



# Катастрофическое забывание в импульсных нейронных сетях

Денис Ларионов

Kaspersky Neuromorphic AI Conference 2025  
13 ноября 2025

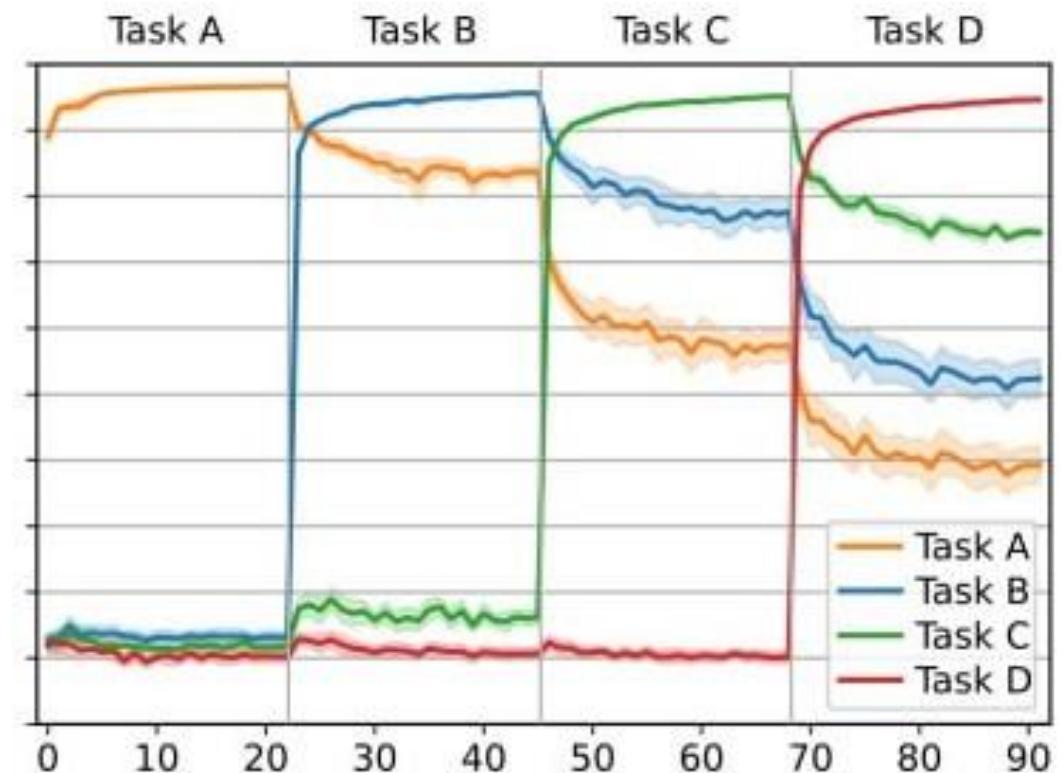
# Непрерывное обучение (continual learning, CL)

Обучение нескольким задачам последовательно, как если бы все задачи были представлены одновременно.

В машинном обучении делается допущение о стационарности распределений данных. Адаптация к новому распределению данных приводит к ухудшению способности работать с предыдущими задачами – **катастрофическому забыванию** (catastrophic forgetting, CF).

Проблематика CL:

- Баланс пластиности обучения и стабильности памяти;
- Возможность различать отличия в распределениях данных как внутри, так и между задачами;
- Оптимизация использования вычислительных ресурсов.



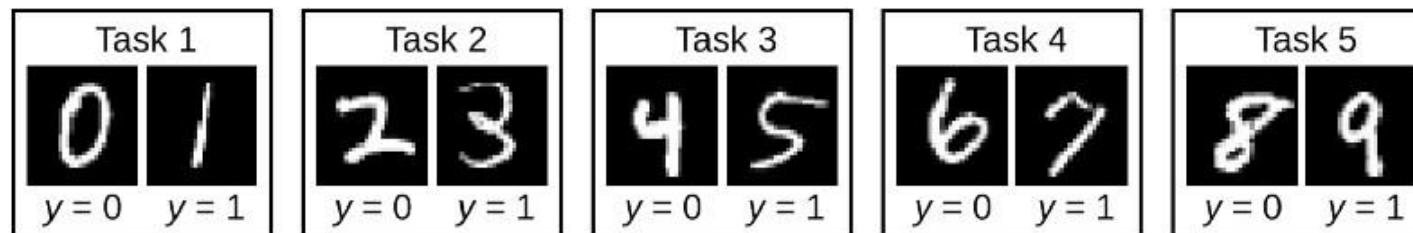
# Типовые сценарии CL

## Виды задач

- **task-based / task-free** - заданы ли границы задач;
- **task- / domain- / class-incremental** - доступны ли идентификаторы задач в тестировании, и если нет, должны ли они определяться;
- **streaming** - в один момент времени предъявляется только один пример;
- **online** - один пример предъявляется только один раз.

## На примере splitMNSIT

- В task-incremental learning (**TIL**) нужно выбрать одну из двух цифр в известной задаче.
- В domain-incremental learning (**DIL**), также нужно выбрать один из двух вариантов, однако идентификатор задачи неизвестен (определить четное число или нет).
- В class-incremental learning (**CIL**) всегда предсказывается одна из 10 цифр.



## Фундаментальная причина забывания – градиентные методы обучения

Практически все успешные стратегии непрерывного обучения, представленные в литературе, предполагают использование градиентных методов оптимизации.

Использование градиентных методов является фундаментальной причиной катастрофического забывания.

Решение проблемы по существу может лежать в плоскости локальных методов обучения, которые позволяют сохранять и использовать информацию, связанную с локальными группами параметров, не используя всю сеть целиком.

Локальное обучение – изменение веса синапса зависит от состояния и активности только связанных с данным синапсом нейронов.

Локальность вычислений - подход к реализации эффективных распределенных вычислительных систем, основанных только на локальных сигналах от соседних физических узлов сети.

Локальность обучения позволяет обеспечить локальность вычислений, что принципиально невозможно при использовании градиентных методов обучения.

