

Auto-gainbegiratuak ikaskuntzaren ahalmena azaleratzen

(Unleashing the power of self-supervised learning)

Aitor Sánchez-Ferrera^{1*}, Borja Calvo Molinos¹, Usue Mori Carrascal¹, Jose A Lozano^{1,2}

¹ Konputazio Zientzia eta Adimen Artifiziala Saila, UPV/EHU

² Basque Center for Applied Mathematics (BCAM)


LABURPENA: Ikasketa automatikoak nabarmen egin du aurrera azken urteotan, eta horren fruitu da garatutako algoritmo sorta izugarria, ataza ezberdin ugari burutzeko ahalmena ematen digutenak. Literaturaren arabera, algoritmo gehienak ikaskuntza gainbegiratuan oinarritzen dira. Hala ere, hainbat atazetan emaitza onak lortu arren, ikaskuntza-paradigma honen eragozpen nagusia etiketatiko mendekotasuna da; izan ere, etiketatze-prozesu hori oso garestia da. Gainera, ikaskuntza automatikoan erabilitako ereduak alborapen okerrak bultzatzen dituzten bide laburrak ikasteko joera handia dute, burutu nahi dituzten atazetan porrot eginez. Aurreko arazoak saihesteko, ikasketa auto-gainbegiratuak arreta bereganatu du azkenaldian ikaskuntza-paradigma gisa. Lan honek ikasketa auto-gainbegiratuari dagokion literaturaren sarrera eskaintzen du, eta ikaskuntza paradigma horren barruan bereizten diren metodo motak bildu eta azaltzen ditu, datu-mota desberdinetan aplikatzeko oinarritzko prozedurak aztertuz.

HITZ GAKOAK: Adimen artifiziala, ikaskuntza automatikoa, errepresentazio-ikaskuntza, ikaskuntza auto-gainbegiratuak.

ABSTRACT: *Machine learning has made significant progress in recent years, resulting in the development of an impressive array of algorithms that enable us to perform a wide variety of tasks. According to the literature, most algorithms rely on supervised learning. However, despite achieving good results in different tasks, the main drawback of this learning paradigm is its dependency on manually created human labels, as the labeling process is very costly. Moreover, machine learning models tend to learn shortcuts that promote incorrect biases, leading to failures in the tasks they aim to accomplish. To avoid these issues, self-supervised learning has recently gained attention as a learning paradigm. This work provides an introduction to the literature on self-supervised learning. It explains the different types of methods distinguished within this learning paradigm and examine the basic procedures for applying them to different types of data.*

KEYWORDS: Artificial intelligence, machine Learning, representation learning, self-supervised learning.

***Harremanetan jartzeko/Corresponding author:** Aitor Sánchez-Ferrera, Konputazio Zientzia eta Adimen Artifiziala, Informatika Fakultatea, 20018, Donostia, Gipuzkoa, Euskal Herria.

 <https://orcid.org/0000-0001-6127-0686>, aitor.sanchezf@ehu.eus

Nola aipatu/How to cite: Sánchez-Ferrera, Aitor; Calvo-Molinos, Borja; Mori-Carrascal, Usue; Lozano, Jose (2024). «Auto-gainbegiratuak ikaskuntzaren ahalmena azaleratzen», Ekaia, DOI: <https://doi.org/10.1387/ekaia.26347>

Jasoa: maiatzak 22, 2024; Onartua: uztailak 12, 2024
ISSN 0214-9001-eISSN 2444-3225 / ©2024 UPV/EHU



Obra Creative Commons Atribución 4.0 Internacional-en lizentziazpean dago

1. Sarrera

Azken urteotan, adimen artifizialak aurrerapen izugarriak izan ditu arlo ugarritan. Gure egunerokotasunean, etengabe egiten dugu topo adimen artifiziala erabiltzen duten sistemekin: etxeko laguntzaile birtual gisa jarduten duten *chatbot*-ak erabiltzean, musika eta bideo plataformek gure gustuen araberako gomendioak eskaintzean, edo web orrialdeetan gure interesen araberako iragarriak jasotzean. Adimen artifizialak erabiltzen dituen teknologia abanikotik, ikaskuntza automatikoa (*machine learning*, ingelesez) da nabarmenetarikoa [1]. Datuak oinarri dituelarik eta hainbat ikasketa paradigmatan oinarrituz, ikaskuntza automatikoa indarrez sartu da eremu desberdinetan, besteak beste, ordenagailu bidezko ikusmenarekin [2] eta hizkuntzaren prozesamenduarekin [3] erlacionatutako atazetan, zein industriaren [4] eta osasungintzaren [5] arloetan.

Esan bezala, ikaskuntza automatikoan ereduak datuak oinarri gisa erabiliz hainbat ataza burutzen ikasten dute. Ikasketa hori burutzeko hainbat ikaskuntza paradigma bereizten dira, baina ikasketa gainbegiratuia (*supervised learning*, ingelesez) da hedatuena. Ikasketa gainbegiratuian, ereduak ataza ebazteko entrenatzeko, aldezturik etiketatutako datu-base erraldoiak erabili ohi dira. Nahiz eta ikaskuntza gainbegiratuian oinarritutako ereduak emaitza onak eman hainbat esparrutan, paradigma bere botila-lepora heltzen ari da. Arrazoi nagusienetako bat etiketen beharra da; normalean, etiketa horiek lortzea garestia izaten da, bai denborari dagokionez, eta askotan baita ekonomikoki ere. Bestalde, askotan datuak etiketatzeko jakintza espezializatua behar da [6]. Are gehiago, batzuetan ezinezkoa izan daitekedatu etiketatuak lortzea (adibidez, istripuen etiketak nahi izanez gero, ezin dira istripuak eragin etiketa horiek lortzeko).

Horretaz gain, atazak ebazten era azkarrago eta errazagoan ikasteko ereduak ‘bide laburrak’ erabili ohi dituzte. Bide labur horiek datuen eta ikasi nahi den atazaren arteko ageriko korrelazio ‘faltsuetan’ oinarritzen dira; hau da, nahiz eta ataza ebazteko pistak eman, alborapen handia sortzen dute, ereduaren suposizio okerrak bultzatuz [7]. Fenomeno hori hobeto ulertzeko, demagun katuen eta txakurren irudiak sailkatzen dituen eredu bat entrenatu nahi dugula. Normalean, katuek etxeetan egon ohi direnez, katuen irudi gehienek atzealdeak altzariak eta etxeko gelak erakutsiko dituzte. Aldiz, txakurrak askotan paseatzen edo parkeetan egon ohi direnez, haien irudien atzeko planoek zuhaitzak, belarra eta kaleko beste elementu batzuk izango dituzte. Kasu horretan, txakurren eta katuen irudiak desberdintzeko entrenatutako eredu batek irudien atzealdea ikasi dezake bide labur gisa, eraikin baten barruan egindako argazkiak katuei eta kalean egindako irudiak txakurrei esleituz. Ondorioz, ereduak sailkapen ataza bide labur horren bitartez ikasten badu, kalean dauden katuen eta etxean dauden txakurren irudiak sailkatzean porrot egingo du.

