Ekaia, 2025, 48, 31-57
https://doi.org/10.1387/ekaia.27338

ekaia
ZIENTZIA eta TEKNOLOGIA ALDIZKARIA

ISSN 0214-9001 – eISSN 2444-3255

Paziente birtuala simulatzeko *txatbot* medikoa

(Virtual Patient Simulation for a Medical Chatbot)

*Mikel Idoyaga Bazan**[1], *Janire Arana Gonzalez*[1], *Jose Vicente Lafuente Sanchez*[2], *Elisa Espina Valiño*[2], *Koldo Gojenola Galletebeitia*[1], *Aitziber Atutxa Salazar*[1]

[1] HiTZ: Hizkuntza Teknologiako Euskal Zentroa, Ixa taldea Bilboko Ingeniaritza Eskola, Rafael Moreno Pitxitxi pasealekua, 3 | 48013 Bilbao
Euskal Herriko Unibertsitatea UPV/EHU
[2] Medikuntza eta Erizaintza Fakultatea UPV/EHU, Bizkaia

LABURPENA: Lan honetan, mediku eta pazientearen arteko elkarrizketan paziente birtualaren rola hartuko duen gaztelaniazko *txatbot* baten prototipoaren sorrera aurkeztuko da, lortutako emaitzekin batera. *Txatbot*aren erantzunak benetako pazientearenak bezalakoak izateko helburuarekin, zenbait baliabide garatu dira lan honetan. Alde batetik, medikuaren galderetatik eta pazienteen txosten klinikoetatik hartutako erantzunen corpus bat baliatu da, eta pazienteak erantzungo lituzkeen esaldien corpus berria sortu da. Baliabide horiek erabilita, paziente birtualaren papera egin dezakeen *txatbot*aren hizkuntza naturalaren sorkuntzarako sistema bat entrenatu da adimen artifizialeko sare neuronalen bidez. Zenbait metrika erabiliz ebaluatu da sistema, emaitza positiboekin. Medikuntzako elkarrizketa-sistema automatikoak eraikitzeko bidea ireki da horrela.

GAKO-HITZAK: adimen artifiziala, hizkuntza naturalaren sorkuntza, elkarrizketa-sistema, testu klinikoen prozesamendua.

ABSTRACT: *In this work, we will present the creation of the prototype of a Spanish chatbot that will take the role of a virtual patient in the conversation between doctor and patient, together with the results obtained. With this aim, we have taken an already developed corpus of doctor/patient questions and answers taken from clinical records as a starting point, and a new corpus of patient-like sentences has been generated. Using these resources, a chatbot that can play the role of a virtual patient has been trained using artificial intelligence and natural language generation techniques, implemented with neural networks. The system has been evaluated using different metrics, paving the way for the construction of automatic medical dialogue systems.*

KEYWORDS: artificial intelligence, natural language generation, dialogue system, clinical text processing.

**** Harremanetan jartzeko/Corresponding author:*** Mikel Idoyaga Bazan, HiTZ Hizkuntza Teknologiako Euskal Zentroa-Ixa, Euskal Herriko Unibertsitatea (UPV/EHU), Sarriena auzoa, z/g (48091 Leioa-Euskal Herria). https://orcid.org/0009-0007-4955-0758, mikel.idoyaga@ehu.eus

Nola aipatu/How to cite: Idoyaga Bazan, Mikel; Arana Gonzalez, Janire; Lafuente Sanchez, Jose Vicente; Espina Valiño, Elisa; Gojenola Galletebeitia, Koldo; Atutxa Salazar, Aitziber (2025). «Paziente birtuala simulatzeko txatbot medikoa», *Ekaia*, 48, 2025, DOI: https://doi.org/10.1387/ekaia.27338

Jasoa: martxoak 05, 2025; Onartua: uztailak 10, 2025

ISSN 0214-9001-eISSN 2444-3225 / © UPV/EHU Press

1. SARRERA

Urtero, 6. ikasturteko medikuntza- eta erizaintza-ikasleek Ebaluazio Kliniko Objektibo eta Egituratua (EKOE), gaitasun klinikoen eta komunikazio-gaitasunen azterketa, egin behar dute, non ikasle bakoitzaren jakintza teorikoa, arrazoiketa klinikoa, eta komunikatzeko gaitasuna eta trebetasuna probatzen diren. Azterketa honetan, ikasle bakoitza zirkuitu batetik pasatzen da eta, bertan, agertoki kliniko bat birsortu edo simulatzen da. Ebaluazioa ahalik eta objektiboen egiteko prestatuta dago; simulazio-egoera bakoitzerako, ikasleek bete beharreko eginkizun zerrenda bat prestatzen da, eta atazaren osatze-tasaren arabera puntuazio bat jasotzen dute.

Espainiako Medikuntza Fakultateetako Dekanoen Konferentzia Nazionalak (*CNDFME*) [1] 20 simulazio-egoera proposatzen ditu, bakoitzak 10 minutu inguruko iraupena duena. Simulazio-egoera horien artean bi mota nagusi bereiz daitezke: paziente simulatukoak eta pazienterik gabekoak. Lehenengo motako simulazio-egoeretan, aktore edo boluntario batek pazientearen rola hartu eta kasu kliniko bat simulatuko du. Ikaslea aktorearekin komunikatu beharko da kontsulta aurrera eramateko, pazientearekin duen interakzioa ebaluatu dadin. Urtero aktoreak kontratatzea eta prestatzea oso prozesu neketsu eta garestia da [2]. Horren ondorioz, paziente birtualak (PB) eraikitzeko ideia proposatu da, pazienteen txosten klinikoak simulatzeko gai baitira, eta lehenengo prototipoak garatu dira [3] (ikus 1. irudia). Sistema horiei esker, fakultateek dirua eta denbora aurreztuko dute aktoreak kontratatzen, azterketa kopurua eta aniztasuna handitu ahal izango dituzte eta ikasleek edozein momentutan praktikatzeko aukera izango dute.

1. irudia. PBaren eta mediku baten arteko elkarrizketaren irudi kontzeptuala.

Paziente birtualak *txatbot*etan oinarritzen dira. Sistema horiek adimen artifizialean oinarritutako sistema automatizatuak dira, eta berariaz diseinatuta daude erabiltzaileekin hizkuntza naturaleko elkarrizketen bidez

informazioa trukatzeko [4]. *Txatbot* baten barnean elkarrizketa-sistema aurki daiteke, zeinen helburu nagusia gizakien eta ordenagailuen arteko komunikazio eraginkorra ahalbidetzea den, erabiltzailearen ekarpenak testu edo ahots moduan ulertuz eta erabiltzailearen eskaerei behar bezala erantzunez.

Paziente birtualak sortzeko existitzen diren *txatbot*-metodologien artean bi mota nagusi bereiz daitezke: *txatbot* sortzaileak (ChatGPT[1] modukoak) eta modularrak. Azken hauek dira egokienak proiektu hau aurrera eramateko, medikuntzaren domeinuan sistemaren kontrol estuagoa ahalbidetzen baitute.

Txatbot modularrek zenbait atal dituzte eta bakoitza elkarrizketa normal baten zati batzuez arduratzen da; honela, hurbilpen sortzaile batek baino aukera gehiago eskaintzen ditu erantzunak kontrolatzeko eta sortzaileen haluzinazioak ekiditeko. Beraz, proiektu honetarako aurretiko prototipo batean oinarritu gara [3], non **Hizkuntza Naturalaren Ulermen** (HNU) modulua inplementatu zen (ikus 2. irudia), honako elementuez osatua:

— ***Adierazpen-Ulermena (AU)***: erabiltzailearen sarrera prozesatzen du. Azpi-modulu honek hainbat ataza burutzen ditu, baina proiekturako garrantzitsuena **intentzio-sailkatzailea** (IS) da, non erabiltzaileak egindako adierazpenaren intentzioa igartzen saiatzen den. Horrez gain, beste ataza batzuk ere egin ditzake; hala nola hitz gakoak harrapatzea eta elkarrizketan zerbait jada aipatu ote den antzematea.
— ***Erantzun-Erauzketa (EE)***: datu-base edo kanpo-dokumentuetan (kasu honetan, paziente birtual bat denez, pazienteak deskribatzen dituzten txosten klinikoetan) erabiltzailearen sarrerari erantzun egokia topatzeaz arduratzen da.

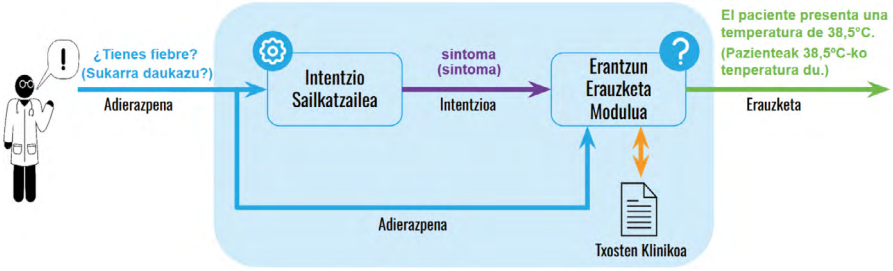

2. irudia. HNU moduluaren egitura [3].