# Импульсные нейронные сети

Математической моделью, которая позволяет использовать STDP, конкуренцию и модуляцию обучения, являются импульсные нейронные сети (ИмНС).

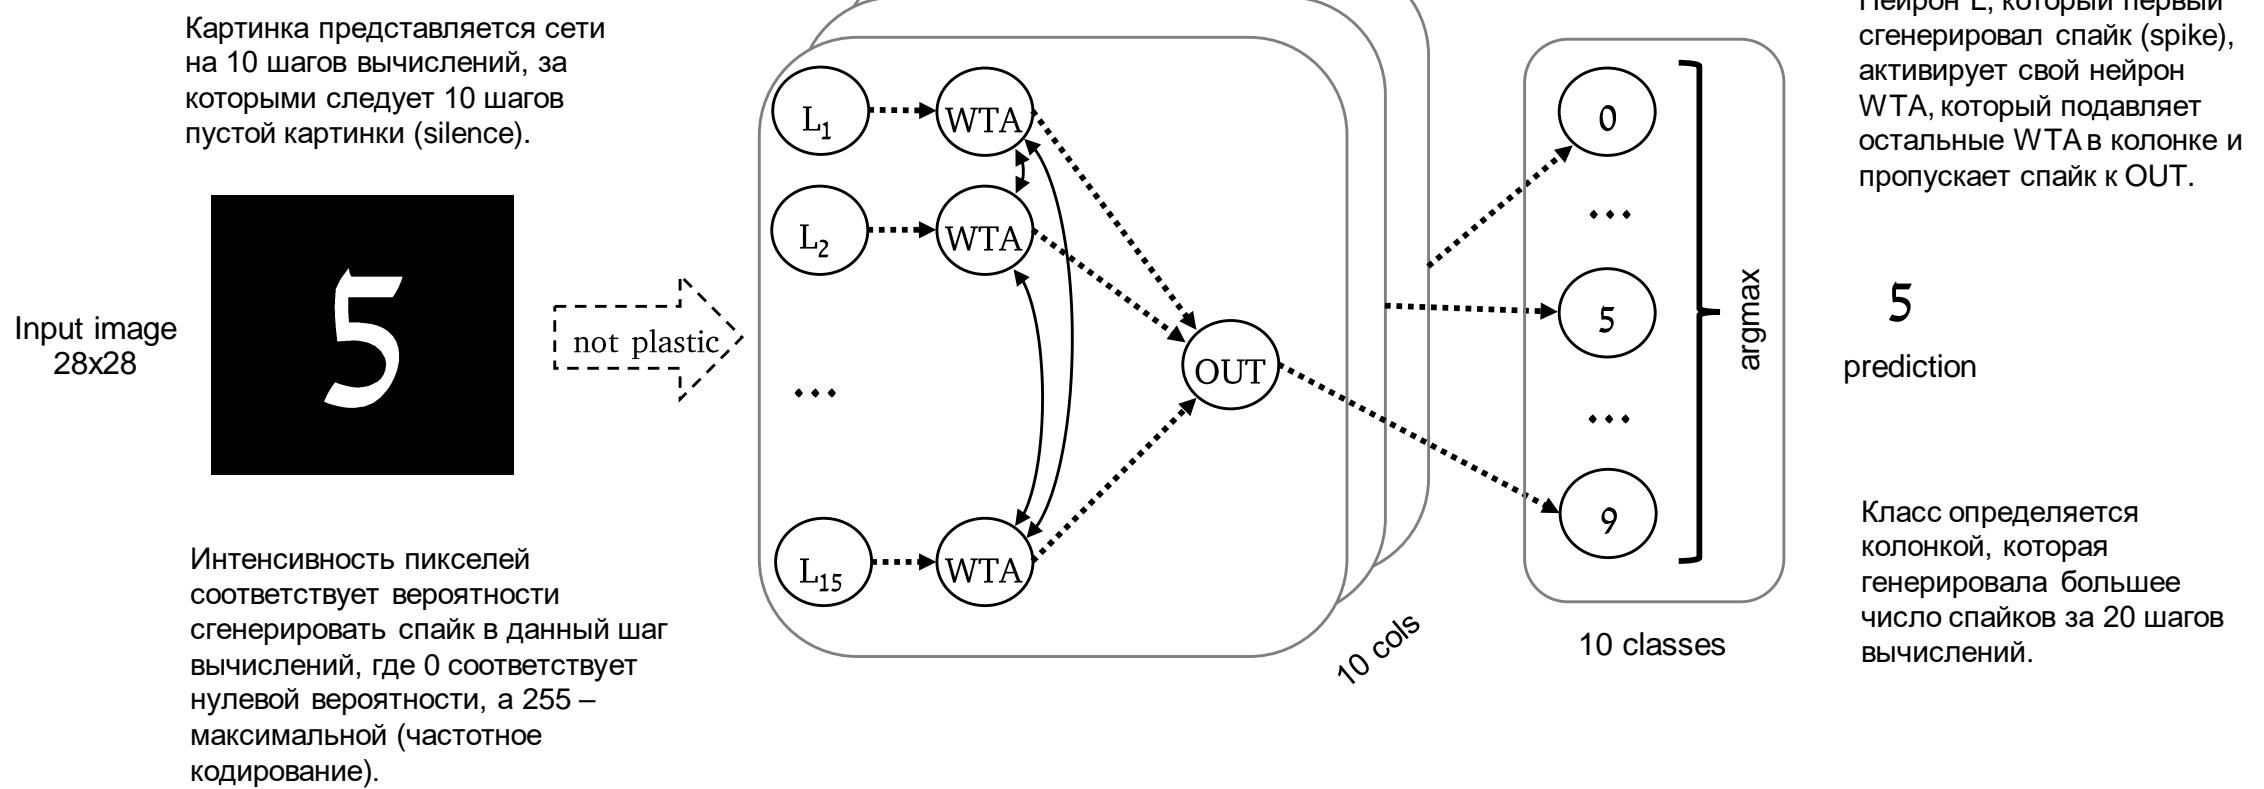
ИмНС уже исследовались в контексте проблемы катастрофического забывания и не показали высокой эффективности (на примере трёхслойной сверточной сети). Одного лишь локального обучения недостаточно.

