

Машинное обучение в физике ускорителей - обзор подходов



25 марта 2024 г.



Дмитрий Колодезев

ООО Промсофт

OpenDataScience
Reliable ML
ML System Design.



Ксения Карюкина

научный сотрудник

ИЯФ СО РАН
ЦКП "СКИФ"

датазавтраки по вторникам ☕
с 8:30 до 10:00 в "Shurubor coffeeshop"

о чем расскажем:

- про ускорители заряженных частиц на примере СКИФ;
- обзор научных статей про то, как машинное обучение помогает решать задачи в ускорителях заряженных частиц:
 - стабилизацию орбиты пучка заряженных частиц
 - коррекцию орбиты пучка
 - и многокритериальную оптимизацию параметров ускорителя



СИБИРСКИЙ КОЛЬЦЕВОЙ
ИСТОЧНИК ФОТОНОВ



ЦПТИ
РОСАТОМ

От эмиттанта сильно зависит яркость излучения
Brightness $\sim 1/\Delta x \Delta \theta$

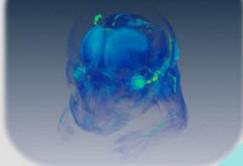
СКИФ будет одним из самым ярким
источником СИ в мире!

СИ находит применение в различных областях

- ☘ “зеленая” энергетика
- 💊 фармацевтика
- 👤 томография
- 🌿 сельское хозяйство
- ✈️ авиация
- 👉 материаловедение
- ★ космос и астрономия
- 🏛️ археология
- ♻️ экология
- 🌍 геология

и нобелевские премии,
конечно!

Мозг мыши

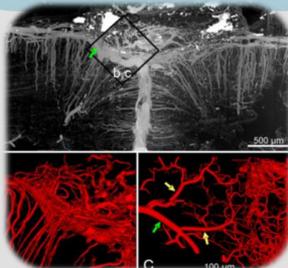


Создано лекарство
против вирусного
гепатита С.



Создание жаростойких
покрытий для лопаток
авиа турбин

Система кровеносных сосудов мозга



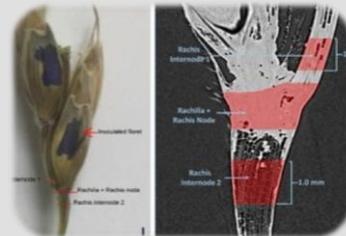
Технология
производства
шоколада с
увеличенным
сроком годности



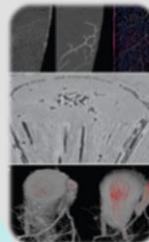
Новые методы изучения
археологических,
палеонтологических и
этнографических
находок с
использованием СИ



Создание космических условий на Земле
для калибровки оборудования.



Селекция сортов
пшеницы, устойчивых к
грибковым заболеваниям



Механизм
гибели
деревьев от
засухи

В авиации уже давно
остро стоит вопрос
ухода от заклепочных
соединений

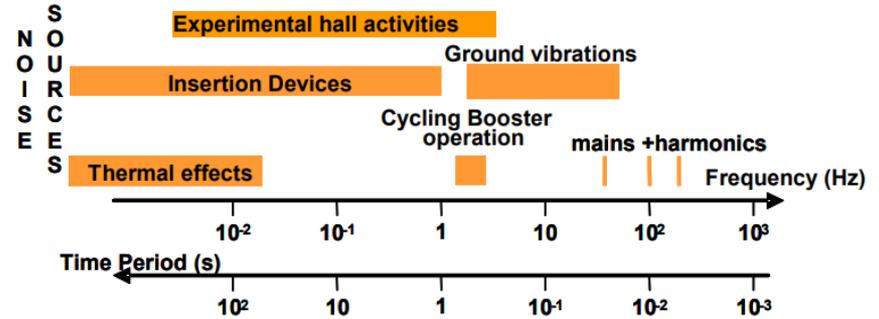




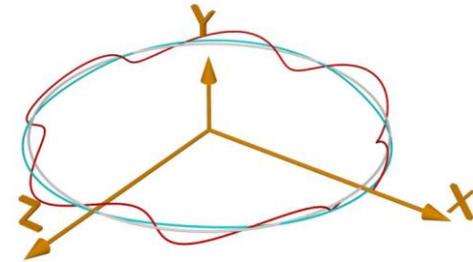
задача на пределе технических возможностей

- ошибки магнитных полей элементов, формирующих орбиту и т.д.
- ошибка выставки магнитных элементов не более 50 микрон
- изменение температуры
- вибрации грунта
- фаза луны - буквально
- Rammstein приехали