[1] https://chatgpt.com/

2. irudian ikusten denez, sistema horretan, galdera baten erantzuna pazientea deskribatzen duen txosten klinikotik erauzten da eta, ondorioz, sistemak bueltatzen duen erantzuna ez da naturala, txostenetik hartutako testu-zatia baita. Hau da, medikuaren galderei erantzutean, txosten klinikoan agertzen diren hitz berberak erabiliko ditu. Beraz, *txatbot*ak ez du benetako paziente batek erantzungo lukeen moduan erantzungo, lehen pertsona erabiliz edo hitz teknikoak saihestuz. Paziente birtuala ahalik eta sinesgarrien izatea nahi denez, hori konpontzeko modulu berri bat gehitu nahi dugu, **Hizkuntza Naturalaren Sorkuntza** (HNS, ikus 3. irudia) modulua, hain zuzen ere. Adibidez, medikuak «Sukarra daukazu?» galdetzen badu, eta kasu klinikoan «Pazienteak 38,5 ºC-ko tenperatura du» agertzen bada, HNSak lehenengo pertsonara bihurtuko du, esanez «Bai, badaukat». Lan honetan, txosten kliniko batetik atera daitezkeen esaldiak paziente batek esango lituzkeen esaldietara bihurtzen dituen modulua garatuko da.

Artikulu honetan, HNS modulu egokiena aurkitzeko garatu diren eredu eta teknikak azalduko dira eta haiek sortzeko beharrezkoak izan diren baliabideak deskribatuko dira. Hala ere, HNS moduluan zentratu arren, IS eta EE moduluak ere erabiliko dira HNS ereduen hobekuntzarako. Izan ere, *txatbot*aren parte dira eta modulu guztiek ondo funtzionatu behar dute elkarlanean. Helburu hori lortzeko, honako baliabide hauek garatu dira:

— **Esaldien egokitzapenerako corpusa**. Corpus horretan txatbot erauzle baten [3] erantzunak pazientearen elkarrizketako erantzunekin parekatu dira, betiere txosten kliniko berean oinarrituta, (*txostenеko esaldia, pazientearen esaldia*) bikoteen corpusa sortzeko. Horrez gain, hainbat corpus-aldaera sortu dira, hizkuntzaren egokitasuna, koherentzia eta fidagarritasuna hobetzeko. Helburua ikasketa automatikorako formatu hoberena identifikatzea da, HNS moduluaren garapenerako baliagarri izango den datu-multzo bat osatuz.

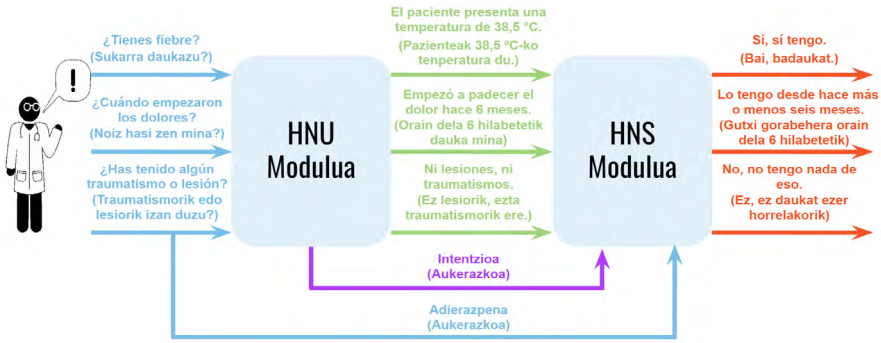

3. irudia. HNS moduluaren funtzionamendua. Lehendik egindako HNU moduluak txosteneko hitzen bidezko erantzunak lortuko ditu (irudiaren erdian), eta HNS moduluak pazientearen hitz egiteko erara aldatuko ditu (irudiaren eskuinean).

— **Hizkuntza Naturalaren Sorkuntza modulua inplementatu eta ebaluatu da** adimen artifizialeko teknikak erabiliz. Horretarako, hainbat arkitektura aztertu dira, baita doiketa-teknikak eta datugehikuntza estrategiak ere. Moduluaren helburua testu klinikoen sorkuntza sinesgarriagoa lortzea da, pazienteen elkarrizketak simulatzeko eta osasun-profesionalen galderei erantzuteko ahalmena hobetzeko.

2. BALIABIDEAK ETA METODOAK

Lortu nahi den HNS modulua garatzeko, adimen artifizialeko eredu bat sortu behar da, gai dena txosten klinikoetatik hartutako edozein esaldi edo *EE* modulutik lortutako erantzunak paziente batek esango lituzkeen esaldietara itzultzeko. Horretarako, corpus bat eraiki da, non bi esaldiak parekatuta dauden (ikus 2.1. azpiatala). Corpus hori oinarri hartuta, hizkuntza naturalaren sorkuntzarako modulu bat garatu da, txosten klinikotik hartutako esaldiak paziente batek esango lituzkeen hizkerara itzultzeko (ikus 2.2. azpiatala).

2.1. VIR-PAT-HNS corpusa

HNS ereduak sortu ahal izateko, ikasketa gainbegiratuko sistemak erabili dira; hau da, ereduek etiketatutako datuetatik ikasiko dute; hortaz, datu-multzo etiketatuak behar dira hori lortzeko. Datuen babesari buruzko legea dela eta, oso zaila da osasun esparruko datuak lortzea eta, horregatik, eskuragarri dauden corpusetatik, VIR-PAT-QA [3] corpusa aukeratu da. Corpus horrek mediku-paziente elkarrizketetatik lortutako txosten klinikoak biltzen ditu, baita medikuek egindako galderak eta haien erantzunak dauzkaten txosteneko zatiak ere.

Gure corpusak hiru aldaera ditu. 4. irudian ikus daiteke corpusaren aldaera bakoitza lortzeko prozesua era laburtuan.

Lehenengoaren abiapuntu gisa, parekatu egin dira VIR-PAT-QA corpuseko erantzunak corpusa sortzeko erabilitako elkarrizketetan pazienteek emandako erantzunekin. Adibidez, 3. irudian ikusten den bezala, txosteneko esaldia «Pazienteak 38,5 ºC-ko tenperatura du» bada, horri dagokion pazientearen esaldia hurrengo hau izan daiteke: «Bai, badaukat.» Jatorrizko erantzunak medikuntzako ikasle eta boluntarioekin grabatutako kontsulta simulatuen audioen transkripzioak eginez sortu ziren EKOE-ko azterketetan [5]. Ingelesez egin zirenez, itzulpen automatikoaren eta itzulpenaren akatsen zuzenketaren bidez lortu ziren guk erabilitako erantzunak [3].

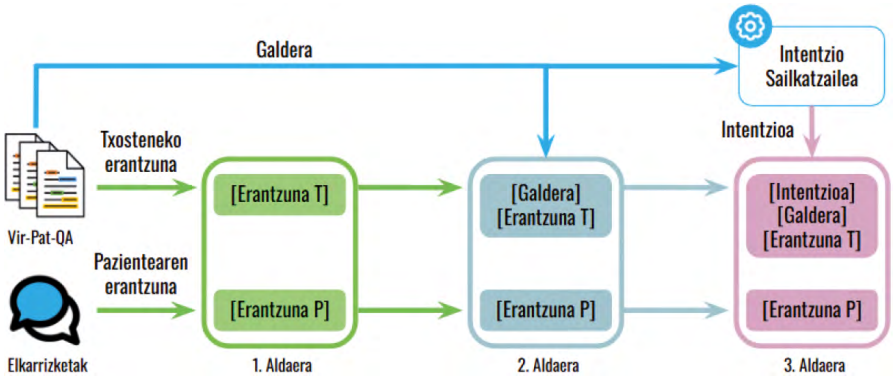

4. irudia. VIR-PAT-HNS corpusaren aldaerak sortzeko prozesua (T = Txostenetik erauzitako erantzuna, P = Pazienteak elkarrizketan emandako erantzuna).

VIR-PAT-QA corpusean hiru galdera mota bereizten dira: a) «erantzuna duten galderak», b) «txosten klinikoan erantzunik ez duten galderak» eta c) «erantzunik behar ez duten galderak», azken bi mota horiek bereziak izanik. *b* motako galderetan txosten klinikoan ez dago erantzunik elkarrizketako esaldiarekin parekatzeko eta, horregatik, mota hori baztertu egin da. *c* motako galderetan, aldiz, erantzunak ez dira txosten klinikotik atera behar (erantzun generikoak espero dira) baina, hala ere, haiek atxikitzea erabaki da, azken batean, galdera hauek medikuaren agurrak, baieztapenak, ezeztapenak. . . biltzen dituztelako eta, hortaz, ez dira galdera/interakzio garrantzitsu bezala hartu behar. Haiek, nahiz eta erantzuna ez den txosten klinikoan bilatu behar, erantzun bat eskatzen dute pazientearen aldetik (ikus 1. taula). Hori dena kontuan izanda, 3.934 pare [*Erantzuna, Pazientearen Erantzuna*] geratzen zaizkigu gure ereduak eraikitzeko.

1. taula. Mota bakoitzeko galdera kopurua entrenamendu, garapen eta test multzoetan, erantzunik gabeko galdera motak kenduta.

Galdera mota	Entrenamendua	Garapena	Test
a) *Erantzuna dutenak*	2.753	295	580
~~b) *Erantzunik ez dutenak*~~	~~*1.820*~~	~~*201*~~	~~*335*~~
c) *Erantzunik behar ez dutenak*	228	27	51
Guztira (*b* mota kenduta)	**2.981**	**322**	**631**

Horren ostean, corpusaren hurrengo aldaera eraiki da. Izan ere, VIR-PAT-QA corpusaren txosteneko erantzunek, zuzenak izan arren, askotan ez

dute testuinguru nahikorik ematen ereduak zeri buruz ari diren ulertu ahal izateko. Adibidez, medikuaren galdera «Noiz izan zenituen lehen sintomak?» bada eta txostenean hartu den zatia bakarrik «orain dela 3 hilabete» bada, HNS ereduak ez du jakingo sintomei buruz ari dela. Horregatik, ereduei testuinguru gehiago emateko aldaera bat egin da, non txosteneko erantzunak eta pazienteak emango lituzkeenak egoteaz gain, egindako galdera ere egongo den. Esaterako, [«Badaukazu sukarrik?», «Pazienteak 38,5 ºC-ko tenperatura du», «Bai, badaukat»], hau da, [*Galdera, Erantzuna, Pazientearen erantzuna*] motako hirukoteak agertuko dira.