Muga horiek gainditzeko estrategia bat errepresentazio-ikaskuntza (*representation learning*, ingelesez) da [8]. Ikaskuntza automatikoko eredu askok datuak dimentsio txikiagoko espazio batean kodetzen dituzte, atazen ikaskuntza eraginkorrari lagun diezaioketen datuen errepresentazio berriak sortuz. Errepresentazio-ikaskuntza datuen errepresentazio ‘didaktikoak’ ikastean datza, datuen informazio erabilgarria arakatzeko eta burutu nahi diren atazen ikasketa errazten dutenak. Horrela, ereduak ataza bat ikasteko behar duten etiketa kopurua handia izatea eta bide laburren ikasketa saihestu daitezke. Ildo horretatik, ikaskuntza auto-gainbegiratuak (*self supervised learning*, ingelesez) arreta handia jaso du, datuetatik errepresentazio esanguratsuak ikasteko berezkoa duen eraginkortasunagatik eta horietatik orokortzeko gaitasunagatik [9].

Lan honek auto-gainbegiratuak ikaskuntzari buruzko sarrera eta ulermena errazeko berrikuspen bat dakar. Zehazki, hauek dira egiten dituen ekarpenak:

- Literaturaren berrikuspena: ikaskuntza auto-gainbegiratuian oinarritutako metodoen azterketa aurkeztzen du dokumentuak. Lana gaiarekiko sarrera bat izan daiteke ikerkuntza-lerro honetan murgildu nahi diren ikerlariarentzat.
- Metodoen sailkapena: arloko literaturan aurki daitezkeen algoritmo auto-gainbegiratu motak bereizten dira. Gainera, aztertzen da ea zein metodo diren ohikoena datu-mota ezberdinetarako.

- Aplikazioen azterketa: ikasketa auto-gainbegiratuaren erabiltzen duten metodoen aplikazio erreala biltzen dira dokumentuan.
- Ikerkuntza-lerroen proposamena: aztertutako lanak oinarritzat hartuz, ikaskuntza auto-gainbegiratuaren arlorako ikerkuntza-lerro berriak proposatzen dira.

2. Zer da ikaskuntza auto-gainbegiratu?

Ikaskuntza automatikoa, ikaskuntza paradigma ezberdinak erabiltzen dira ataza jakin bat burutzeko ereduak eraikitzeko. Burutu nahi dugun ataza hori, *zeregin-ataza* (*downstream task*, ingelesez), sailkapena, erregresioa edo anomaliak detektatzea izan daiteke, besteak beste, eta hauek ebazteko erabiltzen den ikaskuntza paradigmarik ohikoena gainbegiratu da. Atal honetan ikaskuntza gainbegiratuaren nondik norakoak azalduko ditugu eta, haren desabantailetan oinarrituta, alternatiba gisa, ikaskuntza auto-gainbegiratuari sarrera egingo diogu.

2.1. Ikaskuntza gainbegiratu

Ikasketa gainbegiratuaren helburua sarrerako datu bakoitzari bere irteera balioa esleituko dion eredu bat eraikitzea da. Eredu hori eraikitzeko, ikasketa gainbegiratuaren, etiketatutako entrenamendu datu base bat erabiltzen da, hau da, datu-base bat zeinetan sarrera bakoitzaren irteera, hots, etiketa, ezaguna den.

Zehatzago esanda, izan bedi $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^N$ entrenamendurako sarrera-datu multzo bat, non \mathbf{x}_i multzoko i -garren datu-lagina eta N multzoko lagin kopurua diren. Ikasketa gainbegiratuaren, zeregin-atazaren arabera, $\mathbf{Y}^{(z)} = \{y_i^{(z)}\}_{i=1}^N$ zeregin-atazari lotutako irteerako datu-multzo bat izango dugu, non $y_i^{(z)}$ entrenamendu multzoko i -garren datu-laginaren zeregin-atazari lotutako etiketa den. Hobeto ulertzeko, demagun aurreko atalean deskribatutako zeregin-ataza burutu nahi dugula, hau da, katuen eta txakurren irudien sailkapena. Kasu horretan, \mathbf{x}_i datu-lagin bakoitza irudi bat izango da eta $y_i^{(z)}$ etiketak ‘katua’ klasearen balioa hartuko du \mathbf{x}_i irudia katu batena bada eta ‘txakurra’ balioa hartuko du txakur baten irudia bada.

Zeregin-ataza burutzen ikasteko, helburua sarrerako datuak eta etiketak mapatuko dituen $f^{(z)}(\cdot)$ eredu bat entrenatzea da, kasu idealean ereduaren zeregin-atazerako iragarpenak $\hat{y}_i^{(z)} = f^{(z)}(\mathbf{x}_i) = y_i^{(z)}$ izanik. Hemendik aurrera, ereduak neurona-sareak direla asumituko dugu, sarrera-datuaren erre-presentazio berri bat sortuko duen $\phi(\cdot)$ kodetzaile batez eta erre-presentazio horien baitan zeregin-atazerako iragarpenak itzuliko dituen $g^{(z)}(\cdot)$ zeregin-modulu batez osatuak¹. Zehazki, $\phi(\cdot)$ kodetzaileak sarrerako \mathbf{x}_i datu-lagin bakoitzerako $\mathbf{z}_i = \phi(\mathbf{x}_i)$ erre-presentazio berri bat sortuko du dimentsio txikiagoko espazio batean. Ondoren, $g^{(z)}(\cdot)$ zeregin-moduluak \mathbf{z}_i erre-presentazio berria hartuko du sarrera gisa zeregin-ataza burutzeko, hots, $\hat{y}_i^{(z)} = g^{(z)}(\mathbf{z}_i)$. Aurreko adibidearen oinarrian, neurona-sare baten $\hat{y}_i^{(z)} = f^{(z)}(\mathbf{x}_i) = g^{(z)}(\phi(\mathbf{x}_i))$ iragarpenak \mathbf{x}_i datu-laginaren txakur baten edo katu baten irudia izateko probabilitatea adieraziko du.

Ikaskuntza gainbegiratuaren, $f^{(z)}(\cdot)$ ereduaren zeregin-ataza zuzenean ikasteko entrenatzen da, sarrerako \mathbf{x}_i datu-lagin bakoitzari lotutako ereduaren $\hat{y}_i^{(z)}$ iragarpenen eta $y_i^{(z)}$ etiketen arteko berdintasuna helburu ideala izanik. Hala ere, aurreko atalean komentatu dugun bezala, ikaskuntza gainbegiratuak hainbat muga dauzka, entrenamendu multzoko etiketak lortzearen kostea, besteak beste, erre-presentazio-ikaskuntzaren bitartez arindu daitezkeenak. Esplizituki, erre-presentazio-ikaskuntzaren helburua $f^{(z)}(\cdot)$ eredu baten $\phi(\cdot)$ kodetzaileak sortzen dituen erre-presentazioek sarrera-datuaren berrezko ezaugarriak ahalik eta hobekien atzematea da. Helburu hori burutzeko modu bat ikaskuntza auto-gainbegiratu da.

¹Arloko literaturan gehien erabiltzen diren ereduak dira, berezkoak dituzten propietateak egokienak direlako. Hori dela eta, paradigma ondo ulertzeko sare-neuronalen terminologia eta kontzeptuak lagungarriak izango dira.

2.2. Ikaskuntza auto-gainbegiratuak

Ikaskuntza-autogainbegiratuak hainbat definizio desberdin jaso ditu denboran zehar. Gaur egun, ikaskuntza auto-gainbegiratuak hurrengo eran definitzen da: ‘datuen errepresentazio esanguratsuak ikasi datuen zenbait ezaugarri, erlazio edo aldaketa iragarritz, etiketatzen oinarritu gabe’ [9]. Zehazki, ikaskuntza auto-gainbegiratuak, zeregin-atazarekin informazioa partekatzen duten ataza osagarriak ikasiz, ereduak zeregin-ataza ebazteko lagungarriak izan daitezkeen errepresentazioak atzemango dituztela asumitzen da, zeregin-atazaren ikasketa errazagoa, azkarragoa eta eraginkorragoa ahalbidetuz. Literaturan, datuen errepresentazio esanguratsuak atzemateko lagungarriak izan daitezkeen ataza osagarriak *aitzakia-atazak* (ingelesez *pretext task*) deitzen zaie [10].