пучок чувствует всё



спектральное представление источников возмущений



искажение замкнутой орбиты пучка электронов

the Shanghai Synchrotron Radiation Facility

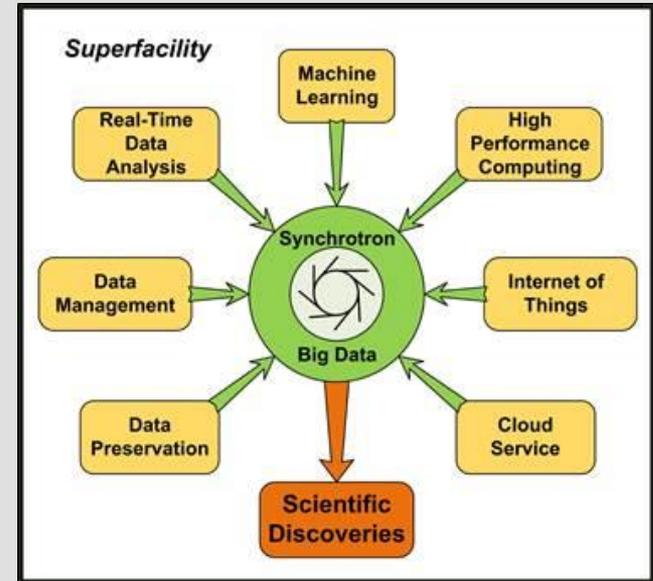
3rd-generation light source

Storage Ring Energy 3.5 GeV; Circumference of 432 meters



Synchrotron
Big Data Science centre

<https://doi.org/10.1002/sml.201802291>



A machine-learning based closed orbit feedback for the SSRF storage ring

Ruichun Li^{1,2,3}, Qinglei Zhang^{1,4,*}, Bocheng Jiang^{5,†}, Zhentang Zhao^{1,2,3,4},
Changliang Li^{1,4}, Kun Wang^{1,4}, and Dazhang Huang^{1,4}

¹ *Shanghai Synchrotron Radiation Facility, Shanghai Advanced Research Institute, Chinese Academy of Sciences, Shanghai 201210, China*

² *Shanghai Institute of Applied Physics, Chinese Academy of Sciences, Shanghai 201800, China*

³ *School of Physical Science and Technology, ShanghaiTech University, Shanghai 201210, China*

⁴ *University of Chinese Academy of Sciences, Beijing 100049, China*

⁵ *Chongqing University, Chongqing 401331, China*

In order to improve the stability of synchrotron radiation, we developed a new method of machine learning-based closed orbit feedback, and piloted it in the storage ring of the Shanghai Synchrotron Radiation Facility (SSRF). In our experiments, not only can the machine learning-based closed orbit feedback carry out horizontal, vertical and RF frequency feedback simultaneously, but it also has better convergence and convergence speed than the traditional Slow Orbit Feed Back (SOFB) system. What's more, the residual values of the correctors' currents variations after correction can be almost ignored. This machine learning-based new method is expected to establish a new closed orbit feedback system and improve the orbit stability of the storage ring in daily operation.

матрица отклика

Classical theory

Матрица отклика представляет изменение орбиты на датчиках положения пучка (BPM) в зависимости от силы магнитных корректоров.

$$\Delta u = (u_1, u_2, \dots, u_m)^T$$

- искажение замкнутой орбиты

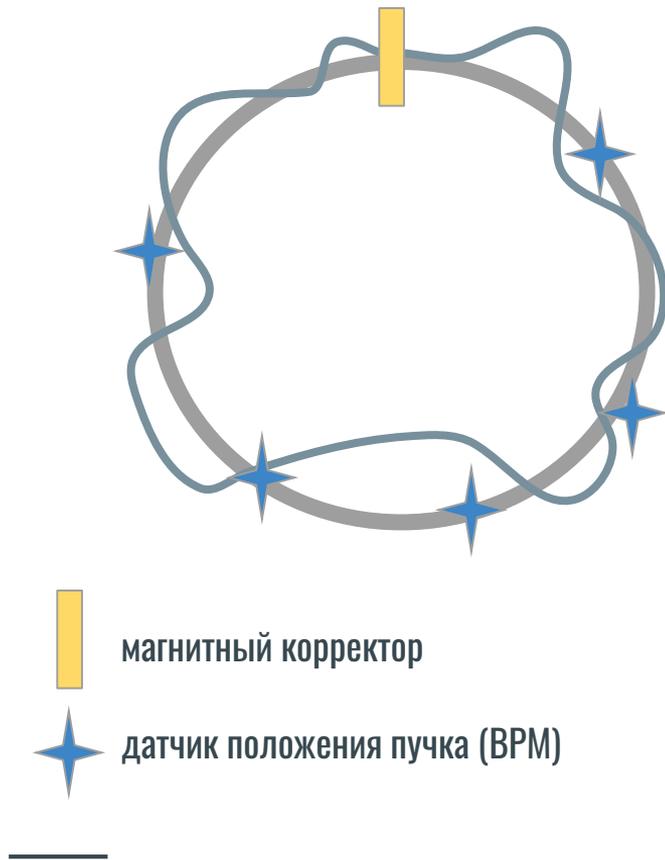
$$\theta = (\theta_1, \theta_2, \dots, \theta_n)^T$$

- изменение силы магнитных корректоров

$$\Delta u = R \theta$$

- матрица отклика

$$\theta = -R^{-1} \Delta u$$



Classical theory

$$\theta = -R^{-1} \Delta u$$

SSRF: 80 магнитных корректоров, ~20 минут;

SKIF: ~ 240 магнитных корректоров - большой объем данных! ~ часа

Время \equiv нобелевские премии ;)

Недостатки:

Матрицу отклика необходимо периодически измерять и обновлять.