2. taula. Intentzio-kategoria nagusien deskribapena.

Kategoria nagusia	Deskribapena	Adibidea	Entrenamendua	Garapena	Test
baieztatu	Erantzun ez beharreko adierazpenak	Bai	109	12	31
agur_esan	Elkarrizketa amaitzeko adierazpenak	Agur	4	0	1
egoera	Pazientearen egoeraren galdera orokorrak	Zelan zaude?	3	0	0
kontsulta arrazoia	Pazientearen etorreraren arrazoia	Zerk ekartzen zaitu hona?	95	10	21
besteak	Beste kategorietara moldatzen ez diren adierazpenak	Emadazu zure osasun-txartela	3	0	0
pertsonala	Pazientearen bizitzaren inguruko galderak	Zein da zure izena?	400	47	100
psikiatria	Pazientearen sentimenduei buruzko adierazpenak	Pozik bizi zara?	48	4	10
kaixo_esan	Elkarrizketa hasteko moduko adierazpenak.	Aupa	15	4	3
sintoma	Pazientearen sintomei buruzko galderak	Alergiarik?	2.006	214	400
tratamendua	Pazienteak izandako tratamenduei buruzko galderak	Beste medikamenturik?	228	31	58
bizitza sexuala	Pazientearen bizitza sexualari buruzko galderak	Bizitza sexual aktiboa duzu?	10	0	7
Guztira			**2.981**	**322**	**631**

Gainera, ikusita aurrekarietan medikuaren intentzioak lagungarriak izan zirela ereduen emaitzak hobetzeko [3], hirugarren aldaera bat sortu da, non txosteneko zatiei intentzioa ere lotzen zaien, aurreko corpusaren patroi bera jarraituz. Hurrengo laukote hau izan genezake: [«Sintoma», «Badaukazu sukarrik?», «Pazienteak 38,5 ºC-ko tenperatura du.», «Bai, badaukat»], hau da, [*Intentzioa, Galdera, Erantzuna, Pazientearen erantzuna*] laukoteak (ikus 4 irudiko. 3. aldaera). Aldaera hau garatzeko, galdera bakoitzaren intentzioa lortzeko intentzio-sailkatzaile automatikoa erabili da [3]. Eredu horrek modu hierarkikoan antolatutako 145 intentzio desberdin (guztiak 11 kategoria nagusitatik hedatuta) bereiz ditzake. Kategoria nagusi horiek medikuen galderetan aurki daitezkeen intentzioen mota nagusiak azaltzeko balio dute, 2. taulan ikus daitekeen bezala. Intentzioen sailkapen osoaren deskribapena ulertzeko, ikus [3].

2.2. **Esperimentuen diseinua**

Hurrengo azpiataletan eredu onena aukeratzeko egindako esperimentuak azaltzen dira. Lehenengo, 2.2.1. azpiatalean, eskuragarri dauden eredu guztietatik egokiena aurkitzeko egin diren esperimentuak biltzen dira. Esperimentu horietan paradigma desberdinak probatu dira eredu bakoitzaren tamaina, arkitektura, aurre-entrenatutako datuak eta amaierako emaitza onenak aurkitzeko. 2.2.2. azpiatala, berriz, proiektuan sortutako corpusetan zentratzen da; hau da, 2.1. atalean azaldutako corpusaren aldaera guztiak erabiltzen dira ereduaren azken doiketa egiteko.

2.2.1. *Ereduen, aurre-entrenamenduaren eta paradigma desberdinen esperimentuak*

Hasteko, VIR-PAT-HNS corpusaren gainean esperimentuak egiteko, VIR-PAT-QA corpuseko distribuzio bera erabili da, hau da, datuen % 75 erabili da ereduaren entrenamendurako (*train*), % 10 garapenerako (*dev*) eta % 15 testerako (test), baina *b* motako galderak kenduta (ikus 1. taula). Gure datu kantitatea txikia ez izan arren, gaur egun erabiltzen diren eredu erraldoien modukoak zerotik entrenatzeko ez daukagu nahiko daturik. Beraz, hori konpontzeko, aurre-entrenatutako ereduak erabiltzea erabaki da; zehatzago esanda, transformadoreetan[2] [6] oinarritutako sistemak. Izan ere, aurre-entrenatutako ereduek aurretiko ezagutza zabala dute, testu eta dokumentu ugari erabiliz prestatu baitira. Hori dela eta, hizkuntzaren egitura eta testuinguruak ulertzeko gai dira, eta askotariko atazetan aplikatzeko prest daude datu kantitate handiak behar izan gabe. Eskuragarri dauden eredu guztien artean, T5 eta FLOR eredu-familiak aukeratu ditugu.

[2] Transformadoreak ikasketa sakoneko algoritmo aurreratuenak eta emaitza onenak ematen dituztenak dira.

2.2.1.1. mT5 kodetzaile-deskodetzailea

Aukeratutako lehenengo eredu-familia T5 [7] izan da, kodetzaile-deskodetzaile arkitektura duena. Zehazki, familia honen barietate eleaniztuna aukeratu da, mT5 familia [8], gaztelaniazko testuekin entrenatu delako. Hori dela eta, gaztelaniazko testuingurua eta sintaxia ulertzeko gai da eta, hortaz, gure helbururako aproposa. Gainera, mT5 familiakoen artean, gaztelaniazko testu medikuekin entrenatuta dagoen eredu bat existitzen da, *Medical mT5*, atazarako are aproposagoa [9]. Eredu horien bitartez hainbat esperimentu egin dira:

- Jatorrizko mT5-en eta *Medical mT5*-en artean konparaketak egin dira, domeinu medikoan entrenatutako eredu batek gure atazan domeinu orokorrekoak baino emaitza hobeak lor ote ditzakeen ikusteko.
- mT5 eta *Medical mT5* ereduen tamaina desberdinak ebaluatu dira, tamainak emaitzetan duen eragina ikusteko. Kasu honetan, bi tamaina erabili dira eredu bakoitzean, *large* (L) eta *extra large* (XL). mT5-L ereduak 1,2 mila milioi parametro ditu eta mT5-XL ereduak 3,7 mila milioi. *Medical mT5* ereduak, berriz, 738 milioi eta 3 mila milioi parametro ditu L eta XL tamainetan, hurrenez hurren.
- *Low-Rank Adaptation of Large Language Models* (LoRa) [10] izeneko optimizazio-teknika aplikatu da. Izan ere, eredu oso handiekin lanean ari garenez, konputazio-indar handia behar da, eta batzuetan karga hain da handia, non ingurune batzuetan ezin den egikaritu ere. LoRa erabiliz, doiketa-prozesua arintzen da eta baliabide-kontsumoa modu nabarmenean murrizten da, eta txikiagotu egiten da, horrela, ereduak entrenatzeko eta exekutatzeko behar den tamaina eta kostua. Hortaz, horretaz baliatuz, optimizazioak ereduen emaitzetan duen eragina ebaluatu da.

2.2.1.2. FLOR deskodetzailea

Esperimentuak osatzeko, deskodetzaile soila (*decoder-only*) eredua jarraitzen duten ereduak ere ebaluatzea erabaki da. Azken finean, mota honetako ereduek abantaila handi bat dute besteen aldean: ez dira berriro entrenatu behar, hau da, kodetzaile-deskodetzaile ereduak egin nahi den atazarako sortutako corpusaren gainean doitu behar dira (*fine-tuning*), baina deskodetzaile soileko ereduak gai dira doiketarik gabe ataza gauzatzeko.

Horretarako, mota horretako FLOR[3] (6,3 mila milioi parametroko tamaina) eredua aukeratu da, hori ere gaztelaniazko testuekin aurre-entrena-

[3] https://huggingface.co/projecte-aina/FLOR-6.3B

tuta dagoelako, baina ez da aurkitu arkitektura bera duen eredurik medikuntzan aurre-entrenatuta. Mota honetako ereduekin beste lau esperimentu garatu dira, lehenengo biak ereduaren aurre-entrenamenduarekin loturikoak, eta beste biak, berriz, ereduaren irteera lortzeko erabiltzen diren paradigma desberdinekin lotuta:

— Eredu hauek entrenatzeko bi modu daude: Instrukzioekin Egokituta (*Instructed*) edo ez. Instrukzioekin egokitutako ereduak gai dira agindu batetik abiatuta ataza betetzeko. Entrenamendu hori jaso ez dutenek, aldiz, ez dute aginduak modu naturalean ulertzeko gaitasunik; hortaz, testua jarraitzeko edo osatzeko joera izango dute, interpretazio espliziturik gabe. Esperimentu hauen helburua da ikustea, bi entrenamendu mota hauetatik, gure atazan zeinek funtzionatzen duen hobeto.
— Deskodetzaile soil motako eredu baten errendimendua ebaluatzeko, ikasketa-adibiderik gabeko (*Zero-shot*) [12] eta ikasketa-adibide bakarreko (*One-shot*) [11] paradigmak erabil daitezke. Ikasketa-adibiderik gabeko paradigman, ereduak ataza bat egin behar du aurretik inolako adibiderik jaso gabe. Adibide bakarreko ikasketan, aldiz, ereduari adibide bakarra ematen zaio atazara egokitzen laguntzeko.

