

Stabilizacja ciągłego uczenia samonadzorowanego poprzez regularyzację przestrzeni reprezentacji

14 października 2026

Jan Szablanowski

Promotor: prof. dr hab. inż. Jacek Mańdziuk

Politechnika Warszawska

01

Wprowadzenie do uczenia ciągłego
(ang. *continual learning*)

02

Metody samonadzorowane w uczeniu ciągłym
(ang. *continual self-supervised learning*)

03

Regularyzacja przestrzeni reprezentacji


04

Modele fundamentalne w uczeniu ciągłym

Co, jeśli chcemy użyć naszego wytrenowanego modelu...



w innym kraju?



w innej pogodzie?




z inną kamerą?

Jak dostosowywać model do zmian warunków, nie tracąc wcześniej nabytej wiedzy?


Uczenie wsadowe a uczenie ciągłe

Uczenie wsadowe (batch learning)



Jednoczesny dostęp do danych
ze wszystkich etapów.

Uczenie ciągłe (continual learning)



Sekwencyjny napływ danych i ograniczony
dostęp do wcześniejszych przykładów.

Cel uczenia ciągłego: uczyć się na nowych danych, zachowując wcześniejszą wiedzę.

Scenariusze uczenia ciągłego

Uczenie

Task-Incremental Learning (Task-IL)

Zadanie 1



Zadanie 2



Class-Incremental Learning (Class-IL)

Zadanie 1



Zadanie 2



Domain-Incremental Learning (Domain-IL)

dzień



noc



mgła



Test: wybór klasy

Podajemy zadanie, np. zadanie 1



Wybór tylko spośród klas tego zadania

Wszystkie poznane klasy




Bez identyfikatora zadania

Te same klasy w każdej domenie




Obrazy z dnia, nocy lub mgły
bez informacji o domenie

Wyzwanie: katastrofalne zapominanie



Nauka zadania 2 może pogarszać wyniki na zadaniu 1.

Wyzwanie: dylemat stabilności–plastyczności



Stabilność

Zachowanie wcześniejszej wiedzy.

Plastyczność

Zdolność uczenia się nowych zadań.

Metryki: dokładność i zapominanie

$a_{k,j}$ — dokładność na zadaniu j po etapie treningu k , n — etap oceny.

		Zadanie testowe j		
		1	2	3
Po etapie treningu k	3	$a_{3,1}$	$a_{3,2}$	$a_{3,3}$
	2	$a_{2,1}$	$a_{2,2}$	—
	1	$a_{1,1}$	—	—

Średnia dokładność ↑

Średnia dokładność na wszystkich poznanych zadaniach po zakończeniu etapu n .

$$AA_n = \frac{1}{n} \sum_{j=1}^n a_{n,j}$$

Średnie zapominanie ↓

Średni spadek dokładności na wcześniejszych zadaniach względem ich najlepszych wyników.

$$FM_n = \frac{1}{n-1} \sum_{j=1}^{n-1} \left(\max_{j \leq k < n} a_{k,j} - a_{n,j} \right)$$

Metryki: transfer wiedzy między zadaniami

$a_{k,j}$ — dokładność na zadaniu j po etapie treningu k , n — etap oceny.

		Zadanie testowe j		
		1	2	3
Po etapie treningu k	3	$a_{3,1}$	$a_{3,2}$	$a_{3,3}$
	2	$a_{2,1}$	$a_{2,2}$	—
	1	$a_{1,1}$	—	—

Transfer wsteczny ↑

Zmiana dokładności na wcześniejszych zadaniach względem wyników tuż po ich nauczaniu.

$$BWT_n = \frac{1}{n-1} \sum_{j=1}^{n-1} (a_{n,j} - a_{j,j})$$

Transfer w przód ↑


Czy wcześniejsza wiedza poprawia wynik na nowym zadaniu w porównaniu z treningiem od zera?

$$FWT_n = \frac{1}{n-1} \sum_{j=2}^n (a_{j,j} - \tilde{a}_j)$$

$\tilde{a}_j$ — wynik nauki tylko zadania j od zera.


Split / Permuted MNIST

Pary cyfr lub permutacje pikseli.



Split CIFAR-100

100 klas; np. 5 zadań po 20 klas.



ImageNet

Klasy dzielone na kolejne zadania.



DomainNet

345 klas w 6 domenach.

