



PEARL: A Multimodal Culturally-Aware Arabic Instruction Dataset

Fakhraddin Alwajih, Samar M. Magdy, Abdellah El Mekki, Omer Nacar, Youssef Nafea, Safaa Taher Abdelfadil, Abdulfattah Mohammed Yahya, Hamzah Luqman, Nada Almarwani, Samah Aloufi, Baraah Qawasmen, Houdaifa Atou, Serry Sibae, Hamzah A. Alsayadi, Walid Al-Dhabyani, Maged S. Al-shaibani, Aya El Aatar, Nour Qandos, Rahaf Alhamouri, Samar Ahmad, Mohammed Anwar Al-Ghrawi, Aminetou Yacoub, Ruwa AbuHweidi, Vatimetou Mohamed Lemin, Reem Abdel-Salam, Ahlam Bashiti, Aisha Alansari, Ahmed Ashraf, Nora Alturayeif, Alcides Alcoba Inciarte, Adel Ammar, Abdelrahim A. Elmadany, Mohamedou Cheikh Tourad, Ismail Berrada, Mustafa Jarrar, Shady Shehata, Muhammad Abdul-Mageed

The University of British Columbia



The Problem: Cultural Bias in AI

- **Western-Centric Bias**

Encodes Western cultural perspectives

- **Shallow Understanding**

Datasets lack cultural depth.

- **Cultural Uniformity**

Overlook nuanced regional variations

- **Our Solution**

Introduce PEARL dataset, benchmarks



Introducing PEARL

PEARL is a foundational resource designed to make LVLMs more culturally intelligent for Arabic.

- **Massive Scale**

Over 309K multimodal examples

- **Comprehensive Coverage**

- 19 Arab Countries
- Spans 10 key cultural domains

- **Authentic & Nuanced**

Built by 37 native annotators.



Modern Context



تظهر الصورة رجل تونسي يرتدي لباساً تقليدياً يُعرف بالكثرون... وهو قطعة ملابس مصنوعة... كيف يمكن دمج الزي التقليدي الذي يظهر في الصورة في الحياة اليومية الحديثة في تونس؟

Problem Solving



تظهر الصورة حي البستكية التاريخي في إمارة دبي، حيث تظهر مباني تقليدية ذات تصميم معماري فريد مع أبراج الرياح... كيف يمكن الحفاظ على المباني التاريخية التي تظهر في الصورة مع التطور الحضري السريع في المنطقة؟

Role Playing



تظهر الصورة واحدة من أشهر وأشهر الأشجار في العالم، وهي شجرة دم الأخوين... تخيل أنك دليل سياحي في جزيرة سقطرى، كيف تشرح للزوار أهمية شجرة دم الأخوين؟

Hypothesis Formation



تُظهر الصورة زوجاً من حيوانات الفلك، يتميزان بفراخهما الرملي... في رأيك لماذا أصبح الفلك رمزاً ثقافياً مهماً في الجزائر، ويُستخدم في الرياضة؟

Hypothesis Formation



تُظهر الصورة برج الرياح التقليدي في البحرين، وهو عنصر معماري تراثي يُستخدم لتبريد المنازل... في اعتقادك لماذا اخترع المعمارون في البحرين والخليج العربي البرج الذي يظهر في الصورة؟

Origin Identification

تُظهر الصورة حكايتاً معاصرة في أحد المعالم المحففة التقليدية، وهو يرتدي ملابس وألباس الشعب، ويجلس... ما هو الأصل التاريخي أو الجغرافي لشخصية الحكايت الذي يظهر في الصورة؟



Scenario Completion

تُظهر الصورة أحد المشاركين في رقصات الطرق الصوفية في السودان، وهو يرتدي زياً تقليدياً معبراً غنياً بالألوان والرموز... بدأ الرجل في الصورة يرقص مع جماعته في احتفال صوفي إذا توقف عن الرقص في الحفل براك، ماذا سيحدث بعد ذلك؟



General Q&A

تُظهر الصورة المسجد النبوي في المدينة المنورة، وهو معلم ديني وتاريخي بارز في المنطقة العربية السعودية. يُظهر في... ما هي الميزة المعمارية البارزة التي تظهر في الصورة والتي تغطي قبر النبي محمد صلى الله عليه وسلم؟



Modern Context



تُظهر الصورة مجموعة من الدمى ترتدي الزي التقليدي للمرأة الفلسطينية. وقد عُرضت لأحد أروقة متحف الشيخ فيصل بن... كيف يمكن استخدام الأزياء التقليدية كطريقة المعروضة في الصورة في عالم اليوم؟