2.2.2. *Datuen aldaerak*

Azpiatal honetan, esperimentuak egin dira datu mota desberdinekin, sarreraren arabera emaitzetan ageri diren aldaketak ikusteko. Honako probak egin dira:

— **Corpus aldaerak.** Ereduen doiketa-prozesua 2.2.1. atalean azaldutako hiru corpus aldaerekin egin da (ikus 3 taula):

- Lehenengo aldaera: doiketa-prozesuan ereduek txosteneko esaldia besterik ez dute sarrera gisa (Erantzuna).
- Bigarren aldaera: doiketa-prozesuan ereduek txosteneko esaldi bat izateaz gain, txosteneko zati hori lortzeko erabili den galdera ere badute sarrera gisa (Galdera, Erantzuna).
- Hirugarren aldaera: bigarren aldaerak dituen eremuez gain, medikuaren galderaren intentzioa ere gehitu zaio sarrerari (Intentzioa, Galdera, Erantzuna). Horrez gain, aldaera honekin beste formatu bat probatu da, non token[4] bereizle bat (</s>) jarri den eremuen artean (Intentzioa </s> Galdera </s> Erantzuna).

[4] *Token* bat testuko unitate linguistiko bat da, normalean hitz bat edo puntuazio marka bat, testua banatu eta prozesatzeko erabiltzen dena.

3. taula. VIR-PAT-HNS corpuseko aldaeren adibideak.

Aldaera	Formatua	Pazientearen erantzuna
1	[*Erantzuna*] [«Pazienteak 38,5 ºC-ko tenperatura du.»]	«Bai, badaukat»
2	[*Galdera, Erantzuna*] [«Badaukazu sukarrik?», «Pazienteak 38,5 ºC-ko tenperatura du.»]	
3	[*Intentzioa, Galdera, Erantzuna*] [«Sintoma», «Badaukazu sukarrik?», «Pazienteak 38,5 ºC-ko tenperatura du.»]	
	[*Intentzioa </s> Galdera </s> Erantzuna*] [«Sintoma» </s> «Badaukazu sukarrik?» </s> «Pazienteak 38,5 ºC-ko tenperatura du.»]	

— **Datu-gehikuntza.** Adimen artifizialak duen sorkuntza-ahalmena dela eta, datu-gehikuntza (*Data Augmentation*) teknika probatu da, datu gehiagorekin ereduek emaitza hobeak lortzen ote dituzten ikusteko. Alabaina, teknika honek konputazio-denbora modu nabarmenean luzatzea dakar eta lehenengo eredu onenak aukeratzeko, jada azaldu ditugun corpusekin (ikus 2.2.2) egin dira esperimentuak. Horrela, gehikuntza aplikatuz lortutako datu-sorta berria onenekin bakarrik probatu da. Hori sortzeko, ChatGPT APIaz[5] baliatu gara datu gehiago lortzeko. Adimen artifizial sortzaileari zera eskatu diogu: txosteneko esaldi bakoitzetik abiatuta 5 esaldi berri sortzeko, eta haren pareko elkarrizketako zatitik, 3 esaldi. Instantzia bakoitzeko, txosteneko 6 esaldi (1 jatorrizkoa + 5 berri) eta elkarrizketako 4 esaldi (1 jatorrizkoa + 3 berri) ditugunez, konbinazio guztiekin 24 instantzia berri izango genituzke, horietatik 23 berriak izanik. Beraz, entrenamenduan 2.981 instantziatik, 71.544 instantzia izatera igaro gara.
Alabaina, token kopuru osoa handitu den arren, hiztegiaren aniztasunaren neurri gisa erabiltzen den *Type-Token Ratio* (TTR-a) gutxitu egin da. Jatorrizko corpusak 31.559 token zituen eta TTR 0,1225 zen, hau da, testuan erabili diren hitzen % 12,25 inguru bakarrak ziren. Aldiz, datu-gehikuntza aplikatu ondoren, corpusa 709.662 tokenera zabaldu da, baina TTR 0,0121era (% 1,21) jaitsi da. Horrek adierazten duenez, nahiz eta testu gehiago sortu den, hitz berrien erabilera murriztu egin da proportzionalki eta, beraz, hiztegiaren aberastasuna txikiagoa da erlatiboki. Hori gertatzen da kasu batzuetan

[5] Aplikazioen Programaziorako Interfazea (*Application Programming Interface*).

esaldiak oso laburrak direlako eta aukera gutxi daudelako esanahi berdineko esaldia sortzeko. Adibidez, esaldia «38 años» (38 urte) bada, ez daude era asko gauza bera esateko hitzak errepikatu gabe.
Edozein kasutan, bermatu egin behar da esaldien kalitatea. Horregatik, datuen fidagarritasuna egiaztatzeko, sortutako adibideak aztertu dituzte bi gaztelania-hiztunek. Ebaluatzaile bakoitzak esaldi-pareak aztertu ditu eta, etiketatze prozesuan, ebaluatzaileei esaldi bakoitzeko hiru etiketatik bat esleitzea eskatu zaie: «OK» etiketak adierazten du esaldia zehatza dela; «KO» etiketak adierazten du esaldiak koherentziarik ez duela; eta «-» etiketak, sorkuntzak koherentzia baduela, baina testuinguru klinikoan edo elkarrizketa batean ez duela zentzurik. Adibidez, txosten klinikoko testu zatian, «38 urte» esaldiaren ordez, ereduak «38 udaberri» sortzen badu, esaldia gramatikala da, baina txosten klinikoaren testuinguruan ez du zentzurik.
Ebaluatzaileen arteko adostasuna kalkulatzeko, ITAko (*Inter Tagger Agreement*) *Cohen's kappa* [13] erabili da, non 0 balioak adostasun eza adierazten duen eta 1 balioak adostasun osoa. Lortutako puntuazioa 0,441 izan da; beraz, neurrizko adostasuna lortu dela esan dezakegu. Emaitza hori azaltzeko, kontuan izan behar da ebaluatzaile bakoitzaren pertzepzio subjektiboak duen eragina, batzuetan testu baten naturaltasuna ebaluatzea hasieran espero baino zailagoa izan baita. Hala ere, bi anotatzaileek instantzien bi heren baino gehiago sailkatu dituzte guztiz egokitzat, eta horrek adierazten du datuak, oro har, kalitate onekoak direla.

— Azkenik, aurreikusita 2.2.1. atalean azaldutako «erantzun behar ez diren» galdera motek HNS modulua nahastu dezaketela, erabaki da eredu onenetan testak instantzia horiek kenduta ere egitea, haien eragina neurtzeko.

3. **EBALUAZIOA**

Aurretik aipatu bezala, corpusa eta haren aldaerak hiru multzotan banatu dira: entrenamendua, garapena eta testa. Entrenamenduko multzoa ereduak entrenatzeko erabiliko da; garapen multzoa esperimentuen aldaketak gidatzeko; eta test multzoa, aldiz, behin sistemak garapen multzoan emaitza onak lortzen dituenean erabiltzen da, inoiz ikusi ez diren datuen igarpenak egiteko. Ereduen errendimendua konparatzeko, gure helburua itzulpen automatikoarekin lotuta dagoenez, esparru horretarako erabiltzen diren metrikak erabili dira.

Hasteko, garapeneko esperimentuetarako, *BLEU* eta ROUGE-L metrikak erabiliko dira, eta azken hau izango da amaierako erabakia hartzen lagunduko duen irizpide nagusia. Horrez gain, bi modelo onenekin esperimentu osagarriak egingo dira test multzoan, eta kasu horietan *BERT*Score metrika ere erabiliko da, azken epaile modura. Amaitzeko, giza ebaluazio bat egingo da, ikusteko gure azken bi modelo onenetatik benetan zein den mundu errealean eraginkorrena, metrika automatikoak alde batera utzita.

3.1. ***BLEU***

BLEU (*Bilingual Evaluation Understudy*) metrika testu-sorkuntza automatikoko sistemak ebaluatzeko erabiltzen da, itzulpen automatikoan batez ere [14]. Metrika honek sistemak sortutako testua eta erreferentziazko testua alderatzen ditu, *n*-gramen[6] antzekotasunean oinarrituta. *BLEU*ren balioak 0 eta 1 artean daude, non 1 balioak bat-etortze osoa adierazten duen eta 0 balioak, berriz, desberdintasun osoa. BLEU kalkulatzeko, (1) ekuazioa erabiltzen da.

$$BLEU = BP \cdot exp\left(\sum_{n=1}^{N} w_n \ log \ p_n\right) \tag{1}$$

BP (*Brevity Penalty*) laburtasun-zigorra da, eta sistemak emandako testua erreferentziazko testua baino laburragoa denean, jaitsi egiten du emaitza. Gainera, formulak n-grama bakoitzaren puntuazioaren batez besteko ponderatua erabiltzen du azken puntuazioa kalkulatzeko.

Bestalde, w_n pisua da, eta *n*-grama bakoitzaren garrantzia (ponderazioa) adierazten du azken puntuazioan. Hala ere, *BLEU*ren ohiko inplementazioetan n-grama bakoitzari pisu berdina ematea da metodo erabiliena; hau da, pisu estandarra $w_n = 1/N$ da.

Azkenik, p_n balioa sistemaren eta erreferentziazko testuaren artean partekatutako *n*-gramen proportzioa da, eta erreferentziazko testuaren *n*-grama guztien kopuruarekiko erlazioan kalkulatzen da; hau da, erreferentziazko testuaren zein proportzio partekatzen den sistemaren testuarekin.

Metrika honen abantaila nagusia da ebaluazio ataza asko errazten duela, guztiz automatikoa delako. Hala ere, *BLEU* metrika soilik erabiltzea ez da komenigarria; izan ere, n-grametan gehiegi zentratzen denez, gerta daiteke esanahi berdina duten baina modu ezberdinean idatzita dauden bi esaldik *BLEU* baxua izatea, sinonimoen edo hitzen ordenaren ondorioz. Esaterako, 4. taulan ikus dezakegu bi esaldik esanahi bera dutela, nahiz eta *BLEU*k 0 balioa eman.

