

پرسش و پاسخ محاوره‌ای برای زبان‌های کم‌منبع: یک معماری جدید تقویت‌شده با مدل‌های زبانی بزرگ

صفورا آقادات جلفایی

دانشجوی دکتری مدیریت فناوری اطلاعات

پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)، تهران، ایران

آزاده محبی*

دکتری مهندسی طراحی سیستم‌ها

استادیار پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک)، تهران، ایران

دریافت: ۱۴۰۴/۰۶/۳۱ | پذیرش: ۱۴۰۴/۰۹/۱۰ | مقاله برای اصلاح به مدت ۱۸ روز نزد پدیدآوران بوده است.

نشریه علمی (رتبه بین‌المللی)
پژوهشگاه علوم و فناوری اطلاعات ایران
شاپا (چاپی) ۲۲۲۳-۲۲۵۱
شاپا (الکترونیکی) ۸۲۳۱-۲۲۵۱
نمایه در SCOPUS LISTA و ISC
<http://jipm.irandoc.ac.ir>
دوره XX | شماره X | صص XX-XX
۱۳XX X

نوع مقاله: مروری / پژوهشی

چکیده: سامانه‌های پرسش و پاسخ محاوره‌ای با ظهور مدل‌های زبانی بزرگ به طور قابل توجهی تکامل یافته‌اند؛ با این حال، این پیشرفت‌ها عمدتاً به نفع زبان‌های پرممنبع بوده و زبان‌های کم‌منبع را نادیده گرفته‌اند. این مقاله چارچوب نوین تقویت‌شده با مدل‌های زبان بزرگ را معرفی می‌کند که به طور خاص برای پر کردن این شکاف زبانی طراحی شده است. معماری پیشنهادی دارای شش مؤلفه است: «پردازش ورودی» برای مدیریت ویژه زبان، «هسته مدل زبانی بزرگ تطبیق‌پذیر»، «بهبود دانش» برای نگاهت بین زبانی، «مدیریت زمینه» برای راهبری کارآمد محاوره، «تولید پاسخ» همراه با انطباق فرهنگی، و «بازخورد انسانی» برای بهبود مستمر. برخلاف رویکردهای موجود، این چارچوب ملاحظات فرهنگی و زبانی را در سرتاسر فرایند پردازش لحاظ می‌کند. برای اعتبارسنجی این چارچوب، از یک ارزیابی کیفی از طریق گروه متمرکز متشکل از پنج متخصص پردازش زبان طبیعی استفاده شد. نتایج ارزیابی متخصصان، اثربخشی چارچوب پیشنهادی را در پرداختن به چالش‌های اساسی زبان‌های کم‌منبع، از جمله محدودیت داده، پیچیدگی‌های صرفی و ظرافت‌های فرهنگی، تأیید کرد. متخصصان به‌طور ویژه، رویکرد نوآورانه چارچوب در «پردازش فرهنگی یکپارچه»، «کارایی منابع» از طریق مدیریت بهینه زمینه، و «معماری ماژولار و مقیاس‌پذیر» را به عنوان دستاوردهای کلیدی برجسته ساختند.

کلیدواژه‌ها: پرسش و پاسخ محاوره‌ای، درک ماشین، پردازش زبان طبیعی.

*پدیدآور رابط

به این مقاله به شکل زیر استناد کنید:

درون متن:

(آقادات جلفایی، محبی، زودآیند)

در فهرست منابع:

آقادات جلفایی، صفورا، محبی، آزاده. زودآیند.

پرسش و پاسخ محاوره‌ای برای زبان‌های کم‌منبع

یک معماری جدید تقویت‌شده با مدل‌های زبانی

بزرگ. پژوهشنامه پردازش و مدیریت اطلاعات.

<http://Jipm.irandoc.ac.ir> (دسترسی در

روزنامه/سال)

۱. مقدمه

در سیستم‌های پرسش و پاسخ^۱، کاربران قادر به دریافت پاسخ‌های دقیق به پرسش‌های زبان طبیعی هستند (J. Gao et al., 2019; Soares & Parreiras, 2020). این سیستم‌ها مؤلفه‌ای مهم از هوش مصنوعی محاوره‌ای^۲ محسوب می‌شوند که دانش حوزه‌های پردازش زبان طبیعی^۳، بازیابی اطلاعات و یادگیری ماشین را در بر دارند. (Gupta et al., 2020). هوش مصنوعی محاوره‌ای به ماشین‌ها امکان درک، پردازش و پاسخگویی به انسان‌ها به زبان طبیعی را می‌دهد (Kusal et al., 2022). طراحی سیستمی که بتواند هم‌تراز یا فراتر از توانایی انسان در یک گفتگوی تعاملی مشارکت داشته باشد، و به پرسش‌هایی در موضوعات گوناگون پاسخ دهد یکی از دستاوردهای هوش مصنوعی است (J. Gao et al., 2019).

یک سیستم پرسش و پاسخ محاوره‌ای^۴ باید قابلیت تفسیر صحیح پرسش به همراه ارائه پاسخ‌های هوشمندانه را داشته باشد. برای تحقق این امر، معمولاً دسترسی به اطلاعات مرتبط در گفتگوهای پیشین نیز ضروری است (Vakulenko et al., 2021; Zaib et al., 2022). سامانه‌های محاوره‌ای باید پاسخ‌های دقیق ارائه دهند (پرسش و پاسخ)، درخواست کاربر را برآورده سازند (تکمیل وظیفه) و قادر به گفتگویی پیوسته و مناسب با کاربر باشند (گفتگوی اجتماعی) (J. Gao et al., 2019).

مدل‌های زبانی بزرگ^۵ موجب بهبود چشمگیر سامانه‌های محاوره‌ای در پاسخگویی به پرسش‌های کاربران در طیف گسترده‌ای از وظایف زبانی شده‌اند. سامانه‌های پاسخگویی محاوره‌ای پیش از ظهور مدل‌های زبانی بزرگ، با محدودیت‌هایی از جمله درک ضعیف زمینه، حوزه‌های دانش محدود و ناتوانی در پردازش پرسش‌های پیچیده مواجه بودند. این سامانه‌ها غالباً پاسخ‌های نادرست یا نامرتب ارائه می‌دادند که به تعاملات غیرطبیعی

¹ Question answering

² Conversational artificial intelligence

³ Natural language processing

⁴ Conversational question answering

⁵ Large language models

می‌انجامید. همچنین، در پردازش اطلاعات گسترده و به‌هنگام در موضوعات متنوع با چالش‌هایی روبرو بودند. معرفی مدل‌های زبانی بزرگ بسیاری از این چالش‌ها را مرتفع ساخته و قابلیت‌ها و تجربه کاربری هوش مصنوعی محاوره‌ای را به‌طور معناداری ارتقاء داده است (Dam et al., 2024).

با این حال، سامانه‌های مبتنی بر مدل‌های زبانی بزرگ اغلب فاقد آگاهی از اهداف^۱ هستند؛ یعنی توانایی درک، حفظ و پیگیری فعالانه اهداف محاوره‌ای مشخص در حین تعامل با کاربران را ندارند. این ضعف عمدتاً از آنجا ناشی می‌شود که مدل‌های زبانی بزرگ معمولاً برای پیروی از دستورالعمل‌های کاربران آموزش دیده‌اند، نه برای پیگیری اهداف محاوره‌ای خاص (Deng et al., 2023). هرچند مدل‌های زبانی بزرگ قابلیت تولید پاسخ را بهبود بخشیده‌اند، اما توسعه سیستم‌های هوش مصنوعی محاوره‌ای که قادر به حفظ رفتارهای مبتنی بر هدف باشند، به‌ویژه برای زبان‌های کم‌منبع^۲ که محدودیت‌های بیشتری هم دارند، همچنان چالش برانگیز است.

توسعه هوش مصنوعی محاوره‌ای برای زبان‌های کم‌منبع به دلایل متعددی چالش برانگیز است؛ از جمله داده‌های آموزشی محدود، منابع محاسباتی ناکافی، چالش‌های ارزیابی، مشکلات فنی مرتبط با ساختارهای ریخت‌شناسی و نیاز به سازگاری فرهنگی (Andersland, 2024; Yong et al., 2024).

با توجه به این شکاف عمیق میان پیشرفت‌ها در زبان‌های پرممنبع و نیازهای اساسی زبان‌های کم‌منبع، این پژوهش با هدف پاسخگویی به سوالات کلیدی زیر شکل گرفته است: ۱. مؤلفه‌های ضروری یک چارچوب جامع برای سیستم‌های پرسش و پاسخ محاوره‌ای که به‌طور خاص برای زبان‌های کم‌منبع طراحی شده باشد، کدامند؟ ۲. این چارچوب چگونه می‌تواند به چالش‌های منحصربه‌فرد این زبان‌ها، از جمله کمبود داده، پیچیدگی‌های ساختاری و ظرافت‌های فرهنگی، به‌طور مؤثری پاسخ دهد؟

در راستای پاسخ به این سوالات، این پژوهش اهداف اصلی مشخصی را دنبال می‌کند:

¹ Goal awareness

² Low-resource languages

نخست، طراحی یک چارچوب جامع و ماژولار که قابلیت انطباق با ویژگی‌های زبان‌های مختلف کم‌منبع را داشته باشد؛ دوم، یکپارچه‌سازی پردازش‌های زبانی و فرهنگی در تمامی مراحل برای تولید پاسخ‌هایی دقیق و متناسب با زمینه فرهنگی؛ و در نهایت، ارائه راه‌حلی کارآمد از نظر محاسباتی که در محیط‌های با منابع محدود نیز قابل پیاده‌سازی باشد. برای دستیابی به این اهداف، در این مقاله یک چارچوب نوین شش مؤلفه‌ای برای پاسخگویی محاوره‌ای به پرسش‌ها معرفی و تشریح می‌شود. این چارچوب برخلاف معماری‌های موجود که عمدتاً برای زبان انگلیسی طراحی شده‌اند، چالش‌های زبان‌های کم‌منبع مانند فارسی را به عنوان محور اصلی طراحی خود در نظر گرفته و راه‌حلی یکپارچه برای غلبه بر آن‌ها ارائه می‌دهد. در ادامه، پس از بررسی کارهای مرتبط، به تفصیل مؤلفه‌های این چارچوب و نحوه پاسخگویی آن‌ها به چالش‌های مطرح‌شده، ارائه خواهد شد.

۲. کارهای مرتبط

پیش از ظهور مدل‌های زبانی بزرگ، سیستم‌های پرسش و پاسخ محاوره‌ای از طریق عامل‌های محاوره‌ای پیاده‌سازی می‌شدند که در دو دسته قرار می‌گرفتند: عامل‌های مبتنی بر پایپ لاین^۱ که با پردازش ترتیبی برای حوزه‌های با داده محدود مناسب بودند (Harms et al., 2019)، و عامل‌های سرتاسری^۲ که مستقیماً از داده‌های بزرگ یاد می‌گرفتند تا تعاملات طبیعی‌تری ایجاد کنند اما با چالش‌های امنیتی همراه بودند (Chen et al., 2017; Dinan et al., 2021). در این سیستم‌ها مؤلفه‌های کلیدی مانند مدل‌سازی تاریخچه گفتگو (Qu et al., 2019; Qian et al., 2022)، درک پرسش (Burgin et al., 2022; V. Kumar & Callan, 2020; et al., 2022)، بازیابی دانش (Christmann et al., 2019; Yang et al., 2019) و تولید پاسخ (Campos, Otegi, et al., 2020; Burgin et al., 2022) وجود داشتند. پژوهش‌ها در این حوزه روی حوزه‌های نظیر بهبود فرآیند مکالمه از طریق استفاده از بازخورد (Campos, Cho, Otegi, et al., 2020)، حل مشکل فراموشی در گفتگوهای چند مرحله‌ای (Qian et al., 2022)، مدیریت داده‌های ساختاریافته و بدون ساختار (Burgin et al., 2022) و بهبود استدلال با یادگیری چندوظیفه‌ای (Kongyoung et al., 2022) متمرکز بودند. نتایج

¹ Pipeline

² end-to-end

این پژوهش‌ها، امکان مدیریت انواع پرسش‌ها و تلفیق منابع دانش گوناگون را فراهم کردند. جدول ۱ نمونه‌ای از چارچوب‌ها و معماری‌های این سیستم‌ها را قبل از ظهور مدل‌های زبانی نشان می‌دهد.

