국어) 또는 `en`(영어)
- `variant_tag`: 로깅 파일 이름 지정을 위한 태그.
- `start_time_kst`: 해당 문제를 풀기 시작한 시간. 한국 표준 시간 기준. (예: 2025-11-13 15:52:28.894)
- `end_time_kst`: 해당 문제 풀이를 종료한 시간. 한국 표준 시간 기준. (예: 2025-11-13 15:56:20.391)
- `model_answer`: 모델이 뱉은 정답. '풀이 지시문'에 모델은 정답을 `\boxed{ }` 안에 기재하도록 강제하고 있으므로, 응답 마지막의 `\boxed{ }` 내부의 값을 파싱한 결과를 저장한다.
- `elapsed_sec`: `start_time_kst`과 `end_time_kst`을 기준으로, 한 문제를 푸는 데 소요된 시간. 소수점으로 밀리세컨드(ms) 단위까지 기록된다.
- `prompt_tokens`: 문제 풀이 프롬프트로 소모된 토큰 양.
- `completion_tokens`: 모델이 응답을 내는 데 소모된 토큰 양.
- `total_tokens`: `prompt_tokens`과 `completion_tokens`을 더한 값. 즉 문제 하나를 푸는 데 소모된 토큰 양 총합.
- `attempt_count`: 시도 횟수. 재시도 없이 한 번에 성공한 경우 1로 기록된다. 에러 발생으로 비정상 종료된 경우 0으로 기록된다.
- `error`: 발생한 에러가 어떤 것인지 기록된다.
- `request_body`: 모델 호출 시에 부가 옵션이 들어간 경우 기록된다. 본 연구에서는 추론 옵션이 기록되는데, (예를 들어 `"Reasoning_effort": "high", "text_verbosity": "low"`)

이와 같은 데이터를 기반으로, 본 연구는 성능과 응답시간의 상관관계, 입력 조건별 성능 변화, 모델 계열 · 규모별 추론 안정성을 정밀하게 분석하도록 하였다.

표 4: 전체 실험 구성 요약. 총 24개 모델에 대해 언어와 입력 모달리티 조건을 교차 평가하고, GPT-5 계열에 대해서는 Reasoning 설정(Effort, Verbosity)에 대한 추가 조합 실험을 수행하였다.

실험 축	수준 수	수준 구성
모델	24	LLM + 멀티모달 모델 (표 2)
언어	2	한국어, 영어
입력 모달리티	3	Text, Image, Text+Figure
GPT-5 Reasoning_Effort	4	Minimal, Low, Medium, High
GPT-5 Text_Verbosity	3	Low, Medium, High
기본 조합 수	$24 \times 2 \times 3$	전 모델 공통 조건
GPT-5 추가 조합 수	4×3	Effort–Verbosity 조합

4.5 CSAT-Math 실험 목적

본 연구는 섹션 1에서 정의한 네 가지 연구 질문(RQ.1–RQ.4)에 답하기 위해, 섹션 4.4에서 기술한 LLM 응답 로그와 Predicted CSAT-Math 데이터를 활용하여 평가를 수행하였다. 이를 바탕으로 모델의 입력 조건, 문제 특성, 추론 설정을 체계적으로 조절하며 LLM의 수학 문제 해결 능력을 다각도로 분석하였다.

- **RQ1. 최신 LLM들의 전반적인 성능 수준을 비교하여, 전체 46문항 기준 누적 점수와 정답률을 통해 모델 간 순위를 산출한다.**
- **RQ2. 출제 영역(수학 I/II, 미적분, 기하, 확률과 통계)뿐 아니라 배점(2/3/4점), 문항 형식(객관식/단답형), 문제 구조 및 난이도에 따라 어떤 개념 · 문항 유형에서 오류가 집중되는지 분석한다.**
- **RQ3. 수능 문항은 텍스트 · 기호 · 도형으로 구성되기 때문에, 모델의 입력 모달리티와 프롬프트 언어가 모델의 성능 및 오류 유형 그리고 Latency에 어떤 영향을 미치는지 비교한다.**
- **RQ4. 모델의 추론 강도를 변화하였을 때 모델의 성능 및 비용과 Latency는 어떠한 관계를 이루는지 정량적으로 평가한다.**

이러한 평가 절차는 (i) 모델 계열 및 규모, (ii) 프롬프트 언어, (iii) 입력 모달리티, (iv) 추론 설정 등 여러 요인을 교차 구성하여 LLM의 실제적인 수학 문제 해결 능력을 정밀하게 측정하고, 각 RQ가 요구하는 실험적 조건을 독립적으로 검증할 수 있도록 설계되었다.

4.6 전체 실험 구성 개요

표 4는 본 연구에서 수행한 전체 실험 구성을 요약한다. 우리는 총 24개 모델을 대상으로 **프롬프트 언어(2) × 입력 모달리티(3)** 조건을 교차하여 평가하였으며, 추가적으로 추론 설정을 세부적으로 제어할 수 있는 GPT-5 계열 모델에 대해서는 `Reasoning_Effort`와 `Text_Verbosity`의 모든 조합(4 × 3 = 12 조건)에 대해 별도 실험을 수행하였다. 이와 같은 다면 평가 설계를 통해 모델의 수학 문제 해결 능력, 모달리티 민감도, 언어적 편향, 그리고 추론 강도의 변화에 따른 성능-비용 양상을 정밀하게 분석할 수 있도록 구성하였다.

4.7 평가 지표

본 연구에서는 Korean-CSAT-Math 벤치마크의 전 구간에 대해 동일한 기준으로 평가 지표를 산출하였다. 또한 실제 수능 수험생은 선택과목 하나만 응시하여 총 30문항(공통 22문항 + 선택 8문항)만 응시하지만, 본 실험에서는 LLM 모델이 세 가지 선택과목을 모두 풀도록 구성하여 총 46문항을 대상으로 평가를 수행하였다.

- **Score**: 모델이 맞힌 문항의 배점 합. (예를 들어 총 46개 문항 중에서 2점 문항을 5개, 3점 문항을 14개, 4점 문항을 17개 맞췄다고 하면, $(2 \times 5) + (3 \times 17) + (4 \times 18) = 133$점이다.)
- **Normalized Score**: 전체 46문항 만점인 152점(표 1 참고, 공통과목 74점 + 확률과통계 26점 + 미적분 26점 + 기하 26점)을 100점 만점으로 정규화한 점수. 계산식은 $\frac{\text{score} \times 100}{152}$이다. 위의 예제는 $\frac{133 \times 100}{152} = 87.5$로 정규화된다.
- **Latency**: 모델의 응답 생성 시간. 모델 호출 시점부터 응답을 모두 수신하기까지의 경과 시간을 측정하였다. Predicted CSAT-Math에서 `elapsed_sec`을 분/초/밀리초 단위로 변환하여 이용된다.

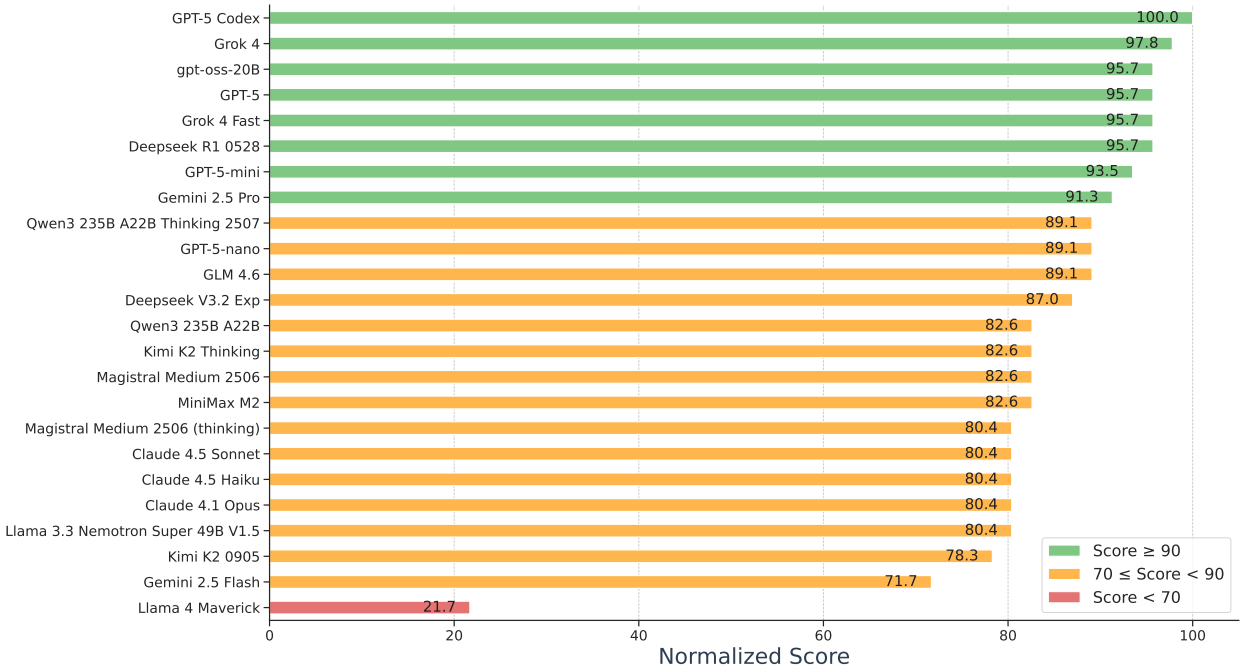

그림 7: 모델별 성능 비교 (입력 모달리티: Text only, 프롬프트 언어: 한국어)

- **Input Token Usage**: 모델이 문제를 이해하기 위해 처리한 입력 토큰의 수를 의미한다.
- **Output Token Usage**: 모델이 응답을 생성하며 출력한 토큰의 수를 나타낸다.
- **Total Token Usage**: 입력 토큰과 출력 토큰의 합. Predicted CSAT-Math에서는 `total_tokens`에 해당한다.
- **Cost ($)**: OpenRouter의 모델별 가격 정책에 따라 산정된 문항 당 예측 비용. 입력 · 출력 토큰 사용량을 기준으로 공급사가 지정한 가격(표 2)대로 계산되며, Open-weight 모델 또한 OpenRouter API를 통해 호출되는 경우 비용이 발생함을 명시한다.[14] 본 연구에서는 모든 모델에 대해 동일한 OpenRouter 기반 계산식을 적용하였다.

5 LLM 실험 결과

5.1 LLM 점수 리더보드

본 연구에서 제안한 Korean-CSAT LLM 평가 프레임워크의 모델별 전체 성능은 부록 A의 표 6에서 확인할 수 있으며, 보다 상세한 결과와 최신 리더보드는 공식 웹사이트[15]에서 확인할 수 있다. 아래는 해당 점수 결과를 기반으로 한 주요 분석 내용을 정리하였다.

본 실험의 주요 분석은 **입력 모달리티: Text-only, 프롬프트 언어: 한국어** 조건에서 수행하였다. 이는 이미지 입력을 지원하지 않는 모델이 존재하며, 평가 대상이 한국 수능 문항이라는 점을 고려하였다.

모델별 성능 분석 그림 7에서 확인할 수 있듯이, 본 분석에서 **GPT-5 Codex**만이 유일하게 정규화 점수 100점을 기록하였다. 다른 GPT-5 계열 모델들(GPT-5: 95.7점, GPT-5 mini: 93.5점), Grok 4 계열(Grok 4: 97.8점, Grok 4 Fast: 95.7점), 그리고 Gemini 2.5 Pro(91.3점)도 모두 90점을 넘어 최신 상용 모델들의 강력한 성능을 보여주었다. 특히 **gpt-oss-20B**은 상대적으로 경량의 공개 모델임에도 상위권에 근접한 성능을 달성하였다.

대부분의 나머지 모델은 70–90점대에 분포하였다. 예를 들어 Qwen3 235B A22B Thinking 2507과 GLM 4.6은 90점에 근접한 성능을 보였고, DeepSeek V3.2 Exp와 Kimi K2 Thinking은 80점대를 기록하였다. 반면 Claude 계열 모델들과 Gemini 2.5 Flash는 다른 상용 모델 대비 낮은 성능을 보였으며, Llama 4 Maverick은 21.7점으로 최하위를 기록하였다. 이러한 결과는 LLM 간 수학 문제 해결 능력의 상당한 편차를 확인 할 수 있다.

[14] gpt oss 20b 같은 오픈 모델은 원래 무료로 사용할 수 있는 모델들이나, 우리는 통일성을 위해 openrouter에서 동일하게 수행했기 때문에 비용이 발생했다.

[15] `https://isoft.cnu.ac.kr/csat2026/`

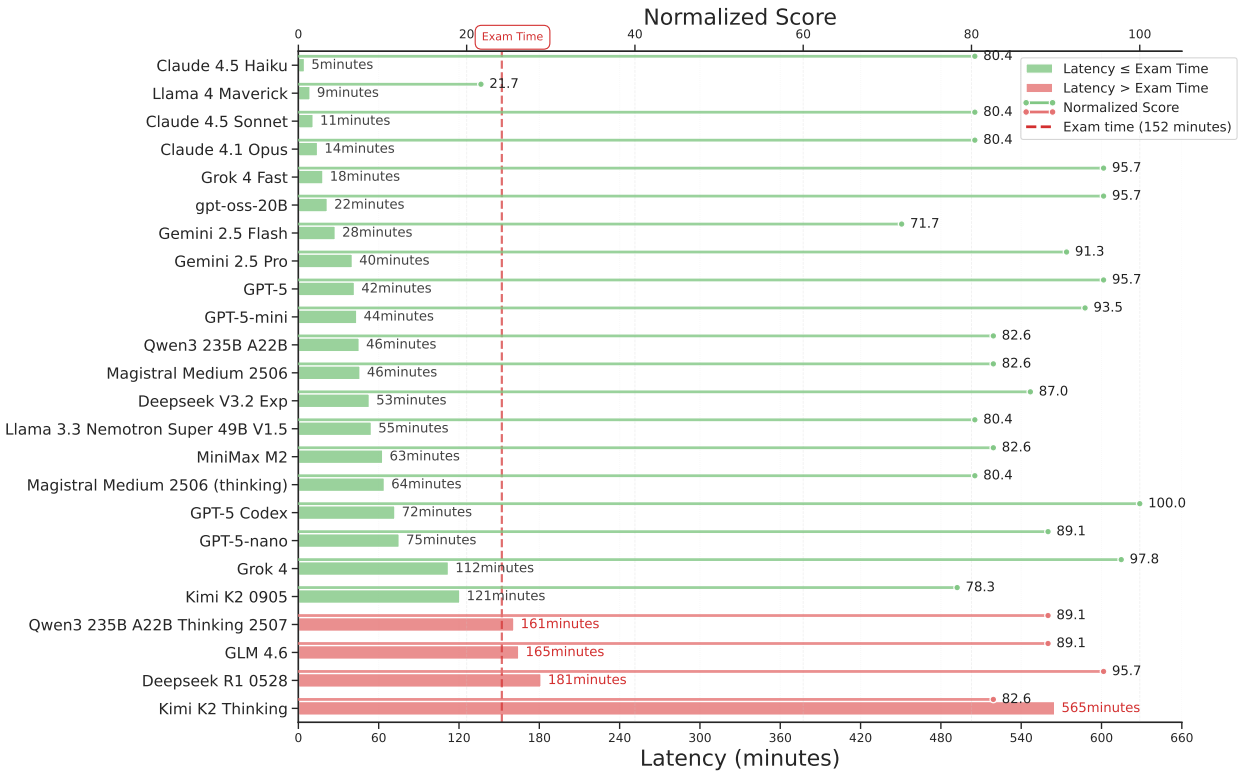

그림 8: 모델별 Latency 및 점수 비교 (Text only, 한국어)

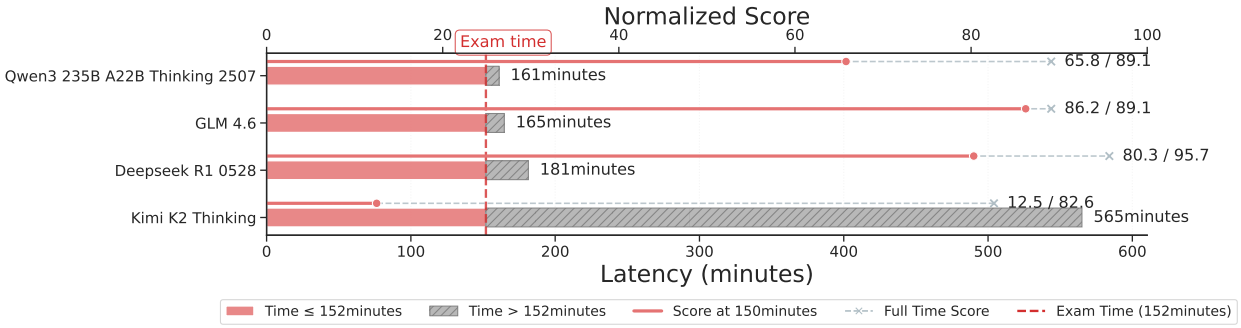

그림 9: 제한 시간 초과 모델의 시간제한 성능

표 5: Latency-Score 상관관계 분석 결과. Pearson, Spearman, Kendall의 상관 분석과 단순 선형 회귀(OLS)를 수행하였고, 모든 상관 계수는 매우 낮았으며 통계적으로 유의하지 않다 ($p > 0.05$).

Method	**Correlation**	p**-value**	**N**
Pearson	0.123	5.68×10^{-1}	24
Spearman	0.291	1.68×10^{-1}	24
Kendall τ	0.186	2.19×10^{-1}	24
Log-latency Pearson	0.377	6.98×10^{-2}	24
OLS Slope (β_1)	0.016	5.68×10^{-1}	24
OLS R^2	0.015	–	24

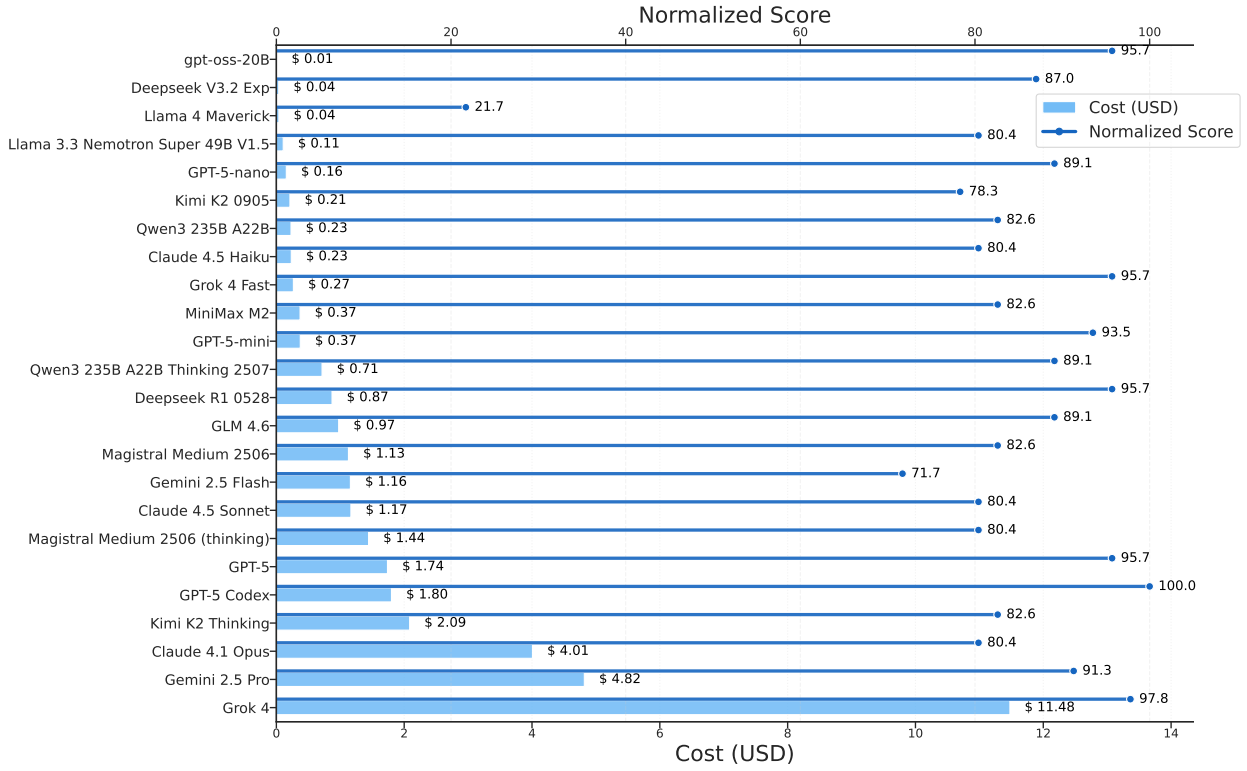

그림 10: 모델별 응답 비용 및 성능 비교 (Text only, 한국어)

모델별 Latency 분석 본 실험에서 LLM은 46문항을 풀도록 설계하였기 때문에, 늘어난 문항 수를 고려하여 제한 시간을 152분으로 확장하였고, 이 시간을 기준으로 **시간 무제한** 및 **제한 실험**을 진행하였다.

1) 시간 무제한 성능 한국어 프롬프트 환경에서 Text only 조건 아래 모델별 Latency와 성능을 그림 8에 표시하였다. 대다수의 모델들이 46문항을 100분 이내에 완료했다는 점은 주목할 만하다. 이는 실제 주어진 시간보다 훨씬 짧은 시간 안에 모든 문항을 풀어냄을 의미한다. 특히 가장 점수가 높았던 GPT-5 Codex도 72분 만에 모든 문제를 풀었음을 확인할 수 있다.

다만, 통계적 유의성 검증을 통해 Latency와 Score의 관계를 살펴본 결과, Pearson · Spearman · Kendall 상관 계수 모두에서 유의한 상관이 확인되지 않았다($|r| < 0.30$, $p > 0.05$). 즉, **문제 풀이 속도가 모델 성능 간의 상관관계는 유의하지 않은 것으로 확인되었다** (표 5).

2) 시간제한 성능 그림 8에 따르면 152분 이내에 46개 문항을 모두 풀지 못한 모델은 4개의 모델(Qwen3 235B A22B Thinking 2507, GLM 4.6, Deepseek R1 0528, Kimi K2 Thinking)이 있다. 해당 모델들은 실제 시험 시간을 초과하여 문제를 풀었으므로, 그림 9은 제한 시간을 초과한 모델들에 대해 무제한 추론 성능과 시간제한 성능을 비교한다.

제한 시간(152분) 내에 도달한 응답만 정답 처리하여 모델 성능이 전체적으로 낮아졌다. 특히 가장 많은 시간을 쓴 Kimi K2 Thinking 모델의 경우 전체 풀이 시간이 565분으로 10시간가량 소요되었고, 시간제한 성능을 측정하였을 때 기존의 82.6점에서 12.5점으로 70점가량 감소했다.

Qwen3 235B A22B Thinking 2507 모델은 후반의 9분 정도를 제외했을 때 약 24점이 감소했으며, GLM 4.6 모델은 후반의 13분을 제외하여 약 3점이 감소했다.

모델별 Cost 분석 그림 10은 모델별로 46문제를 푸는 데 든 비용을 나타낸다. 대부분의 상용 모델은 비교적 높은 비용이 들었다. 대표적으로 Grok 4는 $11.48, Gemini 2.5 Pro는 $4.82, Claude 4.1 Opus는 $4.01의 비용이 소요되었다. 반면 오픈 소스 모델들은 비교적 적은 비용으로 응답을 생성하였다. 대표적으로 gpt-oss-20B가 $0.01, DeepSeek V3.2 Exp가 $0.04, Llama 4 Maverick가 $0.04 순으로 적은 비용이 들었다. 특히 gpt-oss-20B는 95.7점의 높은 점수를 기록하면서도 가장 낮은 비용을 소모하여 우수한 비용-성능 비율을 보였다.