Решение проблемы катастрофического забывания лежит на более высоком уровне абстракций, где рассматриваются не отдельные нейроны, а их группы, организованные специфическим образом (микроколонки).

Основная идея колоночной организации сети заключается в том, что элементы знаний, которые должны переиспользоваться между задачами в непрерывном обучении, должны быть представлены более функциональными структурами, чем может обеспечить один нейрон.

Поэтому, в соответствии с принципом локальности вычислений, именно микроколонки, а не отдельные нейроны, должны выступать физическим субстратом для хранения полезных знаний в условиях непрерывного обучения.

# CoLaNET: Columnar Layered Network (inference)

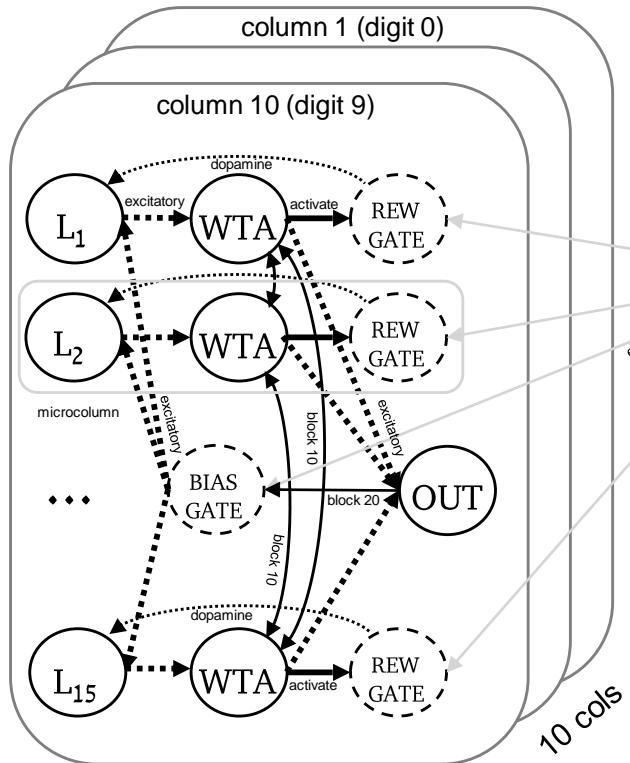


# CoLaNET: Columnar Layered Network (обучение)

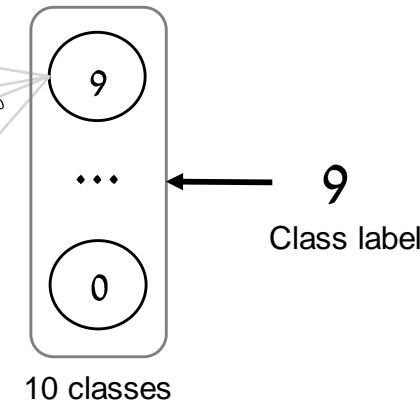
В начале обучения все веса нейронов L равны нулю. С ростом положительной части весов нейроны «закрепляются» на своих паттернах – сложнее активируются на случайные стимулы.



Обучение регулируется тремя факторами: анти-Хеббовской пластичностью (ослабление весов), дофамин-модулируемой пластичностью (усиление весов) и периодической синаптической ренормализацией.



Метка предъявляется на 20 шагов. Каждый класс активирует свою колонку и подавляет остальные.



Каждая колонка на нижних трёх слоях образована тройками нейронов L, WTA и REW GATE. Каждая такая тройка образует одну микроколонку. Одна микроколонка соответствует значительно отличающимся экземплярам (подклассам) одного класса.

# Управление балансом пластиности обучения и стабильности памяти

## Инструменты CoLaNET для непрерывного обучения

- адаптивный порог срабатывания пластичных нейронов;
- количество виртуальных синапсов, которые отвлекают на себя величину изменения веса при ренормализации;
- количество микроколонок в одной колонке.

В CoLaNET адаптивный порог срабатывания  $u_{tr}$  является суммой константной части и дополнительной добавки, которая пропорциональна сумме положительных весов:

$$u_{tr} = u_{const} + \alpha \sum_i w_i^+$$

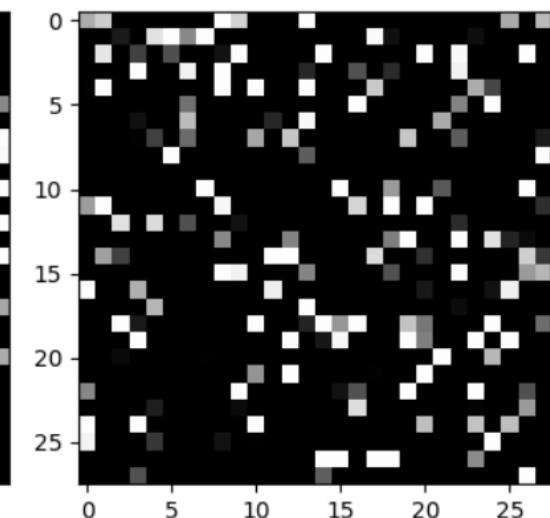
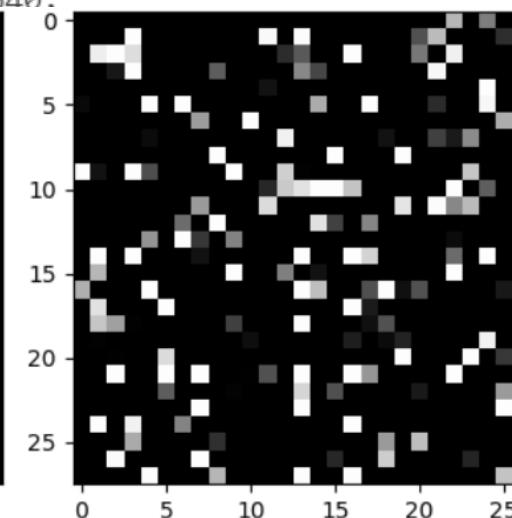
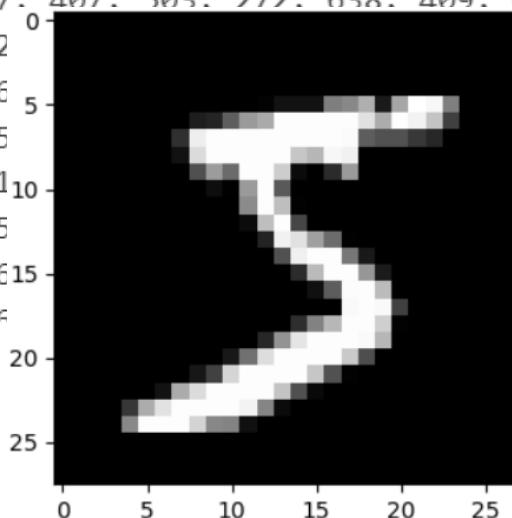
где  $\alpha$  - коэффициент пропорциональности,  $u_{const}$  - фиксированная часть порога (полагается равной 1), а  $w_i^+$  - положительные веса ( $w_i > 0$ ).