جدول ۱: چارچوب‌های پرسش و پاسخ محاوره‌ای پیش از مدل‌های زبانی بزرگ

چارچوب	ویژگی‌های کلیدی	مؤلفه‌های اصلی
(Qu et al., 2019)	تمرکز بر مدل‌سازی و انتخاب تاریخچه	انتخاب تاریخچه، رمزگذار، ماژول استدلال، پیش‌بینی‌کننده خروجی
(Su et al., 2019)	تمایز بین انواع پرسش	استخراج منطق، درک پرسش، پرسش و پاسخ راستی‌آزمایی، پرسش و پاسخ جستجوی دانش
(Burgin et al., 2022)	رویکرد ترکیبی برای داده‌های ساختاریافته و غیرساختاریافته	طبقه‌بندی قصد، بررسی‌کننده
(Christmann et al., 2019)	مدیریت منابع ناهمگن (پایگاه دانش، متن، جداول)	بازنمایی پرسش، ضبط شواهد، تولید پاسخ
(Christmann et al., 2023)	ترکیب چندین منبع با توضیحات	ایجاد گراف ناهمگن، شبکه عصبی گرافی با توجه سطح پرسش

علیرغم ایجاد معماری بنیادی برای هوش مصنوعی محاوره‌ای، این چارچوب‌های پیش از LLM با محدودیت‌های قابل توجهی در رابطه با مقیاس‌پذیری و درک عمیق متنی مواجه بودند. این سیستم‌ها به شدت به مجموعه داده‌های حاشیه‌نویسی شده گسترده و اجزای خط لوله‌ای سفت و سخت متکی بودند، که آنها را به ویژه برای زبان‌های کم‌منبع که در آنها داده‌های آموزشی کمیاب و پیچیدگی مورفولوژیکی بالا است، نامناسب می‌کرد. این محدودیت‌ها، تغییر الگو به سمت معماری‌های انعطاف‌پذیرتر و بهبود یافته با مدل‌های زبانی بزرگ را ضروری ساخت.

در چشم‌انداز کنونی هوش مصنوعی محاوره‌ای، مدل‌های زبانی بزرگ با فراهم کردن تعاملات طبیعی‌تر، قابلیت‌های سیستم‌های پرسش و پاسخ را به طور چشمگیری بهبود بخشیده‌اند (Dam et al., 2024). این مدل‌ها، از طریق فرآیندی سه‌مرحله‌ای شامل تنظیم دقیق^۱، یادگیری تقویتی مبتنی بر بازخورد انسانی^۲ و ارزیابی انسانی آموزش می‌بینند تا با

¹ Fine tuning

² Reinforcement learning from human feedback

هدف کاربر همسو شوند (Zhao et al., 2024; Dam et al., 2024). برای غلبه بر چالش‌های کلیدی مانند نمایش زمینه و کسب دانش، رویکردها از بازنویسی پرسش (Z. Dinan et al., 2021; Wu et al., 2021) به سمت مدل‌سازی مستقیم زمینه مکالمه (Dinan et al., 2021; Harms et al., 2019) با مدل‌های زبانی بزرگ و استفاده از روش‌های تولید تقویت‌شده با بازیابی^۱ برای تکمیل ورودی‌ها با پایگاه دانش بیرونی (Asai et al., 2023; Qin et al., 2023) تکامل یافته‌اند.

مطالعات اخیر رویکردهای نوآورانه‌ای را معرفی کرده‌اند، از جمله رویکردهای ترکیبی که مدل‌های زبانی بزرگ را با عامل‌های سنتی ادغام می‌کنند (Foosherian et al., 2023). چارچوب ConvRAG بازیابی اطلاعات را در سطح مکالمه بهینه می‌کند (Ye et al., 2024). چارچوب RAISE (N. Liu et al., 2024) با الهام از ReAct (Yao, et al., 2023) و با استفاده از حافظه دوگانه، کنترل‌پذیری را افزایش می‌دهد. مدلی دیگر تنظیم دقیق، معماری معلم-شاگرد^۲ و یادگیری تقویتی^۳ را برای پیمایش گراف دانش^۴ ترکیب می‌کند و چارچوبی ارائه می‌دهد که با برنامه‌ریزی پیش از مکالمه و ایجاد یک رویه عملیاتی استاندارد^۵، گفتگوهای هدفمند و انطباق‌پذیر را با حداقل ورودی انسانی ممکن می‌سازد (Z. Li, Peng, et al., 2024).

پیشرفته‌ترین مدل‌های زبانی بزرگ مانند GPT و LLaMA با وجود توانایی‌های استثنایی، در پردازش زبان‌های کم‌منبع به دلیل کمبود داده با چالش مواجه هستند (Z. Li, et al., 2023; Shi, et al., 2024; Robinson et al., 2023). اگرچه روش‌هایی مانند تنظیم دقیق^۶ و یادگیری مستمر^۷ بررسی شده‌اند، اما اغلب به مشکلاتی نظیر فراموشی فاجعه‌آمیز^۸ منجر

¹ Retrieval-augmented generation (RAG)

² teacher-student model

³ reinforcement learning

⁴ Knowledge graph

⁵ Standard Operating Procedure (SOP)

⁶ Language specific fine tuning

⁷ Continuous learning

⁸ Catastrophic forgetting

می‌شوند (Adelani et al., 2021; A. Kumar et al., 2022).

در این میان، یادگیری درون‌زمینه‌ای^۱ به عنوان یک راه‌حل کلیدی مطرح شده که به مدل‌ها اجازه می‌دهد با چند نمونه، دانش خود را به زبان‌های جدید منتقل کرده و نیاز به داده را کاهش دهند (Alam et al., 2024; Cahyawijaya et al., 2024). با این حال، نوع میان‌زبانی^۲ آن همچنان در رقابت با روش‌های مبتنی بر ترجمه برای زبان‌های بسیار کم‌منبع با چالش روبروست (Cahyawijaya et al., 2024; Tanwar et al., 2023). برای رفع این محدودیت‌ها، رویکردهای دیگری نیز توسعه یافته‌اند؛ از جمله ساخت مدل‌های چندوجهی برای زبان‌هایی مانند Amharic^۳ با استفاده از افزایش داده^۴ از طریق ترجمه (Andersland, 2024)، و چارچوب میان‌زبانی به کمک ترجمه^۵ که با به‌کارگیری ترجمه در فرآیند زنجیره-تفکر^۶ و یادگیری برنامه‌ریزی‌شده، هزینه‌های افزودن زبان‌های جدید را کاهش می‌دهد (Upadhyay & Behzadan, 2024). در نهایت، مطالعات نشان می‌دهند که اگرچه مدل‌های زبانی بزرگ در وظایف ساده برای زبان‌های کم‌منبع عملکرد خوبی دارند، اما برای وظایف زبانی پیچیده، تخصص انسانی همچنان برتر است و نیازمند برچسب‌گذاری انسانی است (Nasution & Onan, 2024). جدول ۲ اجزای کلیدی از نمونه چارچوب‌ها و معماری‌های این سیستم‌ها را بعد از ظهور مدل‌های زبانی بزرگ نشان می‌دهد.

¹ In-context learning (ICL)

² Cross-lingual in-context learning - X-ICL

⁴ Data augmentation

⁵ Translation-Assisted Cross-Linguality

⁶ chain-of-thought

^۳ زبان رسمی کشور اتیوپی

جدول ۲: چارچوب‌های پرسش و پاسخ محاوره‌ای پس از بروز مدل‌های زبانی بزرگ

چارچوب	ویژگی‌های کلیدی	اجزای اصلی
(Foosherian et al., 2023)	بهبود عامل‌های مبتنی بر خط لوله سنتی، ایجاد تعادل بین قابلیت‌ها و حریم خصوصی	تولید داده طبقه‌بندی قصد و منظور از طرح پرسش فرمول‌بندی پاسخ
(Ye et al., 2024)	بازایی در سطح گفتگو، بهبود وضوح پرسش	ابزار روشن‌سازی پرسش بازایی اطلاعات خاص بررسی‌کننده مفید بودن اطلاعات
(N. Liu et al., 2024)	تقلید از حافظه انسانی مدیریت گفتگوهای پیچیده	دفترچه یادداشت (حافظه کوتاه‌مدت) مازول بازایی (حافظه بلندمدت) رویکرد چندمرحله‌ای فاز آموزش مدل زبانی بزرگ
(L. Liu et al., 2024)	ترکیب تنظیم دقیق و یادگیری تقویتی تمرکز بر بازفرمول‌بندی پرسش	تنظیم دقیق مدل زبانی بزرگ معماری معلم-شاگرد مکان‌یابی پاسخ مبتنی بر یادگیری تقویتی
(Z. Li, Peng, et al., 2024)	ترکیب برنامه‌ریزی پیش از گفتگو با مدیریت گفتگوی هدف‌محور	ایجاد رویه عملیاتی استاندارد آفلاین برنامه‌ریزی اقدام آنلاین تولید پاسخ هدایت‌شده با رویه عملیاتی استاندارد تولید داده

اگرچه تغییر به معماری‌های مبتنی بر مدل‌های زبانی بزرگ از طریق استدلال پیشرفته، تولید تقویت‌شده با بازایی و برنامه‌ریزی تقویت‌شده با حافظه، هوش مصنوعی محاوره‌ای را متحول کرده است، اما این چارچوب‌ها عمدتاً انگلیسی‌محور و منابع محور باقی مانده‌اند. معماری‌های پیشرفته فعلی اغلب در پرداختن به محدودیت‌های منحصر به فرد زبان‌های کم‌منبع، مانند پیچیدگی مورفولوژیکی و کمبود داده‌های آموزشی با کیفیت بالا، شکست می‌خورند. علاوه بر این، راه‌حل‌های موجود معمولاً سازگاری فرهنگی را به عنوان یک مرحله پس‌پردازش ثانویه به جای یک جزء جدایی‌ناپذیر از خط لوله استدلال در نظر می‌گیرند که منجر به تعاملات از نظر فنی صحیح اما از نظر فرهنگی ناموزون می‌شود.

۳. روش پژوهش

پژوهش حاضر با رویکردی کیفی و توسعه‌ای در دو مرحله اصلی انجام شده است: (۱) طراحی چارچوب نظری و (۲) اعتبارسنجی چارچوب از طریق ارزیابی متخصصان.

مرحله اول (طراحی چارچوب): برای رسیدن به چارچوب پیشنهادی، از روش تحلیل شکاف عملکردی و مرور ساختاریافته ادبیات پژوهش استفاده شد. در این مرحله، ابتدا چارچوب‌ها و معماری‌های موجود برای پرسش و پاسخ محاوره‌ای مورد مطالعه قرار گرفتند. سپس، چالش‌های کلیدی پردازش زبان‌های کم‌منبع که در پژوهش‌های اخیر شناسایی شده‌اند (مانند کمبود داده، پیچیدگی‌های صرفی، و نیاز به انطباق فرهنگی) استخراج گردید. با تحلیل شکاف میان قابلیت‌های چارچوب‌های موجود و نیازمندی‌های زبان‌های کم‌منبع، مؤلفه‌های ضروری برای یک چارچوب جامع شناسایی و طراحی شدند. این فرآیند بر پایه مطالعه و تحلیل عمیق بیش از ۶۰ مقاله کلیدی در این حوزه شکل گرفت.

مرحله دوم (اعتبارسنجی چارچوب): پس از طراحی اولیه چارچوب، برای اعتبارسنجی ساختار و کارایی مفهومی آن، از روش کیفی گروه متمرکز^۱ استفاده شد. در این مطالعه، پنج پژوهشگر متخصص در حوزه پردازش زبان طبیعی مشارکت داشتند. این متخصصان بر اساس معیارهایی نظیر داشتن مدرک دکتری تخصصی در هوش مصنوعی، سابقه انتشار مقالات علمی-پژوهشی در کنفرانس‌ها و مجلات معتبر حوزه پردازش زبان طبیعی، و تجربه عملی در پروژه‌های مرتبط با زبان‌های کم‌منبع (به‌ویژه فارسی) انتخاب شدند. این گروه متشکل از اعضای هیئت علمی دانشگاه و پژوهشگران ارشد بودند. فرآیند ارزیابی شامل مصاحبه‌های نیمه‌ساختاریافته بر اساس پرسشنامه‌ای دقیق (ارائه‌شده در پیوست ۱) و بحث‌های عمیق پیرامون مؤلفه‌های چارچوب بود تا اثربخشی آن‌ها در مواجهه با چالش‌های زبان‌های کم‌منبع سنجیده شود. نتایج این ارزیابی در بخش «ارزیابی و مقایسه» ارائه شده است.

¹ Focus Group

۴. چارچوب پیشنهادی

چارچوب پیشنهادی، همان‌طور که در شکل ۱ نشان داده شده، از شش مؤلفه اصلی (۱) پردازش ورودی، (۲) هسته مدل زبانی بزرگ، (۳) تقویت دانش، (۴) مدیریت زمینه، (۵) تولید پاسخ و (۶) بازخورد انسانی تشکیل شده است.