이러한 결과는 일부 모델의 경우 성능 향상에 비해 비용이 불균형하게 증가하는 반면, 일부 모델은 낮은 비용으로도 상위권 성능을 달성할 수 있음을 보인다.

모델별 효율성 분석 본 절에서는 시간 대비 성능, 가격 대비 성능, 전체 자원 대비 성능 분석을 위해 3가지 Efficiency Score를 정의하였다.

$$(1)\ \mathrm{Eff}_t = \frac{\text{score}}{\text{latency (m)}} \qquad (2)\ \mathrm{Eff}_c = \frac{\text{score}}{\text{cost (\$)}} \qquad (3)\ \mathrm{Eff}_{t,c} = \frac{\text{score}}{\frac{\text{latency}}{152\,\text{min}} + \frac{\text{cost}}{1\,\$}}$$

식 (1)의 Eff_t는 Eff_t는 *시간 효율성(time efficiency)*으로, 값이 클수록 짧은 시간에 높은 점수를 달성했음을 보인다.

식 (2)의 Eff_c *비용 효율성(cost efficiency)*으로, 같은 성능을 더 낮은 비용으로 달성할수록 효율이 높다.

식 (3)의 $\mathrm{Eff}_{t,c}$는 $\mathrm{Eff}_{t,c}$는 *시간-비용 통합 효율성(time–cost efficiency)*을 정의한 지표로, 값이 클수록 적은 시간과 비용으로 더 높은 성능을 의미한다.

그림 11a는 $\texttt{Eff}_t$ 지표를 통해 **모델별 시간 대비 성능**을 시각화한 것이다. Claude 4.5 Haiku 모델은 46개 문항을 5분 만에 풀어 80점을 기록하여 가장 높은 Eff_t을 보인다. 이 외에도 다른 Claude 계열 모델들이 2, 3등을 기록하였고 Grok 4 Fast, gpt-oss-20B 모델 순으로 시간 대비 성능이 뛰어난 것으로 보인다.

그림 11b는 Eff_c 지표를 통해 **모델별 가격 대비 성능**을 시각화한 것이다. gpt-oss-20B의 경우 Normalized Score: 95.7점(3등), Cost: 0.01$(1등)를 기록했는데(그림 10), 비교적 우수한 성능과 저렴한 가격으로 인해 압도적으로 높은 Eff_c를 보였다. 이 외에도 오픈 모델인 Deepseek V3.2 Exp 가 2등을 기록했고, 비용이 가장 높았던 Grok 4($11.48)가 최하위 순위를 기록했다.

그림 11c는 $\mathrm{Eff}_{t,c}$ 지표를 시각화한 것으로, **모델별 시간과 비용을 합산해 전체 소요된 자원 대비 성능**을 보인다. 종합적인 지표를 보았을 때 자원 대비 성능이 가장 좋은 것은 gpt-oss-20bB 모델이다. 두 번째로 성능이 좋은 모델은 Claude 4.5 Haiku였는데, 성능 대비 비용 효율은 다소 낮았으나 시간 효율이 매우 높았기 때문에 $\mathrm{Eff}_{t,c}$지표에서 두 번째로 좋은 모델로 평가된다.

전체 입력 조합에 대한 모든 결과는 부록 B에서 확인할 수 있다.

결과적으로, 시간 대비 성능이 좋은 모델과 비용 대비 성능이 좋은 모델은 서로 약간 다른 양상을 보였다. **사용자가 빠른 응답을 중요시한다면 Claude 4.5 Haiku와 Claude 4.5 Sonnet 모델을, 적은 비용을 중요시한다면 gpt-oss-20B와 Deepseek V3.2 Exp 모델을 사용하는 것**이 자원 대비 좋은 성능을 기록할 수 있다.

5.2 다양한 조건에서의 LLM 성능 분석

5.2.1 모델 파라미터 규모에 따른 차이

모델 규모에 따른 성능 그림 12은 모델의 파라미터 규모가 성능과 문제 당 처리 시간에 미치는 영향을 나타낸다. 그림 12a를 보면 전반적으로는 규모가 커질수록 높은 성능을 보이는 경향이 확인되지만, 그 관계는 일관된 선형적 증가가 아니다. 예를 들어 `gpt-oss-20B`는 파라미터 수가 `Qwen3 235B A22B`보다 약 7배 작음에도 불구하고 점수가 오히려 더 높게 나타난다. 이는 모델 규모가 성능을 결정하는 절대적 기준이 아님을 시사한다.

모델 규모와 응답 시간의 관계 한편, 그림 12b를 보면 일부 대형 모델은 높은 성능에도 불구하고 비교적 짧은 응답 시간을 유지한 반면, 중간 규모 모델 중에서도 문제 당 처리 시간이 매우 길어지는 모델이 존재했다. 즉, 파라미터 규모는 성능과 시간 효율성 사이에서 복합적인 trade-off 구조를 형성하며, 단일 지표만으로 모델의 성능을 판단하기 어렵다.

전체 입력 조합에 관한 결과는 부록 C에서 확인할 수 있다.

결론적으로 대규모 모델들이 평균적으로 좋은 성능을 보이지만 **모델 규모가 성능과 절대적인 관계가 있지는 않으며, 일부 모델들은(gpt-oss-20B 등) 성능 및 효율성 측면에서 대형 모델을 능가한다.**

5.2.2 입력 Modality에 따른 차이

그림 13a은 상용 모델에서 입력 모달리티에 따른 성능을 시각화한 것이다. 주요 관찰 결과는 다음과 같다:

- GPT-5 계열: Text Only 또는 Text+Figure 입력에서 가장 높은 성능을 보였으며, GPT-5 Codex는 Text+Figure로 **100점**을 달성하고 Image 단독 입력 시 성능이 전반적으로 감소한다
- Claude 계열: 전 모델에서 Image Only 입력 시 성능이 가장 크게 하락하였고, Text 및 Text+Figure 입력에서는 성능이 비슷하게 나타난다.

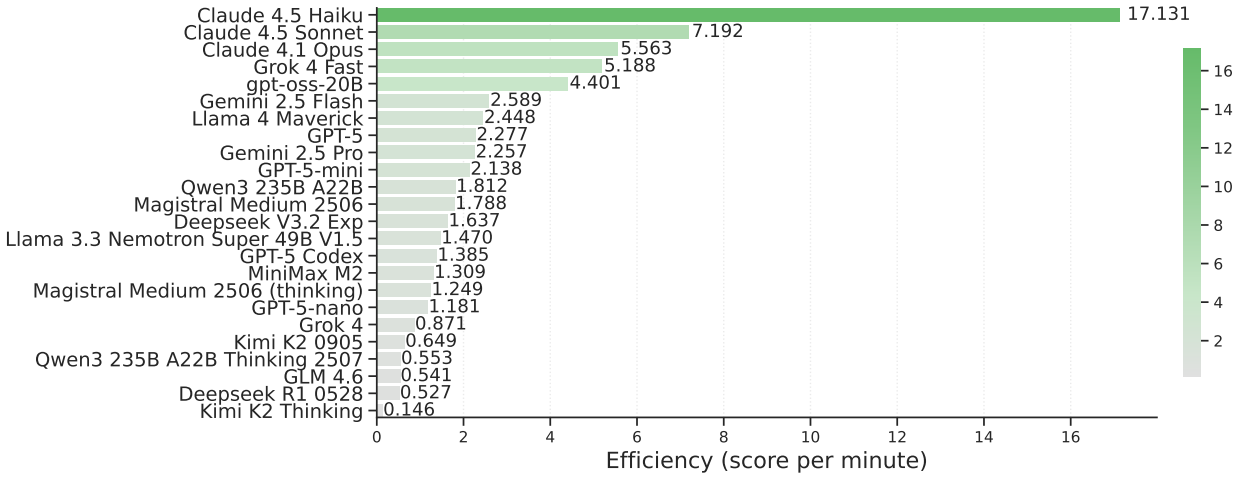

(a) 성능·시간 Efficiency Score 비교 (Text only, 한국어)

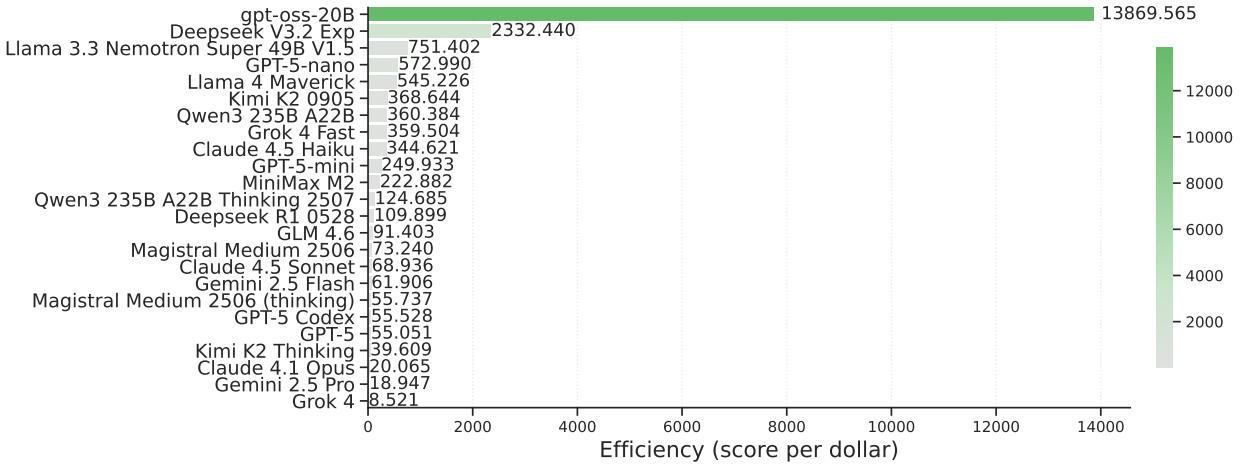

(b) 성능·비용 Efficiency Score 비교 (Text only, 한국어)

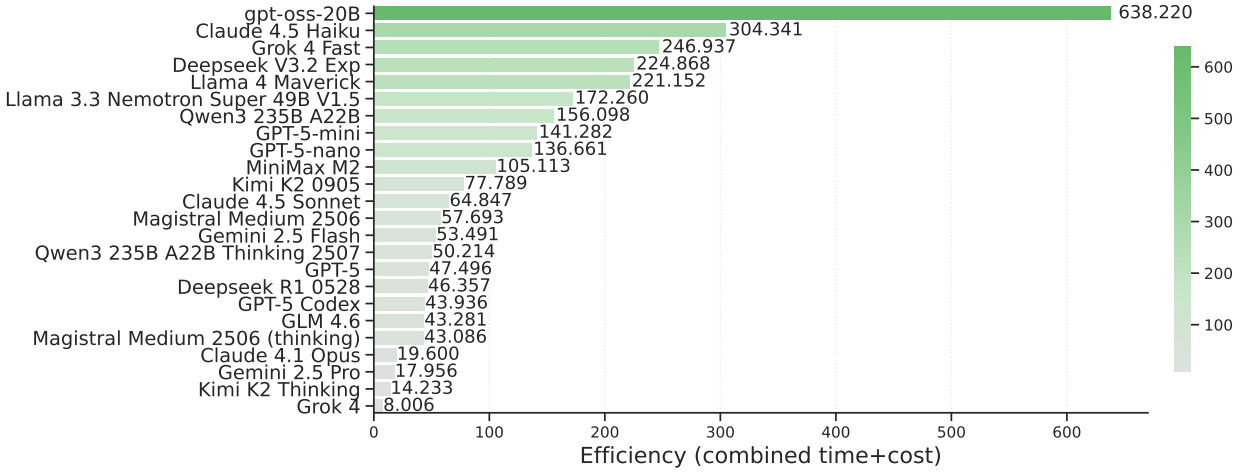

(c) 성능·시간·비용 Efficiency Score 비교 (Text only, 한국어)

그림 11: 성능, 시간 및 비용 간 Efficiency Score 비교 (Text only, 한국어)

- Grok 계열: Claude와 유사하게 Image Only 입력에서 성능 저하가 두드러지며, Text Only 또는 Text+Figure 입력에서 상대적으로 높은 성능을 보인다.

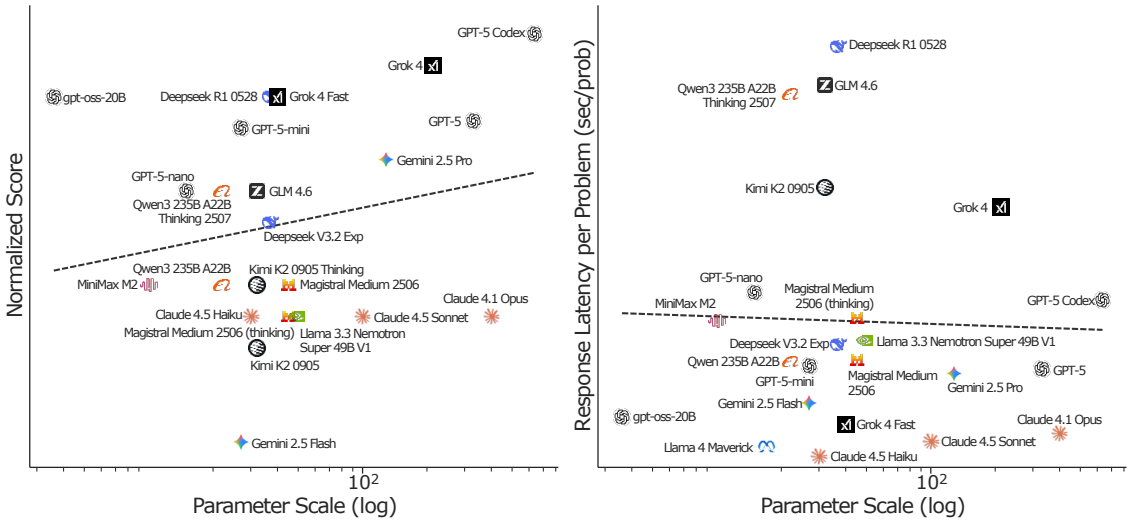

(a) 모델 파라미터 규모에 따른 성능. Llama 4 Maverick 모델의 Normalized Score가 21.7로 낮아 생략되었다.

(b) 모델 파라미터 규모에 따른 소요 시간. Kimi K2 Thinking 모델은 문제 당 소요 시간이 737 s/prob으로 높아 생략.

그림 12: 모델 파라미터 규모에 따른 성능 및 문제 당 소요 시간 (Text only, 한국어)

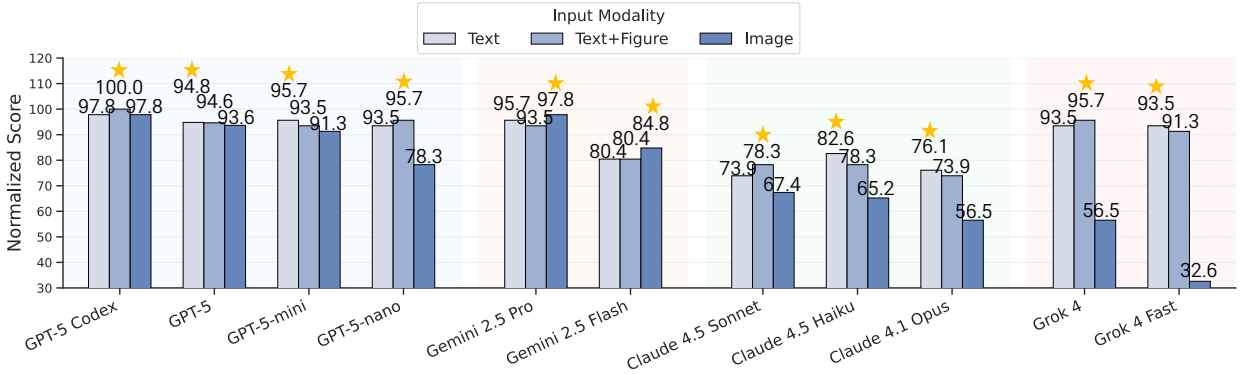

(a) 입력 모달리티에 따른 모델 계열별 점수. 가장 높은 점수를 달성한 모달리티에 별 표시 되어있다.

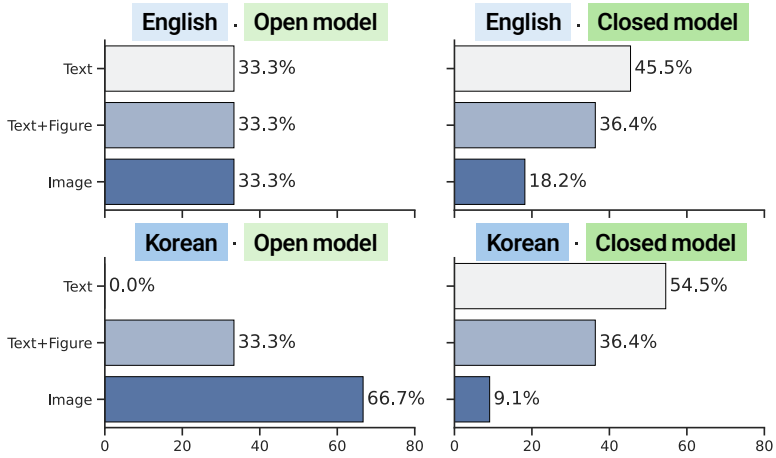

(b) 프롬프트 언어와 모델 가중치 공개 여부에 따른 입력 모달리티별 win rate

그림 13: 입력 모달리티에 따른 점수 및 win rate 비교

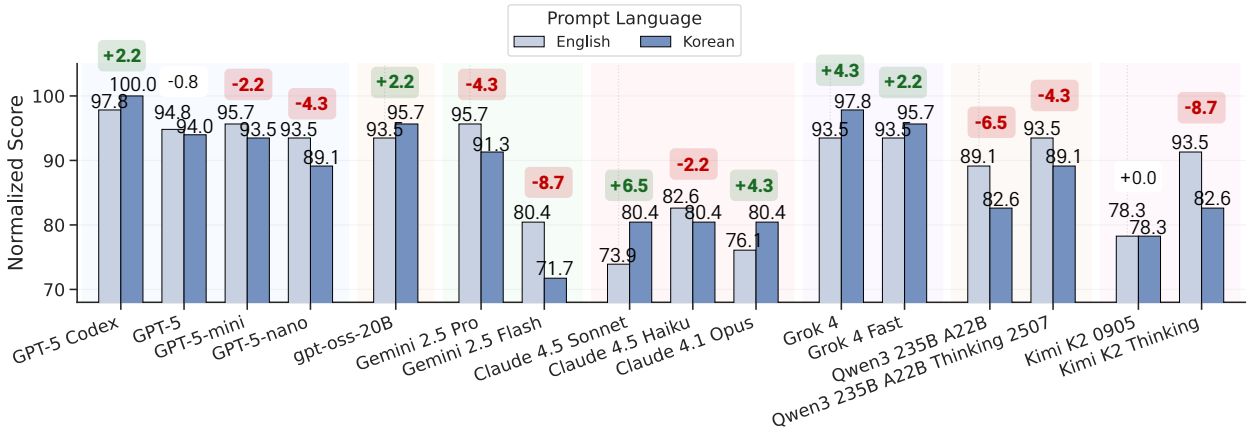

(a) 프롬프트 언어에 따른 모델 계열별 점수. 영어 입력 대비 한국어 입력의 점수 차이가 표시되어 있다. 한국어 입력이 점수가 더 높은 경우 초록색, 낮은 경우 빨간색, 차이가 2점 미만인 경우 흰색으로 표시된다.

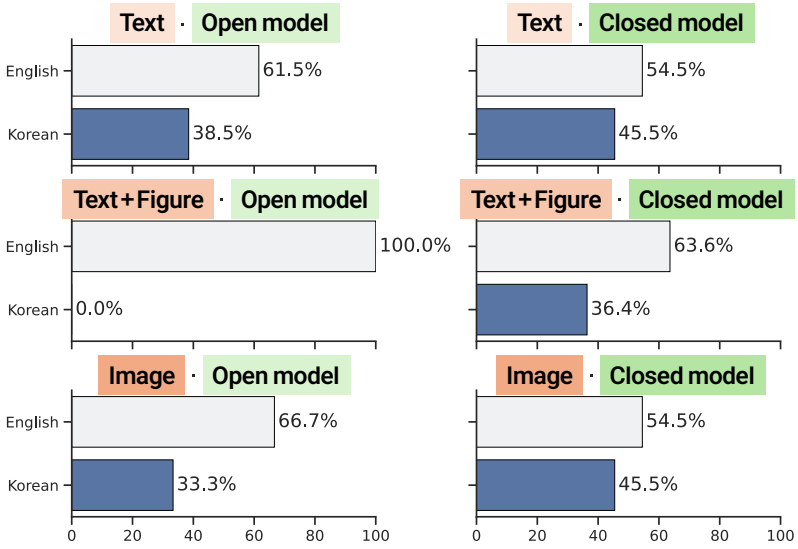

(b) 입력 모달리티와 모델 가중치 공개 여부에 따른 프롬프트 언어별 win rate

그림 14: 프롬프트 언어에 따른 점수 및 win rate 비교

- Gemini 계열: 다른 계열과 달리 **Image Only 입력이 오히려 가장 높은 성능을 보이는 사례**로, 시각 입력 처리에서 강점을 드러낸다.

그림 13b는 입력 모달리티별 win rate를 프롬프트 언어, 모델 가중치 공개 여부에 따라 나누어 시각화한 것이다. 그림 13a에서 나타난 것처럼 가중치 비공개 모델들은 Text 입력과 Text+Figure 입력에 강세를 보였으며, Image 입력의 승률은 비교적 낮았다. 가중치가 공개된 모델들은 약간 다른 경향을 보였는데, 특히 프롬프트 언어가 한국어일 경우 win rate가 0%로 나타났다. 다만 이러한 결과는 이미지 입력을 지원하는 가중치 공개 모델이 현재 Qwen3 235B A22B, Qwen 235b A22B Thinking 2507, Llama 4 Maverick 세 가지밖에 없어서 승률이 0%라고 해도 3번 중 0번을 이긴 것이므로 더한 해석에는 한계가 있다.

5.2.3 Prompting Language에 따른 차이

그림 14a는 프롬프트 언어에 따른 점수를 모델 계열별로 시각화한 것이다. GPT-5 Codex와 gpt-oss-20B는 프롬프트가 한국어로 입력되었을 때 더 높은 점수를 달성하였다. 이 외에도 Claude 계열 모델과 Grok 계열 모델들이 한국어 입력에서 더 높은 점수를 달성하였다. Gemini 계열 모델과 Qwen, Kimi 같은 가중치 공개 모델들의 경우 영어 입력 시에 점수가 더 높았으며, 한국어 입력 시에는 점수가 크게 하락하는 것으로 나타났다.

그림 14b은 프롬프트 언어별 win rate를 입력 모달리티, 모델 가중치 공개 여부에 따라 나누어 시각화한 것이다. 가중치 공개 여부에 상관없이 모든 경우 **영어 입력이 더 우세하게 나타났다.** 또 같은 Text 입력이더라도, 가중치가 공개된 모델이 가중치 비공개 모델보다 영어 입력의 승률이 높았다. Text+Figure, Image 입력의 경우 앞서 설명한 것처럼 이미지 입력을 지원하는 모델이 3개 뿐이기 때문에 편향이 있을 것으로 예상되지만, 여전히 영어 입력이 모델에 도움이 되는 것으로 보인다.

5.3 수학 문제 특성에 따른 LLM 성능 분석

5.3.1 수학 문제의 출제 영역에 따른 모델의 성능 분석

그림 15는 출제 영역별 모델 성능을 나타낸다. 각 영역에서 획득한 점수를 해당 영역의 만점으로 나눈 정규화 된 점수와 함께 표기하였다.

