

ДОСЛІДЖЕННЯ ПРОЦЕСУ ПЕРЕЗАПИСУ СТАНІВ НЕЙРОМЕРЕЖ ТА ЙОГО ВПЛИВУ НА КАЛІБРУВАННЯ ПАМ'ЯТІ

Почтар М.В.¹⁾, Шпінталь М.Я.²⁾

Західноукраїнський національний університет

¹⁾ аспірант; ²⁾ к.т.н., доцент

I. Постановка проблеми

Машинне навчання програмних агентів з підкріпленням є однією з найактуальніших проблем програмної інженерії сьогодення у середовищах, де є потреба взаємодії з навколишнім світом. Лінійне програмування в даних ситуаціях неможливе, оскільки кількість шаблонів взаємодії з середовищем є занадто високою. Крім того, такі системи повинні вміти не лише дотримуватись лінійних правил, а й розпізнавати існуючі шаблони ситуацій і застосовувати їх у нових ситуаціях навколишнього середовища.

Однак, враховуючи специфіку глибокого машинного навчання, навіть найостанніші розробки є неефективними по відношенню до вхідних станів [1], що виражається в зростанні часу та вартості тренування моделі. Особливо проблемними для даного домену є середовища з рідкими подіями [2]. В той час як ускладнення моделі не тільки підвищує вартість тренування і є схильним до запам'ятовування середовища, більш серйозною проблемою даного виду моделей є перезапис пам'яті подіями, що відбуваються більш часто по відношенню до подій, які мають більше значення в контексті досягненні зовнішніх нагород в процесі прийняття рішень Маркова [3].

II. Мета роботи

Метою дослідження є аналіз поведінки агента нейромережі в умовах постійного перезапису стану середовища протилежними значеннями.

III. Деталі проведених експериментів

В основі процесу дослідження перезапису станів нейромереж лежить розробка і тренування мережі з використанням фреймворку Tensorflow для розпаралелювання процесу навчання на багатоядерних графічних процесорах загального призначення GP GPU. Для тренування тестового агента було розроблено систему з наступними параметрами вхідних даних: вхідне число – одна комірка, кількість прихованих нейрокомірок і шарів – змінні N та M відповідно, вихідне число – одна комірка.

Процес навчання побудований таким чином, що на вході подається певне число – завжди фіксоване значення, тим часом як вихідні дані – мітка (label), змінюється в процесі тренування динамічно згідно заданим параметрам поточного експерименту.

В параметри експериментів входять наступні: тип оптимізатора – з динамічним моментом (Adam та RMSProp) або з фіксованим (оптимізатор SGD), рейт навчання оптимізатора – крок від 0.01 до 0.0001, кількість прихованих слоїв нейромережі, кількість нейронів в прихованих шарах, а також кількість та дисперсія вихідних даних. У якості функції визначення втрати використано стандартний mean squared error.

IV. Результати дослідження здатності калібрувати пам'ять

В процесі роботи були проведені експерименти дослідження залежності здатності запам'ятовувати і калібрувати пам'ять відносно невизначеності вхідних даних за умов різних параметрів мережі. Так було встановлено, чим складніша нейромережа, тим більше вона схильна робити похибку в сторону одного чи іншого рішення – незалежно від кількості проведених тренувань (epoch). Однак, при застосуванні лише одного нейрону, система показала здібність максимально ефективно балансувати похибку. Застосування протилежних значень з єдиним нейроном і одним шаром у всіх експериментах показало апроксимацію на рівні середніх значень незалежно від встановлених параметрів епох, рейту навчання, оптимізатора. Після близько трьохсот епох втрата нормалізується на рівні менше 0.05. На практиці, якщо застосування простих систем можливо, використання класичних методів, таких як Random Forest, дерева прийняття рішень та регресійні методи, може бути більш доцільним у зв'язку з їх більшою ефективністю і меншими затратами порівняно з застосування універсальних апроксиматорів [4].

На рисунку 1 зображена залежність рівня визначеності (вираженого в мінімізації втрати) від кількості нейронів.