این ساختار با استفاده از تحلیل شکاف‌ها در چارچوب‌های موجود (Campos, Cho, 2019; Otegi, Soroa, Agirre, et al., 2020; Kongyoung et al., 2022; Su et al., 2019) و رسیدگی به چالش‌های خاص پردازش زبان‌های کم‌منبع که در ادبیات پژوهش‌شناسایی شده‌اند (Kargaran et al., 2023; Yong et al., 2024)، پیشنهاد شده است. مطالعات پیشین بر لزوم مدیریت تخصصی ورودی (Nooralahzadeh et al., 2020)، درک زمینه‌ای (Mao & Yu, 2024; Merx et al., 2024; Robinson et al., 2023) و انطباق فرهنگی (Azime et al., 2025) برای پردازش مؤثر زبان‌های کم‌منبع تأکید کرده‌اند.

اگرچه چارچوب پیشنهادی عمدتاً بر زبان فارسی متمرکز است، اما طراحی این چارچوب به چالش‌های مشترک بسیاری از زبان‌های کم‌منبع رسیدگی می‌کند. به عنوان مثال، مؤلفه پردازش ورودی می‌تواند خطوط هجایی^۱ زبان Amharic (Nigusie & Tegegne, 2023)، ماهیت آهنگین^۲ زبان Yoruba (Adelani et al., 2021) و صرف ترکیبی^۳ زبان کردی (Hassani, 2018) را مدیریت کند. به طور مشابه، ماژول انطباق فرهنگی در بخش تولید پاسخ، سطوح مختلف رسمی بودن را که در زبان‌هایی مانند Swahili (Githiora, 2018) و Amharic ضروری است، در نظر می‌گیرد؛ زبان‌هایی که در آن‌ها سلسله‌مراتب اجتماعی به طور قابل توجهی بر الگوهای ارتباطی تأثیر می‌گذارد.

چارچوب شش مؤلفه‌ای پیشنهادی به طور نظام‌مند به این چالش‌ها رسیدگی کرده و در عین حال، کارایی محاسباتی و سازگاری^۴ را تضمین می‌کند. هر مؤلفه دارای زیرمؤلفه‌ها یا

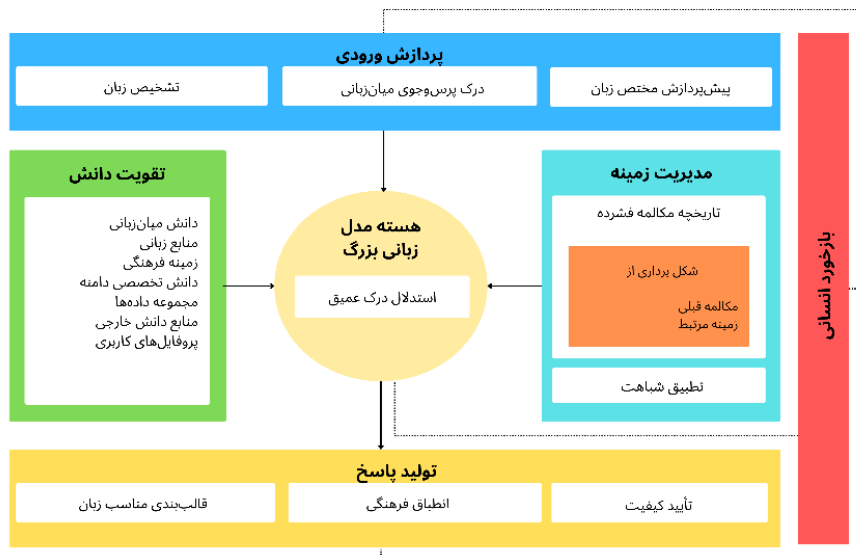
¹ syllabic scripts

² tonal

³ agglutinative morphology

⁴ adaptability

مراحل است که در بخش‌های بعدی به تفصیل شرح داده شده است.



شکل ۱: چارچوب پرسش و پاسخ محاوره‌ای برای زبان‌های کم‌منبع

پردازش ورودی

پردازش ورودی اولین مؤلفه است که تعامل اولیه با پرس و جوهای کاربر به هر زبانی را مدیریت می‌نماید. این مؤلفه برای زبان‌های کم‌منبع به ویژه ضروری است، و سه ماژول کلیدی را در بر می‌گیرد (جدول ۳):

تشخیص زبان^۱: این ماژول زبان را شناسایی کرده و سطح دسترسی به منابع آن را نیز ارزیابی می‌کند تا مبنای تصمیم‌گیری در مراحل پردازش بعدی قرار گیرد. برای مثال، تشخیص اینکه یک پرس و جو به زبان فارسی است و آگاهی از منابع پردازش زبان طبیعی برای آن (Kargaran et al., 2023).

درک پرس و جوی بین‌زبانی^۲: این ماژول، قصد و نیت پرس و جو را حتی در صورت کمیاب بودن منابع پردازشی مستقیم در زبان هدف، مشخص می‌کند. این کار با بهره‌گیری

¹ Language Detection

² Cross-lingual Query Understanding

از یادگیری انتقالی^۱ از زبان‌های پرمینع و بردارهای نهفته بین‌زبانی^۲ انجام می‌شود (Miao et al., 2024; Nooralahzadeh et al., 2020)، به عنوان مثال پرس‌وجوی پزشکی به زبان بنگالی از طریق نگاشت آن به الگوهای مشابه در زبان انگلیسی.

پیش‌پردازش مختص زبان^۳: این ماژول پردازش‌های مربوط به ویژگی‌های منحصر به فرد در زبان کم‌منبع را انجام می‌دهد، مانند: نرمال‌سازی نوشتار^۴، تحلیل صرفی^۵ و توکن‌سازی تخصصی^۶. برای مثال، مدیریت صرف پیچیده در زبان ترکی یا تنوع رسم‌الخط در گویش‌های عربی. تأثیر این مؤلفه بر پردازش زبان‌های کم‌منبع بسیار قابل توجه است (Howcroft & Gkatzia, 2022; Sun et al., 2021).

اگر پردازش ورودی نتواند به درستی یک پرس‌وجوی کم‌منبع را مدیریت کند، کل زنجیره پردازش در مراحل بعدی با اختلال مواجه خواهد شد. به عنوان مثال، هنگام پردازش یک پرس‌وجو به زبان فارسی، این مؤلفه نه تنها باید زبان را تشخیص دهد، بلکه باید رسم‌الخط را نرمال‌سازی کند، صرف پیچیده را مدیریت نماید و قصد پرس‌وجو را به مفاهیمی که برای مدل زبانی بزرگ قابل پردازش است، نگاشت دهد؛ در حالی که تمام این کارها را با ابزارها و منابع زبانی محدودتری در مقایسه با زبان‌های پرمینعی مانند انگلیسی انجام می‌دهد.

¹ transfer learning

² Cross-lingual embeddings

³ Language-specific Preprocessing

⁴ Script normalization

⁵ morphological analysis

⁶ Specialized tokenization

جدول ۳: ماژول‌های پردازش ورودی، شرح، تکنیک‌ها و نمونه پیاده‌سازی‌ها

ماژول	تشریح	نمونه فرایند (حوزه پزشکی)	تکنیک‌ها و ارجاعات
تشخیص زبان	شناسایی زبان و ارزیابی میزان منابع در دسترس	ورودی: سردرد شدید دارم خروجی: زبان: فارسی، خط: فارسی-عربی، سطح منابع: متوسط	Language ID with Resource Assessment (Kargaran et al., 2023) Script and Dialect Detection (Alam et al., 2024; Joshi et al., 2025) Resource Level Classification
درک پرسش میان‌زبانی	درک هدف پرسش در زبان‌های مختلف	ورودی: سردرد شدید دارم خروجی: حوزه: پزشکی، هدف: توصیف علائم، مفهوم اصلی: نگاشت به "having severe headache" نوع پرسش: مشاوره سلامت	Cross-lingual Transfer Learning (Nooralahzadeh et al., 2020) Multilingual Embeddings (Miao et al., 2024)
پیش‌پردازش ویژه زبان	مدیریت ویژگی‌های زبان‌شناختی منحصر به فرد زبان هدف	ورودی: سردرد شدید دارم خروجی: نرمال‌سازی شده: کاراکترهای استاندارد شده، واژه‌بندی شده: ["سردرد"، "شدید"، "دارم"]، تحلیل صرفی: زمان حال، اول شخص آماده برای پردازش مدل زبان بزرگ	Script Normalization (Howcroft & Gkatzia, 2022) Morphological Analysis Specialized Tokenization

هسته مدل زبانی بزرگ

هسته مدل زبانی بزرگ به عنوان مؤلفه مرکزی برای درک عمیق و تولید زبان عمل می‌کند. این بخش به مثابه مرکز شناختی سیستم است که به جای درک سطحی پرس و جو، بر درک عمیق معنایی و استدلال تمرکز دارد. هنگامی که هسته، پردازش یک پرس و جوی ورودی را آغاز می‌کند، به جای نگاشت آن به یک «نیت» ساده (مانند سیستم‌های سنتی)، بر درک عمیق معنایی و استدلال تمرکز می‌نماید. برای مثال، هنگام پردازش یک

پرس و جوی پزشکی درباره علائم کووید به زبان فارسی، هسته صرفاً متوجه نمی‌شود که این یک سؤال مرتبط با سلامت است (که لایه ورودی قبلاً آن را مشخص کرده)، بلکه وارد استدلال عمیق‌تری می‌شود: تعیین می‌کند که چه دانش پزشکی خاصی مورد نیاز است، چگونه باید اطلاعات را برای مخاطب عام قالب‌بندی کرد، چه عوامل فرهنگی را باید در زمینه فارسی‌زبان در نظر گرفت و چگونه یک پاسخ جامع را ساختاربندی نمود. سپس هسته تصمیم می‌گیرد که چه اطلاعاتی را در پاسخ بگنجاند و چگونه آن را ساختاربندی کند، پیش از آنکه این تصمیمات را برای قالب‌بندی نهایی زبانی به لایه تولید پاسخ منتقل نماید. این ویژگی، هسته را هم از پردازش ورودی (که مسئول درک اولیه است) و هم از تولید پاسخ (که مسئول تولید نهایی زبانی است) متمایز می‌سازد. این بخش به عنوان موتور استدلال عمل می‌کند که از طریق پردازش عمیق معنایی و تصمیم‌گیری، پلی میان درک و تولید ایجاد می‌نماید.

به طور خاص برای چالش‌های زبان‌های کم‌منبع، چارچوب پیشنهادی روش‌های انطباق با پارامتر بهینه^۱ را در هسته پیاده‌سازی می‌کند. این رویکرد به طور قابل توجهی نیازمندی‌های محاسباتی را کاهش داده و در عین حال، عملکرد را برای زبان‌های کم‌منبع حفظ کرده و اغلب بهبود می‌بخشد (Gurgurov et al., 2025). روش‌های انطباق سبک‌وزن^۲، انتقال بین‌زبانی مؤثر را با حداقل پارامترهای اضافی امکان‌پذیر می‌سازند، که این امر پیاده‌سازی سیستم را از نظر فنی امکان‌پذیر می‌کند و از نظر اقتصادی برای استقرار در بسترهای زبانی متنوع، نیز مقرون‌به‌صرفه است. جدول ۴ این روش‌ها را نشان می‌دهد.