분석 결과, 모델들은 미적분 영역에서 가장 낮은 성능을 보였으며, 그다음으로 기하 영역이 어려운 분야로 나타났다. 미적분의 난이도는 복잡한 기호 조작과 다단계 논리 추론을 요구한다는 데에서 비롯되며, 기하 영역은 공간적 해석과 시각적 이해에 의존하기 때문에 모델 간 성능 변동이 크게 나타난다.

모든 모델의 Normalized Score의 평균 성능을 비교하면, 미적분(77.7)이 가장 낮았고, 이어서 기하(79.2), 공통과목(83.9), 확률과 통계(84.7) 순으로 모델이 어려워하는 모습을 보였다.

모든 조합(입력 모달리티/프롬프트 언어)에 대한 결과는 부록 D에서 확인할 수 있다.

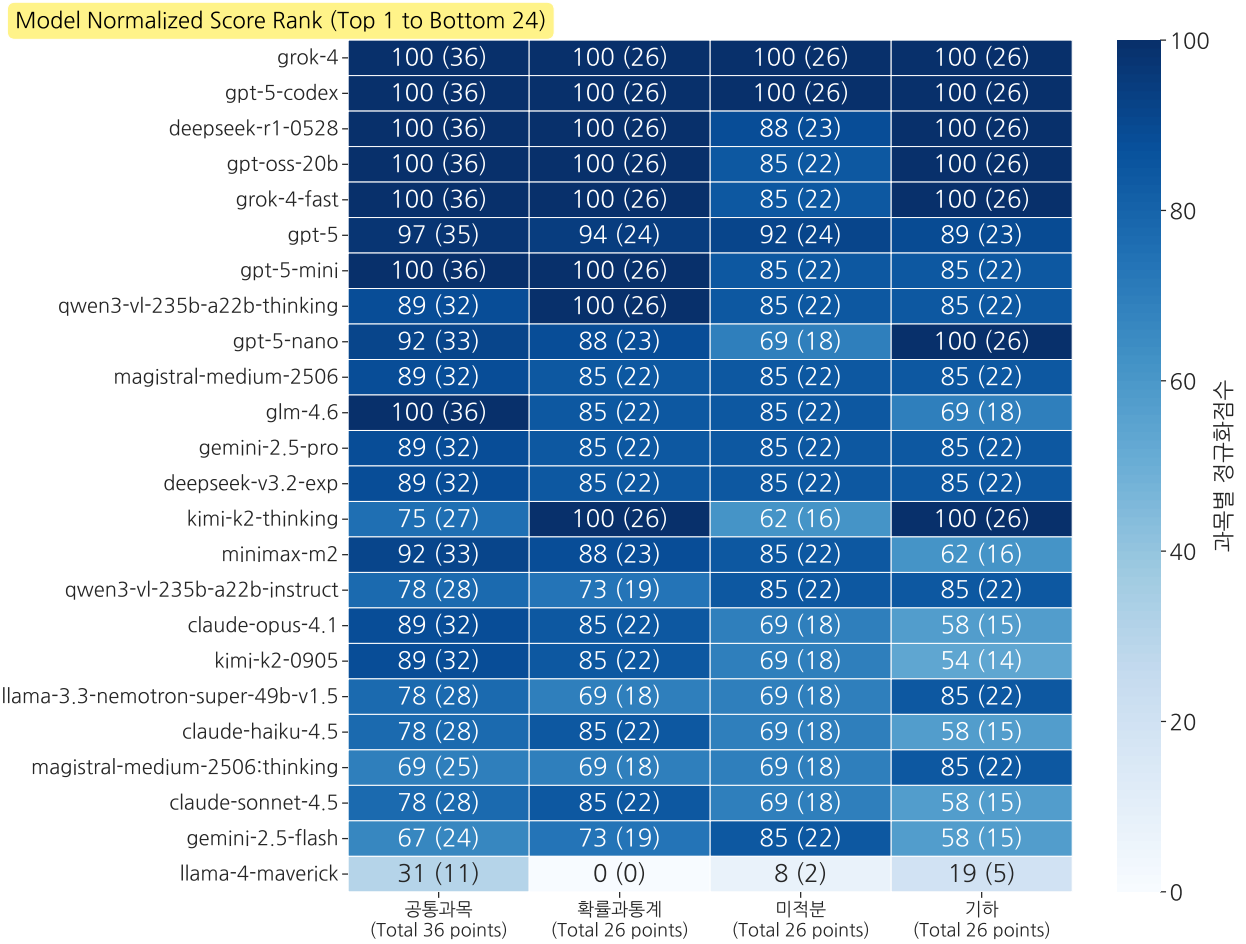

그림 15: 출제 영역별 LLM 성능 비교. 과목별 정규화 점수는 각 영역에서 획득한 점수를 해당 영역의 만점으로 정규화한 값이며, 표기된 수치는 **정규화 점수와 원점수(점)**를 함께 표시한다. 모델의 표기 순서는 Normalized Score가 높은 순으로 정렬되었다.

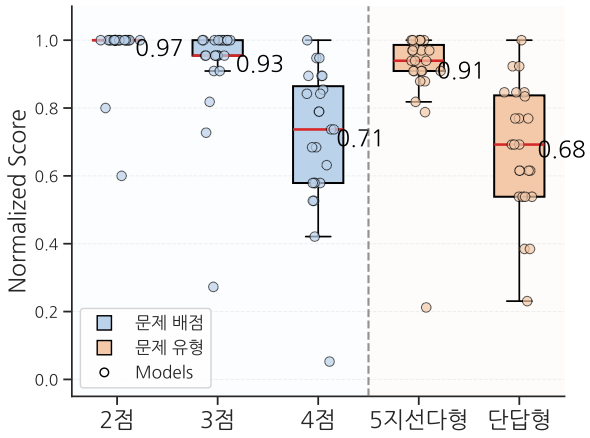

(a) 문항 배점(2/3/4점)과 문항 유형(5지선다형/단답형)에 따른 LLM 성능 분포.

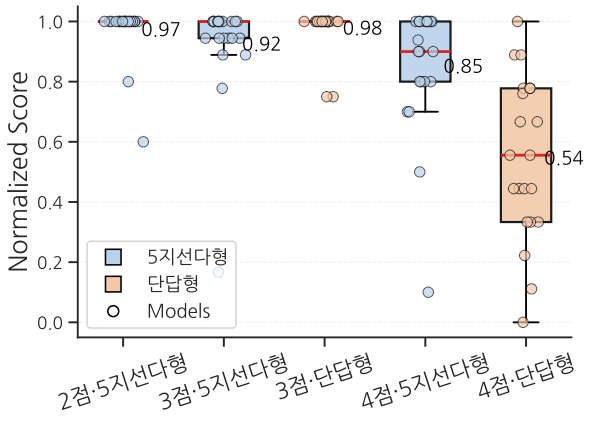

(b) 문항 배점×유형 조합별 LLM 성능 분포.
(2026 수능에 2점 · 5지선다형 문항이 없어 제외)

그림 16: 문항 특성에 따른 LLM 성능 비교. (a)는 배점과 문항 유형이라는 두 축을 각각 독립적으로 살펴본 결과이며, (b)는 두 축을 결합한 문항 조합(배점 × 유형) 단위에서 성능을 분석한 결과이다.

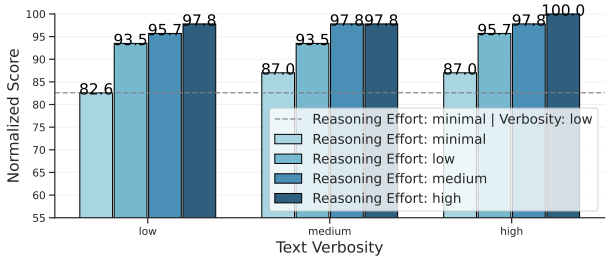

(a) `Reasoning_Effort`와 `Text_Verbosity` 조합에 따른 GPT-5 계열 모델의 성능 변화

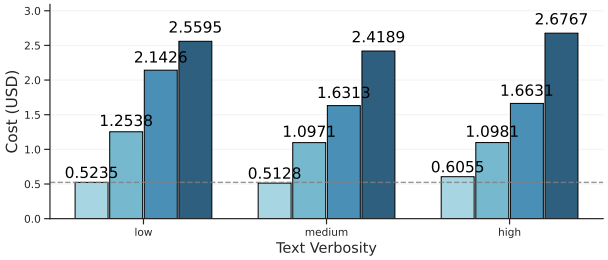

(b) `Reasoning_Effort`와 `Text_Verbosity` 조합에 따른 응답 비용 변화

그림 17: GPT-5 계열 모델에서 `Reasoning_Effort` 및 `Text_Verbosity` 조합의 영향 비교

5.3.2 문항 속성별 모델의 성능 분석

문항 유형에 따른 성능 차이 그림 16a는 문항 유형별 모델 성능을 나타낸다. 분석 결과, LLM은 5지선다형 문항에서 더 높은 성능을 보였다. 객관식 문항의 경우 모델들의 Normalized Score가 91점으로 나타난 반면, 단답형 문항은 68점으로 나타나 문항 유형에 따른 뚜렷한 성능 차이가 관찰되었다.

그러나 이러한 차이를 단순히 문항 형식의 영향으로 해석하기는 어렵다. 수능 수학에서 고난도 문항(4점)은 주로 단답형으로 출제되기 때문에 성능 차이는 문항 유형뿐 아니라 배점(난이도)이 복합적으로 작용한 결과로 보인다.

배점에 따른 성능 차이 배점별 분석에서는 일관된 난이도 하락 패턴이 관찰되었다. 2-3점 문항의 정규화 된 점수는 93-97점으로 높게 나타난 반면, 4점 문항은 71점으로 크게 하락하였다. 배점이 높아질수록 LLM의 정답률이 뚜렷하게 감소하는 경향을 보였으며, 이는 **사람을 위해 설계된 난이도 체계가 LLM에게도 유사하게 작용함을 의미한다.**

그림 16b는 문항 유형(5지선다형 · 단답형)과 배점(2 · 3 · 4점) 조합별 LLM 성능을 비교한 결과이다. 모델들은 대체로 2–3점 문항에서는 높은 성능을 보이지만, 4점 문항에서는 유형과 관계없이 평균 성능이 떨어지고 모델 간 편차가 커지는 경향을 보인다. 5지선다형 역시 4점 문항에서 다른 배점 대비 성능이 크게 낮아진다.

종합하면 2–3점 및 5지선다형과 같이 상대적으로 쉬운 조합에서는 높은 성능이 유지되지만, **4점 · 단답형과 같은 고난도 조합에서는 성능 저하와 모델 간 성능 편차가 두드러진다.** 모든 조합(입력 모달리티/프롬프트 언어)에 대한 결과는 부록 E에서 확인 할 수 있다.

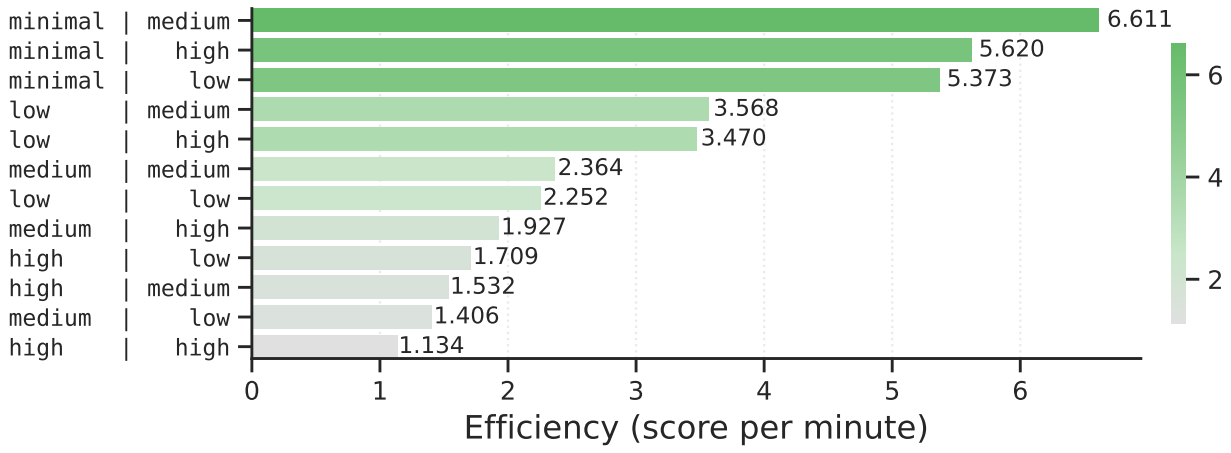

(a) GPT-5 추론 설정에 따른 성능·시간 Efficiency Score 비교

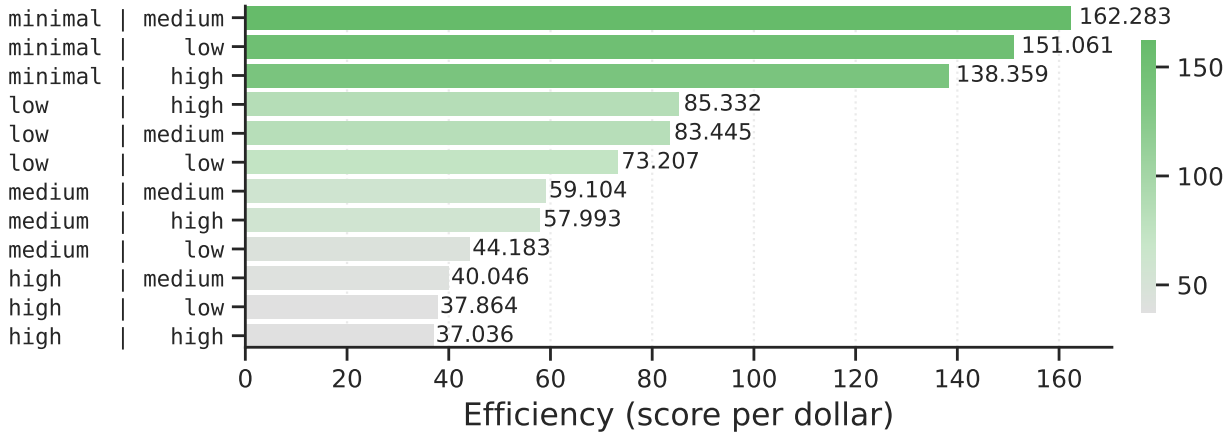

(b) GPT-5 추론 설정에 따른 성능·비용 Efficiency Score 비교

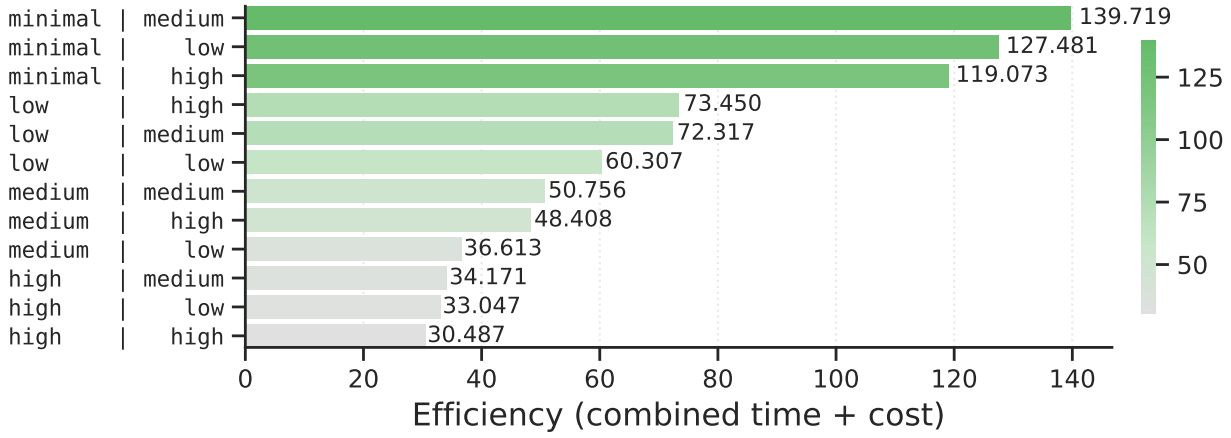

(c) GPT-5 추론 설정에 따른 성능·시간·비용 Efficiency Score 비교

그림 18: GPT-5 추론 설정에 따른 성능, 시간, 비용 간 Efficiency Score 비교 (y축 모델의 추론 방식은 다음과 같이 표기하였다: `Reasoning_Effort | Text_Verbosity`)

5.4 기본 LLM 대비 Reasoning 방식의 효과

5.4.1 Reasoning 방식 변화가 성능에 미치는 영향

Reasoning_Effort와 Text_verbosity의 성능 기여도 그림 17a는 GPT-5 계열 모델에서 `Reasoning_Effort`와 `Text_Verbosity` 조합이 성능에 미치는 영향을 보인다. `Reasoning_Effort`를 높이면 성능이 뚜렷하게 상승한 반면, `Text_Verbosity`를 증가시켜도 성능 변화는 거의 나타나지 않았다.

이는 GPT-5[16] 문서에서 정의한 두 설정의 기능 차이와도 일치한다. 문서에 따르면 `Text_Verbosity`는 "출력 토큰 수를 조절하는 설정"으로, 모델의 추론 방식은 대부분 동일하게 유지되는 반면, `Reasoning_Effort`는 "응답 생성 이전에 생성하는 추론 토큰의 양을 제어하는 설정"으로 실제 내부 추론 과정을 변화시킨다. 따라서 본 연구에서 관찰된 성능 향상이 `Text_Verbosity`가 아니라 `Reasoning_Effort` 증가에서 주로 나타난다는 점은, 두 설정이 수행하는 기능적 차이와 부합한다.

5.4.2 추론 비용 증가와 효율성 저하

그림 17을 보면 추론 설정에 따라 모델의 비용이 크게 달라지는 것을 확인할 수 있다. 이는 단순한 성능 비교뿐 아니라, 추론 방식의 효율성을 함께 고려하는 것이 모델 선택에 중요함을 시사한다. 그림 18a–18c는 `Reasoning_Effort`와 `Text_Verbosity`를 조정할 때 성능 · 시간 · 비용 간 Efficiency Score가 어떻게 변화하는지를 비교한 것이다.전반적으로, GPT-5 계열은 추론 양을 높일수록 성능이 증가하지만 시간과 비용이 크게 상승하여 Efficiency Score는 낮아지는 모습을 보인다.

우선, medium–minimal(`Reasoning_Effort-Text_Verbosity`) 조합은 세 가지 Efficiency Score(성능 · 시간, 성능 · 비용, 성능 · 시간 · 비용) 모두에서 가장 높은 값을 기록하였다. 이는 Text_Verbosity의 minimal 설정이 가장 적은 토큰을 사용하면서도 충분한 성능을 유지하여, 단위 시간 당 · 단위 비용 당 성능이 가장 좋다고 볼 수 있다.

반대로 `Reasoning_Effort`에 투자를 많이 할수록(high로 증가) 효율성은 급격히 저하하였다. 모델의 성능은 오르지만 이에 따른 토큰 사용량 및 비용은 약 4–5배로 증가하고 응답 시간도 크게 늘어나 효율성 점수는 절반 이하로 떨어졌다. high–high 조합은 세 Efficiency Score 모두에서 최하위를 기록했으며, 이는 높은 reasoning이 성능 향상 대비 비용 증가가 훨씬 큰 비효율적 선택임을 보인다.

종합적으로 GPT-5 계열 모델에서 추론 강도를 높이면 성능 향상은 미미한 반면, 비용과 지연 시간은 크게 증가한다. 실제로 2-5점 수준의 성능 개선을 위해 토큰 사용량이 4-5배로 늘어나는 경우가 다수 확인되었다. 이에 따라 다음과 같은 결론을 도출할 수 있다.

- 높은 추론 강도(*high effort*)는 예상대로 성능을 끌어올리지만, 비용 효율성은 매우 낮다.
- *minimal* 또는 *medium* 추론은 전반적인 효율성 측면에서 *high* 추론보다 더 우수한 균형을 제공한다.
- 대부분의 실용적 상황에서는 기본 GPT-5(*baseline*) 또는 *minimal reasoning*이 가장 합리적인 선택이다.
- 대규모 평가나 예산이 제한된 환경에서는 *high reasoning*이 비효율적이다.

종합적으로, GPT-5 모델의 추가 추론은 성능 향상보다 비용 증가가 훨씬 크다. 비용을 고려하지 않고 점수만 높이는 것이 목적이라면 *high reasoning*도 선택할 수 있지만 대규모 또는 시간 제약이 있는 수학 평가 환경에서는 기본모델(*baseline*) 또는 *minimal reasoning*이 가장 현실적이고 효율적인 선택으로 보인다.

6 주요 시사점

본 연구는 데이터 누출이 완전히 배제된 환경에서 2026학년도 한국 대학수학능력시험 수학 영역을 활용하여 24개의 LLM의 수학 문제 해결 능력을 종합적으로 분석하였다. 실험 결과는 LLM의 성능을 단순히 "얼마나 많은 문제를 맞히는가"로 평가하는 것을 넘어, 어떤 조건에서, 어느 정도의 비용으로, 어떤 유형의 문제를 어떻게 해결하는지까지 다각도로 분석하였다. 이를 통해 LLM의 수학 문제 해결 성능은 단순 정답률뿐 아니라 추론 전략, 입력 조건, 비용 효율성, 문제 유형별 편차 등 다차원적 관점에서 평가될 필요가 있음을 보인다.

RQ.1 현시점 LLM의 수학 문제 해결 능력 본 연구에서 GPT-5 Codex는 텍스트 입력과 한국어 프롬프트 조건에서 유일하게 만점(100.0점)을 기록하며 가장 높은 성능을 보였다. Grok 4, GPT-OSS-20B, GPT-5, Deepseek R1 등 또한 95점 이상의 우수한 결과를 달성하여, 단순 암기가 아닌 충분한 수학적 추론 능력을 갖추고 있음을 확인할 수 있었다.

특히 주목할 점은 gpt-oss-20B가 상대적으로 작은 모델 크기임에도 불구하고 95.7점을 기록했다는 사실이다. 이 결과는 모델 파라미터 규모가 반드시 수학 성능을 결정짓는 절대적 요인이 아니라는 점을 보인다. 더불어

[16] `https://platform.openai.com/docs/guides/latest-model`

시간 및 토큰당 비용을 종합적으로 고려했을 때 gpt-oss-20B는 매우 높은 효율성을 보였으며, Claude 4.5 Haiku, Grok 4 Fast, Deepseek V3.2 exp 또한 합리적인 비용 대비 안정적인 성적을 기록하였다.

추가로, 고득점을 달성한 대부분의 모델은 모든 시험 문항을 제한 시간 100분 이내에 해결했으며, 일부 모델은 과도한 추론 단계 생성으로 인해 응답 시간이 크게 지연되는 현상이 관찰되었다.

RQ.2 입력 조건이 성능에 미치는 영향 프롬프트 언어의 효과는 모델 규모에 따라 뚜렷하게 대비되는 양상을 보였다. 대규모 최신 모델(Claude 4.5 Sonnet, GPT-5 Codex 등)은 한국어 프롬프트에서 더 높은 성능을 보였지만, 비교적 작은 모델(GPT-5-mini, Grok 4 Fast 등)은 영어 프롬프트에서 최대 10점가량 성능이 향상되었다. 이는 **소규모 모델일수록 학습 데이터의 언어적 편향에 민감하며, 다국어 일반화 능력이 상대적으로 제한적임을 시사한다.**

입력 모달리티 측면에서도 명확한 경향이 나타났다. **Text-only 조건이 가장 높은 성능을 기록했으며 Image-only 대비 더 우수했다.** Text+Figure 조건은 Text-only와의 성능 차이가 약 0.3%에 불과해 사실상 동일한 수준이었다. 특히 기하 영역에서도 텍스트 입력만으로 높은 성능이 유지되었는데, 이는 2026학년도 수능 수학 문항의 텍스트 서술만으로도 문제 해결에 필요한 정보가 충분히 제공되어 시각 정보의 추가적 이점이 크지 않았기 때문으로 해석된다. 다만 이는 본 시험의 특수성에 기반한 결과이며, 시각적 정보가 문제 해결에 필수적인 환경에서는 다른 양상이 나타날 가능성이 있다.