Механика адаптивного порога заставляет нейроны, у которых в процессе обучения появились большие веса, становиться менее чувствительными ко всем входным стимулам, что понижает вероятность сработать на случайный паттерн.

## Эксперимент 1: Permuted MNIST

```
np.random.RandomState(seed).permutation(28*28) # what is permutation
```

```
array([693,  85, 647, 392, 765,  14, 299, 711,  55,  31, 122, 172, 255,  
 502, 636, 564,  75,  40, 412, 542, 710, 772, 239, 252, 156,  27,  
 500, 777, 103, 365, 516, 236, 751, 529, 415, 401, 588, 230, 477,  
 493, 608, 465,  79, 402, 513, 366,   8, 615, 215, 467, 251, 193,  
 674, 518, 150, 609, 485, 204, 436, 572, 782,   1, 354, 471, 113,  
 760, 491, 774, 434, 293, 315, 367, 407, 503, 272, 638, 409, 640,  
 406, 663, 363, 316, 667, 196, 462  
 351, 214,  18, 768, 458, 735, 676 5  
 566, 162,  39, 702, 590, 283, 655  
 726, 766, 142,   2, 776, 355, 23110  
 375, 382, 250, 756, 338, 740, 575  
 37, 548,  48, 181, 492, 352, 41615  
 720 210 157 400 506 268 206
```



An empirical investigation of catastrophic forgetting in gradient-based neural networks (Goodfellow et. al., 2013)