¹ parameter-efficient adaptation

² lightweight

جدول ۴: روش‌های یکپارچه هسته مدل زبانی بزرگ، شرح، تکنیک‌ها و نمونه پیاده‌سازی‌ها

روش‌های یکپارچه	تشریح	نمونه (حوزه علمی)	تکنیک‌ها و ارجاعات
انطباق با پارامتر بهینه	امکان انطباق دقیق با زبان‌های کم‌منبع را بدون نیاز به منابع محاسباتی گسترده یا مجموعه داده‌های بزرگ فراهم می‌کند	تبدیل یک مدل زبانی عمومی برای پردازش پرسش‌ها به زبان فارسی یا کردی با حداقل داده‌های آموزشی اضافی	LoRA (Hu et al., 2021) Sequential Bottleneck Adapters (Houlsby et al., 2019) Sequential Bottleneck with Invertible Layers (Seq_bn_inv)(Pfeiffer, Vulić, et al., 2020) AdapterFusion (Pfeiffer, Kamath, et al., 2020)
پردازش میان‌زبانی ^۱	امکان انتقال دانش تخصصی از زبان‌های پرمنبع به زبان‌های کم‌منبع را با حفظ دقت حوزه‌ای فراهم می‌کند	ورودی: مقالات جدید در مورد یادگیری عمیق چیست؟ فرایند: نگاشت یادگیری عمیق به "deep learning" شناسایی نوع پرسش علمی تشخیص بررسی مقالات اخیر	mT5 (Xue et al., 2021) XLM-R (Conneau et al., 2020) BLOOM(Workshop et al., 2023) XGLM(X. V. Lin et al., 2022) RemBERT(Deng et al., 2023)
استراتژی‌های پرومپت نویسی	راهنمایی مدل زبان بزرگ برای پردازش محتوا	ورودی: پرس و جوی علمی فرایند: استفاده از نمونه‌های مقالات آکادمیک، ساختاردهی پاسخ علمی، حفظ دقت علمی نمونه پرومپت: با توجه به مقالات اخیر درباره X یافته‌های کلیدی را در قالب Y خلاصه کنید.	Few-shot Learning(Nguyen et al., 2024; Song et al., 2023) Chain of Thought(Upadhayay & Behzadan, 2024; Wei et al., 2023) Tree of thought (Yao, Yu, et al., 2023)

¹ Cross-lingual Processing

تقویت دانش

مؤلفه تقویت دانش به عنوان مخزن جامعی عمل می کند که از هسته مدل زبانی بزرگ در درک و پردازش زبان های کم منبع پشتیبانی می نماید. این بخش هفت نوع دانش ضروری را نگهداری می کند:

۱. دانش بین زبانی^۱ برای نگاشت مفاهیم بین زبان ها،
۲. منابع زبانی^۲ حاوی قواعد دستوری و زبان شناختی،
۳. زمینه فرهنگی^۳ که هنجارهای اجتماعی را در بر می گیرد،
۴. دانش تخصصی^۴ در حوزه های مختلف،
۵. مجموعه داده ها^۵ که اطلاعات ساختاریافته را فراهم می کند،
۶. منابع دانش خارجی^۶ که دانش مرجع تکمیلی ارائه می دهند،
۷. پروفایل های کاربری^۷ حاوی داده های تعاملات پیشین.

مجموعه داده ها، که بخش حیاتی این مؤلفه را تشکیل می دهند، معمولاً توسط انسان برچسب گذاری شده و حاوی حاشیه نویسی هایی شامل نیت، موجودیت، نوع، رابطه و سه تایی هستند (Perez-Beltrachini et al., 2023). این سه تایی ها که برای نمایش دانش ساختاریافته به کار می روند، معمولاً از ساختار (موضوع، گزاره، مفعول) یا (موجودیت ۱، رابطه، موجودیت ۲) پیروی می کنند؛ برای مثال، رابطه پایتختی بین «تهران» و «ایران» با سه تایی (تهران، پایتخت است، ایران) نمایش داده می شود. چالش اساسی در زبان های کم منبع، کمیابی شدید یا نبود کامل مجموعه داده های با کیفیت است. اتکا به برچسب گذاری انسانی برای ایجاد این داده ها، اگرچه دقیق است، اما به دلیل هزینه های بسیار بالا و زمان بردن، اغلب در عمل امکان پذیر نیست (Kusal et al., 2022). در مقابل مدل های زبانی بزرگ پتانسیل آن را دارند که هزینه های مالی و محاسباتی را در

¹ cross-lingual knowledge

² Language resources

³ Cultural context

⁴ Domain-specific knowledge

⁵ Datasets

⁶ External knowledge sources

⁷ User profiles

حاشیه‌نویسی داده‌ها به طور قابل توجهی کاهش دهند، اما همزمان ممکن است منجر به ایجاد توهم^۱ در نتایج بشوند (Kholodna et al., 2024). اگرچه پذیرش سطحی از نویز و توهم در نتایج در این فرآیند اجتناب‌ناپذیر است، اما این رویکرد می‌تواند به ایجاد مجموعه داده‌های اولیه در محیط‌های کم‌منبع کمک شایانی کند. علیرغم این محدودیت‌ها، مؤلفه «تقویت دانش» با فراهم کردن زمینه و نگاشت‌های ضروری (شامل دانش بین‌زبانی و فرهنگی)، به طور فعال به هسته در درک و پردازش پرس و جوها، به‌ویژه در غیاب یا نویزی بودن داده‌های ساختاریافته، کمک می‌کند. در جدول ۵، تمامی انواع دانشی که توسط مؤلفه تقویت دانش نگهداری می‌شوند، به همراه تشریحات و تکنیک‌های پیشرفته مرتبط که توسط پژوهش‌های اخیر پشتیبانی می‌شوند، ارائه شده است.

مدیریت زمینه

مؤلفه مدیریت زمینه با نگهداری یک شکل فشرده یا برداری^۲ از تاریخچه مکالمه مرتبط و استفاده از تطبیق شباهت برای شناسایی زمینه مرتبط، به هسته کمک می‌کند. به عنوان مثال، زمانی که کاربر یک سؤال تکمیلی می‌پرسد، این مؤلفه می‌تواند به سرعت مرتبط‌ترین بخش‌های مکالمه قبلی را بازیابی کرده و در اختیار هسته قرار دهد، به جای اینکه مجبور باشد هر بار کل تاریخچه مکالمه را پردازش کند. این امر به ویژه برای زبان‌های کم‌منبع که در آن‌ها کارایی پردازش اهمیت دارد، مفید است. یک چالش اساسی در زبان‌های کم‌منبع، آن است که داده‌های آموزشی ناکافی منجر به تولید بردارهای برداری تک‌زبانه ضعیف می‌شود که در درک ظرافت‌های معنایی و تطبیق شباهت، کارایی لازم را ندارند. برای غلبه بر این چالش، چارچوب پیشنهادی به جای اتکا به بردارهای بومی، از «بردارهای نهفته میان‌زبانی که در مؤلفه‌های «پردازش ورودی» و «تقویت دانش» نیز به کار گرفته می‌شوند، بهره می‌برد. این بردارها که از طریق هم‌راستاسازی با زبان‌های پرممنبع آموزش دیده‌اند، امکان تطبیق شباهت معنایی را حتی با وجود منابع محدود فراهم

¹ Hallucination

² embedding

می سازند. به عنوان مثال، زمانی که کاربر یک سؤال تکمیلی می پرسد، این مؤلفه می تواند به سرعت مرتبط ترین بخش های مکالمه قبلی را بازیابی کرده و در اختیار هسته قرار دهد، به جای اینکه مجبور باشد هر بار کل تاریخچه مکالمه را پردازش کند.

جدول ۵: انواع منابع دانشی

تکنیک ها	نمونه ها (حوزه پزشکی)	تشریح	انواع دانش
Cross-lingual Embeddings (Conneau et al., 2020) Neural Machine Translation (Tan et al., 2019)	English "headache" → Persian "سر درد" English "take twice daily" → Persian "روزی دو بار میل کنید"	نگاشت مفاهیم بین زبان های مختلف	دانش میان زبانی
Morphological Learning (Fam & Lepage, 2024) Grammar Induction (Kai et al., 2024)	صیغه های فعل پزشکی: بخور، میل کنید	قواعد دستوری و زبان شناختی	منابع زبانی
Cultural Information Extraction (Ringel et al., 2019)	مشارکت خانواده در تصمیمات پزشکی، مفاهیم طب سنتی	هنجارها و باورهای اجتماعی و فرهنگی	زمینه فرهنگی
Knowledge Graph Construction (J. Li et al., 2024)	نام های محلی داروها، ساختار نظام سلامت	اطلاعات تخصصی حوزه	دانش تخصصی
Data Augmentation (Soudani et al., 2023; Q. Wu et al., 2021) Few-shot Learning (Brown, 2020) LLMs (Kholodna et al., 2024)	جفت های پرسش و پاسخ پزشکی به زبان فارسی، پیکره های موازی (متون پزشکی انگلیسی-فارسی)، گفتگوهای حاشیه نویسی شده	مجموعه های داده ساختاریافته	مجموعه داده ها
RAG (Y. Gao et al., 2024; Lewis et al., 2020)	وبسایت ها/اسناد پزشکی، راهنماهای مراقبت سلام، مقالات علمی، پروتکل های پزشکی محلی	مواد مرجع اضافی	منابع دانشی خارجی
User Modeling Pattern Mining	پرسش های پزشکی گذشته، ترجیحات زبانی، علائق حوزه ای، الگوهای پرسش	داده های تاریخچه تعاملات	پروفایل های کاربری

مدیریت زمینه مانند یک سیستم حافظه هوشمند عمل می کند و به هسته کمک می کند تا به جای پردازش مجدد و مداوم زمینه گذشته، بر وظیفه فعلی تمرکز نماید. تنها هدف این

مؤلفه، کمک به کارآمدتر شدن هسته از طریق مدیریت تاریخچه مکالمه به شیوه‌ای است که بار پردازشی را کاهش دهد؛ امری که کارایی محاسباتی را ارتقا داده و به‌ویژه در سناریوهایی که منابع پردازشی نیز (مانند خود داده‌ها) محدود هستند، ضروری است.

تولید پاسخ

مؤلفه «تولید پاسخ»، درک پردازش‌شده را از هسته دریافت کرده و با استفاده از مدل‌های زبانی، یک فرآیند سه‌مرحله‌ای هدایت‌شده را برای ایجاد پاسخ‌های مناسب به زبان کم‌منبع هدف دنبال می‌کند. این رویکرد به جای اتکای به یک تولید تک‌مرحله‌ای و کنترل‌نشده، بر افزایش کنترل‌پذیری و دقت در زبان‌های کم‌منبع تمرکز دارد. این فرآیند با تولید مختص زبان^۱ آغاز می‌شود، که در آن به مدل زبانی دستور داده می‌شود تا خروجی هسته را براساس قواعد دستوری و نحوی زبان هدف شکل دهد؛ به عنوان مثال، هنگام تولید پاسخ به زبان فارسی، این مرحله از صرف صحیح افعال و ترتیب درست کلمات اطمینان حاصل می‌کند. سپس فرآیند به مرحله انطباق فرهنگی^۲ می‌رود، که در آن پاسخ صحیح از نظر زبانی، مجدداً توسط مدل زبانی برای تطابق با زمینه‌های فرهنگی پالایش می‌شود؛ مانند تنظیم سطوح گفتار رسمی/غیررسمی یا جایگزینی اصطلاحات با عبارات متناسب با فرهنگ مقصد. در نهایت، فرآیند با راستی‌آزمایی کیفیت^۳ به پایان می‌رسد، که به عنوان یک بررسی نهایی (که می‌تواند توسط مدل زبانی به عنوان یک ارزیاب یا با رویکرد Self-Refine انجام شود) برای تضمین روانی، انسجام و دقت پاسخ عمل می‌کند.

این مراحل در یک پایپ‌لاین مبتنی بر مدل زبانی با یکدیگر کار می‌کنند: خروجی تولید مختص زبان به «انطباق فرهنگی» وارد می‌شود، که آن نیز به نوبه خود ورودی راستی‌آزمایی کیفیت را فراهم می‌کند. این ساختار تضمین می‌کند که کیفیت هر پاسخ متناسب با زبان و به تناسب فرهنگی ارتقا یابد. جدول ۶ مراحل تولید پاسخ را نشان می‌دهد.