4. taula. Adibidea hiru metrika desberdinetan ebaluatua.

Sortutako testua	Erreferentzia	*BLEU*	ROUGE-L	*BERT*Score
Atal hauetan, pazientearen datuen emaitzak aztertuko dira.	Ondorengo ataletan, emaitzen balorazioa egingo da pazientearen datuetan.	0,0	0,13	0,82

[6] *N*-grama terminoak *N* luzerako hitz segida bati egiten dio erreferentzia. Gehien erabiltzen diren *n*-gramak unigramak, bigramak, trigramak eta 4-gramak dira.

3.2. **ROUGE-L: azpisekuentzia komunetan luzeena**

ROUGE metrikak, *BLEU*k bezala, bi esaldiren arteko antzekotasuna neurtzen du [15]. Metrika hau interesgarria da gure lanerako, oso garrantzitsua delako transformazio-prozesuan iturburuaren informazioa ez galtzea. ROUGE-L metrikak Azpisekuentzia Komunetan Luzeena (AKL) identifikatzen du, hau da, erreferentziazko esaldiaren eta sistemak lortutako testuaren artean agertzen den sekuentzia luzeena, hitz ordena mantenduz. AKL kontzeptua funtsezkoa da, bai testuen antzekotasuna neurtzeko bai testuen egitura eta koherentzia aintzat hartzeko. ROUGE-L metrikak doitasuna, estaldura, eta F1-puntuazioa metrikak erabiltzen ditu. *BLEU*rekiko desberdintasun handiena da *BLEU*k, doitasuna kontuan hartzen duela, baina ez duela estaldura aintzat hartzen.

Sortutako testuaren doitasuna eta estaldura kalkulatzeko, sistemak emandako esaldia eta erreferentziazkoa beharko dira. (2) eta (3) ekuazioetan, *X* aldagaiak erreferentzia adierazten du eta *Y* aldagaiak sistemak emandako testua. Zenbakitzailean, bi esaldien arteko n-grama luzeenaren hitz-kopurua jarriko da. Izendatzailean, *n* aldagaiak *Y*-ren luzera adierazten du, eta *m* aldagaiak *X*-ren luzera.

$$Doitasuna_{AKL} = \frac{AKL(X,Y)}{n} \tag{2}$$

$$Estaldura_{AKL} = \frac{AKL(X,Y)}{m} \tag{3}$$

*F*1-puntuazioa lortzeko (ikus (5) eta (4) ekuazioak), doitasunaren eta estalduraren balioen batez besteko harmonikoa kalkulatzen da. Alabaina, kasu honetan parametro gehigarri bat gehitzen da: β parametroa. β-k $Doitasuna_{AKL}$ eta $Estaldura_{AKL}$ balioen artean dagoen ratioa adierazten du.

$$\beta = \frac{Doitasuna_{akl}}{Estaldura_{akl}} \tag{4}$$

$$F1_{akl} = \frac{\left(1+\beta^2\right) Estaldura_{akl}\ Doitasuna_{akl}}{Estaldura_{akl} + \beta^2 Doitasuna_{akl}} \tag{5}$$

*BLEU*k bezala, ROUGE-L metrikak 0 eta 1 bitarteko balioak hartzen ditu. Horrela, 0 balioak transformazio bat erreferentziekin alderatuta guztiz okerra dela adierazten du eta, 1 balioak, berriz, sortutakoa eta erreferentzia berdinak direla. Metrika hau ere *n*-grametan zentratzen denez, *BLEU*-rekin gertatzen den kasu bera gerta daiteke: emaitza txarra lortzea bi esaldik esanahi bera izan arren. Hala ere, *BLEU* baino metrika leunagoa denez, bi esaldiek zerikusirik badute handiagoa izango da lortutako puntuazioa (ikus 4. taula).

3.3. ***BERT*Score**

*BERT*Score [16] metrikak, bi testu emanik, haien arteko antzekotasun semantikoa neurtzen du, *BERT* eredu [17] batek sortutako esaldi edo hitzen errepresentazio bektoriala erabiliz. Metrika hau sortutako testuaren kalitatea ebaluatzeko erabiltzen da, erreferentziazko testu batekin alderatuta. Garrantzitsua da azpimarratzea metrika honen emaitzak erabilitako ereduaren arabera alda daitezkeela, eta esleitzen duen puntuazioa ez dela fidagarria izango baliabide gutxiko hizkuntzekin. Gure kasuan, datu asko duen hizkuntza batekin ari gara lanean (gaztelaniaz); beraz, *BERT* ereduak ez du arazorik izango datuak prozesatzeko.

Esaldien arteko bektore-antzekotasunak zehazteko, (6) ekuazioko kosinuko antzekotasuna (*KA*) erabiltzen da non, erreferentzia esaldia, esaldiko hitz bakoitza, eta hitzen bektore zerrendak $x = [x_1, ..., x_k]$, eta $X = [X_1, ..., X_k]$ diren, eta sortutako esaldikoak $\hat{x} = [\hat{x}_1, ..., \hat{x}_l]$, $\hat{X} = [\hat{X}_1, ..., \hat{X}_l]$ hurrenez hurren.

$$KA(X,\hat{X}) = \frac{X_i^T \hat{X}_j}{\left|\left|X_i\right|\right| \left|\left|\hat{X}_j\right|\right|} \tag{6}$$

*BERT*Score-k aurretik normalizatutako bektoreak erabiltzen ditu; hortaz, izendatzailea ken daiteke, konputazio-kostua txikitzeko. (7), (8) eta (9) ekuazioek azaltzen dute nola kalkulatzen diren estaldura (E), doitasuna (D) eta *F*1-puntuazioa, hurrenez hurren. Estaldura kalkulatzeko, erreferentziako bektore bakoitzeko, hautagaiaren bektoreen artean antzekotasun handiena duen bektorea bilatzen da, eta batez bestekoa egiten da erreferentziako bektorearen luzerarekin. Doitasunaren kalkulurako, berriz, hautagaiaren luzera erabiltzen da. Azkenik, *F*1-puntuazioa doitasunaren eta estalduraren batez besteko harmonikoaren bidez kalkulatzen da.

$$E_{BERT} = \frac{1}{|x|} \sum_{x_i \in x} \max_{\hat{x}_j \in \hat{x}} KA(X,\hat{X}) \tag{7}$$

$$D_{BERT} = \frac{1}{|\hat{x}|} \sum_{\hat{x}_j \in \hat{x}} \max_{x_i \in x} KA(X,\hat{X}) \tag{8}$$

$$F1_{BERT} = 2\frac{D_{BERT} \cdot E_{BERT}}{D_{BERT} + E_{BERT}} \tag{9}$$

*F*1-puntuazioa 0 eta 1 bitartean dago, non 0k korrelaziorik eza, eta 1ek korrelazio perfektua adierazten duten. Kasu honetan, metrika honek ez dituenez *n*-gramak kontuan hartzen, baizik eta esaldiaren esanahia, esanahi bera duten bi esaldi desberdin ebaluatuz gero, aurreko metrikekin baino emaitza hobeak lor daitezke (ikus 4. taula).

3.4. **Giza ebaluazioa**

Azkenik, HNS eredu onenaren emaitzak paziente baten erantzunak simulatzeko nahiko onak direla egiaztatzeko, osasun-profesional baten eta adimen artifizialean aditu den baten iritziak eskatu ditugu, ereduaren erantzunen ezaugarriak baloratzeko [18]. Ebaluatzaile bakoitzari medikuaren galdera, elkarrizketako pazientearen erantzuna eta ereduak sortutako erantzuna parekatuta eman zaizkio. Horren arabera, hiru ezaugarri ebaluatu behar izan dituzte, ezaugarri bakoitza 1 (txarra) eta 5 (bikaina) bitartean puntuatu delarik:

- **Jariotasuna:** esaldiaren egitura morfosintaktikoa ebaluatzeko.
- **Zuzentasuna:** zuzentasuna edo egiazkotasuna ebaluatzeko, hau da, sortutako erantzunak txosten klinikotik erauzitakoak ematen duen informazio guztia aipatzen ote duen ebaluatzeko. Emaitza paziente errealak emandakoaren desberdina bada, puntuazio baxua izango du.
- **Naturaltasuna:** sortutako esaldiak paziente erreal batek esango ote lukeen neurtzeko. Adibidez, «30 minutu» esan beharrean, «1.800 segundo» esatea, esanahi aldetik berdina izan arren, ez da naturaltzat hartzen.

Ebaluatzaile bakoitzari hainbat instantzia emango zaizkio, eta ezaugarri guztien eta ebaluatzaileen arteko batez bestekoak kalkulatuko dira amaierako puntuazioa lortzeko. Gainera, ebaluatzaileen arteko adostasun maila ere ebaluatu egingo da.

4. **EMAITZAK**

Hurrengo ataletan, garatutako ereduen emaitzak aztertuko dira, bai garapen multzoan, bai test multzoan (4.1. eta 4.2. azpiatalak). Emaitza horien interpretazioa ere egingo da, metrika bakoitzak ereduen errendimendua nola islatu dezakeen azpimarratuz. Halaber, esperimentuen arteko alderaketak egingo dira, egindako hautapenek eta doikuntzek izandako eragina ulertzeko. Amaitzeko, eredu guztien artean onena erabakiko da eta horren giza ebaluazioa egingo da (ikus 4.3. azpiatala).

4.1. **Garapen multzoko emaitzak**

5. taulan, eredu bakoitzak garapen multzoan lortutako puntuazioak daude. Zalantza kasuan, eredu onena aukeratzeko ROUGE-L metrika erabili da, esanahi semantikoa *BLEU*k baino gehiago hartzen duelako kontuan.