RQ.3 수학 문제 특성에 따른 성능 차이 모든 조합의 모델들을 평균했을 때, 미적분 영역의 성능이 가장 낮게 나타났으며, 평균 Normalized Score는 75.3점이었다. 이어서 기하 영역이 78.4점을 기록했으며, 공통과목과 확률·통계는 80점대 초중반 수준을 유지하였다. 이러한 결과는 다단계 논리 추론을 요구하는 미적분과 공간적 추론을 요구하는 기하 영역이 여전히 최신 LLM들에게 가장 큰 도전 과제로 남아 있음을 보여준다.

배점별 분석에서도 유사한 추세가 확인되었다. 2–3점 문항(정규화 점수: 0.91–0.97)에 비해 4점 문항(0.68–0.71)은 약 0.23–0.29 수준의 뚜렷한 성능 격차가 관찰되었다. 이러한 결과는 **수능의 난이도 체계가 LLM의 수학 문제 해결 성능에도 체계적 차이를 유발함을 시사한다**. 문항 형식에 대해서도 5지선다형(0.93–0.97)이 단답형(0.68–0.71)보다 상대적으로 높은 성능을 보였으나, 객관식 문항이 주로 낮은 배점에 집중되어 있다는 점을 고려할 때 형식 효과와 난이도 효과를 독립적으로 분리하기는 어렵다.

RQ.4 Reasoning 강화의 효과와 한계 GPT-5 계열에서 `Reasoning_Effort`를 minimal에서 high로 증가시켰을 때 성능은 82.6점에서 100.0점으로 17.4점 상승하였으나, 토큰 사용량은 약 60 tokens/문항에서 240-268 tokens/문항으로 약 4-5배 증가하였다. Efficiency Score는 minimal 설정에서 1.58-1.70으로 가장 높았으며, high effort에서 0.37로 급격히 하락하였다. `Text_Verbosity`의 영향은 미미하였고, **성능 변화는 주로** `Reasoning_Effort`**에 의해 결정**되었다. 특히 low/minimal reasoning에서는 오히려 성능 저하가 발생하여, **기본 모델이 충분한 추론 능력을 보유한 경우 불필요한 reasoning이 역효과를 낳을 수 있다.**

이는 reasoning effort 증가가 어느 정도 확실한 성능 향상을 가져오지만 동시에 계산 비용의 급격한 증가를 초래하며, 모델의 기본 추론 능력과 문제 난이도를 고려한 적응적 reasoning 설정이 효율성과 성능 간의 최적 균형을 달성하는 데 필수적임을 시사한다.

7 한계점

연구 설계 및 실험 환경의 특성상 다음과 같은 제약이 존재한다.

다양한 언어 모델 활용의 제약 본 연구는 다양한 대규모 언어 모델을 일관된 환경에서 실험하기 위해 OpenRouter의 API를 통해 모든 모델의 실험을 수행하였다. 이는 구현의 편의성과 높은 재현성을 보장하지만, 반대로 여러 가지 제약도 동반한다.

첫째, OpenRouter의 서빙을 통해 활용되는 여러 외부 LLM 들은 상황에 따라 직접 해당 모델을 활용할 때와 미묘하게 다른 성능을 보이는 경우도 있다. 동일 모델이라도 양자화 수준이나 최적화 방식의 설정이 다를 수 있어, 모델 본래의 성능이 완전히 반영되지 않았을 가능성이 있다. 본 연구에서는 이러한 한계를 인지하면서도, OpenRouter에서 제공하는 기본 설정을 모든 모델에 일관되게 적용함으로써 상대적 비교의 공정성을 최대한 확보하고자 하였다. 향후 연구에서는 Open-weight 모델에 대해 로컬 환경에서의 추가 평가를 병행하고, 폐쇄 조건을 엄격히 통제한 환경에서의 평가를 수행할 계획이다.

둘째, OpenRouter 활용 조건, AIME 2025 상위 등록 언어모델 등의 기준에 따라 평가 대상 언어 모델을 선정하는 과정에서 한국어 특화 모델들은 부득이 제외되었다. 한국어에 최적화된 모델의 경우 프롬프트 언어 선택에

따른 성능 변화 양상이 본 연구에서 관찰된 경향과 상이할 가능성이 있다. 이는 후속 연구 및 분석의 주요 대상이라 할 수 있다.

Reasoning 강화 실험의 범위 제한 본 연구에서 `Reasoning_Effort` 및 verbosity 조절 실험은 GPT-5 계열 모델에만 수행되었다. 아직은 추론형 혹은 Thinking 형 기술의 형태와 이름이 혼재하는 상황이어서, 일관된 기준을 통한 비교를 위해 GPT-5로 범위를 한정하였다. 따라서 본 연구의 reasoning 관련 결론과 시사점은 GPT-5 계열에 특화된 것이며, 다른 모델로의 일반화하는 향후 다각도로 검토해야 할 대상이다.

인간 수험생과의 비교 부재 본 연구는 2026학년도 수능 수학 문항을 대상으로 분석을 수행하였으나, 평가 시점에서 공식적인 수험생 통계가 공개되지 않아 LLM과 인간 수험생 간의 문제 해결 패턴 차이를 직접 비교할 수 없었다. 향후 2026학년도 수능의 실제 채점 결과 및 문항별 정답률 분포가 공개되면, 이를 활용하여 기계가 어려워하는 문제와 사람이 어려워하는 문제 간의 격차를 비교, 분석함으로써 LLM의 추론 특성을 더욱 심층적으로 규명할 예정이다.

8 결론

본 연구는 2026학년도 한국 대학수학능력시험 수학 영역을 활용하여, 데이터 누출이 완전히 배제된 환경에서 최신 LLM의 수학 추론 능력을 평가하기 위한 벤치마크와 평가 프레임워크를 제시하였다. 시험 공개 직후 2시간 이내에 46개 문항을 디지털화하고, 24개 모델을 대상으로 입력 조건, 프롬프트 언어, 추론 강도 등을 체계적으로 변화시키며 다각도 평가를 수행하였다.

실험 결과, 최신 상용 모델들은 수능 수학 수준의 문제에서 90점 이상의 높은 성능을 보였으나, 문제 특성(미적분, 고배점), 입력 조건(언어, 모달리티), 그리고 시간 제약 여부에 따라 성능 편차가 크게 나타났다. 특히 추론 강화 기능은 절대 성능을 향상하지만 비용 효율성이 급격히 저하되어, 실용적 관점에서는 기본 모델이 더 합리적인 선택일 수 있음을 확인하였다.

본 연구의 학술적 기여는 크게 세 가지이다. 첫째, 모델 학습 과정에 포함될 수 없는 완전한 비노출 평가 환경을 구현하여 기존 벤치마크의 데이터 오염 문제를 근본적으로 해결하였다. 둘째, 사람을 대상으로 하는 시험지 형태의 데이터를 LLM 평가를 위한 데이터로 변환하는 디지털라이제이션 방법을 제시하고 규격화하였다. 셋째, 단순 정답률을 넘어 시간, 비용, 효율성을 종합적으로 고려한 실용적 평가 관점을 제공하였다.

본 연구는 OpenRouter API 사용에 따른 모델 설정의 제약, 한국어 특화 모델의 부재, GPT-5에 국한된 추론 실험, 그리고 인간 수험생과의 직접 비교 부재 등의 한계를 가진다. 향후 연구에서는 수능 데이터를 활용한 종단 분석, 공식 채점 결과와의 비교, 다른 교과 영역으로의 확장, 그리고 한국어 특화 모델에 대한 평가 등을 수행할 계획이다.

궁극적으로, 본 연구는 LLM 평가가 "얼마나 많이 맞추는가"에서 "실제 제약 조건에서 기계가 얼마나 효율적이고 안정적으로 문제를 해결하는가"로 전환되어야 함을 보인다. 제시된 평가 프레임워크가 수능과 같이 높은 중요도를 가진 실제 시험 환경에서의 LLM 활용 및 평가를 위한 새로운 기준점이 될 수 있을 것으로 기대한다.

References

Simone Balloccu, Patrícia Schmidtová, Mateusz Lango, and Ondřej Dušek. Leak, cheat, repeat: Data contamination and evaluation malpractices in closed-source llms. *arXiv preprint arXiv:2402.03927*, 2024.

Mislav Balunović, Jasper Dekoninck, Ivo Petrov, Nikola Jovanović, and Martin Vechev. Matharena: Evaluating llms on uncontaminated math competitions. *arXiv preprint arXiv:2505.23281*, 2025.

Konstantin Chernyshev, Vitaliy Polshkov, Ekaterina Artemova, Alex Myasnikov, Vlad Stepanov, Alexei Miasnikov, and Sergei Tilga. U-math: A university-level benchmark for evaluating mathematical skills in llms. *arXiv preprint arXiv:2412.03205*, 2024.

Karl Cobbe, Vineet Kosaraju, Mohammad Bavarian, Mark Chen, Heewoo Jun, Lukasz Kaiser, Matthias Plappert, Jerry Tworek, Jacob Hilton, Reiichiro Nakano, Christopher Hesse, and John Schulman. Training verifiers to solve math word problems. *arXiv preprint arXiv:2110.14168*, 2021.

Chunyuan Deng, Yilun Zhao, Xiangru Tang, Mark Gerstein, and Arman Cohan. Investigating data contamination in modern benchmarks for large language models. In *Proceedings of the 2024 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies (Volume 1: Long Papers)*, pages 8706–8719, 2024.

Jesse Dodge, Maarten Sap, Ana Marasović, William Agnew, Gabriel Ilharco, Dirk Groeneveld, Margaret Mitchell, and Matt Gardner. Documenting large webtext corpora: A case study on the colossal clean crawled corpus. In Marie-Francine Moens, Xuanjing Huang, Lucia Specia, and Scott Wen-tau Yih, editors, *Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing*, pages 1286–1305, Online and Punta Cana, Dominican Republic, November 2021. Association for Computational Linguistics. doi: 10.18653/v1/2021.emnlp-main.98. URL https://aclanthology.org/2021.emnlp-main.98/.

Dan Hendrycks, Collin Burns, Saurav Kadavath, Akul Arora, Eric Guo, Robert Baseggio, Colin Chen, Dawn Chen, Jesse Choi, Andy Dang, et al. Measuring mathematical problem solving with the MATH dataset. *arXiv preprint arXiv:2103.03874*, 2021.

Naila Shafirni Hidayat, Muhammad Dehan Al Kautsar, Alfan Farizki Wicaksono, and Fajri Koto. Simulating training data leakage in multiple-choice benchmarks for llm evaluation. *arXiv preprint arXiv:2505.24263*, 2025.

Takeshi Kojima, Shixiang Shane Gu, Machel Reid, Yutaka Matsuo, and Yusuke Iwasawa. Large language models are zero-shot reasoners. *arXiv preprint arXiv:2205.11916*, 2022.

Qintong Li, Leyang Cui, Xueliang Zhao, Lingpeng Kong, and Wei Bi. GSM-Plus: A comprehensive benchmark for evaluating the robustness of LLMs as mathematical problem solvers, 2024.

Hongwei Liu, Zilong Zheng, Yuxuan Qiao, Haodong Duan, Zhiwei Fei, Fengzhe Zhou, Wenwei Zhang, Songyang Zhang, Dahua Lin, and Kai Chen. Mathbench: Evaluating the theory and application proficiency of llms with a hierarchical mathematics benchmark. *arXiv preprint arXiv:2405.12209*, 2024.

Pan Lu, Hritik Bansal, Tony Xia, Jiacheng Liu, Chunyuan Li, Hannaneh Hajishirzi, Hao Cheng, Kai-Wei Chang, Michel Galley, and Jianfeng Gao. Mathvista: Evaluating mathematical reasoning of foundation models in visual contexts. In *International Conference on Learning Representations (ICLR)*, 2024.

Yujun Mao, Yoon Kim, and Yilun Zhou. CHAMP: A competition-level dataset for fine-grained analyses of LLMs' mathematical reasoning capabilities. *arXiv preprint arXiv:2401.06961*, 2024.

Sewon Min, Xinxi Lyu, Ari Holtzman, Mikel Artetxe, Mike Lewis, Hannaneh Hajishirzi, and Luke Zettlemoyer. Rethinking the role of demonstrations: What makes in-context learning work? In Yoav Goldberg, Zornitsa Kozareva, and Yue Zhang, editors, *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*, pages 11048–11064, Abu Dhabi, United Arab Emirates, December 2022. Association for Computational Linguistics. doi: 10.18653/v1/2022.emnlp-main.759. URL https://aclanthology.org/2022.emnlp-main.759/.

Cheonbok Park, Jeonghoon Kim, Joosung Lee, Sanghwan Bae, Jaegul Choo, and Kang Min Yoo. Cross-lingual collapse: How language-centric foundation models shape reasoning in large language models. *arXiv preprint arXiv:2506.05850*, 2025.

Jake Snell et al. Scaling LLM test-time compute optimally can be more efficient than scaling model size. In *Advances in Neural Information Processing Systems (NeurIPS)*, 2024.

Haoxiang Sun, Yingqian Min, Zhipeng Chen, Wayne Xin Zhao, Lei Fang, Zheng Liu, Zhongyuan Wang, and Ji-Rong Wen. Challenging the boundaries of reasoning: An olympiad-level math benchmark for large language models. *arXiv preprint arXiv:2503.21380*, 2025.

Ke Wang, Junting Pan, Weikang Shi, Zimu Lu, Mingjie Zhan, and Hongsheng Li. Measuring multimodal mathematical reasoning with the MATH-Vision dataset. In *Advances in Neural Information Processing Systems (NeurIPS), Datasets and Benchmarks Track*, 2024.

Xuezhi Wang, Jason Wei, Dale Schuurmans, Quoc Le, Ed Chi, Sharan Narang, Aakanksha Chowdhery, and Denny Zhou. Self-consistency improves chain of thought reasoning in language models. *arXiv preprint arXiv:2203.11171*, 2022.

Ruijie Xu, Zengzhi Wang, Run-Ze Fan, and Pengfei Liu. Benchmarking benchmark leakage in large language models. *arXiv preprint arXiv:2404.18824*, 2024.

Zhanke Zhou, Zhaocheng Zhu, Xuan Li, Mikhail Galkin, Xiao Feng, Sanmi Koyejo, Jian Tang, and Bo Han. Landscape of thoughts: Visualizing the reasoning process of large language models. *arXiv preprint arXiv:2503.22165*, 2025.

A 모델별 전체 결과: 성능 · 응답 시간 · 비용

본 부록에서는 본문에서 요약하여 제시한 결과를 보완하기 위해, 모든 모델에 대해 입력 모달리티 및 프롬프트 언어 조합별 정규화 성능, 응답 시간(latency), 총비용을 상세하게 제시한다. 표 6에서는 각 모델의 조합별 정규화 점수를, 표 7에서는 동일 조건에서 측정한 평균 응답 시간을, 표 8에서는 전체 평가를 수행하는 데 소요된 총비용을 정리하였다.

표 6: 모든 모델의 조합별 정규화 성능 비교표

Model Type	Model	English			Korean		
		Text	Image	Text+Figure	Text	Image	Text+Figure
Closed-weight	GPT-5 Codex	97.8	97.8	100.0	100.0	100.0	100.0
	GPT-5	95.7	100.0	95.7	95.7	97.8	97.8
	GPT-5-mini	95.7	91.3	93.5	93.5	91.3	93.5
	GPT-5-nano	93.5	78.3	95.7	89.1	67.4	89.1
	Grok 4	93.5	56.5	95.7	97.8	52.2	95.7
	Grok 4 Fast	93.5	32.6	91.3	95.7	37.0	97.8
	Claude 4.5 Sonnet	73.9	67.4	78.3	80.4	71.7	82.6
	Claude 4.5 Haiku	82.6	65.2	78.3	80.4	67.4	82.6
	Claude 4.1 Opus	76.1	56.5	73.9	80.4	69.6	76.1
	Gemini 2.5 Pro	95.7	97.8	93.5	91.3	93.5	93.5
	Gemini 2.5 Flash	80.4	84.8	80.4	71.7	73.9	71.7
Open-weight	gpt-oss-20B	93.5	–	–	95.7	–	–
	Qwen3 235B A22B	89.1	73.9	91.3	82.6	69.6	84.8
	Qwen3 235B A22B Thinking 2507	93.5	84.8	91.3	89.1	97.8	84.8
	Deepseek R1 0528	93.5	–	–	95.7	–	–
	Deepseek V3.2 Exp	91.3	–	–	87.0	–	–
	GLM 4.6	87.0	–	–	89.1	–	–
	Magistral Medium 2506	71.7	–	–	82.6	–	–
	Magistral Medium 2506 Thinking	84.8	–	–	80.4	–	–
	MiniMax M2	97.8	–	–	82.6	–	–
	Llama 4 Maverick	23.9	65.2	32.6	21.7	43.5	28.3
	Llama 3.3 Nemotron Super 49B V1.5	80.4	–	–	80.4	–	–
	Kimi K2 0905	78.3	–	–	78.3	–	–
	Kimi K2 Thinking	91.3	–	–	82.6	–	–

표 7: Latency(ms) of base model candidates.

Model Type	Model	English			Korean		
		Text	Image	Text+Figure	Text	Image	Text+Figure
Closed-weight	GPT-5 Codex	5457.4	5808.1	6130.2	4333.3	7426.4	5393.7
	GPT-5	2134.3	4839.8	3561.1	2521.6	4832.4	3882.0
	GPT-5-mini	2297.2	2221.5	2012.6	2623.8	2875.0	2402.5
	GPT-5-nano	3081.7	2816.4	3354.8	4527.9	3454.1	2860.4
	Grok 4	6234.1	16463.0	4371.7	6734.4	16875.1	6302.7
	Grok 4 Fast	840.3	2866.6	861.6	1106.7	2812.5	868.4
	Claude 4.5 Sonnet	641.3	719.3	655.3	670.7	751.7	676.8
	Claude 4.5 Haiku	275.9	308.9	284.4	281.6	343.0	294.1
	Claude 4.1 Opus	780.1	927.9	829.2	867.1	958.6	858.0
	Gemini 2.5 Pro	2742.4	2923.7	2581.8	2427.3	2770.0	2421.2
	Gemini 2.5 Flash	1537.0	1461.4	1408.9	1661.7	1736.1	1717.4
Open-weight	gpt-oss-20B	1729.8	-	-	1304.6	-	-
	Qwen3 235B A22B	2890.0	3888.1	2309.5	2735.6	6997.7	5865.2
	Qwen3 235B A22B Thinking 2507	12616.1	9157.2	9288.6	9665.3	10350.5	6639.4
	Deepseek R1 0528	11540.0	-	-	10885.7	-	-
	Deepseek V3.2 Exp	3161.0	-	-	3057.1	-	-
	GLM 4.6	13152.2	-	-	9884.7	-	-
	Magistral Medium 2506	3986.7	-	-	2771.8	-	-
	Magistral Medium 2506 (thinking)	4998.6	-	-	3862.6	-	-
	MiniMax M2	4037.6	-	-	3786.8	-	-
	Llama 4 Maverick	589.7	1151.0	723.6	531.9	915.0	1186.2
	Llama 3.3 Nemotron Super 49B V1.5	3235.2	-	-	3262.7	-	-
	Kimi K2 0905	10250.8	-	-	7242.8	-	-
	Kimi K2 Thinking	26214.9	-	-	33906.9	-	-

표 8: Total Cost($) of base model candidates.

Model Type	Model	English			Korean		
		Text	Image	Text+Figure	Text	Image	Text+Figure
Closed-weight	GPT-5 Codex	2.5181	1.9222	2.0817	1.8009	2.3985	2.0699
	GPT-5	1.4378	1.6743	1.7073	1.7384	1.7896	1.7618
	GPT-5-mini	0.3187	0.3022	0.2683	0.3741	0.3699	0.3258
	GPT-5-nano	0.1063	0.1126	0.1250	0.1555	0.1287	0.1064
	Grok 4	10.5872	24.3791	7.5040	11.4779	26.1858	9.8555
	Grok 4 Fast	0.2028	0.6162	0.2071	0.2662	0.4924	0.2024
	Claude 4.5 Sonnet	1.0253	1.2765	1.1099	1.1663	1.4694	1.2543
	Claude 4.5 Haiku	0.2084	0.2415	0.2214	0.2333	0.2842	0.2456
	Claude 4.1 Opus	3.3942	3.8985	3.6921	4.0069	4.3796	4.0680
	Gemini 2.5 Pro	5.3461	5.8185	5.2356	4.8186	5.4515	4.9693
	Gemini 2.5 Flash	1.0569	1.0381	0.9517	1.1582	1.2454	1.2030
Open-weight	gpt-oss-20B	0.0075	-	-	0.0069	-	-
	Qwen3 235B A22B	0.1886	0.3279	0.1835	0.2292	0.5302	0.3951
	Qwen3 235B A22B Thinking 2507	0.8418	0.8858	0.7319	0.7146	0.6988	0.6756
	Deepseek R1 0528	1.0082	-	-	0.8708	-	-
	Deepseek V3.2 Exp	0.0332	-	-	0.0373	-	-
	GLM 4.6	1.4065	-	-	0.9748	-	-
	Magistral Medium 2506	1.6690	-	-	1.1278	-	-
	Magistral Medium 2506 (thinking)	2.1733	-	-	1.4425	-	-
	MiniMax M2	0.4169	-	-	0.3706	-	-
	Llama 4 Maverick	0.0440	0.0378	0.0353	0.0398	0.0402	0.0328
	Llama 3.3 Nemotron Super 49B V1.5	0.1092	-	-	0.1070	-	-
	Kimi K2 0905	0.2891	-	-	0.2124	-	-
	Kimi K2 Thinking	1.4857	-	-	2.0854	-	-

B 모델별 성능·시간·비용 효율성 전체 결과

본 부록에서는 섹션 5.1에서 분석한 모델별 Efficiency Score를 모든 입력 조합(텍스트/이미지/텍스트+도형 × 한국어/영어)에 대해 보인다. 그림 19는 (Text+Figure, 한국어) 조합에 대한 Efficiency Score 비교, 그림 20는 (Image Only, 한국어) 조합에 대한 Efficiency Score 비교, 그림 21는 (Text Only, 영어) 조합에 대한 Efficiency Score 비교, 그림 22는 (Text+Figure, 영어) 조합에 대한 Efficiency Score 비교, 그림 23는 (Image Only, 영어) 조합에 대한 Efficiency Score 비교를 보인다. 이미지 입력을 지원하지 않는 모델은 Image-only 및 Text+Figure 조건의 평가에서 제외되었다. (Text Only, 한국어) 조합에 대한 그림은 본문의 그림 11에서 확인할 수 있다.