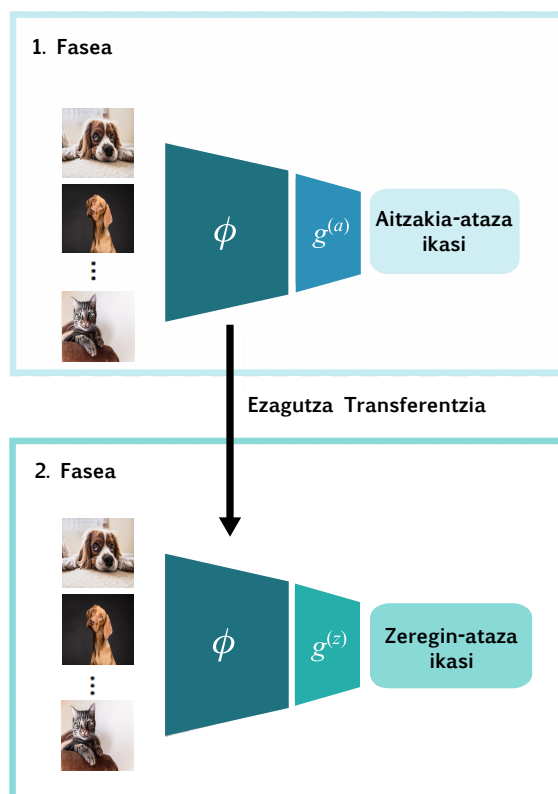
Izan bedi aurreko atalean adierazitako testuinguru berdina: $\mathbf{X} = \{\mathbf{x}_i\}_{i=1}^{(n)}$ entrenamendurako sarrera-datu multzo bat, burutu nahi dugun zeregin-atazaren araberrako $\mathbf{Y}^{(z)} = \{y_i^{(z)}\}_{i=1}^{(n)}$ etiketa multzo bat, eta zeregin-ataza burutzeko erabiliko dugun $f^{(z)}(\cdot)$ eredu bat, $\phi(\cdot)$ kodetzaile batez eta $g^{(z)}(\cdot)$ zeregin-modulu batez osatua. Azalpenak errazteko, aurreko adibidearekin jarraituko dugu, non gure zeregin-ataza katuen eta txakurren irudien sailkapena egitea den. Aitzakia-ataza osagarriak ikastearen helburua $\phi(\cdot)$ kodetzaileak sortutako datuen errepresentazioak ahalik eta esanguratsuenak eta deskriptiboan izatea da. Horretarako, jatorrizko $\mathbf{Y}^{(z)}$ etiketatzen oinarritzen ez den aitzakia-ataza bat definitu daiteke, datuen berezkoak diren zenbait ezaugarri, erlazio edo eraldaketa iragartzean oinarrituta [9].

Literaturan, irudien errepresentazio esanguratsuak ikasteko sarritan erabiltzen den aitzakia-ataza mota bat auto-kodetzaileak dira, non sarrerako datu-lagin bakoitza dimentsio txikiagoko espazio batean kodetzen den eta, ondoren, jatorrizko sarrerako datu-lagina berreraikitzen den [11]. Zehazki, gure adibidean aitzakia-atazaren entrenamendurako sarrera datu-multzoa, \mathbf{X} , zeregin-atazaren berdina izango da: katuen eta txakurren irudi-sorta. Auto-kodetzaileen kasuan, aitzakia-ataza jatorrizko datuak berreraikitzean oinarritzen denez, aitzakia-atazaren irteera-datu multzoa $\mathbf{Y}^{(a)} = \mathbf{X}$ izango da. Aitzakia-ataza ebazteko, $f^{(a)}(\cdot)$ ereduari $\phi(\cdot)$ kodetzaileak sortutako errepresentazioak sarrera gisa erabiliko dituen $g^{(a)}(\cdot)$ aitzakia-modulu bat erantsiko diogu, kasu honetan deskodetzaile bat izango dena. Aitzaki-moduluak $\phi(\cdot)$ kodetzaileak sortutako \mathbf{x}_i sarrerako datu-lagin bakoitzaren errepresentaziotik abiatuta, $\mathbf{z}_i = \phi(\mathbf{x}_i)$, $y_i^{(a)} = \mathbf{x}_i$ berreraikitzen saiatuko da, kasu idealean $\hat{y}_i^{(a)} = f^{(a)}(\mathbf{x}_i) = g^{(a)}(\phi(\mathbf{x}_i)) = \mathbf{x}_i$ izanik. Aitzakia-ataza hau ikasiz, $\phi(\cdot)$ kodetzaileak sarrerako argazkien testuingurua eta edukia hobeto deskribatzen duten errepresentazio baliagarriak eraikiko ditu, zeregin-atazaren ikasketa erraztuko duena [12].

Guzti hori kontuan hartuz, ondorioztatu daiteke metodologia honen gakoa: zeregin-ataza ebazteko baliagarriak diren errepresentazioen ikasketa bultzatzen duten aitzakia-ataza aproposak diseinatzea [13]. Hala ere, nahiz eta aitzakia-atazaren helburua ulertu, beharrezkoa da azaltzea ea nola aprobeztatzen duen ereduak aitzakia-ataza ikastearen bitartez lortutako jakintza zeregin-ataza ikasteko. Jakintza transferentzia gauzatzeko, bi prozedura nagusi desberdintzen dira literaturan: i) ereduaren aurre-entrenamendua aitzakia-atazaren eta ii) aitzakia-atazaren eta zeregin-atazaren ikaskuntza bateratua.

Lehenengo metodoan ereduak aitzakia-ataza ikasteko aurre-entrenatzen da eta lortutako errepresentazioak zeregin-ataza ebazteko erabiltzen dira, sarrera gisa. Zehatz-mehatz, bi azpiprozesu bereiz daitezke (ikus 1 irudia):

1. **Aitzakia-atazaren aurre-entrenamendua.** Fase honetan $f^{(a)}(\cdot)$ ereduak erabiliko da aitzakia-ataza ikasteko. Sarrerako \mathbf{X} datu-multzoa aitzakia-atazaren irteerako $\mathbf{Y}^{(a)}$ datu-multzoarekin mapeatzen ikasiko du $f^{(a)}(\cdot)$ ereduak, $\phi(\cdot)$ kodetzaileak eta $g^{(a)}(\cdot)$ aitzakia-modulua erabiliz, era idealean $\hat{y}_i^{(a)} = f^{(a)}(\mathbf{x}_i) = g^{(a)}(\phi(\mathbf{x}_i)) = \mathbf{x}_i$ izateko. Momentu honetan ez da $f^{(z)}(\cdot)$ ereduaren $g^{(z)}(\cdot)$ zeregin-modulua erabiliko.
2. **Zeregin-atazaren afinazioa.** Behin aitzakia-atazaren aurre-entrenamendua bukatuta, $\phi(\cdot)$ kodetzaileak datuen errepresentazio esanguratsuak atzematen dituela asumitzen da. Berega-