¹ Language-Specific Generation

² Cultural Adaptation

³ Quality Verification

جدول ۶: مراحل فرایند در تولید پاسخ و تشریحات، تکنیک‌ها و نمونه‌ها

تکنیک‌ها	نمونه (پرسش پزشکی)	تشریح	مرحله فرایند
Multilingual Generation (J. Li et al., 2024) Grammar-Aware Generation (Gemechu & Kanagachidambaresan, 2023) Syntax-Controlled NLG (Jia et al., 2025)	ورودی: complete the task by tomorrow خروجی: لطفا کار را تا فردا تمام کنید (اعمال ترتیب صحیح کلمات فارسی، صرف فعل)	شکل دهی خروجی بر اساس قواعد دستوری و نحوی زبان هدف توسط مدل زبانی	تولید مختص زبان
Cultural Style Transfer Politeness Adaptation Context-Aware Generation	ورودی: لطفا کار را تا فردا تمام کنید خروجی: خواهشمند است کار محوله را تا فردا به اتمام برسانید افزودن زمینه کسب و کار رسمی، ادب مناسب	اصلاح پاسخ‌ها برای تناسب فرهنگی توسط مدل زبانی	انطباق فرهنگی
Quality Metrics Coherence Checking Accuracy Validation	بررسی‌ها: دستور/نحو، تناسب فرهنگی، وضوح پیام، دقت محتوا	اطمینان از دقت زبان‌شناختی، تناسب فرهنگی و قابلیت اعتماد محتوا	راستی‌آزمایی کیفیت

بازخورد انسانی

مؤلفه بازخورد انسانی به عنوان یک سازوکار حیاتی برای ارزیابی و بهبود کل سیستم پردازش زبان کم‌منبع عمل می‌کند. این بخش از طریق ارزیابی مستقیم انسانی و جمع‌آوری بازخورد ساختاریافته، به بهبود کیفیت پاسخ، دقت زبانی و تناسب فرهنگی کمک می‌نماید. روش‌های اخیر، نحوه جمع‌آوری و بهره‌برداری از بازخورد انسانی را با استفاده از بهینه‌سازی مستقیم ترجیحات^۱ (Rafailov et al., 2024) به طور قابل توجهی بهبود بخشیده‌اند. این روش‌ها، با بهینه‌سازی مستقیم خروجی‌های مدل زبانی بر اساس ترجیحات

¹ Direct Preference Optimization (DPO)

انسانی و بدون نیاز به مدل‌سازی پاداش پیچیده، یک جایگزین کارآمدتر برای روش سنتی یادگیری تقویتی از بازخورد انسانی^۱ به حساب می‌آیند. هوش مصنوعی مبتنی بر اصول و قواعد با کمک انسان^۲ (Y. Bai et al., 2022) کمک می‌کند تا هم‌راستایی پاسخ‌ها با دستورالعمل‌های رفتاری مشخص، همراه با حفظ کیفیت زبان، تضمین شود. پالایش تکرار شونده از طریق بازخورد انسانی^۳ (Madaan et al., 2023) امکان بهبود تدریجی پاسخ‌های مدل را از طریق چندین دور بازخورد فراهم می‌سازد. علاوه بر این، روش‌هایی مانند یادگیری فعال برای جمع‌آوری بازخورد^۴ (Ji et al., 2024) به اولویت‌بندی نمونه‌هایی که به فوریت بیشتری به بازخورد انسانی نیاز دارند، کمک می‌کنند؛ این امر به ویژه در زبان‌های کم‌منبع که بازخورد متخصصان ممکن است محدود باشد، ارزشمند است.

۵. ارزیابی و مقایسه

این چارچوب که ساختار اولیه آن از طریق تحلیل جامع معماری‌های موجود شکل گرفت، برای اعتبارسنجی در اختیار متخصصان قرار گرفت. با استفاده از روش گروه متمرکز (Huyler & McGill, 2019) با مشارکت پنج پژوهشگر پردازش زبان طبیعی ارزیابی انجام شده است. فرآیند ارزیابی شامل مصاحبه‌های ساختاریافته با استفاده از یک پرسشنامه دقیق (ارائه شده در پیوست ۱) و به دنبال آن، بحث‌های عمیق در مورد اجزای چارچوب و اثربخشی آن‌ها در پرداختن به چالش‌های زبان‌های کم‌منبع بود. هر جلسه تخصصی شامل بررسی دقیقی از معماری چارچوب بود و به طور خاص بر این موضوع تمرکز داشت که چگونه هر یک از اجزا به چالش‌های مشخصی در پردازش زبان‌های کم‌منبع رسیدگی می‌کنند. جدول ۷ چالش‌های کلیدی شناسایی شده و نحوه پاسخگویی اجزای چارچوب پیشنهادی به آن‌ها را خلاصه می‌کند. ستون راه حل در این جدول، بر اساس نتایج مستند بیان شده‌اند.

¹ Reinforcement learning from human feedback

² Constitutional AI with human

³ Iterative Refinement through Human Feedback

⁴ Active Learning for Feedback Collection

متخصصان به طور ویژه بر رویکرد نوآورانه چارچوب در مدیریت عناصر فرهنگی از طریق مؤلفه بهبود دانش و فرآیند تولید پاسخ تأکید کردند و اشاره نمودند که این چارچوب چگونه جنبه‌های مختلف فرهنگی مانند سطوح رسمیت، سلسله‌مراتب اجتماعی و الگوهای ارتباطی غیرمستقیم را که در بسیاری از زبان‌های کم‌منبع رایج است، به طور مؤثر مدیریت می‌کند. مؤلفه بازخورد انسانی نقشی حیاتی در این فرآیند انطباق فرهنگی ایفا می‌کند، زیرا یادگیری مستمر و پالایش درک فرهنگی را امکان‌پذیر می‌سازد. از طریق بازخورد نظام‌مند از گویشوران بومی و کارشناسان فرهنگی، سیستم می‌تواند ظرافت‌های فرهنگی را بیاموزد و خود را با آن‌ها تطبیق دهد، مدیریت خود را بر سطوح رسمیت متناسب با بافت بهبود بخشد و الگوهای ارتباطی محلی را بهتر درک کند. این حلقه بازخورد به ویژه برای زبان‌های کم‌منبع که در آن‌ها مستندات فرهنگی از پیش موجود ممکن است محدود باشد، ارزشمند است و به سیستم اجازه می‌دهد تا پایگاه دانش فرهنگی خود را از طریق تعاملات واقعی و راهنمایی متخصصان بسازد و اصلاح کند.

جدول ۷: چالش‌های زبان‌های کم‌منبع در پرسش و پاسخ محاوره‌ای و راه‌حل‌های مبتنی بر چارچوب

چالش	توصیف	راه‌حل چارچوب و مراجع مربوطه	تأثیر
محدودیت داده‌های آموزشی	پیکره‌های متنی و مجموعه داده‌های حاشیه‌نویسی شده ناکافی برای آموزش مدل‌های مؤثر	سازگاری کارآمد پارامتر در هسته مدل زبانی بزرگ (Gurgurov et al., 2025) افزایش داده در تقویت دانش (Soudani et al., 2023; Q. Wu et al., 2021) تکنیک‌های یادگیری کم‌نمونه (Brown, 2020) استفاده از مدل‌های زبانی بزرگ (Jolfaei & Mohebi, 2025, Kholodna et al., 2024)	امکان آموزش مؤثر حجم کمتر داده زبانی به جای نیاز به مجموعه داده‌های عظیم
پیچیدگی صرفی	ساختارهای واژگانی پیچیده و قواعد دستوری که مدل‌سازی آن‌ها دشوار است	پیش‌پردازش اختصاصی زبان در پردازش ورودی (Howcroft & Gkatzia, 2022)	مدیریت صحیح ویژگی‌های زبانی منحصره‌فرد مانند الصاق، صرف پیچیده فعل، و خط‌های غیرلاتین

چالش	توصیف	راه‌حل چارچوب و مراجع مربوطه	تأثیر
نکات ظریف فرهنگی	عبارات فرهنگی خاص، سطوح رسمیت و الگوهای ارتباطی	سازگاری فرهنگی در تولید پاسخ (Tao, Y et al., 2024) زمینه فرهنگی در تقویت دانش (Li. H et al., 2024) بازخورد انسانی برای تناسب فرهنگی (Zhang et al., 2025)	تولید پاسخ‌های مناسب زمینه‌ای با رعایت سلسله‌مراتب اجتماعی، سطوح رسمیت و ارجاعات فرهنگی
محدودیت‌های انتقال میان‌زبانی	دشواری انتقال دانش از زبان‌های پرمعنی	تعبیه‌های میان‌زبانی (Miao et al., 2024) تکنیک‌های یادگیری انتقالی (Nooralahzadeh et al., 2020)	نگاشت مؤثر مفاهیم بین زبان‌ها و امکان انتقال دانش از زمینه‌های پرمعنی به کم‌منبع
کارایی محاسباتی	منابع محاسباتی محدود در زبان‌های کم‌منبع	مدیریت زمینه برای استفاده بهینه از حافظه سازگاری کارآمد پارامتر (LoRA, Hu et al., 2021) (Seq_bn_inv, Seq_bn, Housby et al., 2019, Pfeiffer, Vulić, et al., 2020)	کاهش نیاز به منابع محاسباتی نسبت به تنظیم دقیق کامل مدل
تنوع خط و گویش	خط‌ها یا تنوعات گویشی متعدد در یک زبان	نرمال‌سازی خط در پردازش ورودی، تشخیص خط و گویش، توکن‌سازی تخصصی (Howcroft & Gkatzia, 2022)	استانداردسازی قالب ورودی و مدیریت تنوعات در سیستم‌های نوشتاری
چالش‌های ارزیابی	فقدان معیارهای ارزیابی استاندارد و محک‌های سنجش	مؤلفه بازخورد انسانی (Ji et al., 2024) بهینه‌سازی ترجیح مستقیم (Rafailov et al., 2024) فرایند اصلاح تکراری (Madaan et al., 2023)	ایجاد حلقه بهبود مستمر با روش‌شناسی ارزیابی ساختاریافته
شکاف‌های دانش حوزه خاص	فقدان واژگان تخصصی و دانش حوزه‌ای	دانش حوزه‌ای در تقویت دانش (Neha et al., 2025) یکپارچه‌سازی منابع دانش خارجی و تکنیک‌های تولید تقویت‌شده با بازایی (Arslan et al., 2024)	تقویت مدل زبانی با تخصص حوزه‌ای در حوزه‌های پزشکی، حقوقی و فنی

چالش	توصیف	راه حل چارچوب و مراجع مربوطه	تأثیر
حفظ زمینه	دشواری حفظ زمینه مکالمه در چندین نوبت	مؤلفه مدیریت زمینه ، بازیابی انتخابی زمینه ، بهینه سازی تاریخچه مکالمه (Christmann et al., 2023)	افزایش کیفیت مکالمه چندنوبتی با حفظ زمینه مرتبط
ریسک توهم	ریسک بالاتر تولید اطلاعات نادرست به دلیل کمبود داده	اعتبارسنجی منابع دانش ، تأیید کیفیت در تولید پاسخ (Chen et al., 2024)	کاهش نرخ توهم از طریق اتکای پاسخ ها به منابع معتبر و قابل راستی آزمایی
کمبود منابع لازم برای پردازش زبان طبیعی	فقدان ابزارهای پایه پردازش زبان طبیعی (توکن ساز، تجزیه گر و غیره)	پیش پردازش اختصاصی زبان اشتراک گذاری منابع میان زبانی سازگاری ابزارهای موجود	ایجاد خط لوله پردازش زبان طبیعی کارآمد حتی برای زبان های که منابع پردازشی زبان در حداقل است.

۶. بحث و بررسی

چارچوب پیشنهادی چندین دستاورد کلیدی دارد که از طریق ارزیابی متخصصان اعتبارسنجی شده است چندین دستاورد کلیدی را در مقایسه با رویکردهای موجود برجسته می سازد:

۱. پردازش فرهنگی یکپارچه: برخلاف چارچوب های موجود که انطباق فرهنگی را به عنوان یک مرحله پس پردازش در نظر می گیرند، چارچوب ما درک فرهنگی را در سرتاسر فرآیند خود ادغام می کند، که منجر به پاسخ هایی با هم راستایی عمیق تر می شود.

۲. استفاده بهینه از منابع: این چارچوب از طریق مؤلفه های مدیریت زمینه و تقویت دانش، کارایی منابع را بهبود می بخشد. این معماری، به ویژه با بازیابی گزینشی زمینه و ذخیره سازی دانش ساختاریافته، چارچوب را برای سناریوهای کم منبع که در آنها کارایی محاسباتی حیاتی است، مناسب تر می سازد. این دو مؤلفه مستقیماً به

چالش‌های محاسباتی مطرح‌شده در پیشینه پاسخ می‌دهند. این معماری، به‌ویژه با بازیابی گزینشی زمینه و ذخیره‌سازی دانش ساختاریافته (RAG)، چارچوب را برای سناریوهای کم‌منبع که در آن‌ها کارایی محاسباتی حیاتی است، مناسب‌تر می‌سازد. ۳. معماری پیمان‌ه‌ای: طراحی پیمان‌ه‌ای (ماژولار) امکان ادغام آسان زبان‌ها و بافت‌های فرهنگی جدید را فراهم می‌کند؛ موضوعی که متخصصان آن را برای پیاده‌سازی عملی، حیاتی تشخیص دادند.

۴. سیستم یادگیری تطبیق‌پذیر: ترکیب مؤلفه‌های تقویت دانش و بازخورد انسانی سیستمی را ایجاد می‌کند که به طور مداوم در حال بهبود است و متخصصان آن را برای توسعه بلندمدت قابلیت‌های زبان‌های کم‌منبع بسیار مؤثر ارزیابی کردند. این یافته، اهمیت سیستم‌های یادگیری را برای زبان‌های کم‌منبع که در آن‌ها داده‌ها به صورت تدریجی در دسترس قرار می‌گیرند، تأیید می‌کند.

۵. یادگیری انتقال بین‌زبانی: توانایی بهبودیافته در بهره‌گیری از دانش زبان‌های پرممنبع برای پردازش زبان‌های کم‌منبع از طریق تکنیک‌های پیشرفته یادگیری انتقال.