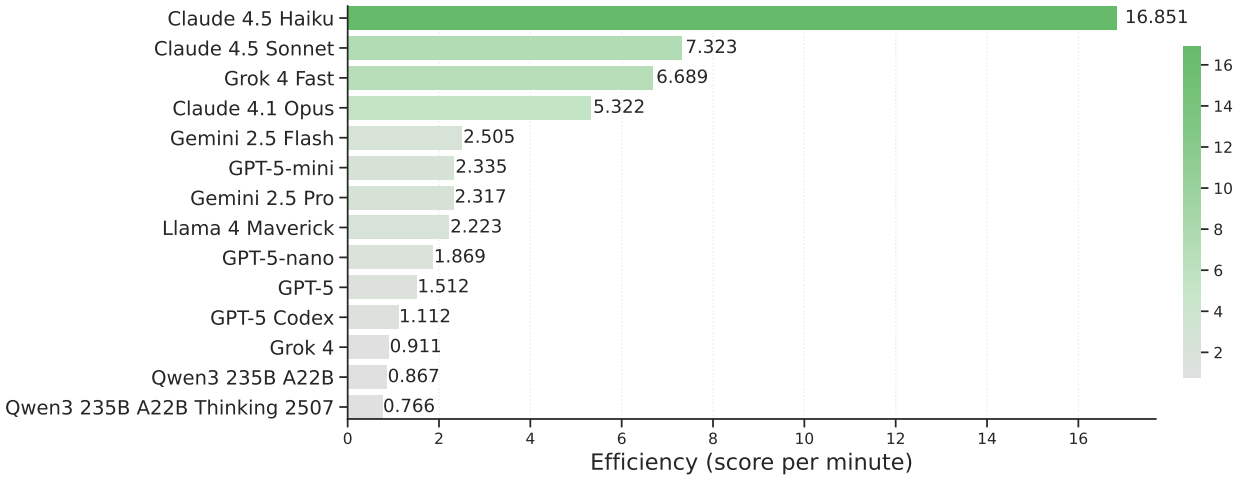

(a) 성능·시간 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 한국어)**

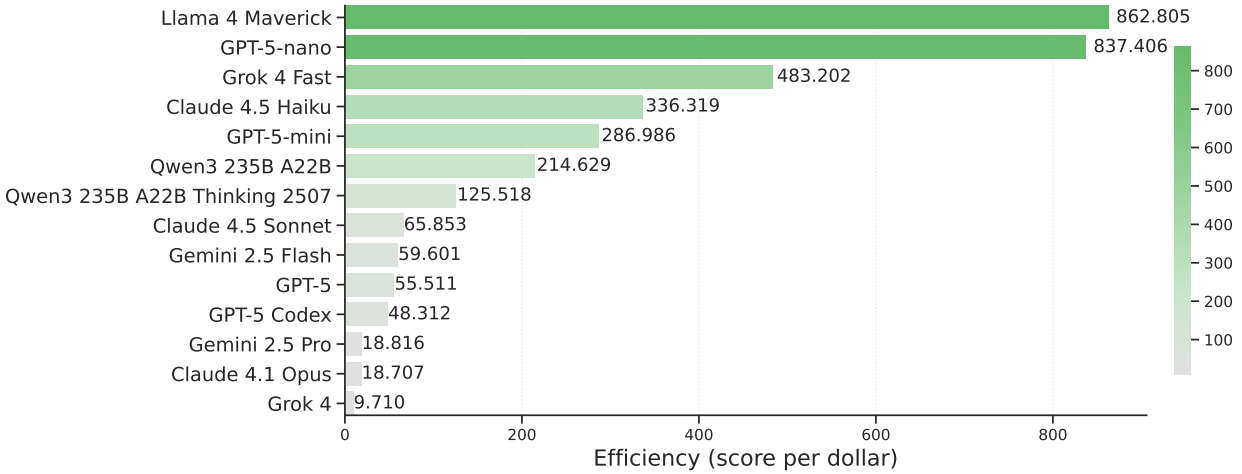

(b) 성능·비용 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 한국어)**

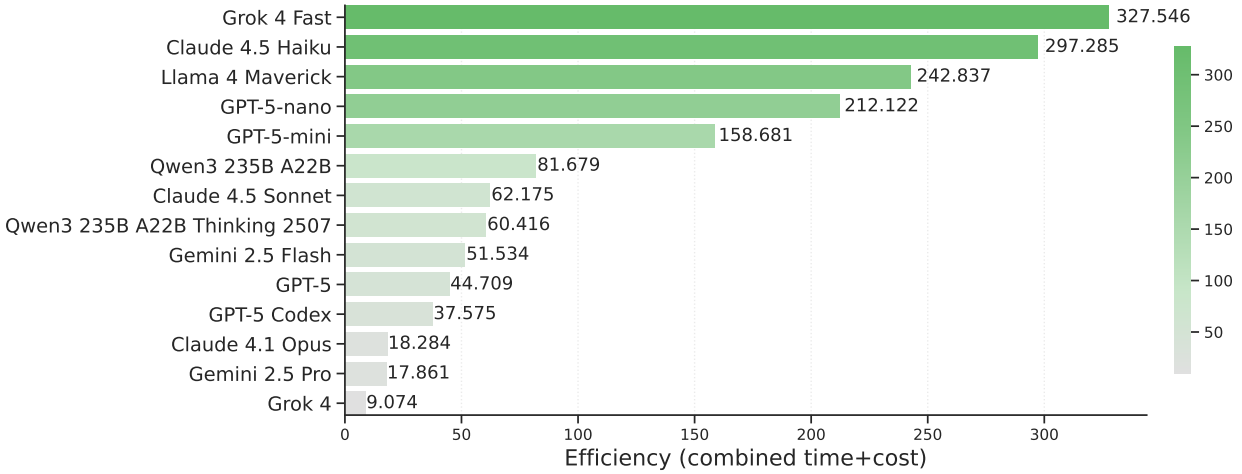

(c) 성능·시간·비용 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 한국어)**(Text+Figure, 한국어)

그림 19: 성능, 시간 및 비용 간 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 한국어)**

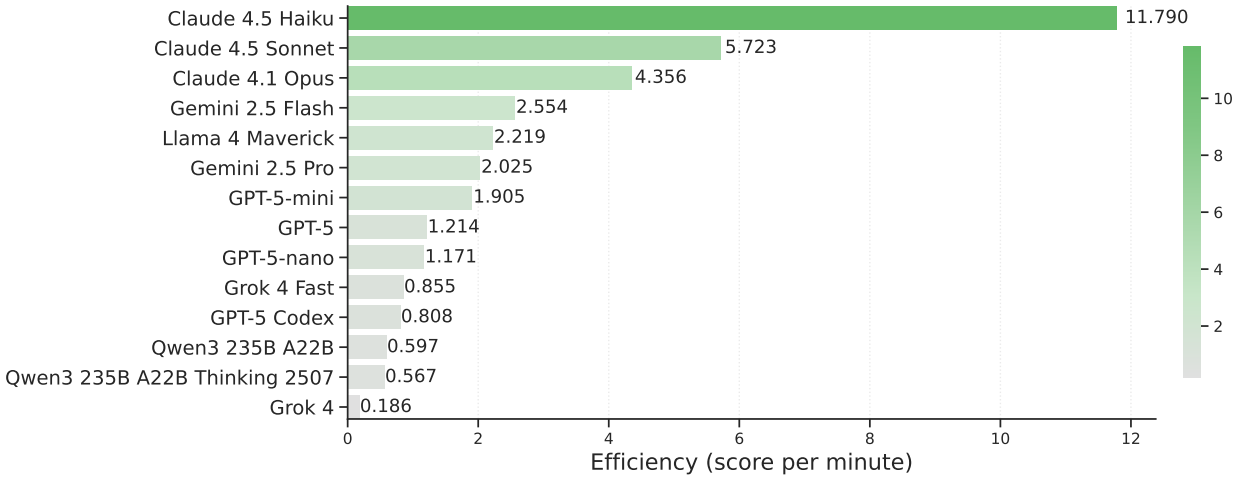

(a) 성능·시간 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 한국어)**

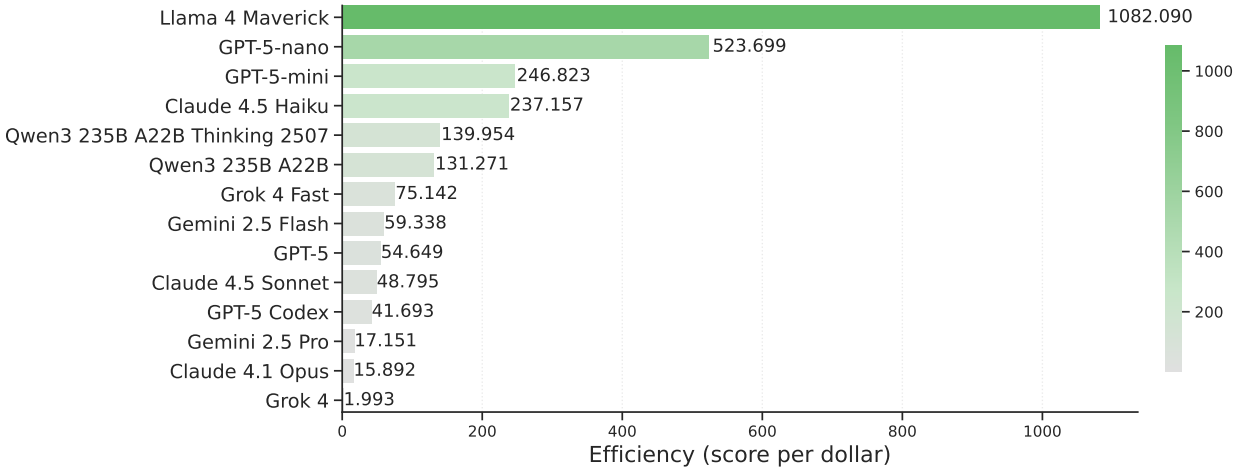

(b) 성능·비용 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 한국어)**

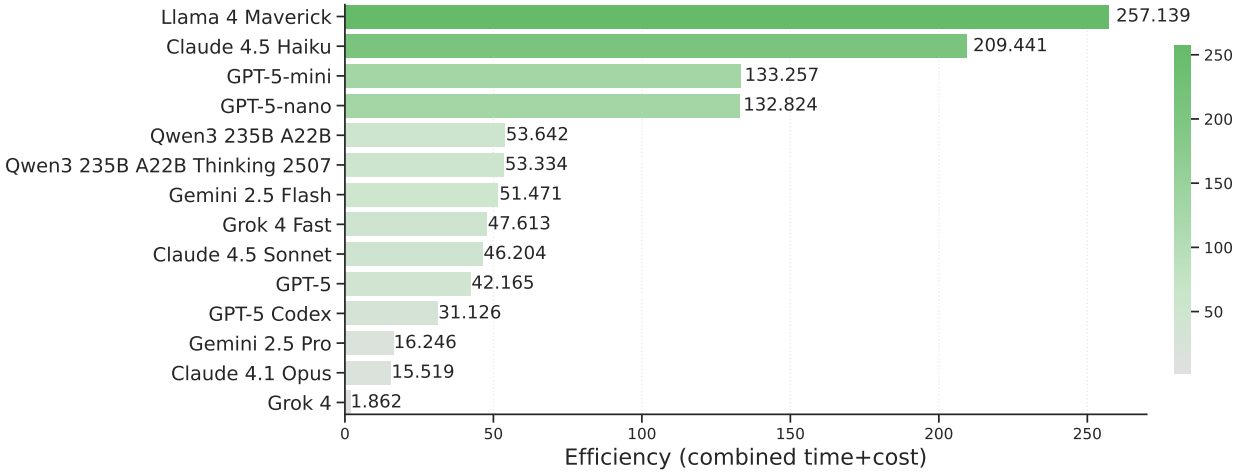

(c) 성능·시간·비용 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 한국어)**

그림 20: 성능, 시간 및 비용 간 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 한국어)**

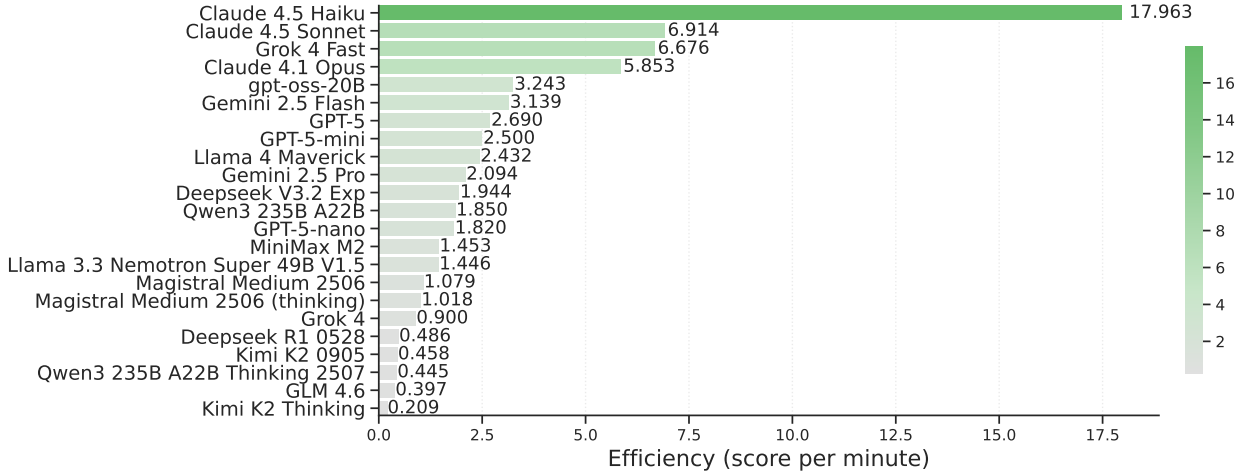

(a) 성능·시간 Efficiency Score 비교 **(입력 모달리티: Text Only, 프롬프트 언어: 영어)**

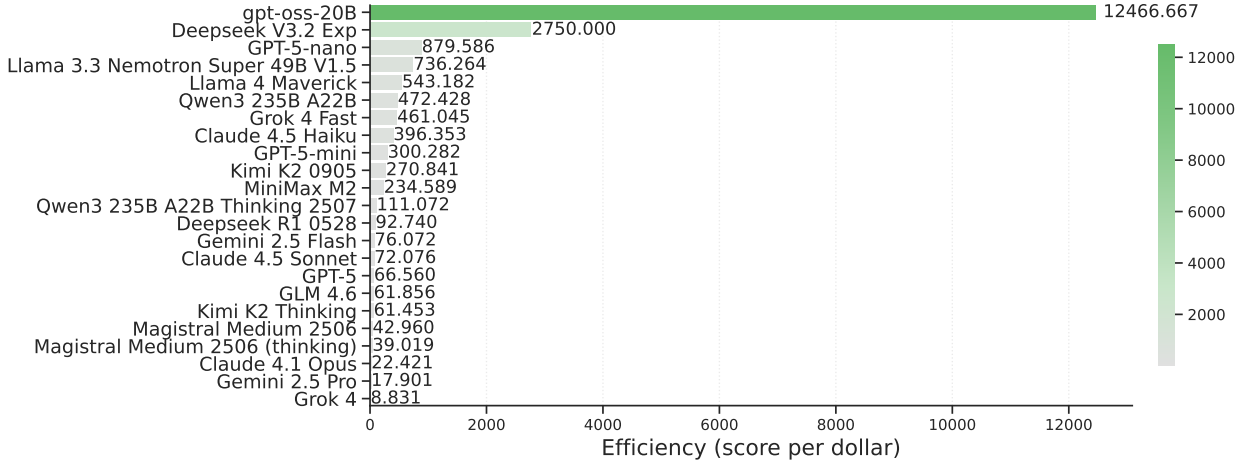

(b) 성능·비용 Efficiency Score 비교 **(입력 모달리티: Text Only, 프롬프트 언어: 영어)**

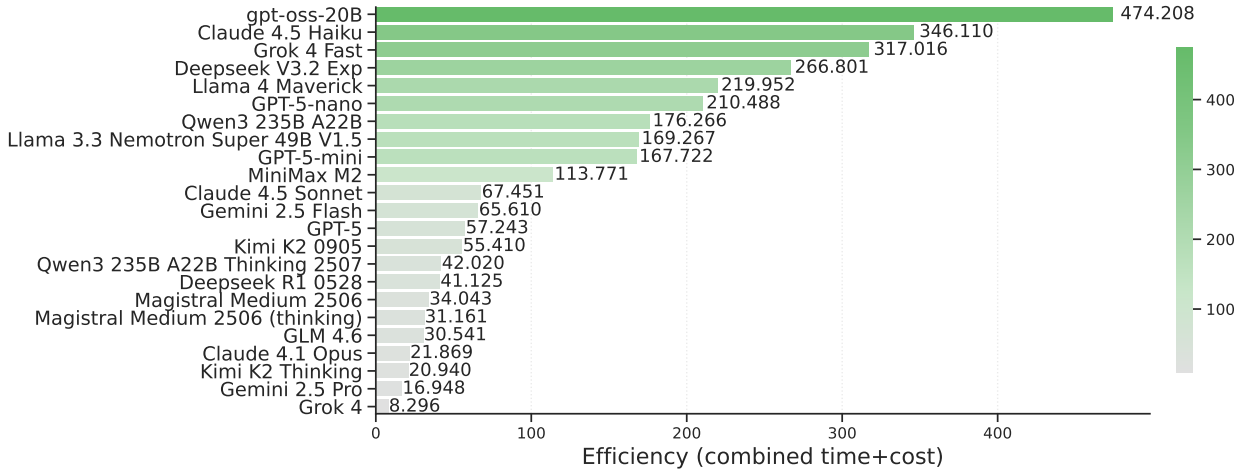

(c) 성능·시간·비용 Efficiency Score 비교 **(입력 모달리티: Text Only, 프롬프트 언어: 영어)**

그림 21: 성능, 시간 및 비용 간 Efficiency Score 비교 **(입력 모달리티: Text Only, 프롬프트 언어: 영어)**

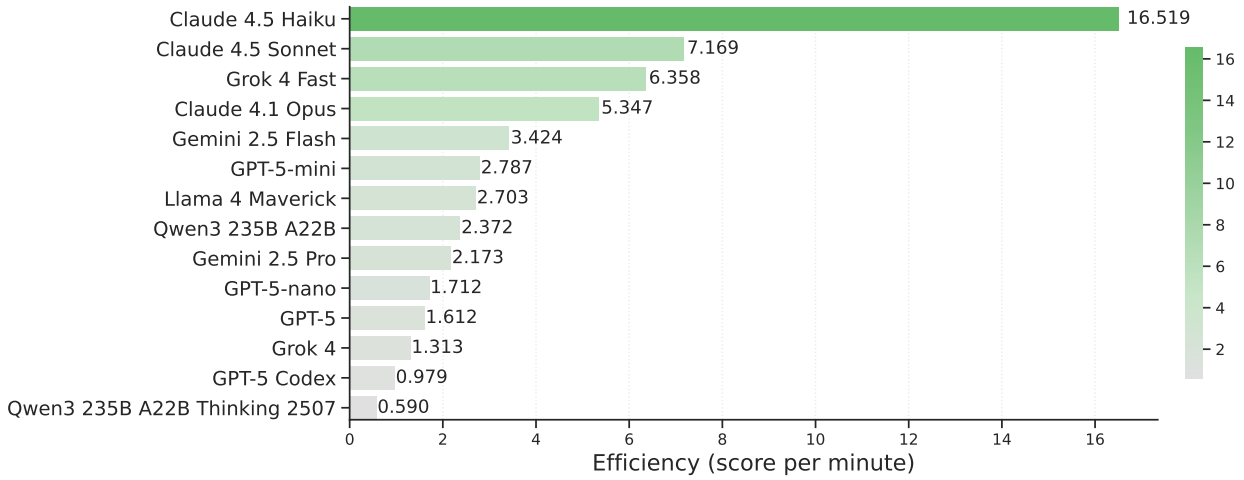

(a) 성능·시간 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)**

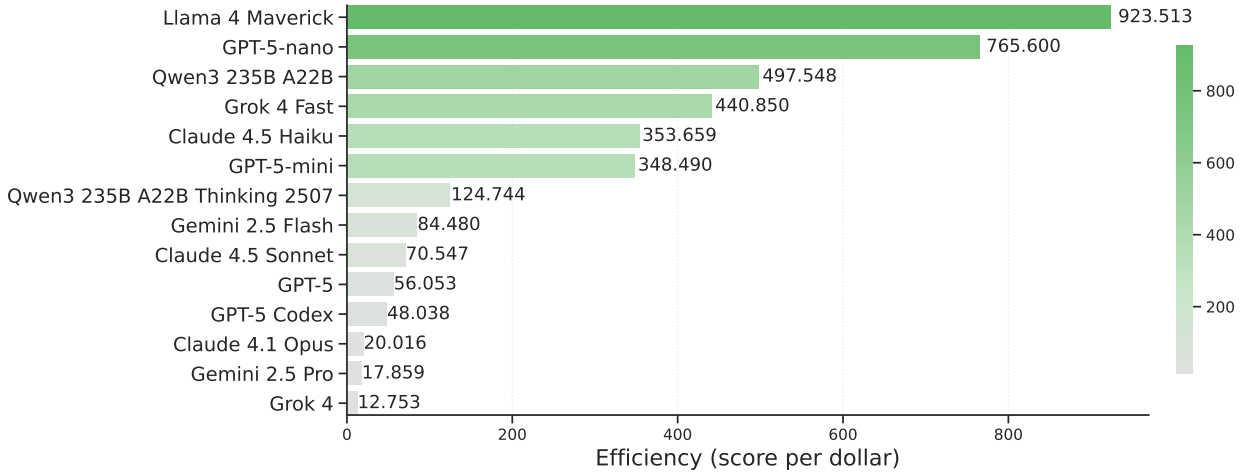

(b) 성능·비용 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)**

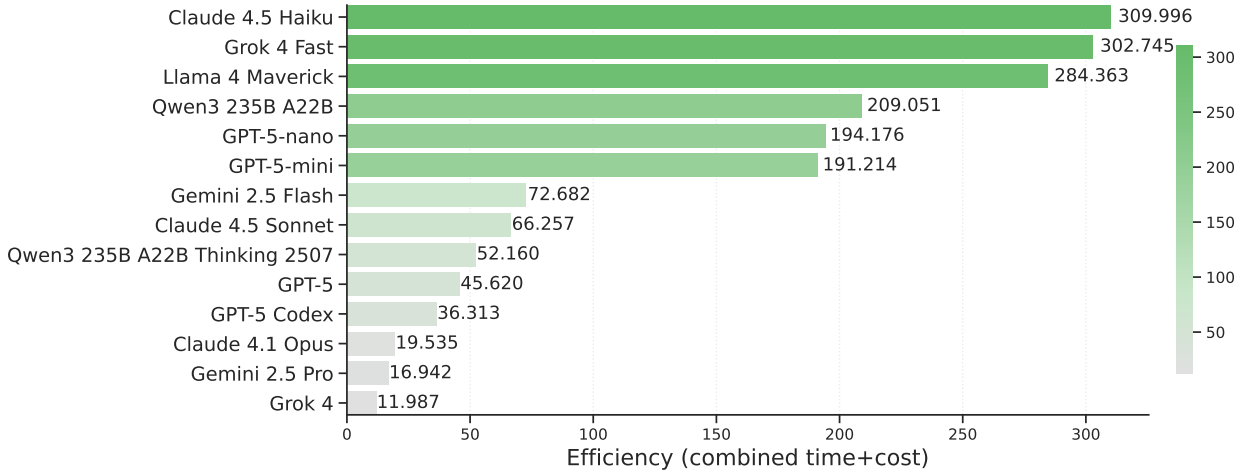

(c) 성능·시간·비용 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)**

그림 22: 성능, 시간 및 비용 간 Efficiency Score 비교 **(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)**

