

593 Appendices

594 For further details on the results and the exact prompts used, see Appendix [A](#).

A DATASET EVALUATION RESULTS

595 A.1 PubmedQA-Swedish-1000

596 The results of the evaluation can be seen in [6](#). Different LLM:s had different prompts, which are noted
597 below. Note that “{question}” is where the actual question was inserted.

598 EIR had the following prompt:

599 Var vänlig och överväg varje aspekt av medicinska frågan nedan noggrant. Ta en stund, andas djupt,
600 och när du känner dig redo, vänligen svara med endast ett av de fördefinierade svaren: ‘ja’, ‘nej’,
601 eller ‘kanske’. Det är viktigt att du begränsar ditt svar till dessa alternativ för att säkerställa tydlighet i
602 kommunikationen .

603 Fråga: {question} svara bara ‘ja’, ‘nej’ eller ‘kanske’

604 Gemma-7b-it, GPT-3.5-t, Llama3-8b had the following prompt:

605 Du är en utmärkt läkare och skriver ett läkarprov. Var vänlig och överväg varje aspekt av medicinska
606 frågan nedan noggrant. Ta en stund, andas djupt, och när du känner dig redo, vänligen svara med
607 endast ett av: ‘ja’, ‘nej’, eller ‘kanske’. Det är viktigt att du begränsar ditt svar till dessa alternativ för
608 att säkerställa tydlighet i kommunikationen. Du ska bara svara med ‘kanske’ ifall det kan vara fallet,
609 annars svara ‘ja’ eller ‘nej’. Svara med det svaret som du tror är mest korrekt.

610 Kom ihåg att svaret inte alltid är ‘ja’, så fundera ordentligt innan du svarar.

611 Fråga: {question}

612 Svara endast ‘ja’, ‘nej’ eller ‘kanske’.

613 GPT-4-t, GPT-4o, o1-mini and Llama3.1-70b had the following prompt:

614 Du är en utmärkt läkare och skriver ett läkarprov. Var vänlig och överväg varje aspekt av medicinska
615 frågan nedan noggrant. Ta en stund, andas djupt, och när du känner dig redo, vänligen svara med
616 endast ett av: ‘ja’, ‘nej’, eller ‘kanske’. Det är viktigt att du begränsar ditt svar till dessa alternativ för
617 att säkerställa tydlighet i kommunikationen.

618 Fråga: {question}

619 Svara endast ‘ja’, ‘nej’ eller ‘kanske’.

620 Llama3-70b had the following prompt:

621 Du är en utmärkt läkare och skriver ett läkarprov. Var vänlig och överväg varje aspekt av medicinska
622 frågan nedan noggrant. Ta en stund, andas djupt, och när du känner dig redo, vänligen svara med
623 endast ett av: ‘ja’, ‘nej’, eller ‘kanske’. Det är viktigt att du begränsar ditt svar till dessa alternativ för
624 att säkerställa tydlighet i kommunikationen. Du ska bara svara med ‘kanske’ ifall det kan vara fallet,
625 annars svara ‘ja’ eller ‘nej’. Svara med det svaret som du tror är mest korrekt.

626 Kom ihåg att svaret inte alltid är ‘ja’, så fundera ordentligt innan du svarar.

627 Fråga: {question} Svara endast 'ja', 'nej' eller 'kanske'.

Table 6. Performance metrics of models on PubMedQA-Swedish

Model	Acc (%)	Macro F1	Yes	No	Maybe
EIR	46.50	26.86	56.35	44.72	6.36
Gemma-7b-it	48.70	23.08	65.76	19.50	7.05
GPT-4-t	53.90	29.46	67.56	36.23	14.07
GPT-3.5-t	27.40	18.36	41.36	14.59	17.58
GPT-4o	27.9	24.38	34.42	6.80	60.00
GPT-4.1	36.80	33.04	51.15	17.42	30.55
Llama3-8b	50.50	25.18	63.48	34.15	3.10
Llama3-70b	56.00	37.11	67.77	41.83	1.72
Llama3.1-70b	56.80	29.20	85.50	25.74	8.18
o1-mini	33.80	28.75	44.93	35.45	15.09
o3	40.6	26.76	54.03	15.96	37.04
Claude-3.5 (July)	33.10	27.39	50.62	17.40	15.75
Claude-3.5 (October)	50.30	37.78	65.97	17.94	29.44
Claude-3.7	36.20	31.28	52.62	16.64	24.59
Deepseek R1 Distill Llama-70b	36.30	22.65	55.00	12.97	22.63

Note: Acc = Accuracy. Yes, No, and Maybe columns show F1 scores.

Sample sizes: Yes (n=552), No (n=338), Maybe (n=110).

A.2 Swedish medical doctors knowledge test

All LLM:s have been evaluated on the same prompt: Du är en utmärkt läkare och skriver ett läkarprov. Var vänlig och överväg varje aspekt av medicinska frågan nedan noggrant. Ta en stund, andas djupt, och när du känner dig redo, vänligen svara med endast ett av alternativen. Svara med hela svarsalternativet. Utöver det är det viktigt att du inte inkluderar någon annan text i ditt svar.