۶. ادغام جامع بازخورد انسانی: تلفیق نظام‌مند بازخورد انسانی که بهبود مستمر جنبه‌های زبانی و فرهنگی را امکان‌پذیر می‌سازد و پاسخی به نیاز مبرم برای مکانیسم‌های هم‌راستایی پویا در پیشینه پژوهش است.

اگرچه چارچوب ما قابلیت‌های امیدوارکننده‌ای برای پردازش زبان‌های کم‌منبع و انطباق فرهنگی نشان می‌دهد، ارزیابی متخصصان چندین محدودیت و زمینه را برای کارهای آتی نیز آشکار ساخت. این دیدگاه‌ها مسیر ارزشمندی را برای تحقیق و توسعه بیشتر فراهم می‌کنند و چالش‌های فنی و عملی را که باید برای پیاده‌سازی استوارتر مورد توجه قرار گیرند، برجسته می‌سازند. این مسائل شامل موارد زیر هستند:

۱. محدودیت‌های فنی:

- نیاز به آزمون‌های گسترده‌تر با زبان‌های بسیار کم‌منبع.
- نیازمندی‌های محاسباتی برای راه‌اندازی اولیه سیستم ممکن است در

محیط‌های با منابع محدود، چالش‌برانگیز باشد.

- وابستگی به کیفیت منابع بین‌زبانی موجود.

۲. ارزیابی فرهنگی:

- نیاز به توسعه معیارهای استاندارد برای سنجش تناسب فرهنگی.

- چالش در کمی‌سازی دقت فرهنگی.

- نیاز به ارزیابی نظام‌مندتر انطباق فرهنگی.

۳. چالش‌های پیاده‌سازی:

- نیاز به ورودی اولیه قابل توجه از سوی متخصصان برای زبان‌های جدید.

- پیچیدگی یکپارچه‌سازی با سیستم‌های موجود.

- نیاز به تخصص ویژه در مرحله استقرار^۱

۴. محدودیت‌های منابع:

- در دسترس بودن محدود کارشناسان فرهنگی برای برخی زبان‌ها.

- چالش در به‌روز نگه‌داشتن دانش فرهنگی.

- نیازمندی‌های منابع برای پردازش مستمر بازخورد.

۵. معیارهای ارزیابی:

- فقدان روش‌های ارزیابی استاندارد برای جنبه‌های فرهنگی.

- نیاز به معیارهای کمی بهتر برای سنجش عملکرد سیستم.

- چالش در مقایسه نتایج میان زبان‌های مختلف.

۶. مسائل مقیاس‌پذیری:

- وجود گلوگاه‌های^۲ ۲ بالقوه در مدیریت همزمان چندین زبان.

^۱ deployment

^۲ bottlenecks

- نیازمندی‌های منابع ممکن است با افزودن زبان‌های جدید به صورت غیرخطی افزایش یابد.
- نیاز به اشتراک‌گذاری کارآمدتر دانش بین‌زبانی.

۷. نتیجه‌گیری

در این پژوهش، چارچوبی نوین برای سیستم پرسش و پاسخ محاوره‌ای در زبان‌های کم‌منبع ارائه شد که بر پردازش کارآمد، انطباق فرهنگی، و بهبود مستمر از طریق بازخورد انسانی تمرکز دارد. معماری این چارچوب چندین مؤلفه کلیدی را یکپارچه می‌کند: «پردازش ورودی» برای درک اولیه زبان، یک «هسته مرکزی مدل زبانی بزرگ» برای پردازش عمیق معنایی، «تقویت دانش» برای مدیریت کارآمد اطلاعات، «مدیریت زمینه» برای مدیریت بهینه مکالمه، و «تولید پاسخ» برای ارائه خروجی متناسب با فرهنگ. یکی از ویژگی‌های متمایز چارچوب پیشنهادی، رویکرد جامع آن به انطباق فرهنگی است که توسط یک سازوکار نظام‌مند بازخورد انسانی پشتیبانی می‌شود و یادگیری مستمر و پالایش درک فرهنگی را امکان‌پذیر می‌سازد.

ارزیابی تخصصی با مشارکت پنج پژوهشگر پردازش زبان طبیعی، اثربخشی این چارچوب را در پرداختن به چالش‌های حیاتی پردازش زبان‌های کم‌منبع تأیید کرد. این ارزیابی چندین دستاورد مهم را برجسته ساخت، از جمله پردازش فرهنگی یکپارچه در سرتاسر فرآیند، بهره‌وری کارآمد از منابع از طریق مدیریت بهینه بافت، و یک سیستم یادگیری تطبیق‌پذیر که بهبود دانش را با بازخورد انسانی ترکیب می‌کند. معماری ماژولار و مقیاس‌پذیر چارچوب به‌طور ویژه به دلیل پتانسیل پیاده‌سازی عملی آن در زبان‌های کم‌منبع مختلف، مورد توجه قرار گرفت.

با این حال، این ارزیابی محدودیت‌ها و زمینه‌هایی را برای کارهای آتی نیز آشکار ساخت؛ از جمله نیاز به آزمون‌های گسترده‌تر با زبان‌های بسیار کم‌منبع، توسعه معیارهای استاندارد برای سنجش تناسب فرهنگی، و چالش‌ها در پیاده‌سازی و مدیریت منابع. این محدودیت‌ها مسیرهای روشنی را برای تحقیقات آینده مشخص می‌کنند، به‌ویژه در زمینه

توسعه معیارهای ارزیابی استوارتر و بهبود کارایی در اشتراک گذاری دانش بین‌زبانی. علی‌رغم این چالش‌ها، چارچوب پیشنهادی گام مهمی رو به جلو در دسترس‌پذیرتر کردن و متناسب‌سازی فرهنگی هوش مصنوعی محاوره‌ای برای جوامع با زبان‌های کم‌منبع محسوب می‌شود و در عین حال، بنیادی را برای توسعه‌های آتی در این حوزه حیاتی ایجاد می‌کند.

فهرست منابع

- Adelani, D. I., Abbott, J., Neubig, G., D'souza, D., Kreutzer, J., Lignos, C., Palen-Michel, C., Buzaaba, H., Rijhwani, S., Ruder, S., Mayhew, S., Azime, I. A., Muhammad, S. H., Emezue, C. C., Nakatumba-Nabende, J., Ogayo, P., Anuoluwapo, A., Gitau, C., Mbaye, D., ... Osei, S. 2021. MasakhaNER: Named Entity Recognition for African Languages. *Transactions of the Association for Computational Linguistics*, 9, 1116–1131. https://doi.org/10.1162/tacl_a_00416
- Adelani, D. I., Ruiter, D., Jesujoba, O., Adebonojo, D., Ayeni, A., Adeyemi, M., Awokoya, A. E., and España-Bonet, C. 2021. [The Effect of Domain and Diacritics in Yoruba-English Neural Machine Translation](#). In *Proceedings of Machine Translation Summit XVIII: Research Track*, pages 61–75. Virtual. Association for Machine Translation in the Americas.
- Alam, F., Chowdhury, S. A., Boughorbel, S., & Hasanain, M. 2024. LLMs for low resource languages in multilingual, multimodal and dialectal settings. In *Proceedings of the 18th Conference of the European Chapter of the Association for Computational Linguistics: Tutorial Abstracts* (pp. 27-33).
- Andersland, M. 2024. Amharic llama and llava: Multimodal llms for low resource languages. *arXiv preprint arXiv:2403.06354*.
- Arslan, M., Ghanem, H., Munawar, S., & Cruz, C. 2024. A Survey on RAG with LLMs. *Procedia computer science*, 246, 3781-3790.
- Asai, A., Wu, Z., Wang, Y., Sil, A., & Hajishirzi, H. 2023. *Self-RAG: Learning to Retrieve, Generate, and Critique through Self-Reflection* (arXiv:2310.11511). arXiv. <http://arxiv.org/abs/2310.11511>
- Azime, I. A., Tonja, A. L., Belay, T. D., Chanie, Y., Balcha, B. F., Abadi, N. H., Ademtew, H. B., Nerea, M. A., Yadeta, D. D., Geremew, D. D., tesfau, A. A., Slusallek, P., Solorio, T., & Klakow, D. 2025. *ProverbEval: Exploring LLM Evaluation Challenges for Low-resource Language Understanding* (arXiv:2411.05049). arXiv. <https://doi.org/10.48550/arXiv.2411.05049>
- Bai, Y., Kadavath, S., Kundu, S., Askell, A., Kernion, J., Jones, A., Chen, A., Goldie, A., Mirhoseini, A., McKinnon, C., Chen, C., Olsson, C., Olah, C., Hernandez, D., Drain, D., Ganguli, D., Li, D., Tran-Johnson, E., Perez, E., ... Kaplan, J. 2022. *Constitutional AI: Harmlessness from AI Feedback* (arXiv:2212.08073). arXiv. <http://arxiv.org/abs/2212.08073>
- Brown, T. B. 2020. Language models are few-shot learners. *arXiv Preprint arXiv:2005.14165*.
- Burgin, E., Dutta, S., Assem, H., & Patel, R. N. 2022. Cage: A Hybrid Framework for Closed-Domain Conversational Agents. 636–640.
- Cahyawijaya, S., Lovenia, H., & Fung, P. 2024. LLMs Are Few-Shot In-Context Low-Resource Language Learners (arXiv:2403.16512). arXiv. <http://arxiv.org/abs/2403.16512>
- Campos, J. A., Cho, K., Otegi, A., Soroa, A., Agirre, E., & Azkune, G. 2020. Improving Conversational Question Answering Systems after Deployment using Feedback-Weighted Learning. *Proceedings of the 28th International Conference on Computational Linguistics*, 2561–2571. <https://doi.org/10.18653/v1/2020.coling-main.230>
- Chen, X., Wang, L., Wu, W., Tang, Q., & Liu, Y. 2024. Honest AI: Fine-Tuning "Small" Language Models to Say "I Don't Know", and Reducing Hallucination in RAG. arXiv preprint arXiv:2410.09699.

- Chen, H., Liu, X., Yin, D., & Tang, J. 2017. A Survey on Dialogue Systems: Recent Advances and New Frontiers. *SIGKDD Explor. Newsl.*, 19(2), 25–35. <https://doi.org/10.1145/3166054.3166058>
- Christmann, P., Saha Roy, R., Abujabal, A., Singh, J., & Weikum, G. 2019. Look before you hop: Conversational question answering over knowledge graphs using judicious context expansion. 729–738.
- Christmann, P., Saha Roy, R., & Weikum, G. 2023. Explainable Conversational Question Answering over Heterogeneous Sources via Iterative Graph Neural Networks. 643–653.
- Conneau, A., Khandelwal, K., Goyal, N., Chaudhary, V., Wenzek, G., Guzmán, F., Grave, E., Ott, M., Zettlemoyer, L., & Stoyanov, V. 2020. *Unsupervised Cross-lingual*
- Dam, S. K., Hong, C. S., Qiao, Y., & Zhang, C. 2024. A Complete Survey on LLM-based AI Chatbots (*arXiv:2406.16937*). *arXiv*. <http://arxiv.org/abs/2406.16937>
- Deng, Y., Lei, W., Huang, M., & Chua, T.-S. 2023. Rethinking Conversational Agents in the Era of LLMs: Proactivity, Non-collaborativity, and Beyond. *Proceedings of the Annual International ACM SIGIR Conference on Research and Development in Information Retrieval in the Asia Pacific Region*, 298–301. <https://doi.org/10.1145/3624918.3629548>
- Dinan, E., Abercrombie, G., Bergman, A. S., Spruit, S., Hovy, D., Boureau, Y.-L., & Rieser, V. 2021. *Anticipating Safety Issues in E2E Conversational AI: Framework and Tooling (Version 3)*. *arXiv*. <https://doi.org/10.48550/ARXIV.2107.03451>
- Fam, R., & Lepage, Y. 2024. A study of universal morphological analysis using morpheme-based, holistic, and neural approaches under various data size conditions. *Annals of Mathematics and Artificial Intelligence*. <https://doi.org/10.1007/s10472-024-09944-8>
- Foosherian, M., Purwins, H., Rathnayake, P., Alam, T., Teimao, R., & Thoben, K. D. 2023. Enhancing pipeline-based conversational agents with large language models. *arXiv preprint arXiv:2309.03748*.
- Gao, Y., Xiong, Y., Gao, X., Jia, K., Pan, J., Bi, Y., Dai, Y., Sun, J., Wang, M., & Wang, H. 2024. Retrieval-Augmented Generation for Large Language Models: A Survey (*arXiv:2312.10997*). *arXiv*. <http://arxiv.org/abs/2312.10997>
- Gao, J., Galley, M., & Li, L. 2019. Neural Approaches to Conversational AI. *Foundations and Trends® in Information Retrieval*, 13(2–3), 127–298. <https://doi.org/10.1561/15000000074>
- Gemechu, E. A., & Kanagachidambaresan, G. R. 2023. Grammar-aware phrase dataset generated using a novel python package. *Data in Brief*, 48, 109237. <https://doi.org/10.1016/j.dib.2023.109237>
- Gupta, S., Rawat, B. P. S., & Yu, H. 2020. Conversational machine comprehension: A literature review. *arXiv Preprint arXiv:2006.00671*.
- Gurgurov, D., Vykopal, I., Genabith, J. van, & Ostermann, S. 2025. Small Models, Big Impact: Efficient Corpus and Graph-Based Adaptation of Small Multilingual Language Models for Low-Resource Languages (*arXiv:2502.10140*). *arXiv*. <https://doi.org/10.48550/arXiv.2502.10140>
- Harms, J.-G., Kucherbaev, P., Bozzon, A., & Houben, G.-J. 2019. Approaches for Dialog Management in Conversational Agents. *IEEE Internet Computing*, 23(2), 13–22. <https://doi.org/10.1109/MIC.2018.2881519>
- Hassani, H. 2018. BLARK for multi-dialect languages: towards the Kurdish BLARK. *Language Resources and Evaluation*, 52(2), 625–644.
- Howcroft, D. M., & Gkatzia, D. 2022. Most NLG is Low-Resource: Here's what we can do about it. *Proceedings of the 2nd Workshop on Natural Language Generation, Evaluation, and Metrics (GEM)*, 336–350. <https://doi.org/10.18653/v1/2022.gem-1.29>
- Houlsby, N., Giurgiu, A., Jastrzebski, S., Morrone, B., de Laroussilhe, Q., Gesmundo, A., Attariyan, M., & Gelly, S. 2019. Parameter-Efficient Transfer Learning for NLP (Version 2). *arXiv*. <https://doi.org/10.48550/ARXIV.1902.00751>
- Hu, E. J., Shen, Y., Wallis, P., Allen-Zhu, Z., Li, Y., Wang, S., & Chen, W. 2021. LoRA: Low-Rank Adaptation of Large Language Models. *CoRR*, *abs/2106.09685*. <https://arxiv.org/abs/2106.09685>
- Huyler, D., & McGill, C. M. 2019. Research Design: Qualitative, Quantitative, and Mixed Methods Approaches, by John Creswell and J. David Creswell. Thousand Oaks, CA: Sage Publication., *New Horizons in Adult Education and Human Resource Development*, 31(3), 75–77.