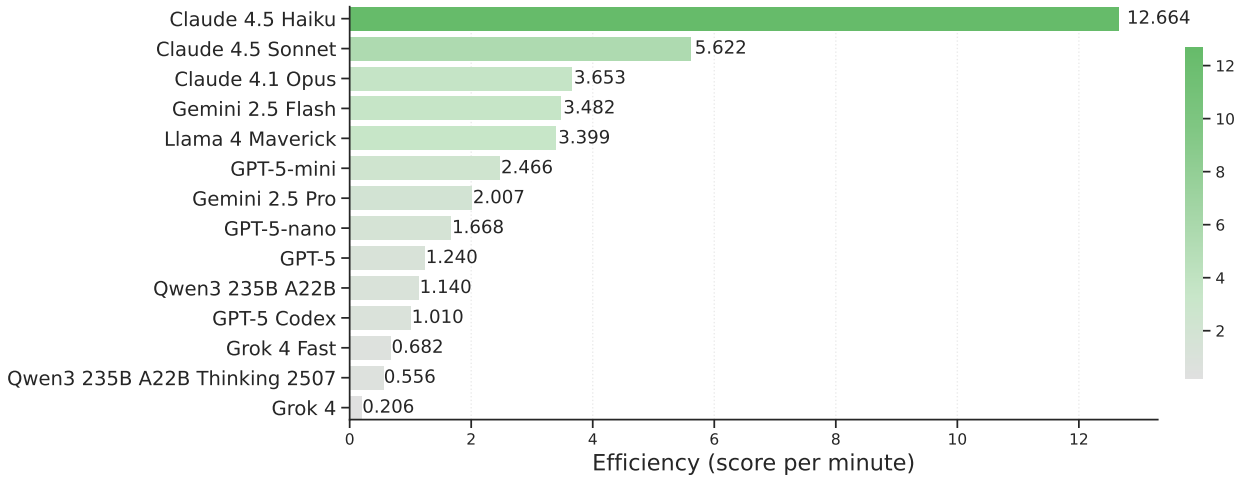

(a) 성능·시간 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 영어)**

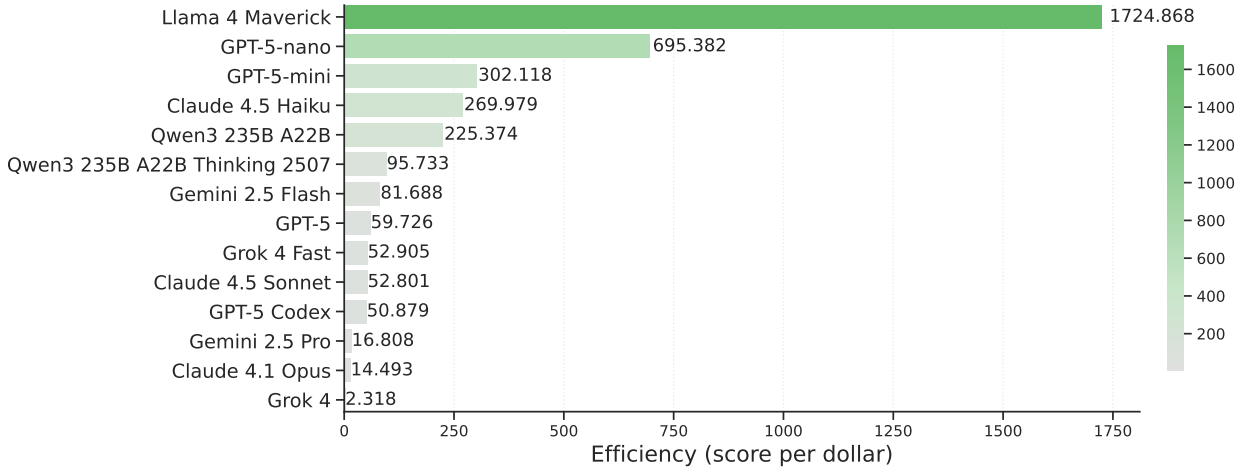

(b) 성능·비용 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 영어)**

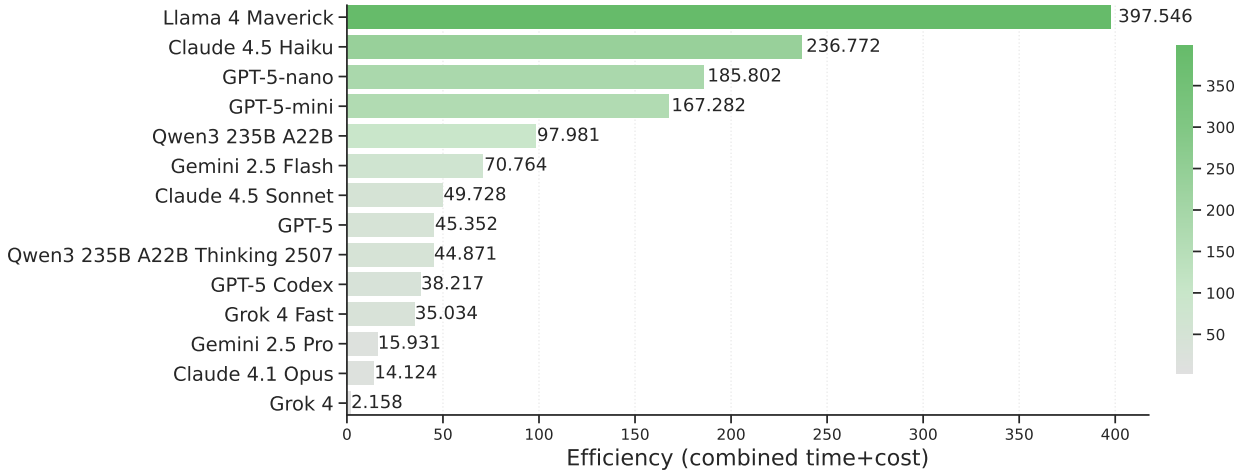

(c) 성능·시간·비용 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 영어)**

그림 23: 성능, 시간 및 비용 간 Efficiency Score 비교 **(입력 모달리티: Image Only, 프롬프트 언어: 영어)**

C 모델 파라미터 규모에 따른 성능 및 응답 시간 전체 결과

본 부록에서는 섹션 5.2.1에서 분석한 모델 규모별 성능(Normalized Score) 및 응답 시간을 모든 입력 조합(텍스트/이미지/텍스트+도형 × 한국어/영어)에 대해 보인다. 그림 24은 (Text+Figure, 한국어) 조합에 대한 모델 규모별 성능 및 응답시간 비교, 그림 25는 (Image Only, 한국어) 조합에 대한 모델 규모별 성능 및 응답시간 비교, 그림 26는 (Text Only, 영어) 조합에 대한 모델 규모별 성능 및 응답시간 비교, 그림 27는 (Text+Figure, 영어) 조합에 대한 모델 규모별 성능 및 응답시간 비교, 그림 28는 (Image Only, 영어) 조합에 대한 모델 규모별 성능 및 응답시간 비교를 보인다. 이미지 입력을 지원하지 않는 모델은 Image Only 및 Text+Figure 조건의 평가에서 제외되었다. (Text only, 한국어) 조합에 대한 그림은 본문의 그림 12에서 확인할 수 있다.

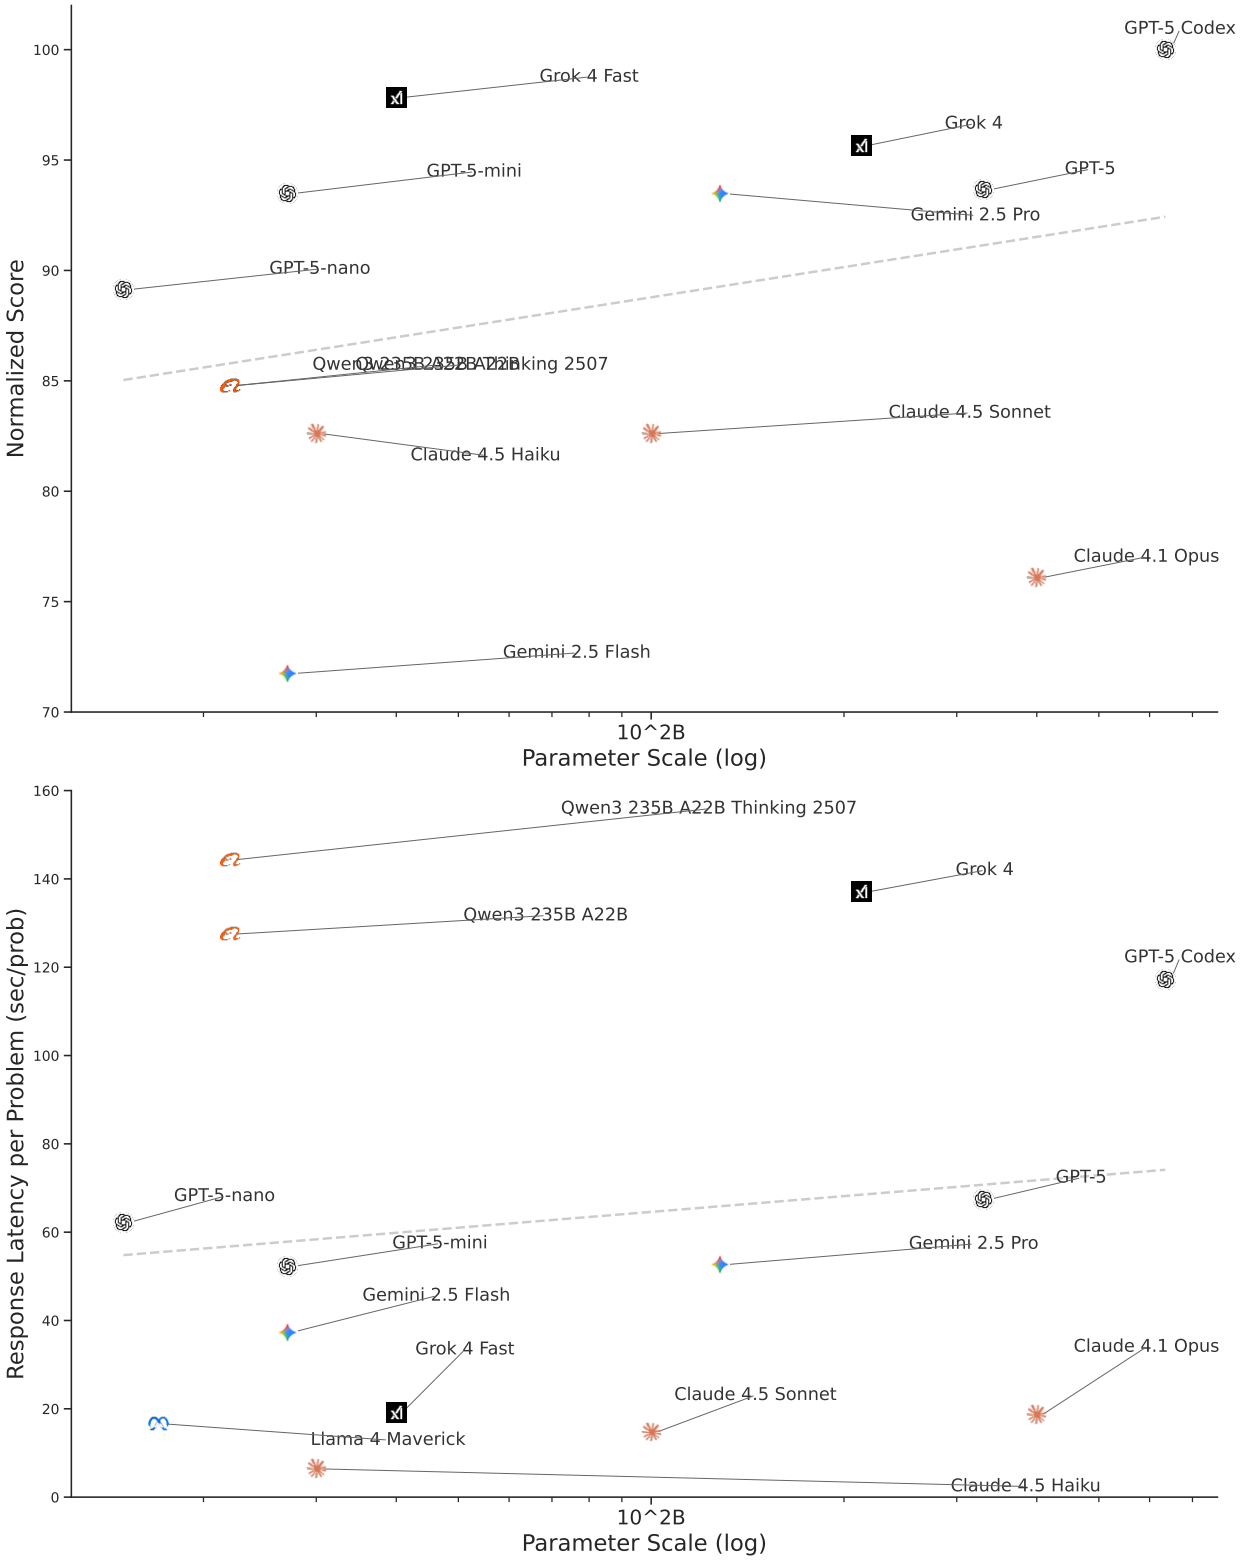

그림 24: 모델 파라미터 규모에 따른 성능 및 문제 당 소요 시간 (**입력 모달리티: Text+Figure, 프롬프트 언어: 한국어**). Llama 4 Maverick 모델의 Normalized Score가 28.3으로 낮아 생략되었다.

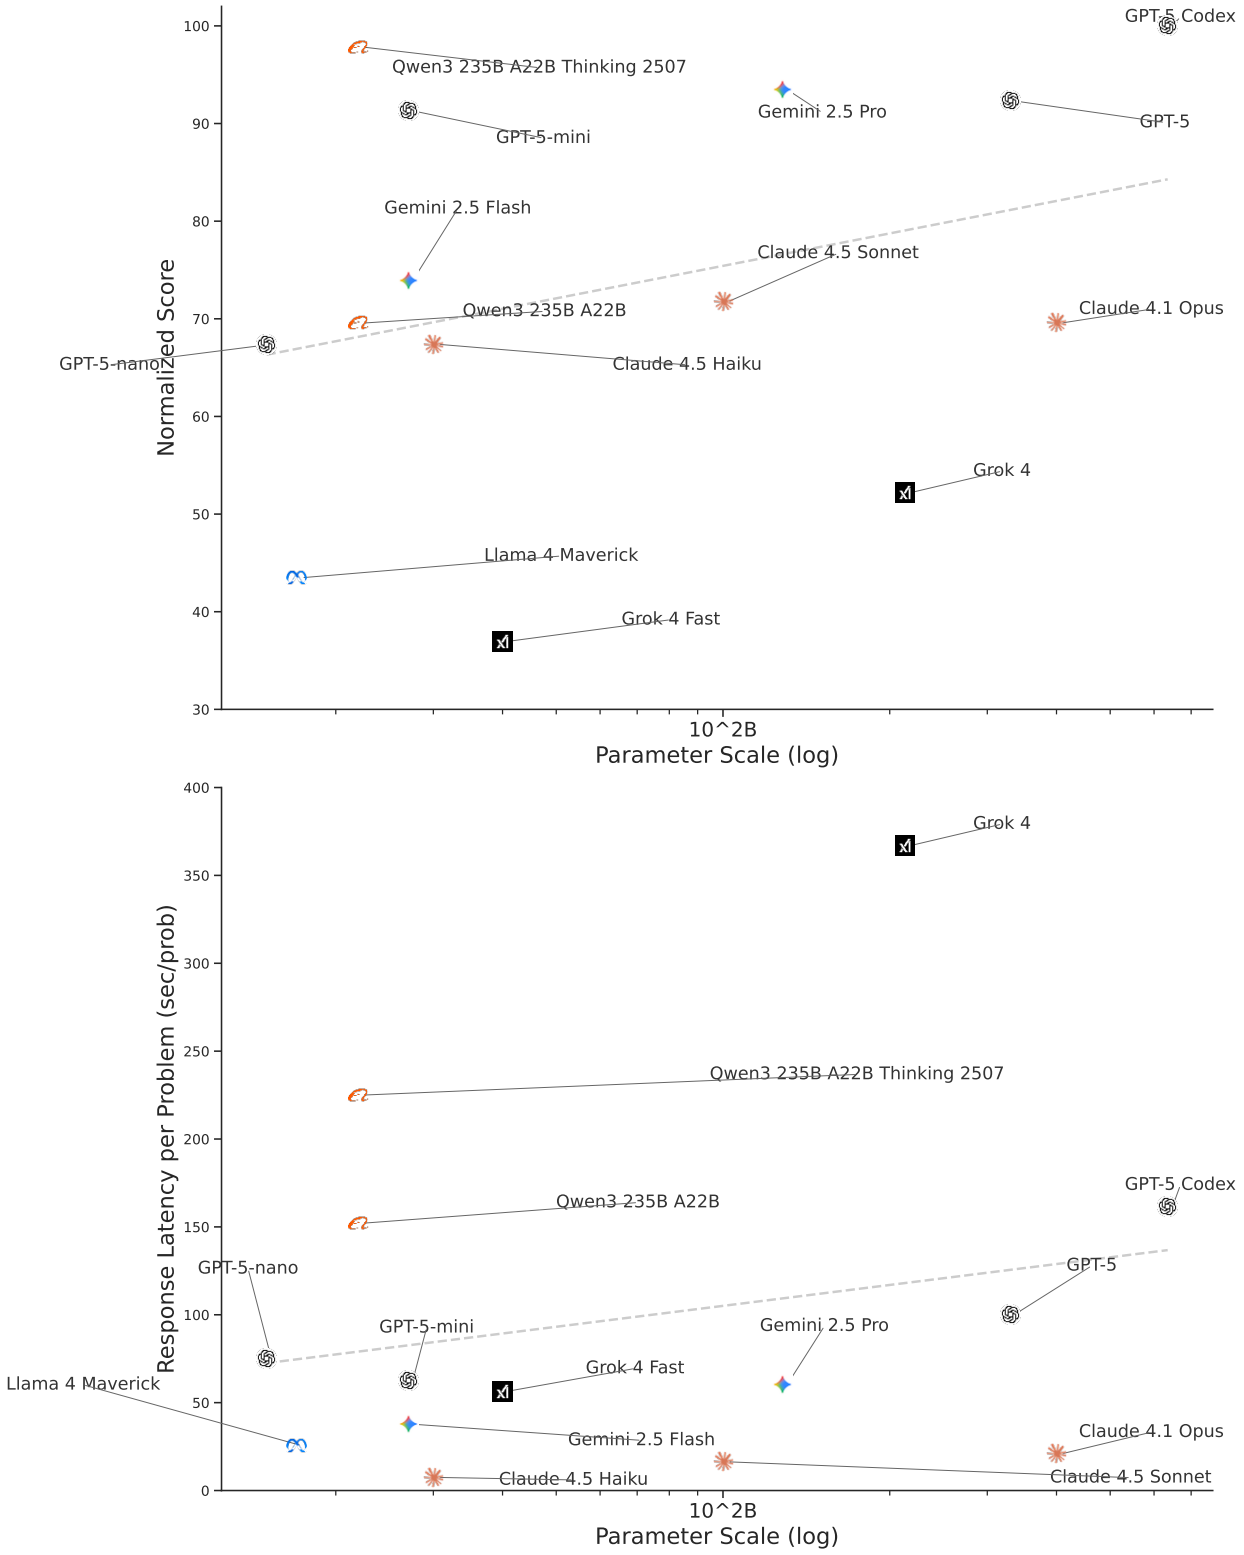

그림 25: 모델 파라미터 규모에 따른 성능 및 문제 당 소요 시간 **(입력 모달리티: Image Only, 프롬프트 언어: 한국어)**

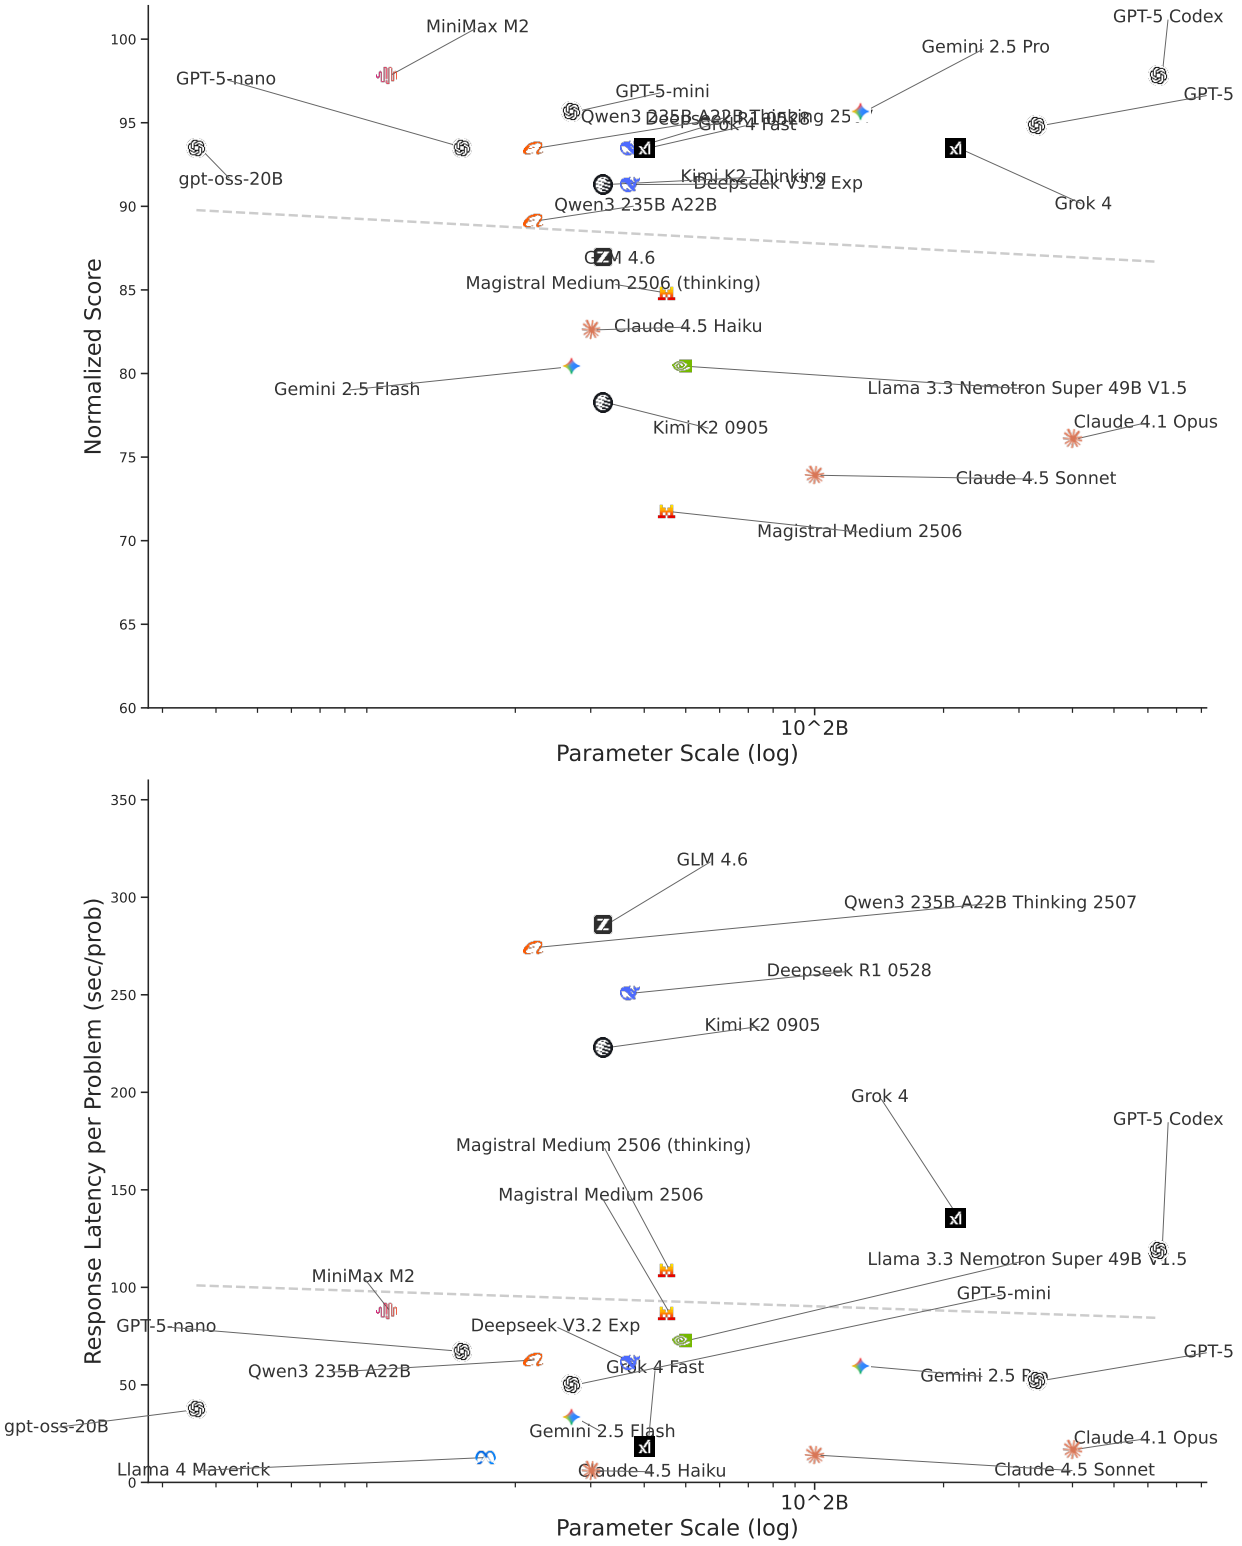

그림 26: 모델 파라미터 규모에 따른 성능 및 문제 당 소요 시간 **(입력 모달리티: Text Only, 프롬프트 언어: 영어)**. Llama 4 Maverick 모델의 Normalized Score가 23.9로 낮아 생략되었고, Kimi K2 Thinking 모델의 문제 당 소요 시간이 570 sec/prob으로 높아 생략되었다.