4.1.1. *mT5*

5. taula aztertuz gero, ikusten da ereduaren tamainak eta domeinu medikoan egindako egokitzapenak (Med) ez dutela eragin handirik izan ROUGE-L eta *BLEU* metriken emaitzetan. Corpusari galderak gehituta, aldiz, (Gal) eredu guztiak hobetzen dira bi metriketan. Hau espero zitekeen, ikusi dugulako kasu batzuetan ez dela pazientearen erantzuna bakarrik behar erantzun egokiak lortzeko, eta medikuak egindako galderak informazio garrantzitsua ematen duela testuingurua ulertzeko. Corpusari intentzioak (Int) gehituz gero, bi metrikak hobetzen dira. Horrez gain, bereizlea (Sep) erabiltzean emaitzak hobetu egiten dira neurri txikiago batean.

LoRa erabili duten ereduen emaitzak aztertzen baditugu, ikusten da optimizazio-teknika honek ez duela inolako eragin negatiborik izan; are gehiago, kasu gehienetan teknika hau erabiltzeak hobetu egin ditu emaitzak; izan ere, emaitza onenen parekoak lortzen dira. Horrez gain, doiketa-prozesua nabarmen arindu da, eredu handietan du eragin handiena, ia erdira murrizten baitu doiketa-denbora.

4.1.2. *FLOR*

Deskodetzaile soileko ereduen emaitzek beherakada nabarmena erakusten dute mT5 familiakoekin alderatuta. Gainera, instrukziorik gabekoek instrukzioekin (Ins) egokitutakoek baino emaitza baxuagoak lortu dituzte. Beste hurbilpenari dagokionez, adibiderik gabeko (*Zero-Shot*) edo bakarreko (*One-Shot*) tekniken artean ez dago desberdintasun esanguratsurik. Esan beharra dago eredu honek gehiegizko informazioa emateko joera duela eta, batzuetan, oso erantzun naturalak sortu arren, ez daude erreferentziatik hurbil. Hori dela eta, metrikek jokabide hori zigortzen dute, erreferentziatik aldentzeak eta informazioa gehitzeak bat-etortze esplizitua murrizten dutelako. Horrek eragin dezake deskodetzaile soileko ereduek puntuazio baxuagoak lortzea.

5. taula. mT5 ereduek garapen-multzoaren gainean lortutako emaitzak (L = *Large*, XL = *Extra Large*, Medikuntza = domeinu medikoa, Int = intentzioa sartuta, Gal = galdera sartuta, Sep = bereizlea sartuta, LoRa = eredu optimizatua, Ins = instrukzioen bidezko eredua).

Eredua	Tamaina	Domeinua	Intentzioa	Galdera	Banatzailea	LoRa	ROUGE-L	*BLEU*
mT5-L	L	Orokorra	—	—	—	—	0,3622	0,0273
mT5-L-Gal	L	Orokorra	—	✓	—	—	0,3821	0,0325
mT5-L-Int-Gal-Sep	L	Orokorra	✓	✓	✓	—	0,3921	0,0423
mT5-L-Int-Gal-Sep-LoRa	L	Orokorra	✓	✓	✓	✓	0,3912	0,0386
mT5-L-Med	L	Medikuntza	—	—	—	—	0,3667	0,0318
mT5-L-Med-Gal	L	Medikuntza	—	✓	—	—	0,3842	0,0411
mT5-L-Med-Int-Gal-Sep	L	Medikuntza	✓	✓	✓	—	0,3907	0,0318
mT5-L-Med-Int-Gal-Sep-LoRa	L	Medikuntza	✓	✓	✓	✓	0,3924	0,0359
mT5-XL	XL	Orokorra	—	—	—	—	0,3668	0,0313
mT5-XL-Gal	XL	Orokorra	—	✓	—	—	0,3843	0,0248
mT5-XL-Int-Gal-LoRa	XL	Orokorra	✓	✓	—	✓	0,3903	0,0385
mT5-XL-Int-Gal-Sep	XL	Orokorra	✓	✓	✓	—	0,3773	0,0433
mT5-XL-Int-Gal-Sep-LoRa	XL	Orokorra	✓	✓	✓	✓	0,3972	0,0335
mT5-XL-Med	XL	Medikuntza	—	—	—	—	0,3650	0,0295
mT5-XL-Med-Gal	XL	Medikuntza	—	✓	—	—	0,3856	0,0393
mT5-XL-Med-Int-Gal-LoRa	XL	Medikuntza	✓	✓	—	✓	0,3878	0,0378
mT5-XL-Med-Int-Gal-Sep	XL	Medikuntza	✓	✓	✓	—	0,3726	0,0451
mT5-XL-Med-Int-Gal-Sep-LoRa	XL	Medikuntza	✓	✓	✓	✓	0,3910	0,0412

6. taula. FLOR guztiek garapen multzoaren gainean lortutako emaitzak.

Eredua	Entrenamendua Instrukzioekin	Hurbilketa	ROUGE-L	*BLEU*
Flor-Instructed-OneShot	✓	Zero-shot	0.0954	0.0033
Flor-Instructed-ZeroShot	✓	One-shot	0.1017	0.0022
Flor-OneShot	—	Zero-shot	0.0627	0.0010
Flor-ZeroShot	—	One-shot	0.0575	0.0027

4.2. **Test multzoko emaitzak**

Garapen multzoko esperimentuen emaitzak aztertu ostean, eredurik onena *mT5-XL-Int-Gal-Sep-LoRa* da, ROUGE-L altuena duen eredua delako. *XL* tamainako eredu bat denez, *large* tamainako eredu onena ere aukeratzea erabaki da (*mT5-L-Med-Int-Gal-Sep-LoRa*). Bi eredu horiek test multzoaren gainean ebaluatu dira haien errendimendua neurtzeko. 7. taulan ikusten den bezala, *mT5-L-Med-Int-Gal-Sep-LoRa* ereduak emaitza hobeak lortu ditu, nahiz eta bi ereduen emaitzen arteko diferentzia txikia den ROUGE-L metrikaren bidez.

7. taula. Eredu onenen emaitzak test multzoaren gainean.

Eredua	Tamaina	Domeinua	Intentzioa	Galdera	Banatzailea	LoRa	ROUGE-L	*BLEU*
mT5-XL-Int-Gal-Sep-LoRa	XL	Orokorra	✓	✓	✓	✓	0,3646	0,0339
mT5-L-Med-Int-Gal-Sep-LoRa	L	Medikuntza	✓	✓	✓	✓	0,3682	0,0385

Amaitzeko, azken esperimentuak egin dira bi sistema onenekin, datu-gehikuntzak (DG) eta «erantzuna behar ez duten» galdera motak kentzearen (EG) eragina neurtzeko (ikus 8. taula). Esperimentu honetan, *BERT*Score metrika ere erabili da *BLEU* eta ROUGE-L baino semantikoagoa delako. Metrika hau ez dugu aurreko esperimentuetan erabili, kostu konputazional altua duelako.

8. taulan ikusten denez, datu-gehikuntza izan duten ereduek puntuazio txarragoak lortu dituzte ROUGE-L metrikan, nahiz eta *BERT*Score-n ez dagoen eragin nabaririk. Gure hipotesia da ereduek lexikoa ikasi dutela eta, ondorioz, erantzuna ez dela erreferentziaren hain antzekoa.

8. taula. Azken esperimentuen emaitzak test multzoan, *BERT*Score metrika gehituta (DG = *Datu-Gehikuntza*, EG = erantzuna behar ez duten galderak kontuan hartu gabe).

Eredua	EG	DG	ROUGE-L	*BLEU*	*BERT*Score
mT5-L-Med-Int-Gal-Sep-LoRa	—	—	0,3682	0,0385	0,7253
mT5-L-Med-Int-Gal-Sep-LoRa-EG	✓	—	0,3725	0,0442	0,7228
mT5-L-Med-Int-Gal-Sep-LoRa-DG	—	✓	0,3265	0,0425	0,7184
mT5-L-Med-Int-Gal-Sep-LoRa-DG-EG	✓	✓	0,3313	0,0434	0,7154
mT5-XL-Int-Gal-Sep-LoRa	—	—	0,3646	0,0339	0,7202
mT5-XL-Int-Gal-Sep-LoRa-EG	✓	—	0,3705	0,0365	0,7170
mT5-XL-Int-Gal-Sep-LoRa-DG	—	✓	0,3158	0,0450	0,7190
mT5-XL-Int-Gal-Sep-LoRa-DG-EG	✓	✓	0,3271	0,0451	0,7183

EG ereduek hobekuntza txikia lortzen dute ROUGE-L eta *BLEU* metrikekin alderatuz gero, baina *BERT*Score-aren puntuazioa apur bat txikitzen da. Hori, neurri batean, EGak dituzten ereduen erantzunak motzagoak direlako gerta daiteke. Izan ere, ROUGE-L eta *BLEU* metrikek *n*-gramen antzekotasuna neurtzen dutenez, esaldi laburragoek bat-etortze handiagoa izan dezakete. Aldiz, *BERT*Score-k semantika osoa aztertzen duenez, erantzunak motzagoak izateak puntuazioa apur bat jaistea ekar dezake. Taulan ikusten da berriro eredurik onenak *mT5-L-Med-Int-Gal-Sep-LoRa* eta beraren EG aldaera direla (ikus 8. taula), ROUGE-L eta *BERT*Score altuenak lortzen dituztelako.

4.3. **Giza ebaluazioa**

Giza ebaluazioa egiteko, eredu onena eta haren datu gehikuntzaren bidez sortutako bertsioa ebaluatu dira: *mT5-L-Med-Int-Gal-Sep-LoRa* eta *mT5-L-Med-Int-Gal-Sep-LoRa-DG*. Bi anotatzailek ebaluatu dute: esparru medikoko profesionalak eta adimen artifizialean aditu den batek. Anotatzaile bakoitzak test multzoko 20 instantzia ebaluatu ditu eredu bakoitzerako; hau da, guztira 40 instantzia anotatzaile bakoitzeko.