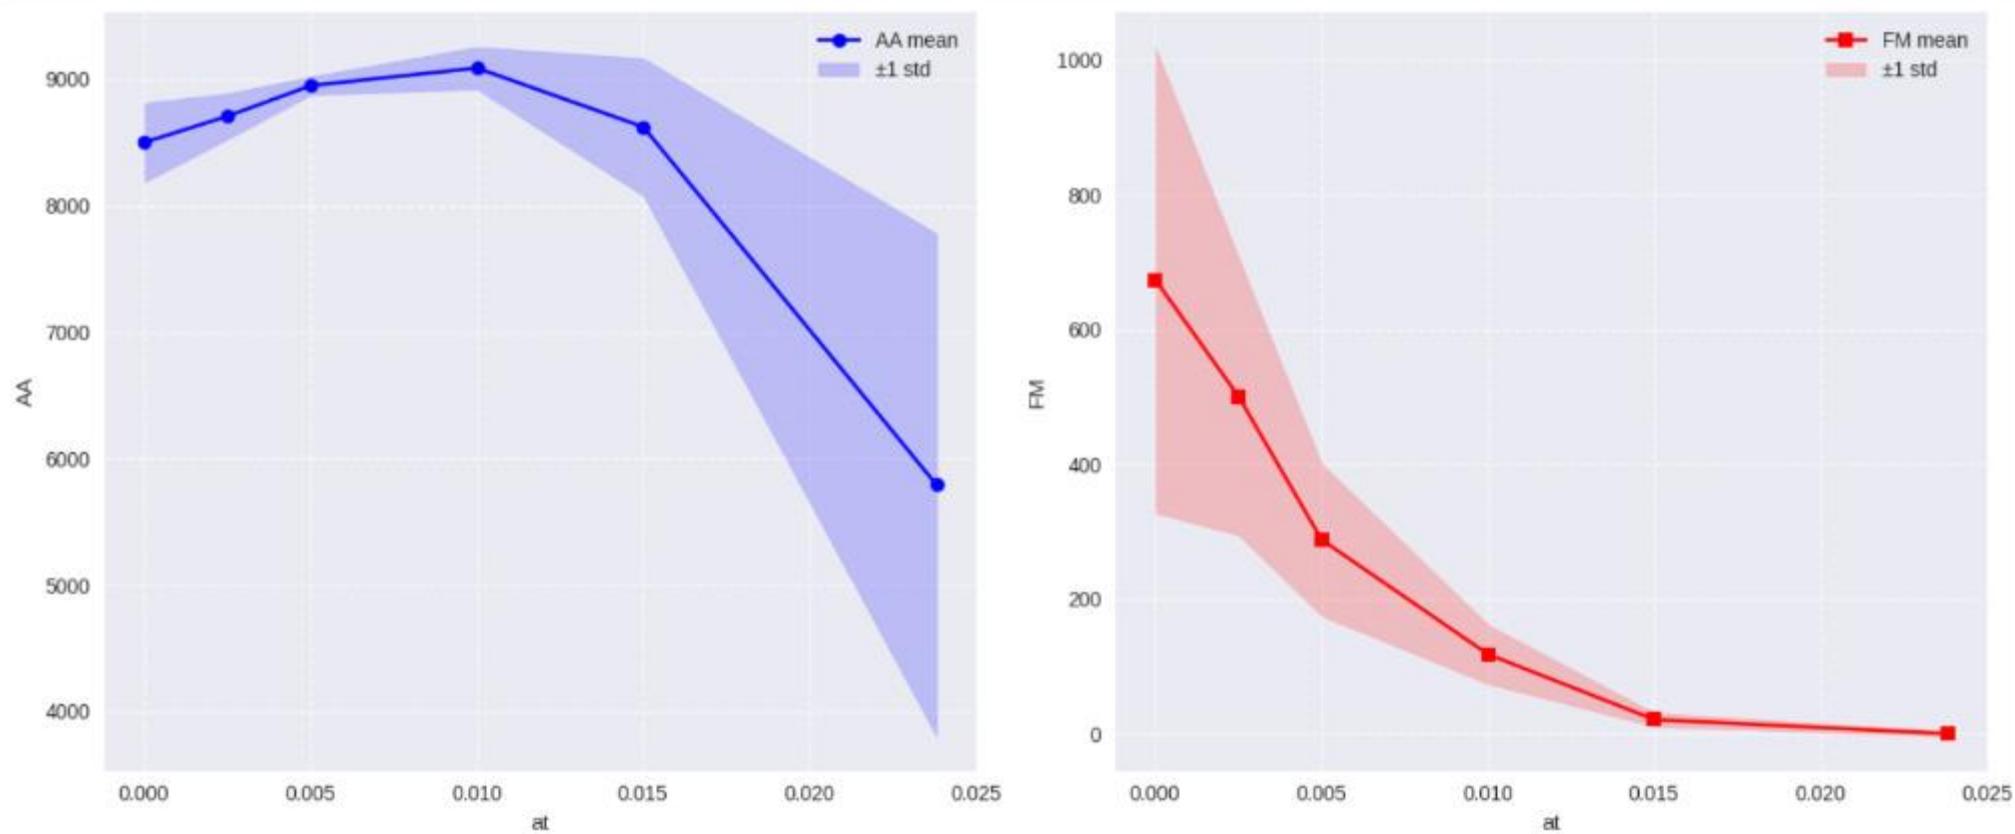
## CoLaNET на Permuted MNIST

### Профиль деградации CoLaNET для 15 микроколонок и $\alpha=0.023817$

Результаты свидетельствуют о смещённом балансе в сторону стабильности памяти, вместо пластичности обучения. Отсутствие забывания говорит о том, что микроколонки, которые специфицировались на одной задаче, закрепляются так сильно, что вообще перестают меняться на других задачах.

Iterations	Tasks									
	1	2	3	4	5	6	7	8	9	10
1	<b>94.36</b>									
2	94.34	<b>83.67</b>								
3	94.34	83.61	<b>34.17</b>							
4	94.34	83.61	34.68	<b>36.75</b>						
5	94.33	83.60	34.68	36.76	<b>25.59</b>					
6	94.45	83.60	34.68	36.76	25.59	<b>23.97</b>				
7	94.45	83.60	34.68	36.76	25.59	23.97	<b>12.01</b>			
8	94.43	83.60	34.68	36.76	25.59	23.97	12.03	<b>15.25</b>		
9	94.43	83.60	34.68	36.76	25.59	23.97	12.03	15.27	<b>11.87</b>	
10	94.43	83.60	34.68	36.76	25.59	23.97	12.03	15.27	11.87	<b>13.55</b>

## Оптимальное значение адаптивного порога $\alpha$



При значениях  $\alpha$  выше 0.015 сеть практически перестает забывать. При значениях  $\alpha$  от 0 до 0.01 растут как метрики точности, так и связанные с уменьшением меры забывания.

## CoLaNET с оптимальным адаптивным порогом

Профиль деградации CoLaNET для 15 микроколонок и  $\alpha=0.005$  (был 0.023817)

Значением  $\alpha$ , выше которого падает пластиичность обучения на десяти задачах, является 0.005.

Iterations	Tasks									
	1	2	3	4	5	6	7	8	9	10
1	<b>91.03</b>									
2	89.35	<b>91.68</b>								
3	85.62	90.60	<b>92.29</b>							
4	85.13	90.54	91.90	<b>92.49</b>						
5	82.65	88.15	90.85	92.01	<b>93.06</b>					
6	80.41	87.83	90.41	91.14	92.77	<b>92.05</b>				
7	80.06	87.21	89.72	91.02	92.10	91.78	<b>91.94</b>			
8	78.85	86.55	89.29	90.58	91.08	91.48	91.89	<b>91.99</b>		
9	78.68	84.51	88.58	89.87	90.76	90.91	91.54	91.74	<b>91.94</b>	
10	78.42	84.00	88.45	89.38	90.14	90.69	91.42	91.59	91.63	<b>91.56</b>

## CoLaNET на 45 микроколонках

### Профиль деградации CoLaNET для 45 микроколонок и $\alpha=0.01$

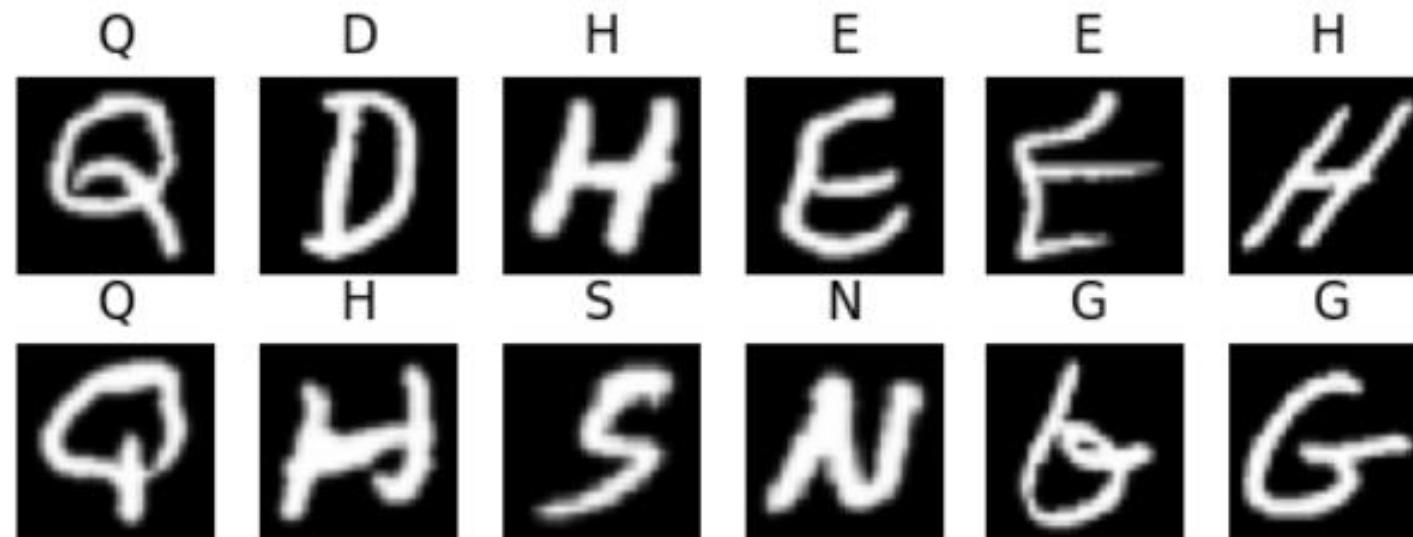
CoLaNET демонстрирует способность эффективно учиться на десяти задачах, и в то же время высокую устойчивость к забыванию, деградируя всего на  $93.30 - 88.95 = 4.35\%$  на первой задаче после обучения девяти другим задачам.