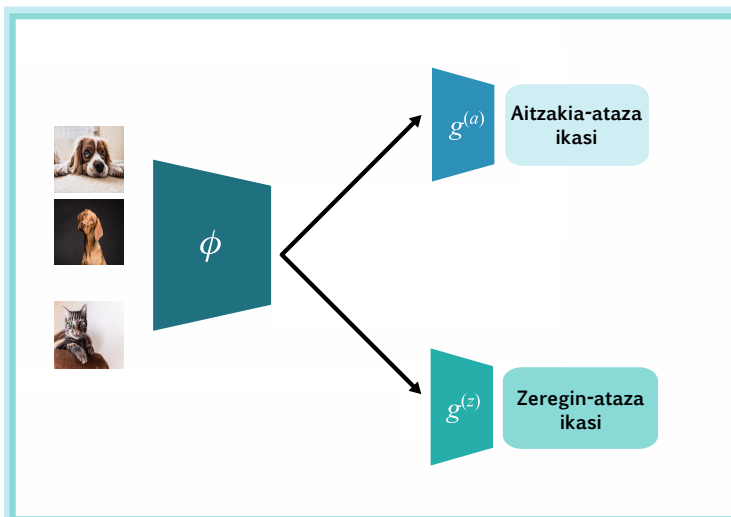


1. irudia. Aitzakia-atazaren aurre-entrenamendua. Lehenengo fasean, eredu aitzakia-ataza burutzen ikas-teko entrenatzen da kodetzaile bat eta aitzakia-modulu bat erabiliz. Behin aitzakia-ataza ikasita, bigarren fasean, aurre-entrenatutako kodetzaileak sortutako errepresentazioak erabiltzen dira zeregin-modulu baten sarrera gisa zeregin-ataza burutzen ikasteko.

natutako jakintza hori zeregin-ataza ikasteko aprobetxatzeko, $g^{(a)}(\cdot)$ aitzakia-modulua deuseztatu eta $g^{(z)}(\cdot)$ zeregin-moduluarekin ordezkatzeko da. Horrela, fase honetan sarrerako \mathbf{X} datu-multzoa zeregin-atazaren irteerako $\mathbf{Y}^{(z)}$ etiketekin mapatzen ikasiko du ereduak (aurreko pausuan ikasitako) $\phi(\cdot)$ kodetzailea eta $g^{(z)}(\cdot)$ erabiliz, bere zeregin-atazerako iragarpenak $\hat{y}_i^{(z)} = f^{(z)}(\mathbf{x}_i) = g^{(z)}(\phi(\mathbf{x}_i))$ izanik. Bigarren fase honetan, lehenengo fasean $\phi(\cdot)$ kodetzaileak atzemandako errepresentazio esanguratsuak aprobetxatzen dira hauek $g^{(z)}(\cdot)$ zeregin-moduluaren sarrera gisa erabiliz.

Aldiz, bigarren metodoan, ereduak aitzakia-ataza eta zeregin-ataza aldi berean ikasten ditu (ikus 2 irudia). Horretarako, $\phi(\cdot)$ kodetzaileak sarrerako \mathbf{x}_i datu-lagin bakoitzerako $\mathbf{z}_i = \phi(\mathbf{x}_i)$ errepresentazio berri bat sortuko du. Ondoren, ataza-modulu bakoitzak \mathbf{z}_i errepresentazio berri hori ataza bakoitzeko irteera-datuekin mapatuko ditu, $\hat{y}_i^{(a)} = g^{(a)}(\phi(\mathbf{x}_i))$ aitzakia-atazerako eta $\hat{y}_i^{(z)} = g^{(z)}(\phi(\mathbf{x}_i))$ zeregin-atazerako iragarpenak konputatuz.

Helburua bera da bi kasuetan: aitzakia-atazaren bitartez lortutako ezagutza aprobetxatzea zeregin-ataza bat (edo gehiago) ikasteko. Hala ere, aitzakia-atazaren ikasketa eta lortutako ezagutzaren transferentzia era desberdinetan burutzen dira. Lehenengo metodoaren helburua datuen errepresentazio baliagarriak lortzen dituzten aitzakia-atazen diseinuan datza. Baldintza idealetan, errepresentazio horiek behar adina orokorrak izango dira zeregin-ataza desberdinetan baliagarriak izateko. Bigarren metodoan, berriz, berriazko zeregin-ataza bat ikasteko onuragarriak izan daitezkeen aitzakia-atazak diseinatzean datza helburua. Azken kasu horretan, aitzakia-ataza eta zeregin-ataza aldi berean entrenatuz, ikasitako errepresentazioak ez daukate zertan hain orokorrak izan behar,



2. irudia. Aitzakia-atazaren eta zeregin-atazaren ikasketa bateratua. Kodetzaileak sortutako errepresentazioak aitzakia-modulu baten eta zeregin-modulu baten sarrera gisa erabiltzen dira, aitzakia-ataza eta zeregin-ataza aldi berean ikasiz.

beste zeregin-ataza batzuetan baliagarriak izateko. Azpimarratzekoa da aurreko bi metodoetan eredu bat entrenatzeko aitzakia-ataza bat baino gehiago konbinatu daitekeela, eskuratutako erre-presentazioen kalitatea eta egokitasuna hobetzeko eta, horrela ereduaren errendimendu orokorra zeregin-atazetan nabarmen hobetzeko [14].

Bi kasuetan, aitzakia-ataza aurrez entrenatuta edo aldi berean, ikaskuntza auto-gainbegiratuari buruzko lanak aitzakia-atazen arabera sailka daitezke. Literaturan, bi aitzakia-ataza mota nagusi bereizten dira: i) ikaskuntza auto-prediktiboan oinarritutakoak eta ii) ikaskuntza kontrastatzailea erabiltzen dutenak [9]. Hurrengo bi ataletan ataza-mota bakoitzaren ezaugarriak eta adibide esan-guratsuenak deskribatuko ditugu.

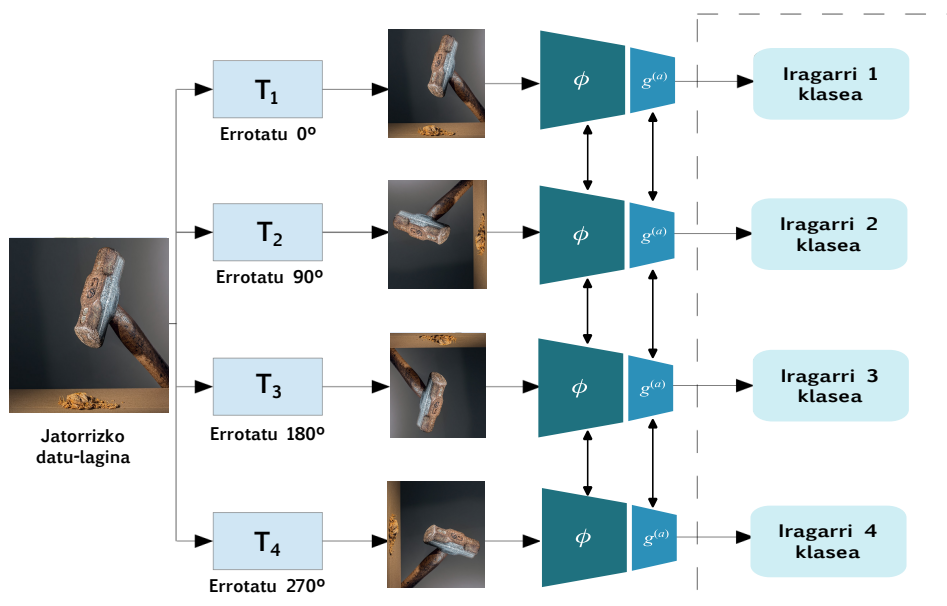
3. Ikaskuntza auto-prediktiboa

Ikaskuntza auto-prediktiboan (ingelesez *self-predictive learning*) oinarritutako aitzakia-atazetan, datuen zati bat erabili ohi da beste zati batzuk iragartzeko. Horretarako, ohikoa da transforma-zio desberdinak aplikatzea datuei, ondoren hauekin aitzakia-atazak ikasteko. Ikaskuntza auto-prediktiboan oinarritutako aitzakia-atazak ikasiz eta ondorioz atzemandako errepresentazioetaz baliatuz zeregin-ataza ikasteko erabili beharreko etiketa kopurua murriztu daiteke.