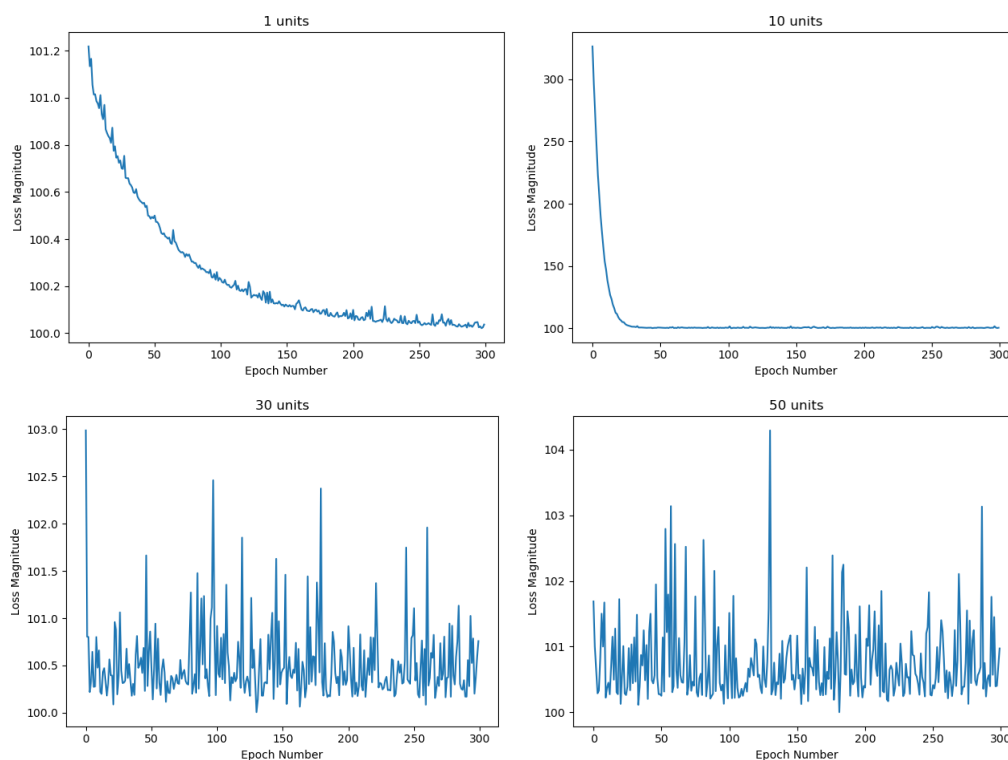


Рисунок 1 – Залежність втрати (loss) по відношенню до кількості нейронів

У проведених експериментах було встановлено, що збільшення кількості нейронів не тільки не призводить до ефективного балансування результатів нейронної мережі, а й негативно призводить до збільшення похибки, а після досягнення певного порогу – до абсолютного дисбалансу нейромережі і втрати здібності навчатись. На рисунку 1 це виражено у вигляді стохастичних коливань показника втрати. Корегування інших параметрів мережі, таких як рейт навчання, оптимізатор, параметри оптимізатора, вхідні значення, до стабілізації мережі не призводить.

Висновок

Здійснено аналіз і дослідження поведінки агента нейромережі в умовах постійного перезапису стану протилежними значеннями. Встановлено, що збільшення кількості шарів нейромережі та/або кількості нейронів універсальних апроксиматорів в шарах призводить до підвищення схильності мережі дотримуватись виключно однієї – але стохастично встановленої – точки зору (значення) в умовах навчання протилежним значенням. Кількість епох (тренувань) та подальший процес перетренування має мінімальний вплив за умови продовження надання системі протилежних значень. У разі перенавчання мережі дійними значеннями, складність перенавчання зростає пропорційно складності самої мережі.

У результаті роботи визначено, що стохастичний градієнт SGD не здатний показати позитивного впливу на процес навчання і перенавчання. Незалежно від встановленого рейту навчання, система поводить себе непередбачувано і схильна до «вибуху градієнта» (gradient explode).

На противагу, оптимізатори з динамічним налаштуванням моменту (Adam та RMSProp) показали позитивну тенденцію в адаптації до середовища з шумними мітками (noisy labels) та ефективному калібруванні результатів за умови налаштування оптимальної структури мережі.

Список використаних джерел

1. Volodymyr Mnih, Koray Kavukcuoglu, David Silver, Alex Graves, Ioannis Antonoglou, Daan Wierstra, Martin Riedmiller Playing Atari with Deep Reinforcement Learning // NIPS Deep Learning Workshop 2013.
2. Jordan Frank, Shie Mannor, Doina Precup Human-level control through deep reinforcement learning // Vol 518, NATURE, 529.
3. Reinforcement Learning in the Presence of Rare Events // Proceedings of the 25th International Conference on Machine Learning, Helsinki, Finland, 2008.
4. Muhammad Waseem Ahmad, Monjur Mourshed, Yacine Rezgui Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption // 2017 The Authors. Published by Elsevier B.V.