Anotatzaileen arteko adostasuna *Cohen's kappa* neurriaren bidez ebaluatu da, emaitza hauekin (0tik 1erako eskalan): jariotasuna 0,88, zuzentasuna 0,54 eta naturaltasuna 0,78. Puntuazio hauek aztertuta, ondoriozta daiteke zuzentasuna dela adostasun txikiena duen ezaugarria, osasun-arloan aditua den ebaluatzaileak puntuazio hobeak eman dituelako adimen artifizialeko adituarekin alderatuta. Desadostasun hori agertu da ereduak ez duenean eman benetako pazienteak emandako informazio osoa. Izan ere, osasun-profesionalarentzat, baliteke ereduak eman ez duen informazioa medikuaren galderarako hain garrantzitsua ez izatea, baina, adimen artifizialeko adituak ez dakienez benetan informazio hori garrantzitsua den edo ez, gehiago zigortu izatea.

9. taula. Giza ebaluazioaren puntuazioak.

Eredua	Jariotasuna	Zuzentasuna	Naturaltasuna
mT5-L-Med-Int-gal-Sep-LoRa	4,50	3,48	4,33
mT5-L-Med-Int-Gal-Sep-LoRa-DG	4,85	3,35	4,63

Nahiz eta antzeko puntuazioak izan (ikus 9. taula), ikus daiteke datu gehikuntzaren bidez sortutako bertsioak jariotasunean eta naturaltasunean emaitza hobeak lortzen dituela beste ereduarekin alderatuta, baina zuzentasunean puntuazio baxuagoak. Hori izan daiteke datuak gehitzean ereduak egitura gehiago ikusi dituelako, eta hortaz, jariotasun eta naturaltasun han-

diagoa lortu duelako. Hala ere, datu gehiago izateak haluzinazioak gertatzeko arriskua handitzen du, eta horrek era negatiboan eragin dezake zuzentasunaren puntuazioa.

4.3.1. *Erroreen Analisia*

HNS ereduek egindako erroreak aztertzeak metriken puntuazioa ulertarazten lagunduko digu eta, aldi berean, ereduen alde onak eta ahuleziak ere erakutsiko dizkigu. Analisia eginda, ikusi dugu erroreak ereduaren araberakoak direla, T5 eta FLOR ereduek errore desberdinak egiten baitituzte. Horrez gain, esan beharra dago ereduen arteko beste desberdintasunek ez dutela eragin nabaririk erroreetan:

— **mT5 ereduen erroreak.**

- Propagazio-erroreak: Erantzun-Erauzketa (EE) modulutik jasotzen ditugun erantzunak sarreratzat erabiltzen ditugunez, EE moduluak huts egiten badu bere iragarpenetan, errore hori HNS eredura igaroko da. Adibidez, EE moduluak «ez» erantzuten badu, baina erantzun zuzena baiezkoa izango balitz, HNS ereduak «ez» hori erabiliko luke benetako erantzuna erabili beharrean, eta horrela errorearen propagazioa egingo luke.
- Kontraesan-erroreak: Batzuetan, HNS ereduak «bai» edo «ez» gehitzen ditu erantzunen hasieran, elkarrizketetan ohikoak diren partikulak direlako eta giza itxura handiagoa ematen dutelako. Hala ere, zenbaitetan partikulak gaizki erabiltzen ditu hasieran, eta jarraian datorren erantzunaren zatia kontraesanean dago ezezko partikularekin. Adibidez:

  (1) Galdera: *¿Zure mukiak berdeak al dira?*
  Erauzketa: *muki berdeak ditu*
  Erantzuna: *Ez, nire mukiak berdeak dira*.

- Metriken mugetatik sortutako erroreak: Metrikek erantzun batzuk gehiegi zigortzen dituzte. Kasurik nabarmenena da ereduak erantzun labur bat iragartzen duenean eta helburua luzea denean edo alderantziz. 2 adibidean, helburuko eta iragarritako erantzunak bideragarriak dira eta zuzenak izan daitezke, baina metrikak ez du gaitasunik hori neurtzeko. Horren ordez, iragarpena erreferentziatik oso urrun dagoela irizten dio, eta ia guztiz okerra dela baloratzen du.

  (2) Elkarrizketako erantzuna: *Ez*
  Pazientearen erantzuna: *Ez, ez dut sukarra*.

— **FLOR modeloen erroreak:**

- Zentzurik gabeko erroreak: Instrukzioekin entrenatu ez diren ereduen iragarpenek, maiz, galderarekin edo medikuntzaren domeinuko edukiarekin zerikusirik ez duten erantzunak sortzen dituzte, eta beste kasu batzuetan sortutako erantzunek ez dute egitura sintaktiko zuzenik.
- Haluzinazioak: Mota honetako ereduekin ohikoa den moduan, haluzinazioak agertzen dira; hau da, itxuraz onak diruditen baina zuzenak ez diren erantzunak. Gure modeloen erantzunetan ere halako kasuak ikusi ditugu. Batzuetan, pazientearen erantzuna simulatu beharrean, ereduek medikuaren edo erizainaren rola hartzen dute. Beste batzuetan, ereduek paziente gisa ondo egiten dute, baina txosteneko erantzunean ez zegoen informazio gehigarria sartzen dute.
- Metriken mugak sortutako erroreak: Errore mota hau T5 ereduetan azaldutakoen berdina da. FLOR ereduek erantzun luzeagoak sortzeko joera dute, eta hori batzuetan zigortu egiten da, egokia izan arren.

4.4. **Metriken inguruko eztabaida**

Ereduek lortutako emaitzak hobeto ulertzeko, 10. taula erabiliko da azalpenaren oinarri gisa. Lehenik eta behin, esan beharra dago *BLEU* metrikak, oro har, puntuazio baxuak ematen dituela gizakien ebaluazioarekin alderatuta. Izan ere, esaldiek ia esanahi bera izan arren, *BLEU* metrikak 0tik hurbileko puntuazioa ematen du. Adibidez, «Zigarroak ez, inoiz ez» eta «Ez, ez dut erretzen» esaldiek antzeko esanahia dute, baina *BLEU* metrikak ez du 0 baino puntuazio handiagorik ematen. Horrek erakusten du metrika honek zorrotz neurtzen duela testuaren egitura edo hitzen arteko antzekotasuna; hau da, n-grametan guztiz oinarrituta dago, baina ez du beti gizakiek bezala esanahiaren baliokidetasuna kontuan hartzen.

Bestalde, ROUGE-L metrika ere n-grametan oinarritzen den arren, egiten duen kalkuluak *BLEU*k baino hurbilpen semantikoagoa ahalbidetzen du. Hala ere, ez dator guztiz bat giza ebaluazioarekin; hori dela eta, esanahiaren antzekotasuna neurtzeko modu zehatzagoak behar dira, testuinguruaren eta hitzen antzekotasuna kontuan hartzeko.

Horregatik, erabaki da *BERT*Score ere erabiltzea, testuaren errepresentazio semantiko sakonagoa eskaintzen duelako. Emaitzak alderatuta, ikusi da *BERT*Score-aren balorazioak giza ebaluazioaren antzekoagoak direla, testuingurua eta antzekotasuna kontuan hartzen dituelako. Adibidez, 10. taulako lehenengo eta bigarren adibideetan ikus daiteke nola bi esaldik, nahiz eta egitura desberdina izan, *BERT*Score altua lortzen duten, esanahi oso antzekoa dutelako.

10. taula. Erantzunen alderaketa metrika bakoitzean (giza ebaluazio, jariotasun, zuzentasun eta naturaltasun ezaugarrien batez bestekoa da).

Galdera	Txosteneko Esaldia	Pazientearen Esaldia	Ereduaren Esaldia	ROUGE-L	*BLEU*	*BERT*Score	Giza Ebaluazioa (1-5)
Ok, ¿y usa alguna medicación para el asma?	Usa el inhalador azul ocasionalmente	Sí, uso ese inhalador azul a veces. Supongo que sólo cuando lo necesito, pero no muy a menudo.	Sí, utilizo el inhalador azul como único tratamiento.	0,22	0,00	0,76	4,67
Ondo, eta asmarako medikamenturik erabiltzen duzu?	Noizean behin inhalagailu urdina erabiltzen du	Bai, batzuetan inhalagailu urdin hori erabiltzen dut. Behar dudanean bakarrik, baina ez oso maiz.	Bai, inhalagailu urdina erabiltzen dut tratamendu bakar gisa.				
Vale, ¿y consume alguna droga como la marihuana?	Consume marihuana 1-2 veces por semana	Sí, a veces sí, fumo como una o dos veces por semana, con un amigo o algo así.	Um, tomo como una o dos veces por semana.	0,48	0,16	0,80	3,83
Bale, eta drogarik kontsumitzen duzu, marihuana adibidez?	Astean 1-2 alditan kontsumitzen du marihuana	Bai, batzuetan bai, astean behin edo bitan erretzen dut, lagun batekin, edo halako zerbait.	Um, astean behin edo bitan hartzen dut.				
Ok, ¿y fuma?	No fuma	Cigarrillos no, nunca.	No, no fumo.	0,33	0,00	0,76	4,33
Ondo, eta erretzen al duzu?	Ez du erretzen	Zigarroak ez, inoiz ez.	Ez, ez dut erretzen.				