Iterations	Tasks									
	1	2	3	4	5	6	7	8	9	10
1	<b>93.30</b>									
2	91.84	<b>93.23</b>								
3	91.03	92.51	<b>93.62</b>							
4	90.48	92.01	93.45	<b>93.87</b>						
5	90.19	91.86	93.02	93.48	<b>92.97</b>					
6	89.75	91.69	92.88	93.22	92.86	<b>93.01</b>				
7	<b>89.57</b>	91.36	92.82	92.95	92.79	92.99	<b>93.03</b>			
8	89.09	91.20	92.69	92.60	92.62	92.99	93.27	<b>91.73</b>		
9	89.00	91.19	92.46	92.57	92.47	92.92	92.96	91.69	<b>92.35</b>	
10	88.95	91.29	92.37	92.37	92.31	92.65	92.75	91.43	92.30	<b>91.22</b>

## Эксперимент 2: Extended MNIST

- Task1: 0, 1, 2, 3, 4, 5, 6, 7, 8, 9.
- Task2: A, B, D, E, G, H, N, Q, R, S.

Из EMNIST в соответствии с Antonov2022 выбрано balanced разбиение, из которого используется десять классов (для соотнесения с MNIST): буквы A, B, D, E, G, H, N, Q, R, S. В каждой задаче 28 тыс. изображений.



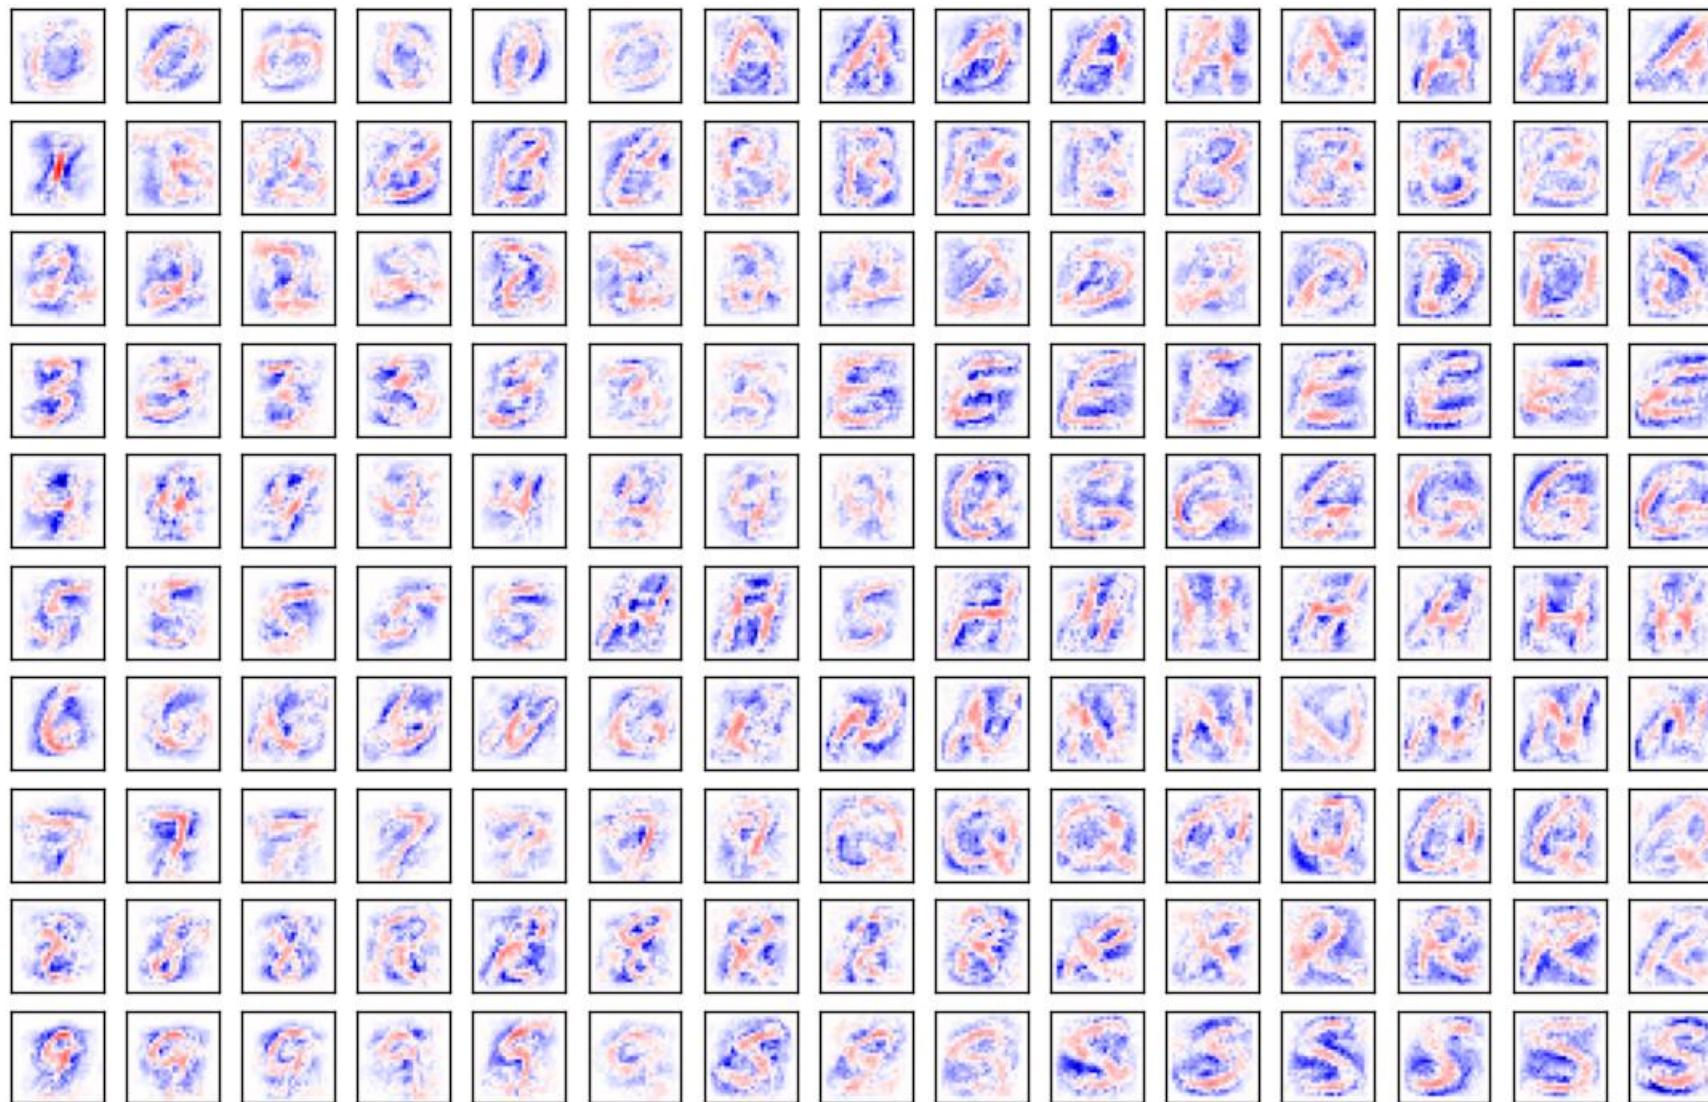
EMNIST: an extension of MNIST to handwritten letters (Cohen et. al., 2017)