Perspective Shifting



تُظهر الصورة أطفال فلسطينيين يرتدون الزي الفلسطيني التقليدي. ناقش كيف يختلف فهم الزي الفلسطيني التقليدي الذي في الصورة ولادته عند النظر إليه من وجهة نظر فلسطيني يعيش في المهجر؟

Chronological Sequence



تُظهر الصورة الخنجر الشمالي التقليدي، والمعروف أيضاً باسم "الجنبية" في بعض المناطق. يتميز الخنجر... كيف تطور استخدام الخنجر الذي يظهر في الصورة عبر الزمن؟

Comparative Analysis

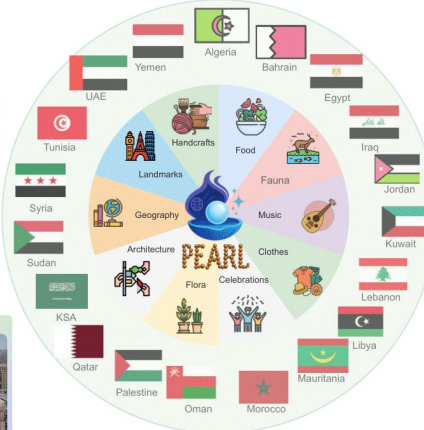


تُظهر الصورة مجموعة متنوعة من الأحذية التقليدية المغربية الملونة والمزخرفة، مزينة بشكل منظم... كيف يختلف الحذاء التقليدي الذي يظهر في الصورة عن الأحذية الحديثة من حيث التصميم والوظيفة؟

Origin Identification



تُظهر الصورة أطلال معبد روماني ضخم في مدينة بعلبك اللبنانية، وهو أحد أبرز المعالم الأثرية في لبنان والشرق الأوسط. ما هو الأصل التاريخي للمنصر المعماري الموجود في الصورة؟



Origin Identification

الصورة تُظهر مجموعة من فوانيس رمضان التقليدية المعلقة على أشجار، بألوان زاهية وخارص مهججة... ما هو الأصل التاريخي أو الجغرافي للمنصر الثقافي الموجود في الصورة؟



Cause and Effect

تُظهر الصورة مجموعة من العازقين العراقيين من فرقة فنون شعبية، يرتدون الزي التقليدي، ويؤدون عزفاً موسيقياً... لماذا يُستخدم الزمزام في الموسيقى الشعبية العراقية؟