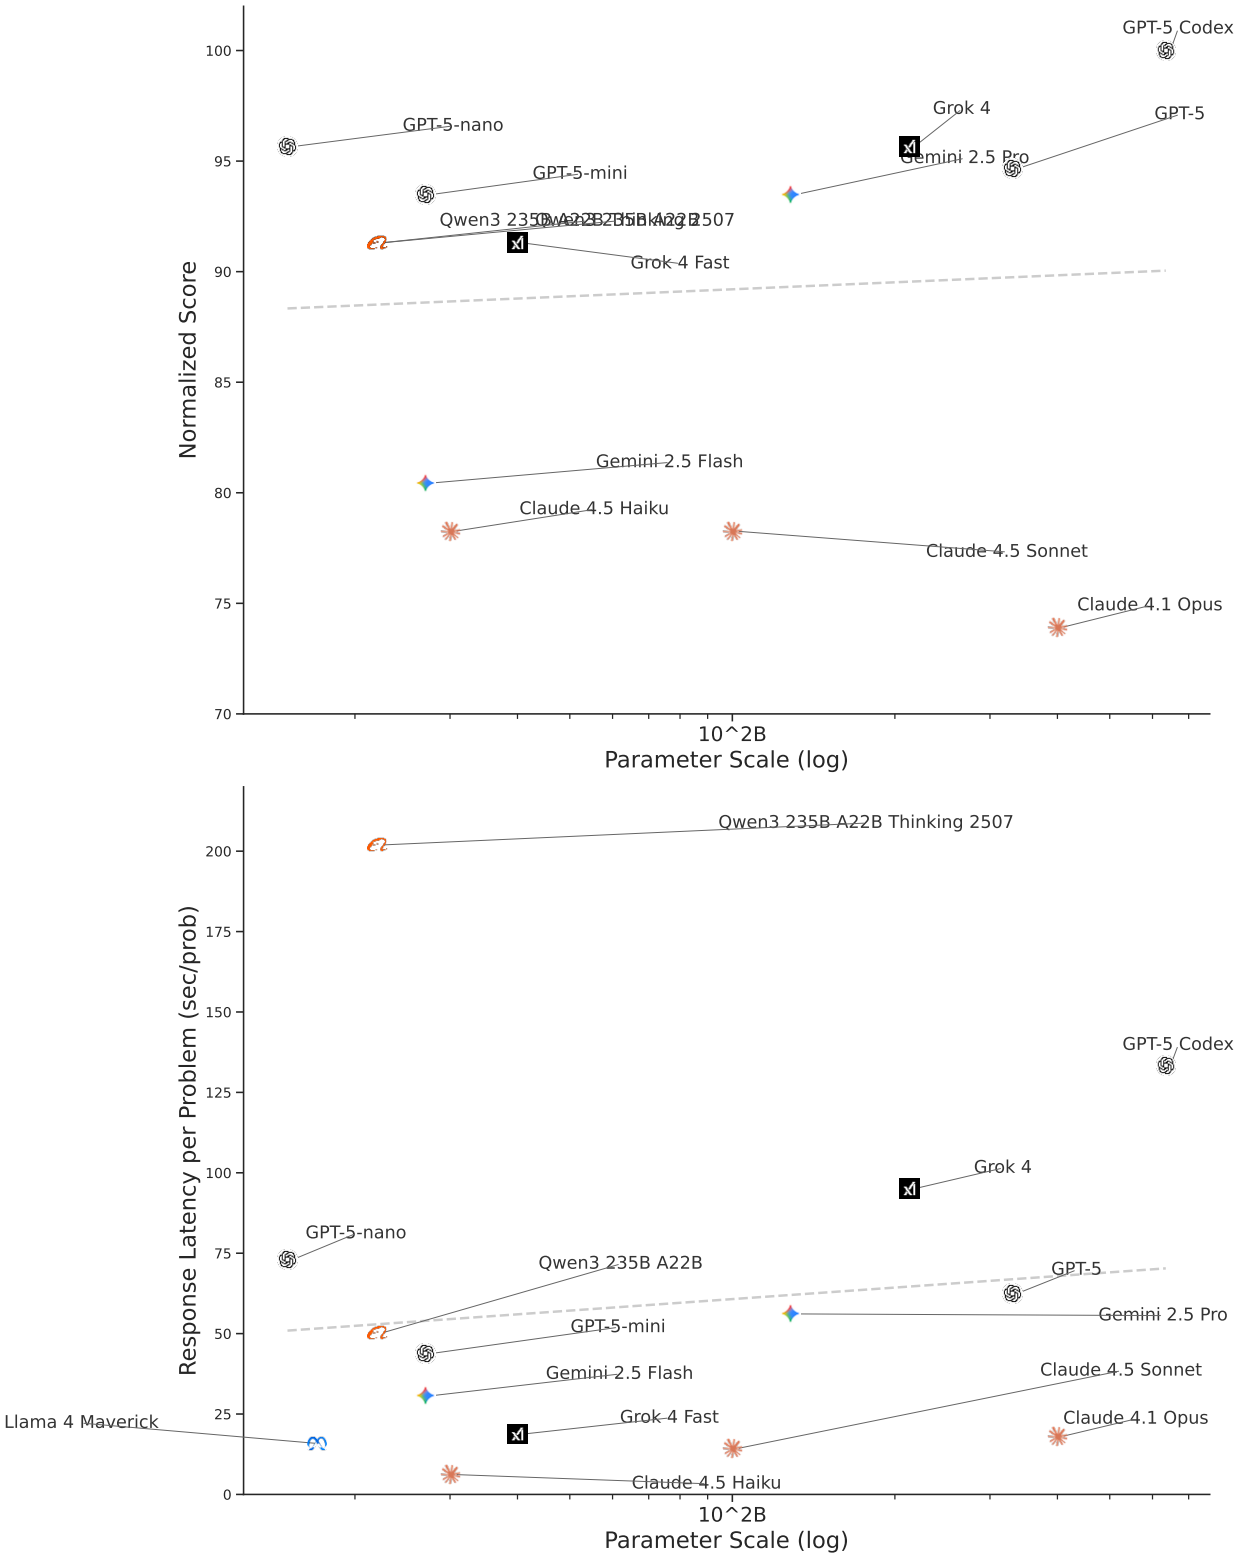

그림 27: 모델 파라미터 규모에 따른 성능 및 문제 당 소요 시간 **(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)**. Llama 4 Maverick 모델의 Normalized Score가 32.6으로 낮아 생략되었다.

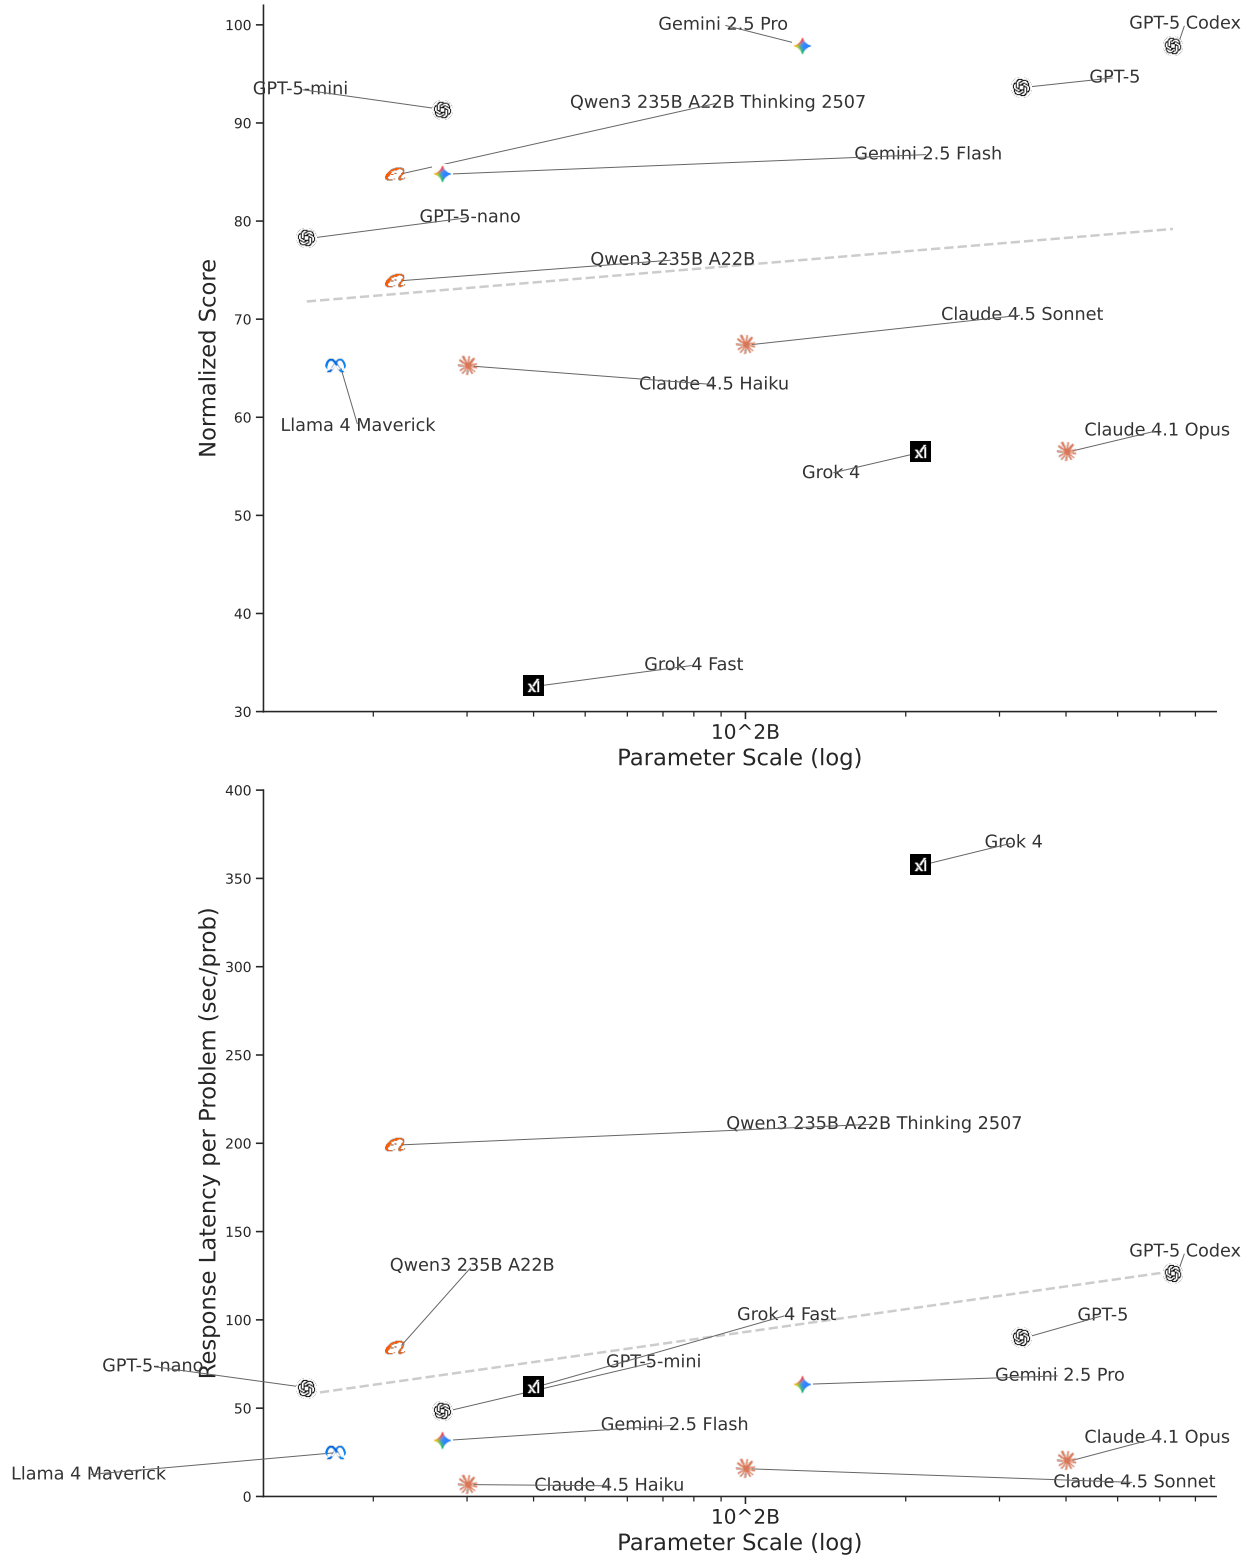

그림 28: 모델 파라미터 규모에 따른 성능 및 문제 당 소요 시간 **(입력 모달리티: Image Only, 프롬프트 언어: 영어)**

D 수학 문제의 출제 영역에 따른 모델의 성능 전체 결과

본 부록에서는 섹션 5.3.1의 출제 영역(공통과목, 확률과 통계, 미적분, 기하)에 따른 모델별 성능을 전체적으로 보여준다. 모든 입력 조합(텍스트/이미지/텍스트+도형 × 한국어/영어)에 대해 각 출제 영역별 정규화 점수를 계산하였으며, 이를 통해 특정 출제 영역에서의 강·약점이 일관되게 나타나는지, 혹은 입력 방식에 따라 패턴이 달라지는지를 보다 정밀하게 분석할 수 있다. 그림 29는 출제 영역별 (Text+Figure, 한국어) 조합에 대한 성능 비교, 그림 30는 출제 영역별 (Image Only, 한국어) 조합에 대한 성능 비교, 그림 31는 출제 영역별 (Text Only, 영어) 조합에 대한 성능 비교, 그림 32는 출제 영역별 (Text+Figure, 영어) 조합에 대한 성능 비교, 그림 33는 출제 영역별 (Image Only, 영어) 조합에 대한 성능 비교를 보인다. 이미지 입력을 지원하지 않는 모델은 Image Only 및 Text+Figure 조건의 평가에서 제외되었다. (Text Only, 한국어) 조합에 대한 그림은 본문의 그림 15에서 확인할 수 있다.

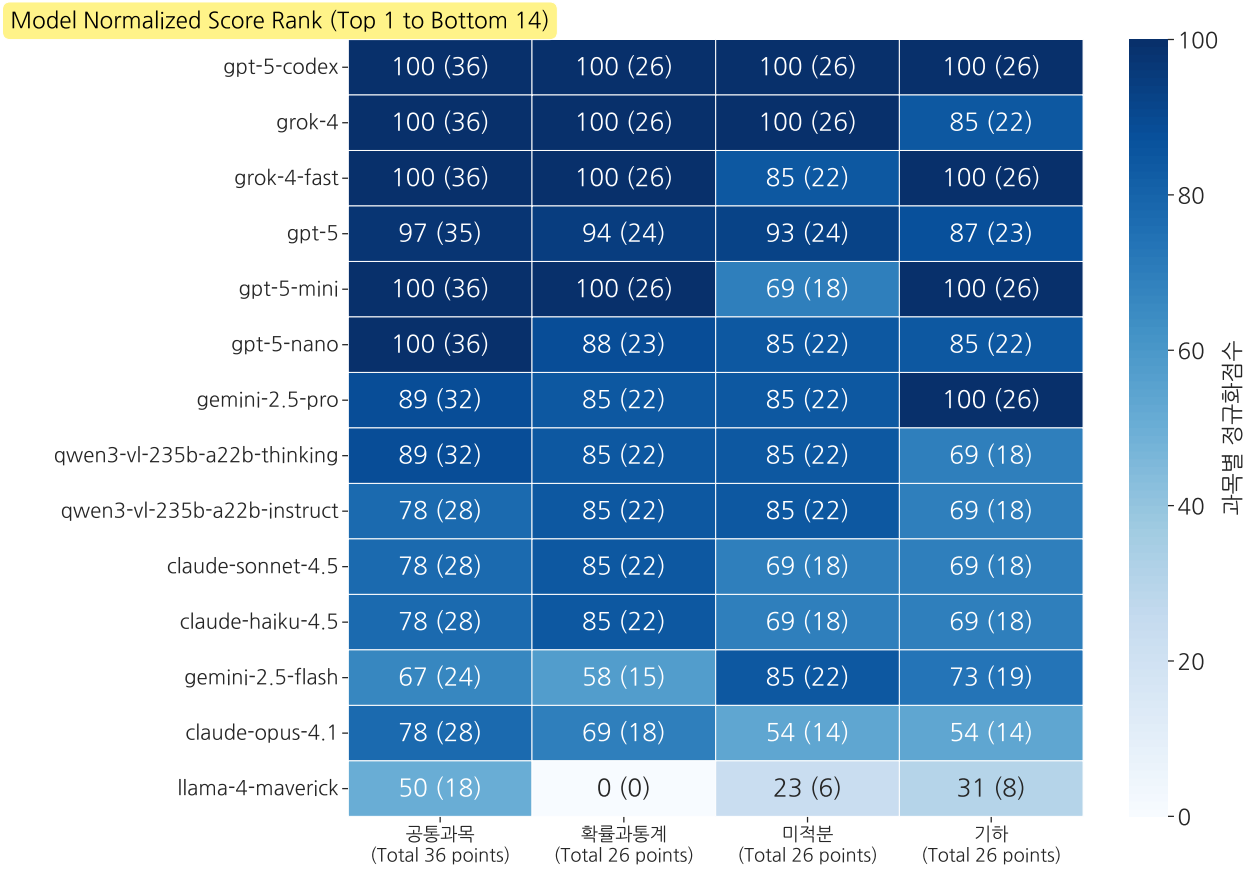

그림 29: 출제 영역별 **LLM(입력 모달리티: Text+Figure, 프롬프트 언어: 한국어)** 성능 비교. 과목별 정규화 점수는 각 영역에서 획득한 점수를 해당 영역의 만점으로 정규화한 값이며, 표기된 수치는 **정규화 점수와 원점수(점)**를 함께 표시한다. 모델의 표기 순서는 Normalized Score가 높은 순으로 정렬되었다.

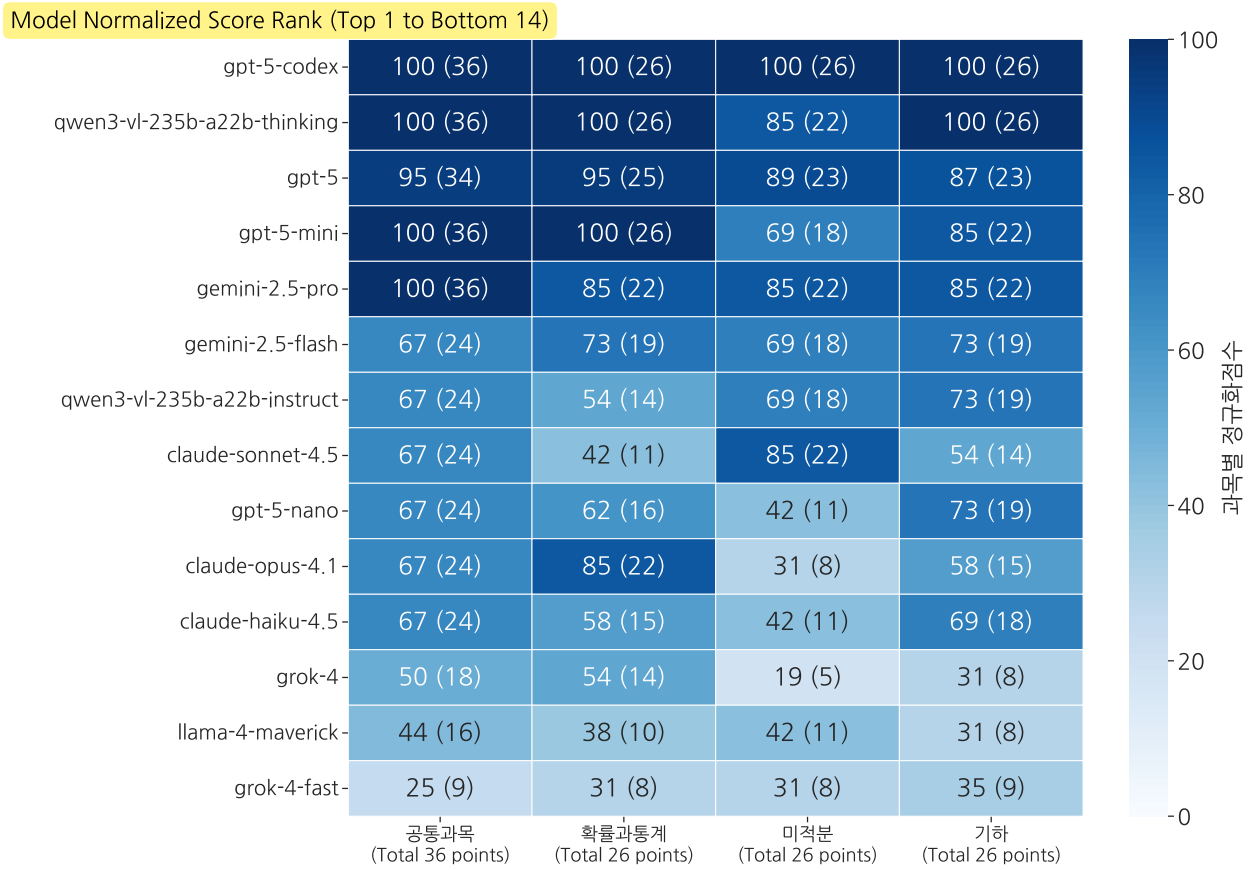

그림 30: 출제 영역별 **LLM(입력 모달리티: Image Only, 프롬프트 언어: 한국어)** 성능 비교. 과목별 정규화 점수는 각 영역에서 획득한 점수를 해당 영역의 만점으로 정규화한 값이며, 표기된 수치는 **정규화 점수와 원점수(점)**를 함께 표시한다. 모델의 표기 순서는 Normalized Score가 높은 순으로 정렬되었다.