Continuous learning of spiking networks trained with local rules (Dmitry Antonov, Kirill Sviatov, Sergey Sukhov, 2022)

## CoLaNET на E/MNIST

Parameters $\alpha$ and $ns$	MNIST →EMNIST	MNIST	FM1	EMNIST →MNIST	EMNIST	FM2
0	88.67→82.50	25.09	63.58	79.72→88.65	19.27	60.45
0.00125	92.65→82.45	32.32	60.33	80.57→91.37	30.92	49.65
0.00125, 0	90.87→87.72	40.70	50.17	87.20→92.72	35.77	51.43
0.00125, 1k	91.87→87.50	43.40	48.47	87.25→92.70	44.80	42.45
0.00125, 10k	92.07→87.75	38.22	53.85	86.40→92.75	44.67	41.73
0.00125, 100k	91.15→87.17	40.39	50.76	86.62→93.45	44.19	42.43
0.0015	92.40→82.92	39.90	52.50	81.15→90.10	35.57	45.58
0.0015, 0	91.15→87.45	41.22	49.93	87.07→92.62	39.12	47.95
0.0015, 1k	91.97→87.90	41.82	50.15	88.22→93.17	43.92	44.30
0.0015, 10k	91.15→87.95	41.67	49.48	86.70→93.62	46.85	39.85
0.0015, 100k	92.70→88.35	42.90	49.80	88.10→93.52	48.77	39.33
0.002	92.60→81.10	49.02	43.58	80.10→89.47	38.05	42.05
0.002, 0	91.85→81.12	44.19	47.66	86.95→74.85	52.40	34.55
0.002, 1k	92.30→86.65	44.47	47.83	88.97→89.90	52.99	35.98
0.002, 10k	91.92→86.02	42.02	49.90	88.50→91.20	52.30	36.20
0.002, 100k	92.35→87.67	44.80	47.55	88.50→91.90	53.42	35.08
0.00238	92.42→78.35	56.87	35.55	78.49→86.65	38.37	40.12
0.00238, 0	91.10→65.52	52.75	38.35	83.25→29.70	55.95	27.30
0.00238, 1k	92.20→81.60	50.22	41.98	87.57→80.95	54.47	33.10
0.00238, 10k	92.47→79.64	53.02	39.45	88.07→86.70	58.02	30.05
0.00238, 100k	92.90→84.25	49.50	43.40	88.40→87.72	56.35	32.05
0.003	92.12→63.95	66.55	25.57	74.54→82.12	40.24	34.30
0.003, 0	91.72→26.55	61.00	30.72	69.17→44.40	44.07	25.10
0.003, 1k	93.35→59.77	63.72	29.63	82.20→36.65	54.72	27.48
0.003, 10k	91.60→44.19	66.87	24.73	85.92→67.62	56.47	29.45

## CoLaNET после обучения на MNIST, потом на EMNIST



# Сравнение результатов

## 10 задач Permuted MNIST

	AA	FM
Joint training	$89.05 \pm 0.27$	
GEM [20]	$74.57 \pm 0.10$	$7.40 \pm 0.11$
AGEM [4]	$69.50 \pm 0.76$	$13.10 \pm 0.63$
MER [25]	$75.75 \pm 0.65$	$8.74 \pm 0.73$
MIR [1]	$78.31 \pm 0.63$	$7.15 \pm 0.67$
CTN [23]	$79.70 \pm 0.44$	$5.08 \pm 0.44$
NCC [30]	$83.47 \pm 0.43$	$3.44 \pm 0.26$
CoLaNET (15 microcolumns)	$89.67 \pm 0.16$	$2.75 \pm 0.23$
CoLaNET (45 microcolumns)	$92.39 \pm 0.13$	$0.94 \pm 0.17$

Сравнение эффективности разных подходов воспроизведения памяти на размере буфера 50 элементов на десяти задачах Permuted MNIST для одной эпохи обучения на каждой задаче. В нижней части приведены аналогичные результаты для CoLaNET в конфигурациях на 15 и 45 микроколонок. Результаты усреднены по десяти независимым экспериментам.