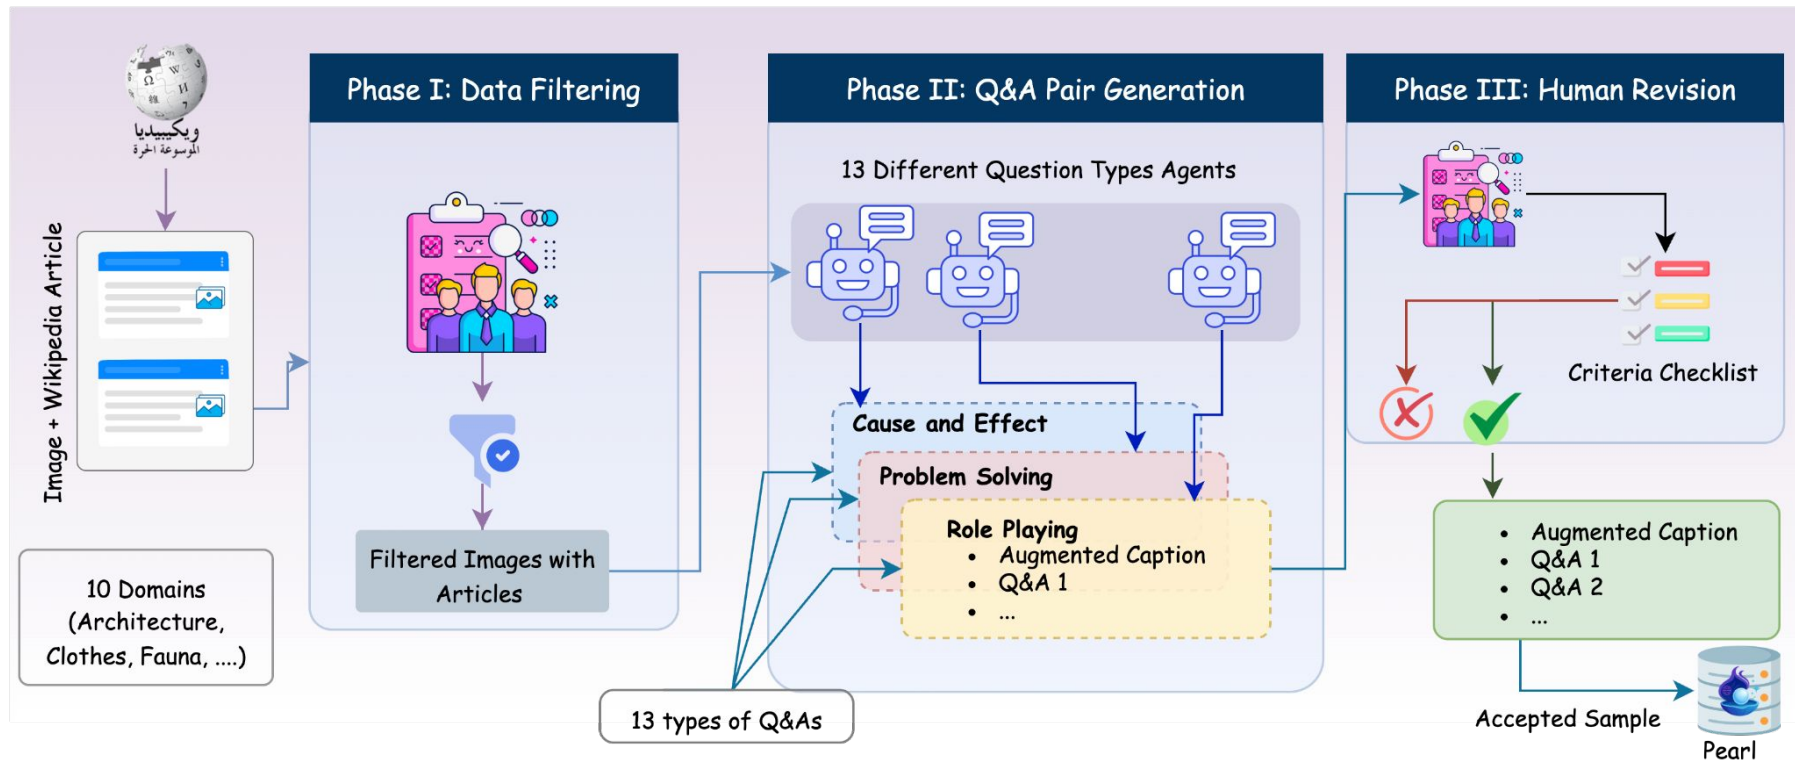
Comparative Analysis

تُظهر الصورة طبقاً شهياً من المخبوس أو الكسة الخليجية، وهو أحد أشهر أل... كيف يختلف الطبق الذي في الصورة عن أطباق الأرز التقليدية في دول عربية أخرى مثل المنسف الأردني؟





How We Built PEARL: A 3-Phase Workflow





The PEARL Ecosystem: Datasets for All Needs

PEARL isn't just one dataset; it's a suite of resources available to the research community.

- **Core Assets:**

- **12k** Images
- **309k** Automated Q&A Pairs with captions.
- **16k** Human-Revised Q&A Pairs

- **Evaluation Benchmarks:**

- **PEARL**: The main benchmark with **6,301** samples.
- **PEARL-LITE**: A smaller **893** samples.
- **PEARL-X**: A specialized benchmark with **367** Q&As with **61** shared concepts



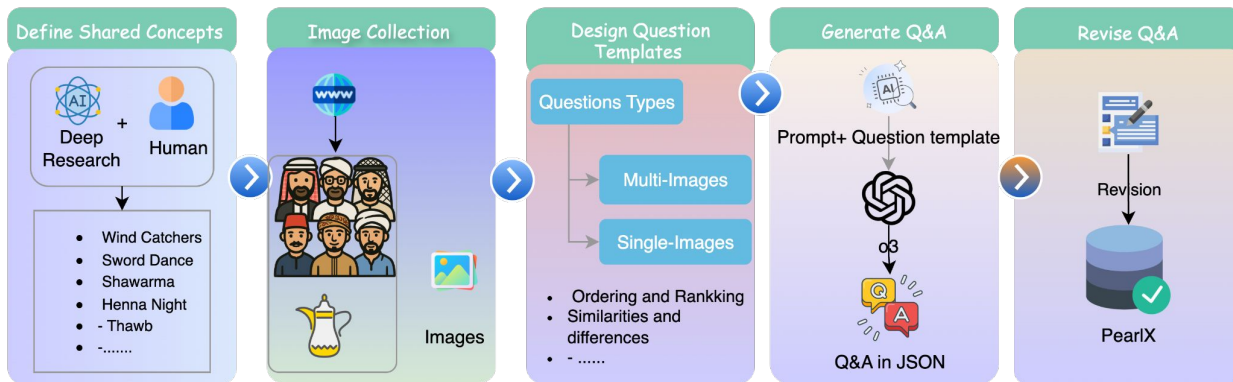
A Deeper Challenge: PEARL-X

- **The Goal of PEARL-X**

To test if models can recognize these nuanced differences.