<https://doi.org/10.1002/nha3.20258>

- Jia, X., Mao, Z., Zhang, Z., Lv, Q., Wang, X., & Wu, G. 2025. Syntax-controlled paraphrases generation with VAE and multi-task learning. *Computer Speech & Language*, 89, 101705. <https://doi.org/10.1016/j.csl.2024.101705>
- Ji, K., He, J., & Gu, Q. 2024. Reinforcement Learning from Human Feedback with Active Queries (*arXiv:2402.09401*). *arXiv*. <http://arxiv.org/abs/2402.09401>
- Joshi, A., Dabre, R., Kanojia, D., Li, Z., Zhan, H., Haffari, G., & Dippold, D. 2025. Natural language processing for dialects of a language: A survey. *ACM Computing Surveys*, 57(6), 1-37.
- Kargaran, A. H., Imani, A., Yvon, F., & Schütze, H. 2023. GlotLID: Language Identification for Low-Resource Languages. *Findings of the Association for Computational Linguistics: EMNLP 2023*, 6155–6218. <https://doi.org/10.18653/v1/2023.findings-emnlp.410>
- Kai, J., Hou, S., Huang, Y., & Lin, Z. 2024. Leveraging Grammar Induction for Language Understanding and Generation (*arXiv:2410.04878*). *arXiv*. <http://arxiv.org/abs/2410.04878>
- Kholodna, N., Julka, S., Khodadadi, M., Gumus, M. N., & Granitzer, M. 2024. LLMs in the Loop: Leveraging Large Language Model Annotations for Active Learning in Low-Resource Languages. In A. Bifet, T. Krilavičius, I. Miliou, & S. Nowaczyk (Eds.), *Machine Learning and Knowledge Discovery in Databases. Applied Data Science Track* (Vol. 14950, pp. 397–412). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-70381-2_25
- Kongyoung, S., Macdonald, C., & Ounis, I. 2022. monoQA: Multi-Task Learning of Reranking and Answer Extraction for Open-Retrieval Conversational Question Answering. 7207–7218.
- Kumar, A., Shrotriya, H., Sahu, P., Mishra, A., Dabre, R., Puduppully, R., Kunchukuttan, A., Khapra, M. M., & Kumar, P. 2022. IndicNLG Benchmark: Multilingual Datasets for Diverse NLG Tasks in Indic Languages. *Proceedings of the 2022 Conference on Empirical Methods in Natural Language Processing*, 5363–5394. <https://doi.org/10.18653/v1/2022.emnlp-main.360>
- Kumar, V., & Callan, J. 2020. Making information seeking easier: An improved pipeline for conversational search. 3971–3980.
- Kusal, S., Patil, S., Choudrie, J., Kotecha, K., Mishra, S., & Abraham, A. 2022. AI-based conversational agents: A scoping review from technologies to future directions. *IEEE Access*.
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W., & Rocktäschel, T. 2020. Retrieval-augmented generation for knowledge-intensive nlp tasks. *Advances in Neural Information Processing Systems*, 33, 9459–9474.
- Li, J., Song, S., Yan, S., Hu, G., Lai, C., & Zhou, Y. 2024. DANTE: Dialog graph enhanced prompt learning for conversational question answering over KGs. *Knowledge-Based Systems*, 301, 112294. <https://doi.org/10.1016/j.knosys.2024.112294>
- Li, H., Jiang, L., Hwang, J. D., Kim, H., Santy, S., Sorensen, T., ... & Choi, Y. 2024. Culture-gen: Revealing global cultural perception in language models through natural language prompting. *arXiv preprint arXiv:2404.10199*.
- Li, Z., Peng, J., Wang, Y., Shen, T., Zhang, M., Su, L., Wu, S., Wu, Y., Wang, Y., Wang, Y., Hu, W., Li, J., Wang, S., Xiao, J., & Xiong, D. 2024. Planning with Large Language Models for Conversational Agents (*arXiv:2407.03884*). *arXiv*. <http://arxiv.org/abs/2407.03884>
- Li, Z., Shi, Y., Liu, Z., Yang, F., Payani, A., Liu, N., & Du, M. 2024. Language Ranker: A Metric for Quantifying LLM Performance Across High and Low-Resource Languages (*arXiv:2404.11553*). *arXiv*. <https://doi.org/10.48550/arXiv.2404.11553>
- Lin, X. V., Mihaylov, T., Artetxe, M., Wang, T., Chen, S., Simig, D., Ott, M., Goyal, N., Bhosale, S., Du, J., Pasunuru, R., Shleifer, S., Koura, P. S., Chaudhary, V., O'Horo, B., Wang, J., Zettlemoyer, L., Kozareva, Z., Diab, M., ... Li, X. 2022. Few-shot Learning with Multilingual Language Models (*arXiv:2112.10668*). *arXiv*. <http://arxiv.org/abs/2112.10668>
- Liu, L., Hill, B., Du, B., Wang, F., & Tong, H. 2024. Conversational Question Answering with Language Models Generated Reformulations over Knowledge Graph. *Findings of the Association for Computational Linguistics ACL 2024*, 839–850. <https://doi.org/10.18653/v1/2024.findings-acl.48>
- Liu, N., Chen, L., Tian, X., Zou, W., Chen, K., & Cui, M. 2024. From LLM to Conversational Agent: A

- Memory Enhanced Architecture with Fine-Tuning of Large Language Models (arXiv:2401.02777). arXiv. <http://arxiv.org/abs/2401.02777>
- Madaan, A., Tandon, N., Gupta, P., Hallinan, S., Gao, L., Wiegrefe, S., Alon, U., Dziri, N., Prabhunoye, S., Yang, Y., Gupta, S., Majumder, B. P., Hermann, K., Welleck, S., Yazdanbakhsh, A., & Clark, P. 2023. Self-Refine: Iterative Refinement with Self-Feedback (arXiv:2303.17651). arXiv. <http://arxiv.org/abs/2303.17651>
- Mao, Z., & Yu, Y. 2024. Tuning LLMs with Contrastive Alignment Instructions for Machine Translation in Unseen, Low-resource Languages (arXiv:2401.05811). arXiv. <http://arxiv.org/abs/2401.05811>
- Merx, R., Mahmudi, A., Langford, K., Araujo, L. A. de, & Vylomova, E. 2024. Low-Resource Machine Translation through Retrieval-Augmented LLM Prompting: A Study on the Mambai Language (arXiv:2404.04809). arXiv. <https://doi.org/10.48550/arXiv.2404.04809>
- Miao, Z., Wu, Q., Zhao, K., Wu, Z., & Tsuruoka, Y. 2024. Enhancing Cross-lingual Sentence Embedding for Low-resource Languages with Word Alignment. *Findings of the Association for Computational Linguistics: NAACL 2024*, 3225–3236. <https://doi.org/10.18653/v1/2024.findings-naacl.204>
- Neha, F., Bhati, D., & Shukla, D. K. 2025. Retrieval-Augmented Generation (RAG) in Healthcare: A Comprehensive Review. *AI*, 6(9), 226.
- Nasution, A. H., & Onan, A. 2024. ChatGPT Label: Comparing the Quality of Human-Generated and LLM-Generated Annotations in Low-Resource Language NLP Tasks. *IEEE Access*, 12, 71876–71900. <https://doi.org/10.1109/ACCESS.2024.3402809>
- Nguyen, X.-P., Aljunied, S. M., Joty, S., & Bing, L. 2024. *Democratizing LLMs for Low-Resource Languages by Leveraging their English Dominant Abilities with Linguistically-Diverse Prompts* (arXiv:2306.11372). arXiv. <https://doi.org/10.48550/arXiv.2306.11372>
- Nigusie, G., & Tegegne, T. 2022. Amharic Text Complexity Classification Using Supervised Machine Learning. In *International Conference on Advances of Science and Technology* (pp. 1-12). Cham: Springer Nature Switzerland.
- Nooralahzadeh, F., Bekoulis, G., Bjerva, J., & Augenstein, I. (2020). *Zero-Shot Cross-Lingual Transfer with Meta Learning* (arXiv:2003.02739). arXiv. <http://arxiv.org/abs/2003.02739>
- Pfeiffer, J., Kamath, A., Rücklé, A., Cho, K., & Gurevych, I. 2020. AdapterFusion: Non-Destructive Task Composition for Transfer Learning. <https://doi.org/10.48550/ARXIV.2005.00247>
- Pfeiffer, J., Vulić, I., Gurevych, I., & Ruder, S. 2020. MAD-X: An Adapter-Based Framework for Multi-Task Cross-Lingual Transfer. *Proceedings of the 2020 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 7654–7673. <https://doi.org/10.18653/v1/2020.emnlp-main.617>
- Perez-Beltrachini, L., Jain, P., Monti, E., & Lapata, M. 2023. Semantic parsing for conversational question answering over knowledge graphs. *arXiv Preprint arXiv:2301.12217*.
- Qian, J., Zou, B., Dong, M., Li, X., Aw, A., & Hong, Y. 2022. Capturing conversational interaction for question answering via global history reasoning. 2071–2078.
- Qin, Y., Cai, Z., Jin, D., Yan, L., Liang, S., Zhu, K., Lin, Y., Han, X., Ding, N., Wang, H., Xie, R., Qi, F., Liu, Z., Sun, M., & Zhou, J. (2023). WebCPM: Interactive Web Search for Chinese Long-form Question Answering. *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 8968–8988. <https://doi.org/10.18653/v1/2023.acl-long.499>
- Qu, C., Yang, L., Qiu, M., Croft, W. B., Zhang, Y., & Iyyer, M. (2019). *BERT with history answer embedding for conversational question answering*. 1133–1136.
- Rafailov, R., Sharma, A., Mitchell, E., Ermon, S., Manning, C. D., & Finn, C. 2024. *Direct Preference Optimization: Your Language Model is Secretly a Reward Model* (arXiv:2305.18290). arXiv. <http://arxiv.org/abs/2305.18290>
- Ringel, D., Lavee, G., Guy, I., & Radinsky, K. 2019. Cross-Cultural Transfer Learning for Text Classification. *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, 3871–3881. <https://doi.org/10.18653/v1/D19-1400>
- Robinson, N. R., Ogayo, P., Mortensen, D. R., & Neubig, G. (2023). *ChatGPT MT: Competitive for High- (but not Low-) Resource Languages* (arXiv:2309.07423). arXiv.