## 2 задачи E/MNIST

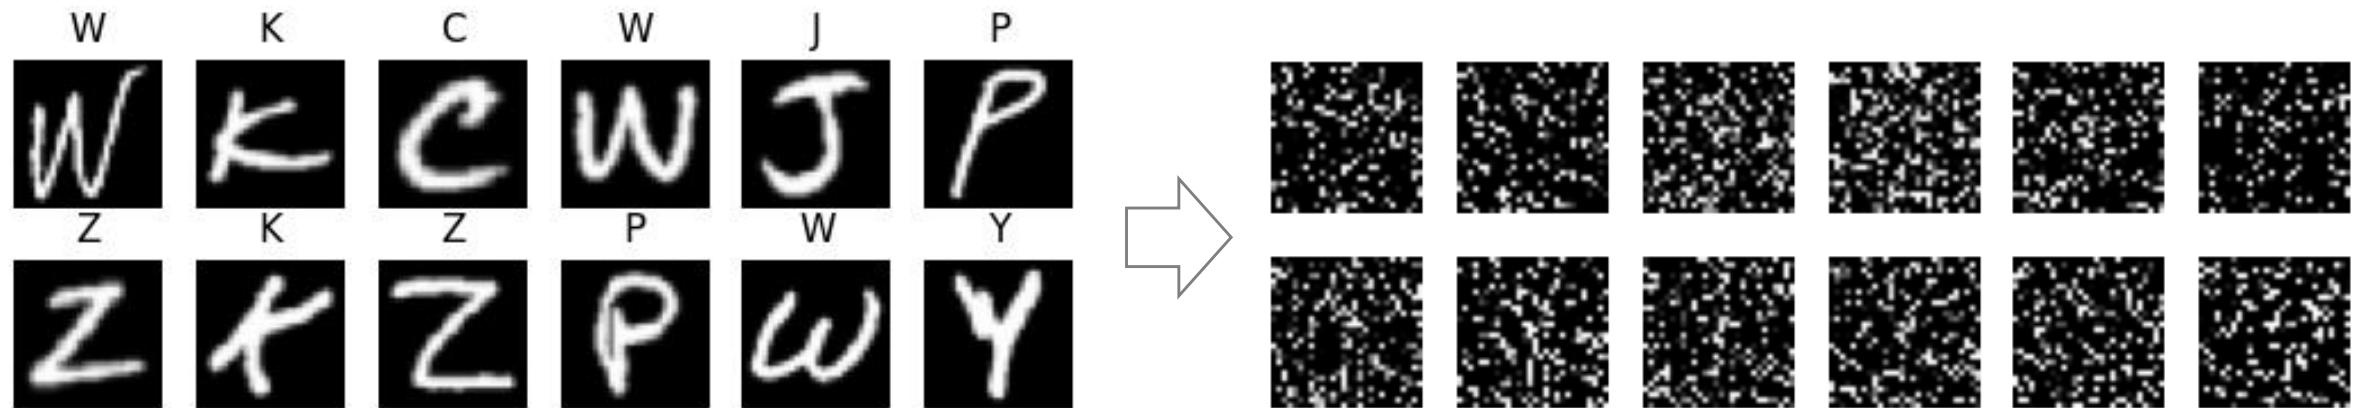
	MNIST→EMNIST	MNIST	FM
SNN [31]	$90.8 \rightarrow 78.4$	48.1	42.7
Lateral inhibition	$94.8 \rightarrow 88.9$	78.6	16.2
Pseudo-rehearsal	$93.6 \rightarrow 79.0$	43.5	50.1
Self-reminder (0.25%)	$93.6 \rightarrow 74.0$	74.5	19.1
Self-reminder (10%)	$93.6 \rightarrow 77.8$	91.1	2.5
Noise regularization	$93.9 \rightarrow 87.8$	67.2	26.7
Dropout	$94.2 \rightarrow 87.6$	62.9	31.3
Frozen large weights	$93.6 \rightarrow 69.2$	78.2	15.4
Langevin dynamics	$93.6 \rightarrow 78.3$	82.2	11.4
Joint training	$93.6 \rightarrow 79.7$	92.0	1.6
CoLaNET	$92.9 \rightarrow 84.3$	49.5	43.4
CoLaNET + permutation	$92.14 \rightarrow 86.96$	$90.87 \pm 0.32$	$1.27 \pm 0.37$

Результаты на Permuted MNIST не воспроизводятся на E/MNIST, так как в признаковом представлении задач присутствует общность. Убрать общность возможно ценой потери пространственных паттернов, применив к каждому датасету случайную перестановку (permutation).

## Эксперимент 3: Permuted E/MNSIT

- Task1: 0, 1, 2, 3, 4, 5, 6, 7, 8, 9.
- Task2: A, B, D, E, G, H, N, Q, R, S.
- Task3: Z, X, Y, U, W, J, L, P, K, C.

К каждой задаче применяется случайная перестановка (одинаковая для всех изображений задачи). В признаковых пространствах больше нет общности, что позволяет значительно улучшить метрики CL.



	Task1	Task2	Task3
1	<b>93.30</b>		
2	91.84	<b>93.23</b>	
3	91.03	92.51	<b>93.62</b>

## Контакты и материалы

tg: <https://t.me/nrmairus>

git: <https://gitflic.ru/project/dlarionov/cl>