- **How it Works**

- It focuses on 61 shared cultural concepts.
- It uses both single-image and multi-image questions.





PEARL-X (Examples)

Multiple Image Questions



أي من الصور التالية تُمثل الثوب القطري؟

English Translation: Which of the following images represents the Qatari thobe?

Single Image Questions



اشتق اسم هذه النسخة من القطايف من كلمة عربية تعني «العصفور». أي خيار يشرح بدقة سبب التسمية؟

English Translation: The name of this variation of qatayef is derived from the Arabic word for "sparrow." Which option accurately explains the reason for this naming?



The Experiment: Testing the Best AI Models

- **Models Tested**
 - **Open Models** and **Proprietary Models**
 - Different sizes and architectures
 - Reasoning and non reasoning models
- **Evaluation Protocol**
 - LVLM-as-Judge (InternVL3.5-38B)
 - **Accuracy** for Closed-form questions.
 - **Correctness, Coherence, Fluency, Detail, and Overall** for open-ended questions
 - **Cultural Awareness Score** (CAS) binary score for open-end questions
- **Validated by human evaluators and found a strong correlation (ICC=0.708)**



Key Finding 1: Reasoning Beats Scale

- The Surprise Winner**

Reasoning model
outperformed larger
one.

- The Takeaway**

Reasoning alignment is
key.

- Proprietary Models Lead**

Proprietary models
superior overall.

Model	Open-Ended					Closed	
	COR	COH	DET	FLU	OVR	CAS%	ACC%
Qwen2.5-VL-3B-Instruct	2.59	3.12	2.15	3.68	2.83	37.09	73.10
gemma-3-4b-it	2.97	3.56	2.62	4.12	3.25	47.68	70.73
Qwen2.5-VL-7B-Instruct	3.02	3.66	2.55	4.11	3.27	47.68	73.77
aya-vision-8b	3.23	3.85	2.67	4.21	3.44	46.69	70.56
gemma-3-12b-it	3.10	3.63	2.54	4.14	3.30	52.65	76.82
gemma-3-27b-it	3.38	3.81	2.95	4.26	3.55	60.93	80.88
aya-vision-32b	3.37	3.92	2.76	4.31	3.55	51.66	75.63
Qwen2.5-VL-32B-Instruct	3.69	4.09	3.39	4.42	3.85	66.56	80.03
Qwen2.5-VL-72B-Instruct	3.36	3.91	2.76	4.25	3.53	55.63	79.36
claude-sonnet-4-20250514	3.77	4.03	3.71	4.43	3.94	76.49	79.53
gemin-2.5-pro	4.36	4.48	4.45	4.77	4.48	83.11	89.00
o3-2025-04-16	4.39	4.44	4.52	4.71	4.49	87.09	86.97

Results for the PEARL-LITE subset. The metrics are as follows: Correctness (COR), Coherence (COH), Detail (DET), Fluency (FLU), Overall Score (OVR), Cultural Awareness Score (CAS) for open-ended questions, and Accuracy (ACC) for closed-ended questions.



Key Finding 2: Nuance is Hard

The PEARL-X benchmark proved to be a difficult test for every model.

- **The Challenge**

Identifying subtle differences is tough.

- **Performance**

Top models show difficulty.

- **Implication**

Reasoning is critical for nuance.

Model	Accuracy %
Qwen2.5-VL-3B-Instruct	59.67
gemma-3-4b-it	64.58
Qwen2.5-VL-7B-Instruct	61.31
aya-vision-8b	64.03
gemma-3-12b-it	69.21
gemma-3-27b-it	69.21
aya-vision-32b	71.66
Qwen2.5-VL-32B-Instruct ♦	71.66
Qwen2.5-VL-72B-Instruct	73.57
gemini-2.5-pro-preview-05-06 ♦	77.93
o3-2025-04-16 ♦	78.75

Accuracy on the Pearl-X
shared-concepts benchmark.



Conclusion

- **Our Contribution:** First large-scale Arabic benchmark.
- **Key Insight:** Reasoning-alignment is most effective.
- **New Frontiers:** With PEARL-X, we've provided a novel way to measure a model's understanding of nuanced, cross-country cultural variations.
- **Limitations:** Wikipedia bias, representation gaps.



Thank you!



Canada Research Chairs



Digital Research
Alliance of Canada



Social Sciences and
Humanities Research
Council of Canada

Canada

Conseil de recherches
en sciences humaines
du Canada

INNOVATION.CA
CANADA FOUNDATION
FOR INNOVATION | FONDATION CANADIENNE
POUR L'INNOVATION