Replay

Powtarzamy dawne przykłady.

$$\mathcal{L}_{\text{CL}} = \mathcal{L}_{\text{new}} + \mathcal{L}_{\text{replay}}$$

Przykład: **Experience Replay (ER)**

Regularyzacja parametrów

Chronimy ważne parametry dla wcześniejszych zadań.

$$\mathcal{L}_{\text{CL}} = \mathcal{L}_{\text{new}} + \|\theta - \theta^*\|_{\Sigma}$$

θ^* — wcześniejsze, zamrożone parametry.

Σ — macierz opisująca wagność parametrów.

Przykład: **Elastic Weight Consolidation (EWC)**

Regularyzacja funkcjonalna

Ograniczamy zmiany predykcji modelu.


$$\mathcal{L}_{\text{CL}} = \mathcal{L}_{\text{new}} + D(f_{\theta}, f_{\theta^*})$$

D — miara rozbieżności predykcji bieżącego i poprzedniego, zamrożonego modelu.

Przykład: **Learning without Forgetting (LwF)**


Experience Replay (ER)

Nowe dane + przykłady z pamięci.



Ograniczony bufor wymaga selekcji przykładów, np. metodą próbkowania zbiornikowego (ang. *reservoir sampling*).

EWC: chronimy ważne parametry



Bez ochrony

Zapominanie zadania A.

Jednakowa kara

Ograniczamy zmiany wszystkich wag tak samo.

EWC


Silniej chronimy parametry ważne dla A.

$$\mathcal{L}(\theta) = \underbrace{\mathcal{L}_{\text{new}}(\theta)}_{\text{nowe zadanie}} + \underbrace{\frac{\lambda}{2} \sum_{i=1}^P F_i (\theta_i - \theta_i^*)^2}_{\text{ważona kara za zmianę parametrów}}$$

θ^* — wcześniejsze parametry.

F_i — i -ty element diagonalny macierzy informacji Fishera: ważność parametru dla wcześniejszego zadania.

(e) Learning without Forgetting



Destylacja wiedzy

Poprzedni model podaje wzorcowe predykcje dawnych klas.

Nowe dane

Uczymy się nowego zadania i ograniczamy zmiany tych predykcji.

$$\mathcal{L}(\theta) = \underbrace{\mathcal{L}_{\text{new}}(\theta)}_{\text{nowe zadanie}} + \underbrace{\frac{\lambda}{N} \sum_{n=1}^N D_{\text{KL}}(p_{\text{old}}(\cdot | x_n) \| p_{\theta}(\cdot | x_n))}_{\text{dopasowanie predykcji dawnych klas na nowych danych}}$$

$p_{\text{old}}, p_{\theta}$ — predykcje zamrożonego poprzedniego i bieżącego modelu.

D_{KL} — dywergencja Kullbacka–Leiblera (miara rozbieżności rozkładów predykcji).

Metody samonadzorowane w uczeniu ciągłym

Czy etykieta mówi wszystko o obrazie?



Etykieta: ograniczenie do 50 km/h.


Dziś: rozpoznawanie znaku.

A jutro: ocena widoczności?


Nowe obrazy mogą być dostępne wcześniej niż ich etykiety.

A gdyby sygnał do nauki pochodził z samych obrazów?

Etapy uczenia samonadzorowanego (self-supervised learning, SSL)



1. **Uczenie reprezentacji bez etykiet klas.**
(ang. *pretext task*)



2. **Ocena reprezentacji z etykietami.**
(ang. *downstream task*)

Dlaczego SSL w uczeniu ciągłym?

- ▶ **Bez czekania na etykiety**

Sygnał uczący pochodzi z napływających danych.

- ▶ **Stabilniejsze reprezentacje**

Część badań wskazuje, że uczenie samonadzorowane jest mniej podatne na katastrofalne zapominanie.

- ▶ **Uczenie online i task-free**

Możliwa nauka ze strumienia danych bez jawnych granic zadań.

Duże modele i reprezentacje do wielu zadań


DINOv3 — pretrening samonadzorowany; zbiór bazowy: 1,7 mld obrazów.



U góry obrazy, u dołu wizualizacja ich cech (PCA).

Jak dalej uczyć taki model, zachowując wcześniejszą wiedzę?

DINO: struktura przestrzeni reprezentacji



DINOv2 ViT-B/14 · dwuwymiarowa wizualizacja

Struktura semantyczna

Obrazy o podobnej treści tworzą grupy w przestrzeni cech.

Hipoteza dla uczenia ciągłego

Kontrola geometrii reprezentacji może ograniczać zapominanie podczas dalszego uczenia.