Orokorrean, aitzakia-ataza auto-prediktiboak hiru multzo nagusitan bereiz daitezke: *sailkapen auto-gainbegiratua* (*self-supervised classification*), *berreraikitze auto-gainbegiratua* (*self-supervised reconstruction*) eta *iragarpen auto-gainbegiratua* (*self-supervised forecasting*) [9].

3.1. Sailkapen auto-gainbegiratua

Kategoria honetan sartzen diren aitzakia-atazetan, $\mathcal{T} = \{T_1, \dots, T_K\}$ transformazio familia bat aplikatzen zaio entrenamendu multzoko \mathbf{x}_i lagin bakoitzari. Horren emaitza gisa, lagin ori-ginalaren $\mathcal{T}(x_i) = \{T_1(\mathbf{x}_i), \dots, T_K(\mathbf{x}_i)\}$ ikuspegi multzo bat sortzen da, non $T_k(\mathbf{x}_i)$ ikuspegiari atxikitutako sasi-etiketa k den. Sailkapen auto-gainbegiratuaren zeregina $f^{(a)}(\cdot)$ eredu bat entre-natzea da, \mathbf{x}_i -ren ikuspegi bakoitza gauzatzeko honi aplikatutako transformazioa iragarriko due-na, egoera idealean $f^{(a)}(T_k(\mathbf{x}_i)) = k$ izanik ($1 \leq k \leq K$). Teknika honetan, proposatutako transformazioak aplikatzean, datuek izango duten portaera iragartzen da. Horrela, ereduak datuen




3. irudia. Sailkapen auto-gainbegiratua. Jatorrizko datu-laginari transformazio sorta bat aplikatzen zaio, transformazio bakoitzeko laginaren ikuspegi berri bat sortuz. Ondoren, transformazioen bitartez sortutako ikuspegi bakoitza sarrera gisa erabiliz, ikuspegi bakoitzari lotutako transformazioaren etiketa iragartzen da.

berezko ezaugarriei buruzko informazio baliagarria ikasiko dutela asumitzen da. Multzo honetan aurki ditzakegun aitzakia-atazen arrakasta, problema bakoitzerako onuragarriak izan daitezkeen transformazio egokiak aukeratzearen menpekoa da.

Teknika hau hobeto ulertzeko, [15] lanean irudien errepresentazio esanguratsuak ikasteko proposatutako aitzakia-ataza azalduko dugu (ikus 3 irudia). Zeregin-ataza tresna desberdinen irudien sailkapena izanik, lau errotazio-transformazio desberdinetan oinarritutako sailkapen auto-gainbegiratua proposatzen da ereduaren aurre-entrenamendua egiteko. Sarrerako datu-lagin bakoitzari lau transformazioak aplikatuz, datu-lagin bakoitzaren lau ikuspegi berri sortzen dira. Ondoren, kodetzaile batez eta sailkatzaile lana egiten duen aitzakia-modulu bat erabiliz, ikuspegi bakoitza sortzeko jatorrizko datu-laginari aplikatutako transformazioaren etiketa iragartzen da. Kasu honetan, egileek asumitzen dute errotazio-transformazioak bereizteko ereduak tresna bakoitzaren berezko ezaugarriak ikasten dituela (tresnaren ohiko posizioa, hain zuzen). Behin eredu aurre-entrenatuta, aitzakia-modulua deuseztatu eta sailkapenerako zeregin-modulu batez ordezkatzten da. Honek aitzakia-atazan aurretik entrenatutako kodetzailearen errepresentazioak erabiliko ditu zeregin-ataza burutzen ikasteko, tresnen irudien sailkapena hain zuzen.

Kontuan hartzekoa da hautatutako transformazioak eskura daukagun datu-motaren menpekoak direla, hau da, beharbada datu-mota batean aplikatu daitezkeen transformazioak ez dira bideragarriak beste datu-mota batzuetan aplikatzeko. Irudien kasuan, transformazio geometrikoak dira ohikoenak [16, 15]. Era antzekoan, hainbat lanek transformazio afinen erabilera proposatzen dute denbora-segiden sailkapen auto-gainbegiratua gauzatzeko [17, 18]. Hizkuntzaren prozesamenduaren arloan aldiz, testu bateko esaldien ordena iragartzea proposatzen da sailkapen auto-gainbegiratua egiteko [19]. Azken kasu honetan, nabarmentzekoa da ez dela transformaziorik erabiltzen aitzakia-ataza eraikitzeko, testuaren koherentzia erabiltzen baita seinale auto-gainbegiratu gisa. Modu honetan, sailkapen auto-gainbegiraturako sasi-etiketak esaldien ordenak definitzen du.



4. irudia. Berreraikitze auto-gainbegiratuaren diagrama. Jatorrizko datu-laginarik transformazio bat aplikatzen da, honen ikuspegi berri bat sortuz. Ondoren, eredu bat entrenatzen da ikuspegi berritik jatorrizko datu-lagina berreraikitzeko.

3.2. Berreraikitze auto-gainbegiratuaren

Kategoria honetako aitzakia-atazek T transformazio bat aplikatzen diote \mathbf{x}_i sarrera lagin bakoitzari, lagin horren $T(\mathbf{x}_i)$ ikuspegi berri bat sortuz. Berreraikitze auto-gainbegiratuaren esparruan, $f^{(a)}(\cdot)$ eredu bat entrenatzen da, $T(\mathbf{x}_i)$ sarrera gisa hartuta $f^{(a)}(T(\mathbf{x}_i)) = \mathbf{x}_i$ jatorrizko lagina berreraikitzen saiatuko dena. Horrela, ereduaren irteeraren eta jatorrizko laginaren arteko errorea minimizatzea da entrenamenduaren helburua.


Multzo honetan sartzen diren aitzakia-atazen arteko desberdintasun nagusia proposatutako transformazioan datza. Aukera hedatuena, aurreko atalean azaldutako auto-kodetzaileen erabilera da [20]. Hontaz aparte, badaude beste metodo batzuk auto-kodetzaileak beste transformazio batzuekin konbinatzen dituztenak. Kasu hauetan, datu-lagin bakoitzari hautatutako transformazioa aplikatzen zaio, eta ondoren, auto-kodetzailearen bitartez jatorrizko lagina berreraikitzen da.