Model	Error bar, with clustering (%)	Error bar, without clustering (%)
gpt-4o-2024-08-06	1.60	1.62
gpt-4-t	1.73	1.76
gpt-4.1-2025-04-14	1.52	1.50
o3	1.55	1.42
llama3-70b	2.03	1.98
llama3-8b	2.24	2.13
llama3.1-70b-versatile	2.20	1.95
llama3.1-8b-instant	1.12	1.05
gemma2-9b-it	2.07	2.11
gemma-7b-it	1.90	1.93
claude-3-5-sonnet-20240620	1.49	1.60
claude-3-5-sonnet-20241022	1.48	1.50
claude-3-7-sonnet-20250219	1.63	1.57
deepseek-r1-distill-llama-70b	1.91	1.80
gemini-2.5-flash-preview-04-17		2.16

Table 7. Error bars of evaluated models on SMDT, comparison of using clustering and not using it.

claude-3-5-sonnet-20240620 passed every exam, while gpt-4o-2024-08-06 and gpt-4-t failed one exam out of the total 26 exams.

B EXAMPLE CASE DESCRIPTION EMERGENCY MEDICINE

Emma, en 8-årig flicka, har haft buksmärtor i ett par dagar som förvärrats och nu åtföljs av illamående och kräkningar. Hon har också haft feber och hennes föräldrar märker att hon är ovanligt trött och orolig.




Figure 5. Confusion Matrix of PQ-S results for selected models.

637 Vid undersökning visar Emma ömhet i nedre högra kvadranten av buken och har svårt att röra sig utan att
638 känna smärta.

QUESTIONS

639 1. Vilken av följande är den mest sannolika diagnosen för Emmas symptom?

- 640 a. Obstipation
- 641 b. Gastroenterit
- 642 c. Appendicit
- 643 d. Urinvägsinfektion

644 **Correct Answer:** C) Appendicit

645 **Explanation:** Emmas symptom på buksmärta, illamående, kräkningar och ömhet i nedre
646 högra kvadranten tyder på appendicit.

647 2. Vilken undersökning är förstahandsval vid misstanke om appendicit hos Emma?

- 648 a. Lungröntgen
- 649 b. Kolonröntgen
- 650 c. Buköversikt (BÖS)
- 651 d. Ultraljud

652 **Correct Answer:** D) Ultraljud

653 **Explanation:** Ultraljud är förstahandsval vid misstanke om appendicit hos barn eftersom
654 det är en säker och effektiv metod för att visualisera en inflammerad appendix.

655 3. Vilken differentialdiagnos är viktig att överväga vid akut buksmärta hos barn som
656 Emma?

- 657 a. Pneumoni
- 658 b. Otit
- 659 c. Urinvägsinfektion
- 660 d. Alla ovanstående

661 **Correct Answer:** D) Alla ovanstående

662 **Explanation:** Pneumoni, otit och urinvägsinfektion är alla viktiga differentialdiagnoser
663 att överväga vid akut buksmärta hos barn, eftersom dessa tillstånd kan presentera sig med
664 buksmärta.

665 4. Vad är den lämpligaste omedelbara åtgärden för Emma på akutmottagningen?

- 666 a. Hemgång med poliklinisk uppföljning
- 667 b. Observation och smärtlindring
- 668 c. Akut operation
- 669 d. Antibiotikabehandling och avvakta

670 **Correct Answer:** B) Observation och smärtlindring

671 **Explanation:** Initialt bör Emma observeras och få smärtlindring för att noggrant bedöma
672 hennes tillstånd och behovet av eventuell kirurgi.

RECOMMENDED TREATMENT PLAN

- 673 • **Misstänkt appendicit:** Ultraljud för att bekräfta diagnosen, följt av observation, smärtlindring och
674 förberedelse för eventuell kirurgi.
- 675 • **Bekräftad appendicit:** Kirurgisk intervention (appendektomi) och perioperativ antibiotikabehandling.
- 676 • **Differentialdiagnostik vid buksmärta:** Uteslutning av andra orsaker som urinvägsinfektion,
677 pneumoni och otit genom relevant anamnes, fysisk undersökning och laboratorieprover.

EXAMPLE CASE DESCRIPTION GENERAL MEDICINE

678 Jonas, en 42-årig man, upptäcker en mjuk, elastisk knöl på nacken som har vuxit långsamt under de senaste
679 månaderna. Knölen är tydligt avgränsbar och förskjutbar mot underlaget. Den har nyligen börjat ömma och
680 rodna.

QUESTIONS

681 1. Vilken diagnos är mest sannolik baserat på Jonas symtom och kliniska fynd?

- 682 a. Lipom
- 683 b. Furunkulos
- 684 c. Aterom (talgkörtelcysta)
- 685 d. Angiolipom

686 **Correct Answer:** C) Aterom (talgkörtelcysta)

687 **Explanation:** Jonas har en mjuk, elastisk, tydligt avgränsbar och förskjutbar knöl som
688 nyligen börjat ömma och rodna, vilket är typiskt för ett aterom (talgkörtelcysta).