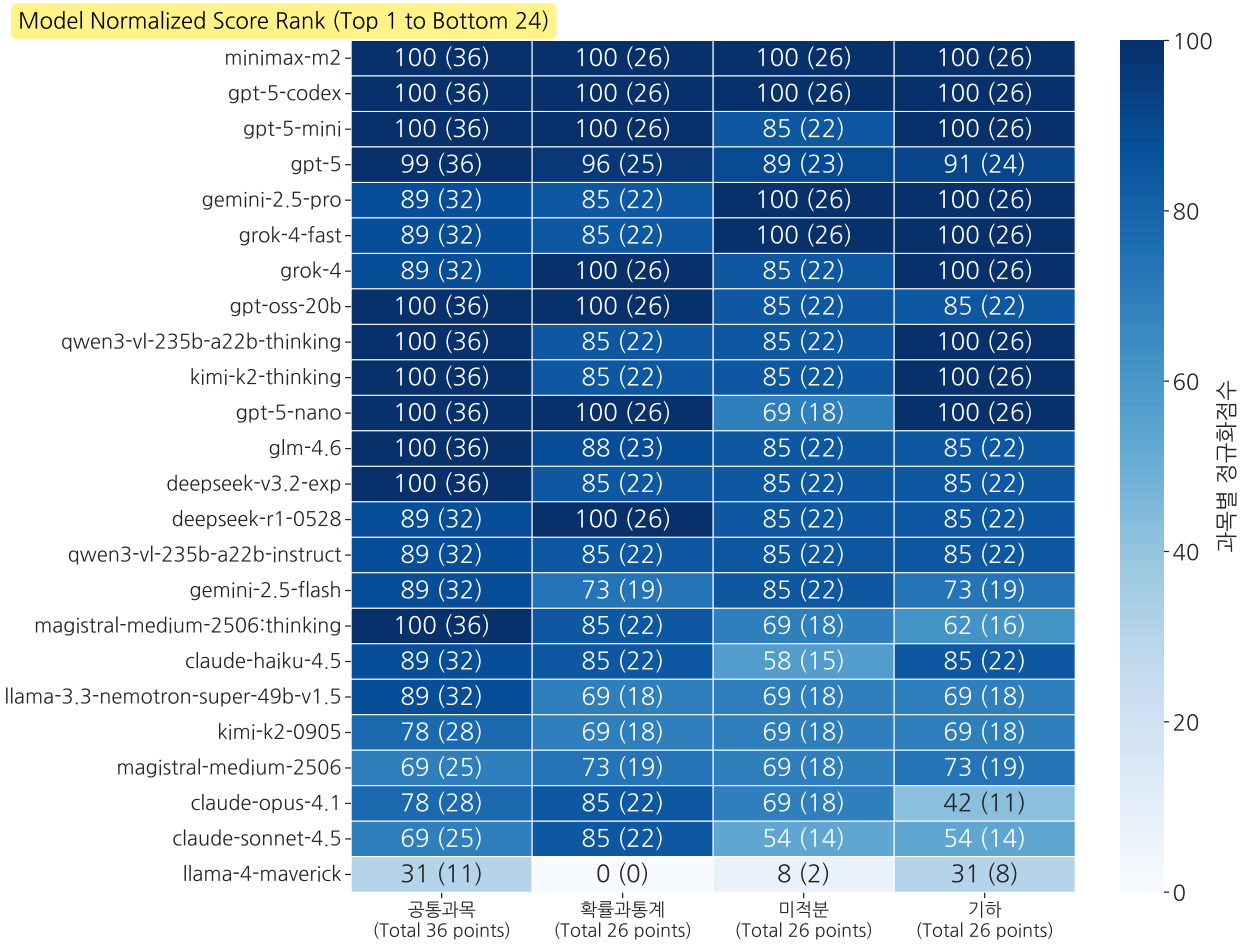

그림 31: 출제 영역별 **LLM(입력 모달리티: Text Only, 프롬프트 언어: 영어)** 성능 비교. 과목별 정규화 점수는 각 영역에서 획득한 점수를 해당 영역의 만점으로 정규화한 값이며, 표기된 수치는 **정규화 점수와 원점수(점)**를 함께 표시한다. 모델의 표기 순서는 Normalized Score가 높은 순으로 정렬되었다.

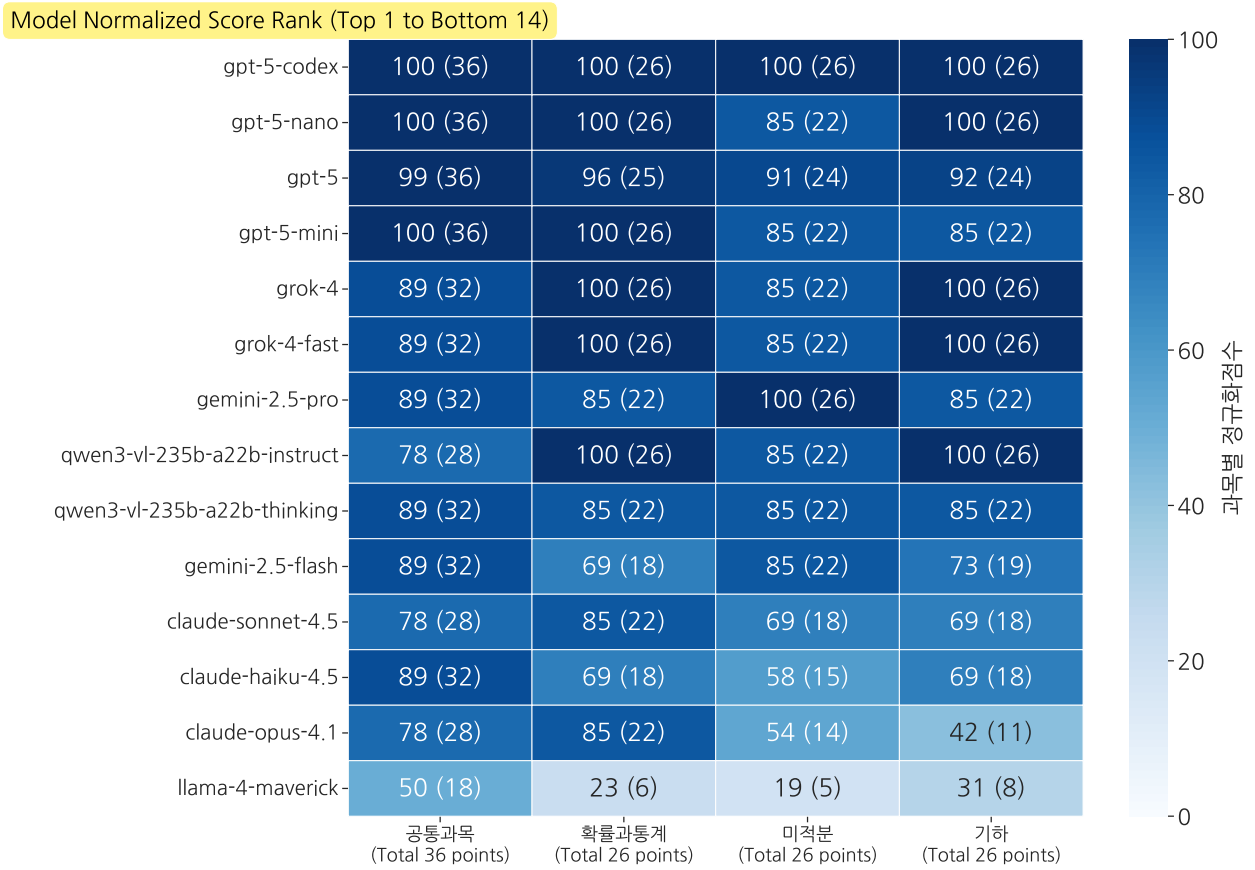

그림 32: 출제 영역별 **LLM(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)** 성능 비교. 과목별 정규화 점수는 각 영역에서 획득한 점수를 해당 영역의 만점으로 정규화한 값이며, 표기된 수치는 **정규화 점수와 원점수(점)**를 함께 표시한다. 모델의 표기 순서는 Normalized Score가 높은 순으로 정렬되었다.

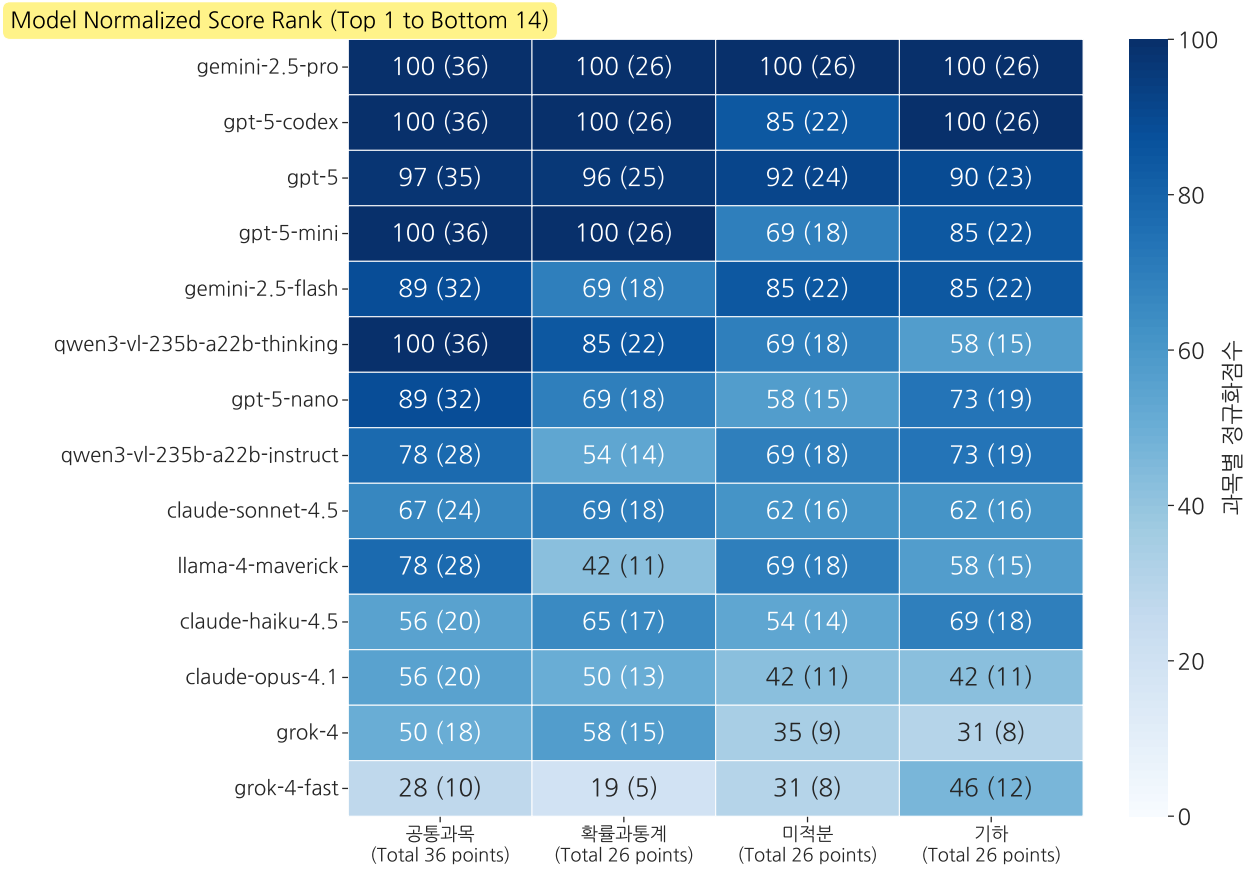

그림 33: 출제 영역별 **LLM(입력 모달리티: Image Only, 프롬프트 언어: 영어)** 성능 비교. 과목별 정규화 점수는 각 영역에서 획득한 점수를 해당 영역의 만점으로 정규화한 값이며, 표기된 수치는 **정규화 점수와 원점수(점)**를 함께 표시한다. 모델의 표기 순서는 Normalized Score가 높은 순으로 정렬되었다.

E 문항 속성에 따른 모델의 성능 전체 결과

본 부록에서는 섹션 5.3.2의 문항 속성(문항 유형, 배점)과 입력 조합(텍스트/이미지/텍스트+도형 × 한국어/영어)에 따른 모델의 성능을 전체적으로 보인다. 그림 34는 문항 속성별 (Text+Figure, 한국어) 조합에 대한 성능 비교, 그림 35는 문항 속성별 (Image Only, 한국어) 조합에 대한 성능 비교, 그림 36는 문항 속성별 (Text Only, 영어) 조합에 대한 성능 비교, 그림 37는 문항 속성별 (Text+Figure, 영어) 조합에 대한 성능 비교, 그림 38는 문항 속성별 (Image Only, 영어) 조합에 대한 성능 비교를 보인다. (Text Only, 한국어) 조합에 대한 그림은 본문의 그림 16에서 확인할 수 있다.

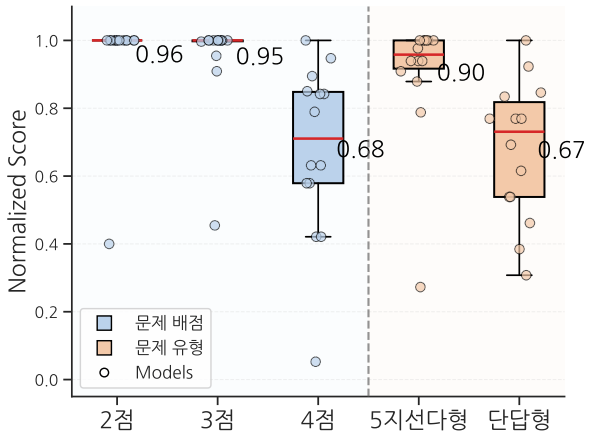

(a) 문항 배점(2/3/4점)과 문항 유형(5지선다형/단답형)에 따른 LLM 성능 분포.

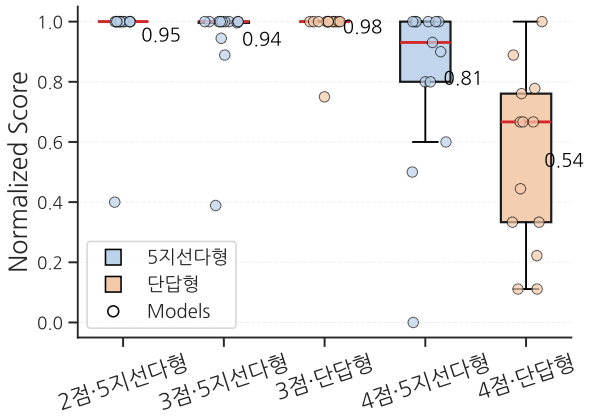

(b) 문항 배점×유형 조합별 LLM 성능 분포. (2026 수능에 2점 · 5지선다형 문항이 없어 제외)

그림 34: 문항 특성에 따른 **LLM(입력 모달리티: Text+Figure, 프롬프트 언어: 한국어)** 성능 비교. (a)는 배점과 문항 유형이라는 두 축을 각각 독립적으로 살펴본 결과이며, (b)는 두 축을 결합한 문항 조합(배점 × 유형) 단위에서 성능을 분석한 결과이다.

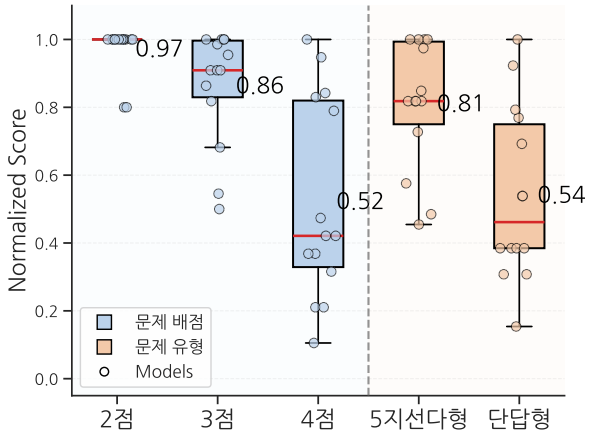

(a) 문항 배점(2/3/4점)과 문항 유형(5지선다형/단답형)에 따른 LLM 성능 분포.

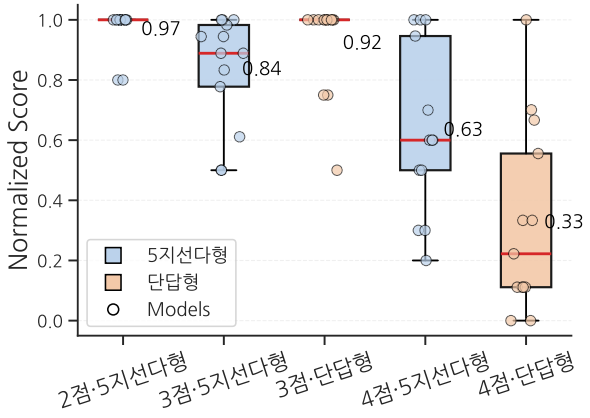

(b) 문항 배점×유형 조합별 LLM 성능 분포. (2026 수능에 2점 · 5지선다형 문항이 없어 제외)

그림 35: 문항 특성에 따른 **LLM(입력 모달리티: Image Only, 프롬프트 언어: 한국어)** 성능 비교. (a)는 배점과 문항 유형이라는 두 축을 각각 독립적으로 살펴본 결과이며, (b)는 두 축을 결합한 문항 조합(배점 × 유형) 단위에서 성능을 분석한 결과이다.

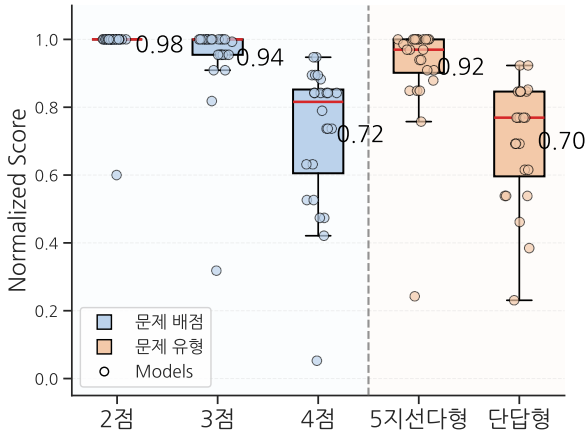

(a) 문항 배점(2/3/4점)과 문항 유형(5지선다형/단답형)에 따른 LLM 성능 분포.

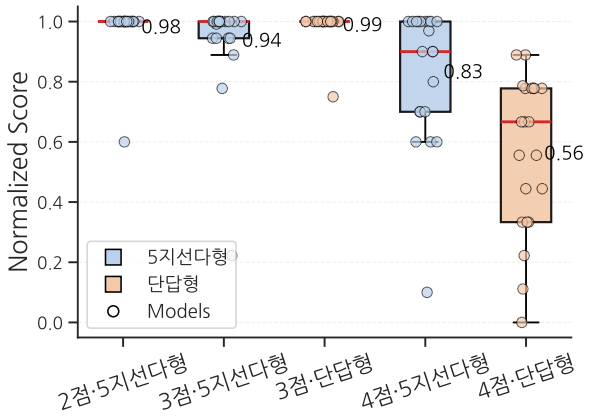

(b) 문항 배점×유형 조합별 LLM 성능 분포.
(2026 수능에 2점 · 5지선다형 문항이 없어 제외)

그림 36: 문항 특성에 따른 **LLM(입력 모달리티: Text Only, 프롬프트 언어: 영어)** 성능 비교. (a)는 배점과 문항 유형이라는 두 축을 각각 독립적으로 살펴본 결과이며, (b)는 두 축을 결합한 문항 조합(배점 × 유형) 단위에서 성능을 분석한 결과이다.

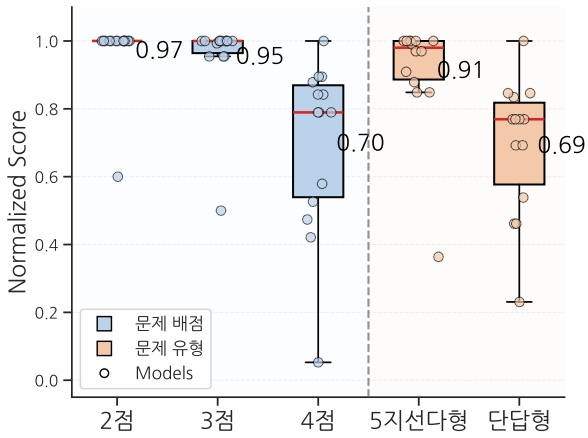

(a) 문항 배점(2/3/4점)과 문항 유형(5지선다형/단답형)에 따른 LLM 성능 분포.

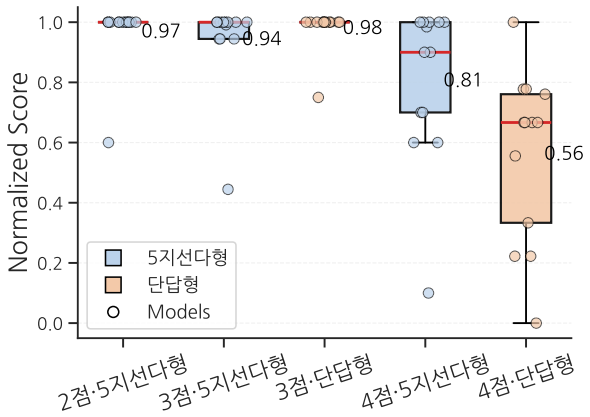

(b) 문항 배점×유형 조합별 LLM 성능 분포.
(2026 수능에 2점 · 5지선다형 문항이 없어 제외)

그림 37: 문항 특성에 따른 **LLM(입력 모달리티: Text+Figure, 프롬프트 언어: 영어)** 성능 비교. (a)는 배점과 문항 유형이라는 두 축을 각각 독립적으로 살펴본 결과이며, (b)는 두 축을 결합한 문항 조합(배점 × 유형) 단위에서 성능을 분석한 결과이다.

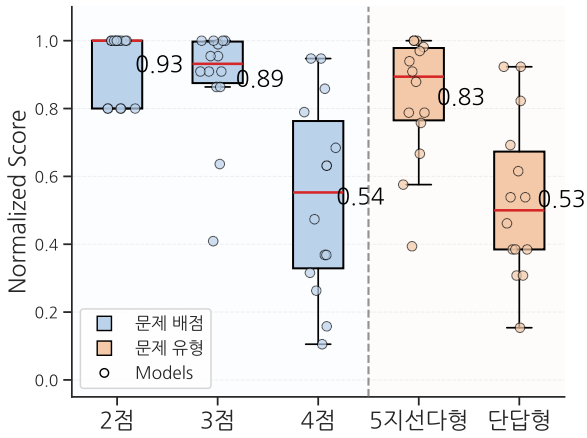

(a) 문항 배점(2/3/4점)과 문항 유형(5지선다형/단답형)에 따른 LLM 성능 분포.

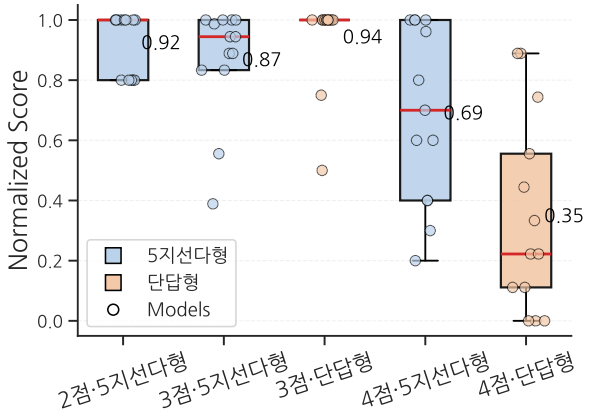

(b) 문항 배점×유형 조합별 LLM 성능 분포.
(2026 수능에 2점 · 5지선다형 문항이 없어 제외)

그림 38: 문항 특성에 따른 **LLM(입력 모달리티: Image Only, 프롬프트 언어: 영어)** 성능 비교. (a)는 배점과 문항 유형이라는 두 축을 각각 독립적으로 살펴본 결과이며, (b)는 두 축을 결합한 문항 조합(배점 × 유형) 단위에서 성능을 분석한 결과이다.