Adibide gisa, [21] lanean proposatutako aitzakia-atazan, irudien errepresentazioak ikasteko sarrera-datuaren zati bat maskaratzea (zati bat ezabatzea) proposatzen da transformazio gisa (ikus 4 irudia). Aitzakia-ataza zati bat maskaratu dituzten datu-laginak berreraikitzea da. Horretarako, $f^{(a)}$ ereduak kodetzaile batez eta aitzakia-modulua den deskodetzaile batez osatuta egongo da, sarreran maskaratu lagina hartuko du, eta egoera idealean jatorrizko lagina \mathbf{x}^i itzuliko du. Egileek asमितzen dute maskaratu zatiak iragartzeko, ereduak irudi osoen testuingurua ulertu behar duela, kodetzailearen errepresentazio esanguratsuak atzemateko ahalmena bultzatuz. Ondoren, aitzakia-modulua sailkapen zeregin-modulu batez ordezkatzeko da, eta irudien sailkapenean oinarritutako zeregin-ataza bat ikasten da aurre-entrenatutako kodetzailearen errepresentazioak oinarritzat hartuz.

Literaturan, maskaratze bidezko berreraikitze auto-gainbegiratuaren datu-mota desberdinetan aplikatzen duten lanak aurkitu ditzakegu, hala nola, denborazko serieetan [22, 23] eta hizkuntzaren prozesamenduan [24]. Bestalde, badaude beste lan batzuk zarata Gaussiarraren injekzioa erabiltzen dutenak aitzakia-ataza hauetarako transformazio gisa, datu-mota desberdinen errepresentazio-ikaskuntzarako [25].

3.3. Iragarpen auto-gainbegiratuaren

Iragarpen auto-gainbegiratuaren, datu-mota batzuek berezkoak dituzten denbora-dependentsiak erabiltzen dira aitzakia-atazak eraikitzeko. Izan bedi denboraren menpekota den $\mathbf{x} \in \mathbb{R}^{D \times T}$ lagin bat, non D laginaren dimentsio kopurua eta T denboran zehar egindako laginaren neurketakopuru osoa diren. Era honetan, $\mathbf{x}_t \in \mathbb{R}^D$ -k laginak t unean duen balioa adierazten du. Multzo honetan biltzen diren aitzakia-atazetan, jatorrizko laginaren $\mathbf{x}_{t-w,t} = (\mathbf{x}_{t-w}, \mathbf{x}_{t-w+1}, \dots, \mathbf{x}_t)$ denbora-leiho bat oinarritzat hartuz, lagin horren hurrengo p puntuz osatutako denbora-leiho $\mathbf{x}_{t+1,t+p} = (\mathbf{x}_{t+1}, \dots, \mathbf{x}_{t+p})$ iragartzen da.



5. irudia. Iragarpen auto-gainbegiratu. Uneko denbora-leiho bat sarrera gisa erabiliz, ereduak laginaren hurrengo balioak iragartzen ikasi behar du.

Hizkuntzaren prozesamendurako lan batean proposatutako aurre-entrenamendurako aitzakia-ataza daukagu (ikusi 5 irudia) honen adibide gisa [26]. Honetan, hitz-sekuentzia bat erabiltzen da ereduaren sarrera gisa (denbora leihoa) kodetzailearen eta aitzakia-moduluaren bitartez sekuentziaren hurrengo hitza iragartzeko. Honen bitartez, kodetzaileak sortzen dituen errepresentazioek kontzeptuen testuinguru eta erlazioa atzemango dituzte. Behin aurre-entrenatuta, aitzakia-modulua sailkapenerako zeregin-modulu batez ordezkatzeko da eta ikasitako errepresentazioak sentimendu analisis oinarritutako zeregin-ataza bat ikasteko erabiltzen dira, hau da, testu baten emozioak eta iritziak automatikoki identifikatzeko eta sailkatzeko.

Multzo honetako aitzakia-atazak bideoen errepresentazio ikaskuntzan [27] eta denborazko serieen arloan [28] ere aplikatu izan dira.

4. Ikaskuntza kontrastatzailea

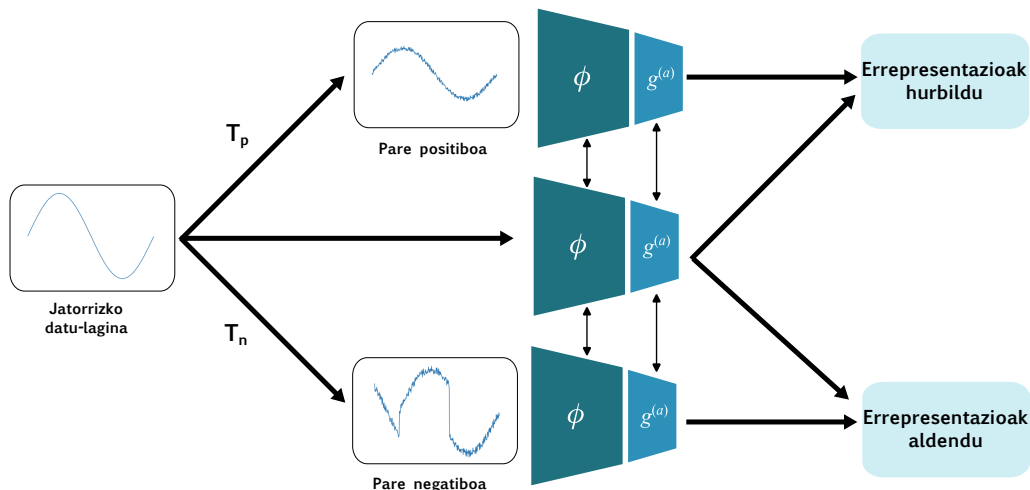
Ikaskuntza kontrastatzaileak (*contrastive learning*, ingelesez) datu-laginen arteko antzekotasun nabarmentzean oinarritzen da. Testuinguru honetan erabiltzen diren ereduak sarrerako datuak dimentsio txikiagoko espazio berri batean kodetzen dituzte kodetzaile baten bitartez. Ondoren, espazio horretan ikasitako errepresentazioak datuen arteko antzekotasunaren arabera izatera bultzatzen dira. Zehazki, bi datu-lagin zenbait irizpideren arabera antzekoak badira (literaturan pare positiboa osatzea deritzona), ereduak haien errepresentazioak elkarrengandik hurbil mantentzen saiatuko da. Aldiz, laginak ez badira antzekoak (hau da, pare negatiboa osatzen badute), haien errepresentazioak ahal den heinean aldenduko ditu ereduak. Horrela, ereduak datuen baitako antzekotasun esanguratsua atzemango dituela asमितzen da. Ezagutza horrek balio handia duela ikusi da, ereduaren errendimendua hobetu baitezake zeregin-ataza anitzetan, bide laburrak saiheztuz [29].

Kategoria honetan sartzen diren aitzakia-atazen arteko bereizketa nagusia, pare positiboak eta negatiboak osatzeko hartutako irizpideetan oinarritzen da. Horren arabera, nahiz eta literaturan aitzakia-ataza mota ugari bereizten diren, bi dira oinarritzkoenak: *transformazio-kontrastea* (*transformation contrast*) eta *testuinguru-kontrastea* (*sampling contrast*).

4.1. Transformazio-kontrastea

Transformazio-kontrastea pare kontrastatzaileak eratzeko teknika ohikoena da, non sarrerako datuei transformazioak aplikatzen zaizkien pare positiboak eta negatiboak sortzeko. Zehazki, sarrerako x_i lagin bakoitzari, aingura deritzona, T_p transformazio positibo bat aplikatzen zaio, $x_i^{(p)}$ pare positiboa osatuz. Hori oinarritzat hartuz, ereduak x_i ainguraren eta $x_i^{(p)}$ pare positiboaren errepresentazioak hurbiltzen saiatuko da, ainguraren eta $x_i^{(n)}$ pare negatiboaren errepresentazioak aldentzen dituen bitartean. $x_i^{(n)}$ pare negatiboa osatzeko aukera ohiko bat x_i aingurari T_n transformazio negatibo bat aplikatzea da.