Regularyzacja przestrzeni reprezentacji

$$\mathcal{L} = \underbrace{\mathcal{L}_{\text{task}}}_{\text{cel uczenia}} + \underbrace{\lambda \mathcal{L}_{\text{reg}}}_{\text{regularyzacja}}$$

Stabilizacja geometrii reprezentacji

Kontrolujemy strukturę przestrzeni cech, aby cechy zachowały zróżnicowanie.


Przykłady: VICReg, SIGReg / LeJEPa

Stabilizacja reprezentacji w czasie

Ograniczamy zmiany cech, aby zachować wcześniejszą wiedzę.

Przykłady: CaSSLe, PNR, Osiris

VICReg: podobieństwo, wariancja i kowariancja



Podobieństwo widoków

Dwa widoki obrazu mają bliskie cechy.

Wariancja

Cechy nie skupiają się w jednym punkcie.


Kowariancja

Ograniczamy korelacje współrzędnych.

$$\mathcal{L} = \underbrace{\lambda s(Z_A, Z_B)}_{\text{podobieństwo}} + \underbrace{\mu [v(Z_A) + v(Z_B)]}_{\text{wariancja}} + \underbrace{\nu [c(Z_A) + c(Z_B)]}_{\text{kowariancja}}$$

SIGReg i LeJEPA: kontrola rozkładu cech

SIGReg — Sketched Isotropic Gaussian Regularization




- **Dopasowanie widoków:** zbliżamy osadzenia widoków tego samego obrazu.
- **Losowe projekcje:** rzutujemy osadzenia z partii na losowe kierunki.
- **Dopasowanie rozkładów:** zbliżamy rozkład projekcji do $\mathcal{N}(0, 1)$ za pomocą testu Epps–Pulleya.

$$\mathcal{L}_{\text{LeJEPA}} = (1 - \lambda)\mathcal{L}_{\text{pred}} + \lambda\mathcal{L}_{\text{SIGReg}}$$

Macierz ewaluacji zmodyfikowanej metody LeJEPA

Split CIFAR-100 · 5 etapów po 20 klas · ResNet-18 · 100 epok na etap



Ewaluacja liniowa

Po każdym etapie zamrażamy enkoder i uczymy nowy klasyfikator liniowy z etykietami na wszystkich 100 klasach. Test oceniamy osobno dla każdego zadania.


Pierwsze zadanie

58,2% → 58,1%

Po etapie 1 → po etapie 5

Po ostatnim etapie cechy nadal pozwalają rozpoznawać klasy pierwszego zadania.

CaSSLe: zachować wcześniejsze reprezentacje



Bieżący model (student)

Uczy się na nowych obrazach.

Poprzedni model (nauczyciel)

Wyznacza wcześniejsze cechy tych samych obrazów.

Predyktor

Mapuje nowe cechy do wcześniejszej przestrzeni.

Funkcja straty

Porównuje wyjście predyktora z cechami zamrożonego nauczyciela.

Bez bufora dawnych obrazów. Kopia modelu po każdym etapie.

$$\mathcal{L} = \underbrace{\mathcal{L}_{\text{SSL}}(Z_A, Z_B)}_{\text{uczenie nowych cech}} + \underbrace{\mathcal{L}_{\text{SSL}}(p_\psi(Z_A), \text{sg}(\bar{Z}_A))}_{\text{destylacja}}$$

$$Z_A, Z_B \in \mathbb{R}^{N \times d}$$

Cechy dwóch wersji każdego obrazu w partii.
 N — liczba obrazów, d — wymiar cech.

$$\bar{Z}_A$$

Cechy z zamrożonego poprzedniego modelu.

$$p_\psi$$

Predyktor dopasowujący nowe cechy do wcześniejszych.


sg — **stop-gradient**

Zatrzymuje przepływ gradientu do nauczyciela.

Ta sama strata SSL służy też do destylacji.

Czy SSL pomaga w uczeniu ciągłym?


CIFAR-100 · 5 etapów po 20 klas · ResNet-18 · końcowa dokładność ewaluacji liniowej (%)



**Sam SSL nie gwarantuje przewagi.
CaSSLe poprawia jakość reprezentacji w badanym protokole.**

PNR: pseudo-negatywy z poprzedniego modelu

Pseudo-Negative Regularization · rozszerzenie metody CaSSLe zwiększające plastyczność



Pełne punkty: bieżący model. Puste: poprzedni model.

SSL + destylacja


Zbliżamy widoki i zachowujemy wcześniejsze cechy.

Pseudo-negatyw

Reprezentacja drugiego widoku z poprzedniego modelu.

Odpychamy od pseudo-negatywu bieżące reprezentacje (czerwona strzałka).

Osiris: dwa projektory, trzy cele



Nowe dane

Uczymy cechy przez projektor g .