https://doi.org/10.1387/ekaia.27338

Galdera	Txosteneko Esaldia	Pazientearen Esaldia	Ereduaren Esaldia	ROUGE-L	*BLEU*	*BERT*Score	Giza Ebaluazioa (1-5)
Ok y que tipo de dolor diría que es, ¿es como un dolor sordo? ¿Es un dolor agudo y punzante? ¿Cómo lo describiría?	Sordo.	Es un dolor sordo.	Es como un dolor sordo.				
Ondo eta zein min mota dela esango zenuke, minsorra bezalakoa da? Min zorrotz eta ziztagarria da? Nola deskribatuko zenuke?	Sorra.	Min sorra da.	Min sor modukoa da.	0,88	0,54	0,94	4,50
¿Algún cansancio o malestar?	Dice tener fatiga y malestar.	Sí, he estado un poco más fatigado de lo habitual, y sí, he tenido algo de malestar también.	Sí, me he sentido bastante cansada.				
Nekerik edo ondoezik?	Nekea eta ondoeza dituela esaten du.	Bai, ohi baino apur bat nekatuago egon naiz, eta bai, ondoez pixka bat ere izan dut.	Bai, nahiko nekatuta sentitu naiz.	0,15	0,00	0,78	4,83

Adibideetan ikusten da ereduak gehienetan zigortu egin direla pazientearen informazio guztia ez dutelako islatu haren esaldietan. Bi arrazoi nagusirengatik gerta daiteke hau. Lehenengoa, txostenean ez delako gorde pazienteak esandako informazio guztia; adibidez, 10. taulako bigarren adibidean, txostenean ez da idatzi marihuana lagunekin kontsumitzen duela, seguruenik medikuaren ikuspuntutik ez delako garrantzitsua, eta giza ebaluazioarenetik ezta, ontzat eman delako ebaluazioan. Bigarren arrazoia ereduak erabakiak hartu behar dituenean gertatzen da; hau da, eredua ez da beti gai informazio guztia behar bezala islatzeko, eta hori bereziki nabaria da galdera luzeetan. Hala ere, galdera laburretan ere gerta daiteke. Adibidez, azken adibidean, ereduak ondoezari buruzko aipamenik egin ez duela ikusten da, nekean bakarrik zentratu delako.

5. ONDORIOAK ETA ETORKIZUNEKO LANA

Artikulu honetan, elkarrizketa-sistema bat osatzeko oinarrizko baliabideak eta tresnak aurkeztu dira, medikuaren eta pazientearen arteko elkarrizketa modelatzeko eta gaztelaniazko paziente birtual baten prototipo batentzako.

Helburu horrekin, alde batetik baliabideak garatu dira, datuak edukitzea ezinbestekoa baita tresna automatikoak inplementatzeko. Lehenengo, pazientearen deskribapena duen txosten mediko bateko esaldietatik paziente batek emango lituzkeen esaldien corpus bat osatu da. Hori erabilita, paziente birtualaren papera har dezakeen *txatbot* baten hizkuntza naturalaren sorkuntzarako sistema entrenatu da adimen artifiziala eta sare neuronalak erabiliz. Azkenik, zenbait metrika erabiliz ebaluatu da, emaitza positiboz, eta bidea ireki da, horrela, medikuntzako elkarrizketa-sistema automatikoak eraikitzeko.

Lan honek etorkizunerako bide berriak irekitzen ditu elkarrizketa-sistema garatzeko. Alde batetik, bideragarria da euskarara egokitzea, orain eskuragarri dauden itzulpen-teknikak eta euskarazko galdera-erantzun sistemak erabiliz. Bestalde, erronka handia izango da —pazientearen datu objektiboak lortzeak berak dituen zailtasunez gain— elkarrizketa-sistemei benetako pazienteen nortasun eta ezaugarri psikologikoak gehitzea, erabiltzailearekiko harremana hobea izan dadin.

ESKERRAK

Lan hau Virtual Patient 1.0 proiektuaren baitan garatu da, EUSK22/19 kode ofizialarekin, Euskampus Fundazioaren Misiones Euskampus 2.0 Programa 2022 barruan. Horrez gain, lehen egileak UPV/EHUren dokto-

rego-aurreko bekaren (PIF24/223) babesa jaso du lan honen garapenean. Lan hau HiTZ Zentroan egin da, Eusko Jaurlaritza (ikerketa-taldeen deialdia IT1570-22), eta Espainiako Unibertsitate, Zientzia eta Berrikuntzako Ministerioaren proiektu hauen bidez: EDHIA PID2022-136522OB-C22 (FEDER, UE funtsekin batera), DeepR3 TED2021-130295B-C31 (MCIN/AEI/10.13039/5011 00011033, European Union NextGeneration EU/PRTR funtsekin lagunduta).

ERREFERENTZIAK

[1] J. G.-E. López. 2013. «Prueba nacional de evaluación de competencias clínicas de la conferencia nacional de decanos de facultades de medicina de españa», *FEM Rev Fund Educ Médica*, **16**, 59-70.

[2] A. Vargas Guzmán eta M. F. Rico Gaviria. 2011. «Los riesgos del actor: cómo lo afectan las variables de su escuela, director y papel». URL http://hdl.handle.net/10554/5809

[3] J. Arana, M. Idoyaga, M. Urruela, E. Espina, A. Atutxa Salazar eta K. Gojenola. 2024. «A virtual patient dialogue system based on question-answering on clinical records», N. Calzolari, M.-Y. Kan, V. Hoste, A. Lenci, S. Sakti eta N. Xue (editoreak), *Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024)*, Orrialdeak 2017-2027, ELRA and ICCL, Torino, Italia. URL https://aclanthology.org/2024.lrec-main.182/

[4] A. Isaza, M. Teresa, G. Cifuentes Alvarez eta A. Arguello. 2018. «The virtual patient as a learning tool: A mixed quantitative qualitative study», *BMC Medical Education*, **18**.

[5] F. Fareez, T. Parikh, C. Wavell, S. Shahab, M. Chevalier, S. Good, I. De Blasi, R. Rhouma, C. Mc Mahon, J.-P. Lam, T. Lo eta C. W. Smith. 2022. «A dataset of simulated patient-physician medical interviews with a focus on respiratory cases», *Scientific Data*, **9**(1), 313. URL https://doi.org/10.1038/s41597-022-01423-1

[6] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. Ñ. Gomez, L. U . Kaiser eta I. Polosukhin. 2017. «Attention is all you need», I. Guyon, U. V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan eta R. Garnett (editoreak), *Advances in Neural Information Processing Systems*, Bolumena 30, Curran Associates, Inc. URL https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf

[7] C. Raffel, N. Shazeer, A. Roberts, K. Lee, S. Ñarang, M. Matena, Y. Zhou, W. Li eta P. J. Liu. 2020. «Exploring the limits of transfer learning with a unified text-to-text transformer», *J Mach Learn Res*, **21**(1).

[8] L. Xue, N. Constant, A. Roberts, M. Kale, R. Al-Rfou, A. Siddhant, A. Barua eta C. Raffel. 2021. «mt5: A massively multilingual pre-trained text-to-text transformer».

[9] I. GARCÍ A-FERRERO, R. AGERRI, A. A. SALAZAR, E. CABRIO, I. DE LA IGLESIA, A. LAVELLI, B. MAGNINI, B. MOLINET, J. RAMIREZ-ROMERO, G. RIGAU, J. M. VILLA-GONZALEZ, S. VILLATA eta A. ZANINELLO. 2024. «Medical mT5: An Open-Source Multilingual Text-to-Text LLM for The Medical Domain», Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING).

[10] E. J. HU, Y. SHEN,P. WALLIS, Z. ALLEN-ZHU, Y. LI, S. WANG, L. WANG eta W. CHEN. 2021. «Lora: Low-rank adaptation of large language models».

[11] B. ROMERA-PAREDES eta P. TORR. 2015. «An embarrassingly simple approach to zero-shot learning», F. BACH eta D. BLEI (editoreak), *Proceedings of the 32nd International Conference on Machine Learning*, Bolumena 37 of *Proceedings of Machine Learning Research*, Orrialdeak 2152-2161, PMLR, Lille, France. URL https://proceedings.mlr.press/v37/romera-paredes15.html

[12] T. UCAR, A. GONZALEZ-MARTIN, M. LEE eta A. D. SZWARC. 2020. «One-shot learning for language modelling».

[13] R. ARTSTEIN eta M. POESIO. 2008. «Inter-Coder Agreement for Computational Linguistics», *Computational Linguistics*, **34**(4), 555-596. URL https://doi.org/10.1162/coli.07-034-R2

[14] K. PAPINENI, S. ROUKOS, T. WARD eta W.-J. ZHU. 2002. «Bleu: a method for automatic evaluation of machine translation», *Proceedings of the 40th Annual Meeting on Association for Computational Linguistics*, ACL '02, Orria 311-318, Association for Computational Linguistics, USA. URL https://doi.org/10.3115/1073083.1073135

[15] C.-Y. LIN eta F. J. OCH. 2004. «Automatic evaluation of machine translation quality using longest common subsequence and skip-bigram statistics», *Proceedings of the 42nd Annual Meeting of the Association for Computational Linguistics (ACL-04)*, Orrialdeak 605-612, Barcelona, Spain. URL https://aclanthology.org/P04-1077

[16] T. ZHANG, V. KISHORE, F. WU, K. Q. WEINBERGER eta Y. ARTZI. 2020. «Bertscore: Evaluating text generation with bert».

[17] J. DEVLIN, M.-W. CHANG, K. LEE eta K. TOUTANOVA. 2019. «Bert: Pre-training of deep bidirectional transformers for language understanding».

[18] W. LIU, J. TANG, J. QIN, L. XU, Z. LI eta X. LIANG. 2020. «Meddg: A large-scale medical consultation dataset for building medical dialogue system», *CoRR*, **abs/2010.07497**. URL https://arxiv.org/abs/2010.07497