Pareak eratzeko transformazioei dagokienez, T_p transformazio positiboaren helburua ereduak transformazio horrekiko inbariantza lortzea da. Aldiz, T_n transformazio negatiboak proposatzean,



6. irudia. Transformazio-contrastea. Jatorrizko datu-laginari transformazio positibo bat eta negatibo bat aplikatuz, pare positibo bat eta negatibo bat sortzen dira. Horrela, helburua ainguraren eta pare positiboaren errepresentazioak hurbiltzea izango da, ainguraren eta pare negatiboaren errepresentazioak aldentzen diren bitartean.

helburua datuen berezko ezaugarriak aldatzea da, aingurarekiko desberdina den ikuspegi berri bat sortuz. Behin pareak eratuta, $f^a(\cdot)$ ereduak $\phi(\cdot)$ kodetzaileak sortutako ainguraren $\mathbf{z}_i = \phi(\mathbf{x}_i)$ eta pare positiboaren $\mathbf{z}_i^{(p)} = \phi(\mathbf{x}_i^{(p)})$ errepresentazioak hurbilduko ditu, aipatutako T_p transformazioarekiko inbariantza bultzatuz. Aldi berean, ainguraren $\mathbf{z}_i = \phi(\mathbf{x}_i)$ eta pare negatiboaren $\mathbf{z}_i^{(n)} = \phi(\mathbf{x}_i^{(n)})$ errepresentazioak aldentuko ditu [32].


Multzo honetako lanen desberdintasun nagusia datuen testuinguruaren araberrako transformazio positiboaren eta negatiboaren aukeraketan dago. Adibidez, [33] lanean denborazko serieen errepresentazioen ikaskuntzarako transformazioetan oinarritutako ikaskuntza kontrastatzailea erabiltzen dute (ikusi 6 irudia). Zarata Gaussiarraren injekzioa eta balioen eskalatzea konbinatzen dituzte transformazio positibo gisa, perturbazio horiekiko inbariantzia bultzatu nahian. Aldi berean, zarata Gaussiarraren injekzioa eta denbora-segida osatzen duten azpi-sekuentzien permutazioa (azpi-sekuentzian ordena aldatzea) konbinatzen dituzte ainguraren pare negatiboak sortzeko. Behin eredu aitzakia-ataza kontrastatzailean entrenatuta, zeregin-modulu bat erantzen diote aurre-entrenatutako kodetzaileari, eta sailkapenean oinarritutako zeregin-ataza ikasten dute ikasitako errepresentazioak moduluaren sarrera gisa erabiliz.

Transformazioetan oinarritutako ikaskuntza kontrastatzailea lan askotan erabiltzen da, hainbat datu-motei lotutako errepresentazio esanguratsuak ikasteko, testuinguru bakoitzaren araberrako transformazio positibo eta negatibo egokiak proposatuz [29, 30].

4.2. Testuinguru-contrastea

Testuinguru-contrastean, transformazioak erabili ordez, datuen berezko ezaugarri buruzko intuizioa erabiltzen da pare kontrastatzaileak eratzeko. Kasu honetan, \mathbf{x}_i ainguraren pare positibo eratzeko, sarrera datu-multzoko irizpide batzuen araberraren antzekoa den $\mathbf{x}_i^{(p)}$ datu-lagin bat aukeratzen da. Aldiz, pare negatibo osatzeko, \mathbf{x}_i aingurarekiko desberdina dela asumitzen dugun $\mathbf{x}_i^{(n)}$ datu-lagin bat aukeratzen da. Horrela, $f^a(\cdot)$ ereduak $\phi(\cdot)$ kodetzaileak sortutako ainguraren $\mathbf{z}_i = \phi(\mathbf{x}_i)$ eta pare positiboaren $\mathbf{z}_i^{(p)} = \phi(\mathbf{x}_i^{(p)})$ errepresentazioak hurbilduko ditu, pare negatiboaren $\mathbf{z}_i^{(n)} = \phi(\mathbf{x}_i^{(n)})$ errepresentazioa aldentzen duen bitartean.

Teknika hau oso lagungarria izan daiteke bide laburrak ekiditeko. Hori ulertzeko, gogora de-



7. irudia. Testuinguru-kontrastea. Datuen testuinguruan oinarritutako irizpide bat izanik, jatorrizko datu-laginarekiko pare positiboa eta negatiboa osatuko duten bi datu-lagin aukeratu dira. Horrela, helburua ainguraren eta pare positiboaren errepresentazioak hurbiltzea izango da, ainguraren eta pare negatiboaren errepresentazioak aldentzen diren bitartean.

zagan sarreran azaldutako bide labur posiblea katuen eta txakurren irudien sailkapenean: etxe barruko atzealdea duten irudiei 'katua' klasea eta kaleko irudiei 'txakurra' klasea esleitzea. Bide labur hori ekiditeko, klase bereko datu-laginak pare positibo gisa eta klase desberdinekoak pare negatibo gisa erabil ditzakegu (ikusi 7 irudia). Zehazki, gure aingura katu baten irudia bada, katu bat duen argazki bat eta txakur bat duen beste argazki bat har ditzakegu ainguraren pare positibo eta negatibo gisa, hurrenez hurren. Horrela, katuen irudien errepresentazioak hurbilago egongo dira kodetzaileak sortutako dimentsio txikiagoko espazioan, txakurren irudien errepresentazioak horietatik aldentuta egonik. Horrek bide laburra ekiditen lagunduko du. Aitzakia-ataza hori eta sailkapenean oinarritutako zeregin-ataza era bateratuan ikasi daitezke lehen deskribatutako bide laburra ekiditeko.

Aurreko adibideaz gain, badaude beste zenbait lan testuinguru-kontrastea erabiltzen dutenak, hainbat datu-moten errepresentazio esanguratsuak ikasteko eta problema bakoitzaren testuinguruaren arabera pare kontrastatzaileak osatzeko irizpideak proposatzen dituztenak [29, 31, 32].

5. Ondorioak

Ikaskuntza gainbegiratuaren mugak kontutan hartuta, ikaskuntza auto-gainbegiratu ikaskuntza paradigma interesgarri moduan aurkeztu da literaturan azken urteotan. Ikaskuntza paradigma honen helburua zeregin-ataza jakin baterako erabilgarriak izango diren datuen errepresentazioak ikastea da, horretarako zeregin-atazako etiketak erabiliko ez dituen aitzakia-ataza bat baliatuz.

Artikulu honek datuen errepresentazio esanguratsuen ikaskuntza bultzatzen duten ikaskuntza auto-gainbegiratuaren oinarritutako aitzakia-atazak laburbiltzen ditu. Nahiz eta dibertsitate handia egon, aitzakia-atazak bi multzo nagusitan sailkatzen ditugu: ikaskuntza auto-prediktiboa eta ikaskuntza kontrastatzailea. Multzo bakoitzean aurki daitezkeen ataza mota desberdinak definitzen ditugu, eta hauek datu-mota desberdinetan nola aplikatu daitezkeen erakusten duten adibide argiak ematen ditugu.

Hona hemen etorkizunerako proposatzen ditugun hainbat ikerkuntza-lerro ikaskuntza auto-gainbegiratuaren arloan:

- **Oinarri teorikoen garapena.** Nahiz eta ikaskuntza auto-gainbegiratuak errepresentazio

esanguratsuen ikaskuntza bultzatzeko teknika oso baliagarriak biltzen dituen, lan oso gutxi aztertu dute paradigma honen arrakastaren arrazonamendu teorikoa. Ondorioz, beharrezkoa da metodologia honen oinarri teorikoak finkatzen dituzten lanak garatzea.