Dawna wiedza

Chronimy ją przez projektor h , wykorzystując destylację lub replay.

Konsolidacja między zadaniami

Odróżniamy nowe i dawne przykłady w przestrzeni h .

Jeden enkoder, dwa projektory i bufor dawnych przykładów.

Modele fundamentalne w uczeniu ciągłym

Modele po pretreningu jako punkt startowy

Model fundamentalny
po pretreningu
samonadzorowanym


+

Mechanizm
uczenia ciągłego

Wyuczone reprezentacje

Wykorzystanie lub adaptacja cech
na kolejnych danych

RanPAC: losowa projekcja cech



Losowa projekcja

Stała warstwa zwiększa wymiar cech i dodaje nieliniowość.


Aktualizacja klasyfikatora

Zachowujemy statystyki cech i klas, bez bufora dawnych danych.

CIFAR-100 · ViT-B/16 · rozkład cech w przestrzeni 2D

Enkoder i projekcja pozostają zamrożone.

InfLoRA: ograniczenie interferencji między zadaniami



LoRA

Low-Rank Adaptation

Wagi modelu pozostają zamrożone. Uczymy tylko dodawaną do nich korektę.

InfLoRA


Dobiera kierunki poprawki **ortogonalne** do podprzestrzeni dawnych zadań.

$$\Delta W_t = A_t B_t$$

A_t — uczona macierz adaptacji.

B_t — zamrożona baza ortogonalna do wcześniejszych cech.

Rosnący horyzont zadań agentów opartych na LLM



Kiedy pamięć i kontekst przestają wystarczać,
a potrzebna staje się trwała aktualizacja wiedzy?

- ▶ **Uczenie ciągłe** rozwija metody stopniowego zdobywania i zachowywania wiedzy, inspirowane ludzkim uczeniem się przez całe życie (ang. *lifelong learning*).
- ▶ **Uczenie samonadzorowane** rozszerza możliwości uczenia ciągłego poza nadzorowaną klasyfikację, ale stawia nowe wyzwania.
- ▶ **Regularyzacja przestrzeni reprezentacji** kontroluje strukturę i zmiany cech oraz może ograniczać katastrofalne zapomnienie.
- ▶ **Modele fundamentalne** dostarczają użytecznych reprezentacji, które można wykorzystywać lub adaptować w uczeniu ciągłym.

Dziękuję za uwagę

Pytania i dyskusja

- [1] L. Wang, X. Zhang, H. Su i J. Zhu. *A Comprehensive Survey of Continual Learning: Theory, Method and Application*. IEEE Trans. Pattern Anal. Mach. Intell., 2024.
- [2] J. Kirkpatrick i in. *Overcoming catastrophic forgetting in neural networks*. Proceedings of the National Academy of Sciences, 2017.
- [3] Z. Li i D. Hoiem. *Learning without Forgetting*. ECCV, 2016.
- [4] A. Bardes, J. Ponce i Y. LeCun. *VICReg: Variance-Invariance-Covariance Regularization for Self-Supervised Learning*. ICLR, 2022.
- [5] R. Balestriero i Y. LeCun. *LeJEPA: Provable and Scalable Self-Supervised Learning Without the Heuristics*. arXiv:2511.08544, 2025.
- [6] E. Fini i in. *Self-Supervised Models are Continual Learners*. CVPR, 2022.
- [7] S. Cha, K. Cho i T. Moon. *Regularizing with Pseudo-Negatives for Continual Self-Supervised Learning*. ICML, 2024.
- [8] Y. Zhang i in. *Integrating Present and Past in Unsupervised Continual Learning*. CoLLAs, 2024.
- [9] O. Siméoni i in. *DINOv3*. arXiv:2508.10104, 2025.
- [10] D. Schnaus i in. *Shared Geometry As A Rosetta Stone: Cross-Modal Alignment Without Paired Data*. arXiv:2610.09411, 2026.
- [11] G. M. van de Ven i A. S. Tolias. *Three scenarios for continual learning*. arXiv:1904.07734, 2019.
- [12] M. D. McDonnell i in. *RanPAC: Random Projections and Pre-trained Models for Continual Learning*. NeurIPS, 2023.
- [13] E. J. Hu i in. *LoRA: Low-Rank Adaptation of Large Language Models*. ICLR, 2022.
- [14] Y.-S. Liang i W.-J. Li. *InfLoRA: Interference-Free Low-Rank Adaptation for Continual Learning*. CVPR, 2024.
- [15] METR. *Task-Completion Time Horizons of Frontier AI Models*. Raport internetowy, 2026.