689 2. Vilken av följande är inte en riskfaktor för att utveckla aterom?

- 690 a. Anabola steroider
- 691 b. Hyperhidros
- 692 c. Diabetes
- 693 d. Akne

694 **Correct Answer:** C) Diabetes

695 **Explanation:** Riskfaktorer för att utveckla aterom inkluderar anabola steroider, hyperhidros
696 och akne, men diabetes är inte en direkt riskfaktor.

697 3. Vilken behandling rekommenderas om Jonas aterom är inflammerat och smärtsamt?

- 698 a. Antibiotikabehandling
- 699 b. Incision och dränage
- 700 c. Strålbehandling
- 701 d. Excision

702 **Correct Answer:** B) Incision och dränage

703 **Explanation:** Vid inflammerat och smärtsamt aterom rekommenderas incision och dränage.
704 Antibiotikabehandling är sällan nödvändigt.

705 4. Vilken differentialdiagnos bör övervägas om Jonas knöl inte är fritt förskjutbar och har
706 en snabb tillväxt?

- 707 a. Lipom

- 708 b. Angiolipom
709 c. Sarkom
710 d. Fibrom

711 **Correct Answer:** C) Sarkom

712 **Explanation:** Om knölen inte är fritt förskjutbar och har snabb tillväxt, bör sarkom
713 övervägas som differentialdiagnos.

RECOMMENDED TREATMENT PLAN

- 714 • **Aterom utan inflammation:** Ingen behandling nödvändig om det inte är kosmetiskt störande för
715 patienten.
716 • **Inflammerat aterom:** NSAID för symtomlindring. Vid mer uttalad inflammation: incision och
717 dränage.
718 • **Återkommande inflammerade aterom eller kosmetiskt störande:** Excision i lugnt skede för att ta
719 bort hela cystan inklusive kapseln.

TABLE WITH MODEL PERFORMANCE AND RANKING

720 Included is a table of all their models with a preliminary ranking of the models depending on their
721 performance on the SMLB.

Table 8. Performance of LLMs on the Swedish Medical LLM Benchmark Including Rank Score

Model	Rank	PQ-S	SMDT	EM	GM	SMLB
GPT-4-t	1	53.90 (± 1.58)	79.07 (± 1.73)	93.10 (± 1.18)	93.09 (± 0.98)	75.57 (± 0.76)
Claude-3.5 (October)	2	50.30 (± 1.58)	85.98 (± 1.48)	90.73 (± 1.35)	93.09 (± 0.98)	75.20 (± 0.74)
o3	3	40.6 (± 1.55)	87.66 (± 1.55)	94.83 (± 1.03)	97.00 (± 0.66)	73.58 (± 0.70)
GPT-4.1	4	36.80 (± 1.53)	85.98 (± 1.52)	94.62 (± 1.05)	95.05 (± 0.84)	71.30 (± 0.71)
Claude-3.7	5	36.20 (± 1.52)	84.30 (± 1.63)	93.32 (± 1.16)	94.59 (± 0.88)	70.39 (± 0.72)
Claude-3.5 (July)	6	33.10 (± 1.49)	83.74 (± 1.49)	94.61 (± 1.05)	95.95 (± 0.76)	69.68 (± 0.69)
Deepseek R1 Distill	7	36.30 (± 1.52)	77.76 (± 1.91)	85.56 (± 1.63)	90.39 (± 1.14)	66.72 (± 0.80)
Llama-70b	8	27.90 (± 1.42)	83.18 (± 1.60)	90.51 (± 1.36)	88.88 (± 1.21)	65.38 (± 0.73)
GPT-4o	9	56.00 (± 1.57)	69.91 (± 2.03)	74.35 (± 2.03)	67.57 (± 1.81)	64.88 (± 0.92)
Llama3-70b	10	56.80 (± 1.57)	71.40 (± 2.20)	62.93 (± 2.24)	71.02 (± 1.76)	64.35 (± 0.94)
Llama3.1-70b	11	39.70 (± 1.55)	52.15	56.46 (± 2.30)	61.71 (± 1.88)	52.51
Gemini-2.5-flash	12	46.50 (± 1.58)	25.04	40.51 (± 2.28)	35.28 (± 1.85)	38.34
EIR						
Llama3-8b	-	50.50 (± 1.58)	41.68 (± 2.24)	-	-	-
Llama3.1-8b	-	-	6.36 (± 1.12)	-	-	-
Gemma2-9b	-	-	61.31 (± 2.07)	-	-	-
Gemma-7b	-	48.70 (± 1.58)	27.48 (± 1.90)	-	-	-
GPT-3.5	-	27.40 (± 1.41)	-	-	-	-
o1-mini	-	33.80 (± 1.50)	-	-	-	-
Gemini-2.5-flash- RAG	-	-	65.57	-	-	-

Note: "-" indicates no evaluation. Accuracy in %. PQ-S: PubMedQA-Swedish-1000; SMDT: Swedish Medical Doctors Test; EM: Emergency Medicine; GM: General Medicine; SMLB: Swedish Medical LLM Benchmark.