- **Aitzakia-atazaren aukeraketa.** Zeregin-ataza bakoitza burutzen ikasteko baliagarriak izan daitezkeen aitzakia-atazen azterketari buruzko lanen falta dago. Interesgarria izango litzateke zeregin-ataza jakin bakoitza burutzen ikasteko balio handiko aitzakia-atazak diseinatzeke irizpideak esploratzea.
- **Aitzakia-ataza moten konbinazioa.** Ikaskuntza auto-prediktiboan eta ikaskuntza kontrastatzailean oinarritutako aitzakia-atazak erabiltzen dituzten lanek emaitza onak ematen dituzte. Hala ere, aitzakia-ataza bat baino gehiago konbinatu daitekeenez lan berean, interesgarria litzateke ataza auto-prediktiboak eta kontrastatzaileak konbinatzen dituzten lanak garatzea.

Bibliografia

- [1] Michalski, R. S., Carbonell, J. G., Mitchell, T. M. (Eds.). (2013). *Machine learning: An artificial intelligence approach*. Springer Science Business Media.
- [2] Voulodimos, A., Doulamis, N., Doulamis, A., Protopapadakis, E. (2018). Deep learning for computer vision: A brief review. *Computational intelligence and neuroscience*, 2018.
- [3] Chowdhary, K., Chowdhary, K. R. (2020). Natural language processing. *Fundamentals of artificial intelligence*, 603-649.
- [4] Bertolini, M., Mezzogori, D., Neroni, M., Zammori, F. (2021). Machine Learning for industrial applications: A comprehensive literature review. *Expert Systems with Applications*, **175**, 114820.
- [5] Miotto, R., Wang, F., Wang, S., Jiang, X., Dudley, J. T. (2018). Deep learning for healthcare: review, opportunities and challenges. *Briefings in bioinformatics*, **19(6)**, 1236-1246.
- [6] Oquab, M., Bottou, L., Laptev, I., Sivic, J. (2015). Is object localization for free?-weakly-supervised learning with convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 685-694).
- [7] Geirhos, R., Jacobsen, J. H., Michaelis, C., Zemel, R., Brendel, W., Bethge, M., Wichmann, F. A. (2020). Shortcut learning in deep neural networks. *Nature Machine Intelligence*, **2(11)**, 665-673.
- [8] Bengio, Y., Courville, A., Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, **35(8)**, 1798-1828.
- [9] Liu, X., Zhang, F., Hou, Z., Mian, L., Wang, Z., Zhang, J., Tang, J. (2021). Self-supervised learning: Generative or contrastive. *IEEE transactions on knowledge and data engineering*, **35(1)**, 857-876.
- [10] Zhai, X., Oliver, A., Kolesnikov, A., Beyer, L. (2019). S4l: Self-supervised semi-supervised learning. In *Proceedings of the IEEE/CVF international conference on computer vision* (pp. 1476-1485).
- [11] Tschannen, M., Bachem, O., Lucic, M. (2018). Recent advances in autoencoder-based representation learning. *arXiv preprint arXiv:1812.05069*.

- [12] Gui, J., Chen, T., Zhang, J., Cao, Q., Sun, Z., Luo, H., Tao, D. (2023). A survey on self-supervised learning: Algorithms, applications, and future trends. arXiv preprint arXiv:2301.05712.
- [13] Misra, I., Maaten, L. V. D. (2020). Self-supervised learning of pretext-invariant representations. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 6707-6717).
- [14] Doersch, C., Zisserman, A. (2017). Multi-task self-supervised visual learning. In Proceedings of the IEEE international conference on computer vision (pp. 2051-2060).
- [15] Gidaris, S., Singh, P., Komodakis, N. (2018). Unsupervised representation learning by predicting image rotations. arXiv preprint arXiv:1803.07728.
- [16] Golan, I., El-Yaniv, R. (2018). Deep anomaly detection using geometric transformations. *Advances in neural information processing systems*, **31**.
- [17] Blázquez-García, A., Conde, A., Mori, U., Lozano, J. A. (2021). Water leak detection using self-supervised time series classification. *Information Sciences*, **574**, 528-541.
- [18] Zhang, J., Saleeby, K., Feldhausen, T., Bi, S., Plotkowski, A., Womble, D. (2021, December). Self-supervised anomaly detection via neural autoregressive flows with active learning. In *NeurIPS 2021 workshop on deep generative models and downstream applications*.
- [19] Ghosal, D., Majumder, N., Mihalcea, R., Poria, S. (2021). Stack: Sentence ordering with temporal commonsense knowledge. arXiv preprint arXiv:2109.02247.
- [20] Bank, D., Koenigstein, N., Giryes, R. (2023). Autoencoders. *Machine learning for data science handbook: data mining and knowledge discovery handbook*, 353-374.
- [21] Pathak, D., Krahenbuhl, P., Donahue, J., Darrell, T., Efros, A. A. (2016). Context encoders: Feature learning by inpainting. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2536-2544).
- [22] He, K., Chen, X., Xie, S., Li, Y., Dollár, P., Girshick, R. (2022). Masked autoencoders are scalable vision learners. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 16000-16009).
- [23] Feichtenhofer, C., Li, Y., He, K. (2022). Masked autoencoders as spatiotemporal learners. *Advances in neural information processing systems*, **35**, 35946-35958.
- [24] Devlin, J., Chang, M. W., Lee, K., Toutanova, K. (2018). Bert: Pre-training of deep bidirectional transformers for language understanding. arXiv preprint arXiv:1810.04805.
- [25] Tschannen, M., Bachem, O., Lucic, M. Recent advances in autoencoder-based representation learning. arXiv 2018. arXiv preprint arXiv:1812.05069.
- [26] Dai, A. M., Le, Q. V. (2015). Semi-supervised sequence learning. *Advances in neural information processing systems*, **28**.
- [27] Schiappa, M. C., Rawat, Y. S., Shah, M. (2023). Self-supervised learning for videos: A survey. *ACM Computing Surveys*, **55(13s)**, 1-37.
- [28] Zhang, K., Wen, Q., Zhang, C., Cai, R., Jin, M., Liu, Y., ... Pan, S. (2024). Self-supervised learning for time series analysis: Taxonomy, progress, and prospects. *IEEE Transactions on Pattern Analysis and Machine Intelligence*.

- [29] Jaiswal, A., Babu, A. R., Zadeh, M. Z., Banerjee, D., Makedon, F. (2020). A survey on contrastive self-supervised learning. *Technologies*, **9(1)**, 2.
- [30] Chen, T., Kornblith, S., Norouzi, M., Hinton, G. (2020, November). A simple framework for contrastive learning of visual representations. In *International conference on machine learning* (pp. 1597-1607). PMLR.
- [31] Le-Khac, P. H., Healy, G., Smeaton, A. F. (2020). Contrastive representation learning: A framework and review. *Ieee Access*, **8**, 193907-193934.
- [32] Cai, T. T., Frankle, J., Schwab, D. J., Morcos, A. S. (2020). Are all negatives created equal in contrastive instance discrimination?. *arXiv preprint arXiv:2010.06682*.
- [33] Eldele, E., Ragab, M., Chen, Z., Wu, M., Kwoh, C. K., Li, X., Guan, C. (2021). Time-series representation learning via temporal and contextual contrasting. *arXiv preprint arXiv:2106.14112*.