<https://doi.org/10.48550/arXiv.2309.07423>

- Soares, M. A. C., & Parreiras, F. S. (2020). A literature review on question answering techniques, paradigms and systems. *Journal of King Saud University-Computer and Information Sciences*, 32(6), 635–646.
- Song, Y., Wang, T., Cai, P., Mondal, S. K., & Sahoo, J. P. 2023. A Comprehensive Survey of Few-shot Learning: Evolution, Applications, Challenges, and Opportunities. *ACM Computing Surveys*, 55(13s), 1–40. <https://doi.org/10.1145/3582688>
- Soudani, H., Kanoulas, E., & Hasibi, F. (2023). Data augmentation for conversational ai. 5220–5223.
- Su, L., Guo, J., Fan, Y., Lan, Y., Zhang, R., & Cheng, X. (2019). An Adaptive Framework for Conversational Question Answering. *Proceedings of the AAAI Conference on Artificial Intelligence*, 33(01), 10041–10042. <https://doi.org/10.1609/aaai.v33i01.330110041>
- Sun, K., Li, Z., & Zhao, H. (2021). Multilingual pre-training with universal dependency learning. *Advances in Neural Information Processing Systems*, 34, 8444–8456.
- Tao, Y., Viberg, O., Baker, R. S., & Kizilcec, R. F. 2024. Cultural bias and cultural alignment of large language models. *PNAS nexus*, 3(9), pgae346.
- Tan, X., Ren, Y., He, D., Qin, T., Zhao, Z., & Liu, T.-Y. 2019. Multilingual Neural Machine Translation with Knowledge Distillation (arXiv:1902.10461). arXiv. <http://arxiv.org/abs/1902.10461>
- Tanwar, E., Dutta, S., Borthakur, M., & Chakraborty, T. (2023). Multilingual LLMs are Better Cross-lingual In-context Learners with Alignment. *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, 6292–6307. <https://doi.org/10.18653/v1/2023.acl-long.346>
- Upadhyay, B., & Behzadan, V. (2024). *TaCo: Enhancing Cross-Lingual Transfer for Low-Resource Languages in LLMs through Translation-Assisted Chain-of-Thought Processes* (arXiv:2311.10797). arXiv. <http://arxiv.org/abs/2311.10797>
- Vakulenko, S., Longpre, S., Tu, Z., & Anantha, R. (2021). *Question rewriting for conversational question answering*. 355–363.
- Wei, J., Wang, X., Schuurmans, D., Bosma, M., Ichter, B., Xia, F., Chi, E., Le, Q., & Zhou, D. 2023. Chain-of-Thought Prompting Elicits Reasoning in Large Language Models (arXiv:2201.11903). arXiv. <http://arxiv.org/abs/2201.11903>
- Workshop, B., Scao, T. L., Fan, A., Akiki, C., Pavlick, E., Ilić, S., Hesslow, D., Castagné, R., Luccioni, A. S., Yvon, F., Gallé, M., Tow, J., Rush, A. M., Biderman, S., Webson, A., Ammanamanchi, P. S., Wang, T., Sagot, B., Muennighoff, N., ... Wolf, T. 2023. *BLOOM: A 176B-Parameter Open-Access Multilingual Language Model* (arXiv:2211.05100). arXiv. <http://arxiv.org/abs/2211.05100>
- Wu, Q., Feng, S., Chen, D., Joshi, S., Lastras, L. A., & Yu, Z. (2021). DG2: Data augmentation through document grounded dialogue generation. arXiv Preprint arXiv:2112.08342.
- Wu, Z., Luan, Y., Rashkin, H., Reitter, D., Hajishirzi, H., Ostendorf, M., & Tomar, G. S. (2021). Conqrr: Conversational query rewriting for retrieval with reinforcement learning. *arXiv preprint arXiv:2112.08558*.
- Xue, L., Constant, N., Roberts, A., Kale, M., Al-Rfou, R., Siddhant, A., Barua, A., & Raffel, C. 2021. mT5: A massively multilingual pre-trained text-to-text transformer (arXiv:2010.11934). arXiv. <http://arxiv.org/abs/2010.11934>
- Yang, L., Hu, J., Qiu, M., Qu, C., Gao, J., Croft, W. B., Liu, X., Shen, Y., & Liu, J. (2019). *A hybrid retrieval-generation neural conversation model*. 1341–1350.
- Yao, S., Zhao, J., Yu, D., Du, N., Shafran, I., Narasimhan, K., & Cao, Y. (2023). *ReAct: Synergizing Reasoning and Acting in Language Models* (arXiv:2210.03629). arXiv. <http://arxiv.org/abs/2210.03629>
- Ye, L., Lei, Z., Yin, J., Chen, Q., Zhou, J., & He, L. (2024). Boosting Conversational Question Answering with Fine-Grained Retrieval-Augmentation and Self-Check. *Proceedings of the 47th International ACM SIGIR Conference on Research and Development in Information Retrieval*, 2301–2305. <https://doi.org/10.1145/3626772.3657980>
- Yong, Z.-X., Menghini, C., & Bach, S. H. (2024). *Low-Resource Languages Jailbreak GPT-4*

(arXiv:2310.02446). arXiv. <https://doi.org/10.48550/arXiv.2310.02446>

Zaib, M., Zhang, W. E., Sheng, Q. Z., Mahmood, A., & Zhang, Y. (2022). Conversational question answering: A survey. *Knowledge and Information Systems*, 64(12), 3151–3195.

Zhang, H., Chen, K., Bai, X., Xiang, Y., & Zhang, M. 2025. Evaluating and Improving Cultural Awareness of Reward Models for LLM Alignment. arXiv preprint arXiv:2509.21798.

Zhao, W. X., Zhou, K., Li, J., Tang, T., Wang, X., Hou, Y., Min, Y., Zhang, B., Zhang, J., Dong, Z., Du, Y., Yang, C., Chen, Y., Chen, Z., Jiang, J., Ren, R., Li, Y., Tang, X., Liu, Z., ... Wen, J.-R. (2024). *A Survey of Large Language Models* (arXiv:2303.18223). arXiv. <http://arxiv.org/abs/2303.18223>

پیوست ۱

پرسش‌ها

پردازش ورودی

الف. ماژول تشخیص و ارزیابی زبان، در شناسایی زبان‌های کم‌منبع و تعیین روش‌های پردازش مناسب، تا چه حد مؤثر عمل می‌کند؟

ب. ماژول درک پرس و جوی فرازبانی، توانایی سیستم در فهم پرس و جوها به زبان‌های کم‌منبع را تا چه میزان افزایش می‌دهد؟

ج. برای پردازش زبان‌های کم‌منبع که از نظر صرفی پیچیده هستند، چه تکنیک‌های پردازشی زبان-محور دیگری را پیشنهاد می‌کنید؟

هسته مدل زبانی بزرگ

الف. اثربخشی تکنیک‌های انطباق با پارامتر بهینه مانند LoRA را برای پردازش زبان‌های کم‌منبع چگونه ارزیابی می‌کنید؟

ب. محدودیت‌های هسته مدل زبانی بزرگ در پردازش زبان‌های بسیار کم‌منبع چیست و این محدودیت‌ها چگونه باید برطرف شوند؟

تقویت دانش

الف. مؤلفه تقویت دانش در این چارچوب (شامل دانش فرازبانی، منابع زبانی، زمینه فرهنگی و غیره) چگونه امکان درک مطلب در محیط‌های زبان کم‌منبع را فراهم می‌آورد؟

ب. توصیه‌های شما برای ساخت و نگهداری مؤثر منابع دانش برای زبان‌های بسیار کم‌منبع چیست؟

ج. یکپارچه‌سازی زمینه فرهنگی تا چه حد چالش‌های انطباق فرهنگی در پردازش زبان‌های کم‌منبع را برطرف می‌سازد؟

مدیریت زمینه

الف. رویکرد تاریخیچه فشرده مکالمه تا چه اندازه چالش‌های حفظ درک متنی را در سناریوهای کم‌منبع برطرف می‌کند؟

ب. برای فرآیند تطبیق شباهت به منظور بازیابی زمینه مرتبط در گفتگوی چندنوبتی، چه تغییراتی را پیشنهاد می‌کنید؟

تولید پاسخ

الف. ماژول انطباق فرهنگی تا چه حد مسئله تولید پاسخ‌های متناسب با فرهنگ را در زبان‌های کم‌منبع برطرف می‌کند؟

ب. چه روش‌های راستی‌آزمایی کیفیت دیگری را برای تضمین دقت زبانی و تناسب فرهنگی در پاسخ‌های تولیدشده پیشنهاد می‌کنید؟

بازخورد انسانی

الف. در هنگام جمع‌آوری و بهره‌برداری از بازخورد انسانی برای زبان‌های کم‌منبع، چارچوب باید چه چالش‌ها یا نگرانی‌های خاصی را مدیریت کند؟

ب. نقش بازخورد انسانی در بهبود سیستم و عملکرد کلی برای زبان‌های کم‌منبع چقدر اهمیت دارد؟

ارزیابی کلی چارچوب

الف. چارچوب توصیف‌شده، مسائل مختص زبان‌های کم‌منبع را در بستر پاسخگویی به پرسش‌های محاوره‌ای تا چه حد به‌خوبی پوشش می‌دهد؟

ب. بر اساس تجربه خود، آیا ویژگی‌ها یا بهبودهای دیگری را برای شخصی‌سازی بیشتر چارچوب به منظور دستیابی به عملکرد بهتر برای زبان‌های کم‌منبع پیشنهاد می‌کنید؟

ج. چارچوب پیشنهادی در مقایسه با روش‌های موجود، با توجه به ویژگی‌های خاص فرهنگی و زبانی زبان‌های کم‌منبع، چگونه عمل می‌کند؟

Conversational Question Answering for Low-Resource Languages: A Novel Architecture Enhanced by Large Language Models

Safoura Aghadavoud Jolfaei, PhD Candidate in Iranian Research Institute for
Information Science and Technology (IranDoc), Tehran, Iran.

aghadavood@students.irandoc.ac.ir

Azadeh Mohebi*, PhD in Systems Design Engineering
Assistant Professor in Iranian Research Institute for Information Science and
Technology (IranDoc), Tehran, Iran.

mohebi@irandoc.ac.ir

Abstract

Conversational Question Answering (CQA) systems have evolved significantly with the advent of Large Language Models (LLMs); however, these advancements have predominantly favored high-resource languages, often overlooking low-resource ones. This paper introduces a novel LLM-enhanced framework specifically designed to bridge this linguistic gap. The proposed architecture comprises six components: "Input Processing" for language-specific handling, an "Adaptive LLM Core," "Knowledge Enhancement" for cross-lingual mapping, "Context Management" for efficient conversation navigation, "Response Generation" incorporating cultural adaptation, and "Human Feedback" for continuous improvement. Unlike existing approaches, this framework integrates cultural and linguistic considerations throughout the entire processing pipeline. To validate the framework, a qualitative evaluation was conducted using a focus group consisting of five Natural Language Processing (NLP) experts. Expert evaluation results confirmed the proposed framework's effectiveness in addressing fundamental challenges of low-resource languages, including data scarcity, morphological complexities, and cultural nuances. Experts particularly highlighted the framework's innovative approach to "integrated cultural processing," "resource efficiency" via optimized context management, and its "modular and scalable architecture" as key achievements. This research demonstrates that integrating human feedback and cultural adaptation within an efficient architecture offers a practical solution for developing Conversational Question Answering systems in low-resource languages.

Keywords: Conversational Question Answering, Interactive Question Answering, Machine Comprehension, Natural Language Processing.

*Corresponding Author

صفورا آقاداود جلفایی

دانشجوی دکتری رشته مدیریت فناوری اطلاعات، گرایش کسب‌وکار هوشمند است. مدل‌های زبانی بزرگ، سیستم‌های پرسش و پاسخ محاوره‌ای و پردازش زبان‌های کم‌منبع از جمله علایق پژوهشی وی است.



آزاده محبی

دارای مدرک دکتری در رشته مهندسی طراحی سیستم‌ها از دانشگاه واترلو کانادا است. ایشان هم‌اکنون استادیار پژوهشکده فناوری اطلاعات پژوهشگاه علوم و فناوری اطلاعات ایران (ایرانداک) است. تعامل انسان و کامپیوتر، داده‌کاوی، سیستم‌های هوشمند، بازشناسی الگو، متن‌کاوی و بازیابی اطلاعات از جمله علایق پژوهشی وی است.