Представляет собой лишь линейное отображение и не полностью и точно не отражает характеристики машины.

Какую проблему решали

- Параметры установки “плывут”
- Матрицу отклика приходится время от времени переснимать
- SVD ловит только линейные зависимости
- Нужно “угадать” - сколько собственных значений оставить
- Спустя некоторое время можно наткнуться на насыщение корректоров

Хотелось:

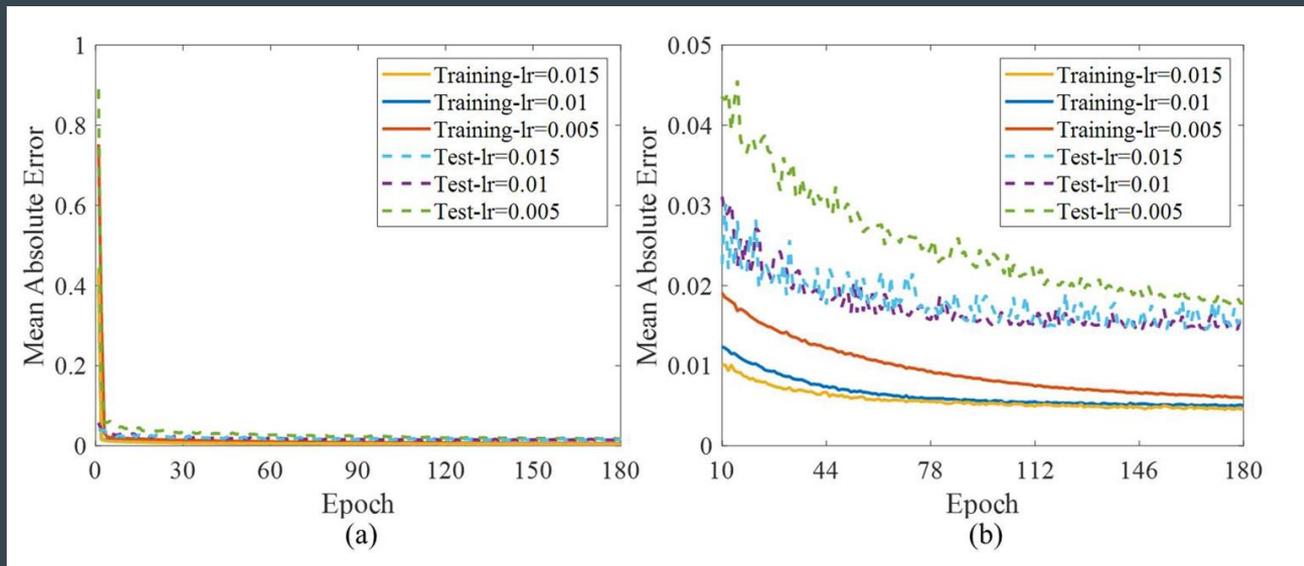
- Черный ящик, быстро аппроксимирует поведение установки
- На входе данные положения пучка, на выходе ток на корректорах
- Посреди - чудо

Данные

- Вход - 138 показаний положения пучка
- Выход - 80 настроек корректоров
- Отсчеты за 40 минут, раз в 3 секунды (800 отсчетов).
- 100 - тест, 700 - обучение
- У данных разный масштаб. Нормализовали, чтобы лучше училось (L2!)
 - Предполагали данные унимодальными
- Нормализовали как входные, так и выходные данные (RMSE!)

Процесс обучения

- Ноутбук. Без графического ускорителя
- Две минуты
- 180 эпох (sgd!)



Как тестировали

- RF frequency feedback
 - “сбили” частоту на 30 Hz.
 - Корректировка каждые 5 сек максимум на 10 Hz, за несколько циклов сошлось
- Joint feedback
 - Случайные горизонтальные и вертикальные возмущения + 15Hz RF, так же сошлось
- Slow Orbit Feed Back
 - Сравнивали с Slow orbit feedback (SOFB), сошлось лучше и быстрее
- Долгосрочная проверка устойчивости
 - 16 часов, оставили на ночь. Дрейф вертикальный / горизонтальный не более 40 μm / 20 μm
 - без корректировки - “сотни микрон”
 - странная флуктуация по вертикали через 3 часа - “мы верим, что это не ошибка метода”

Как тестировали

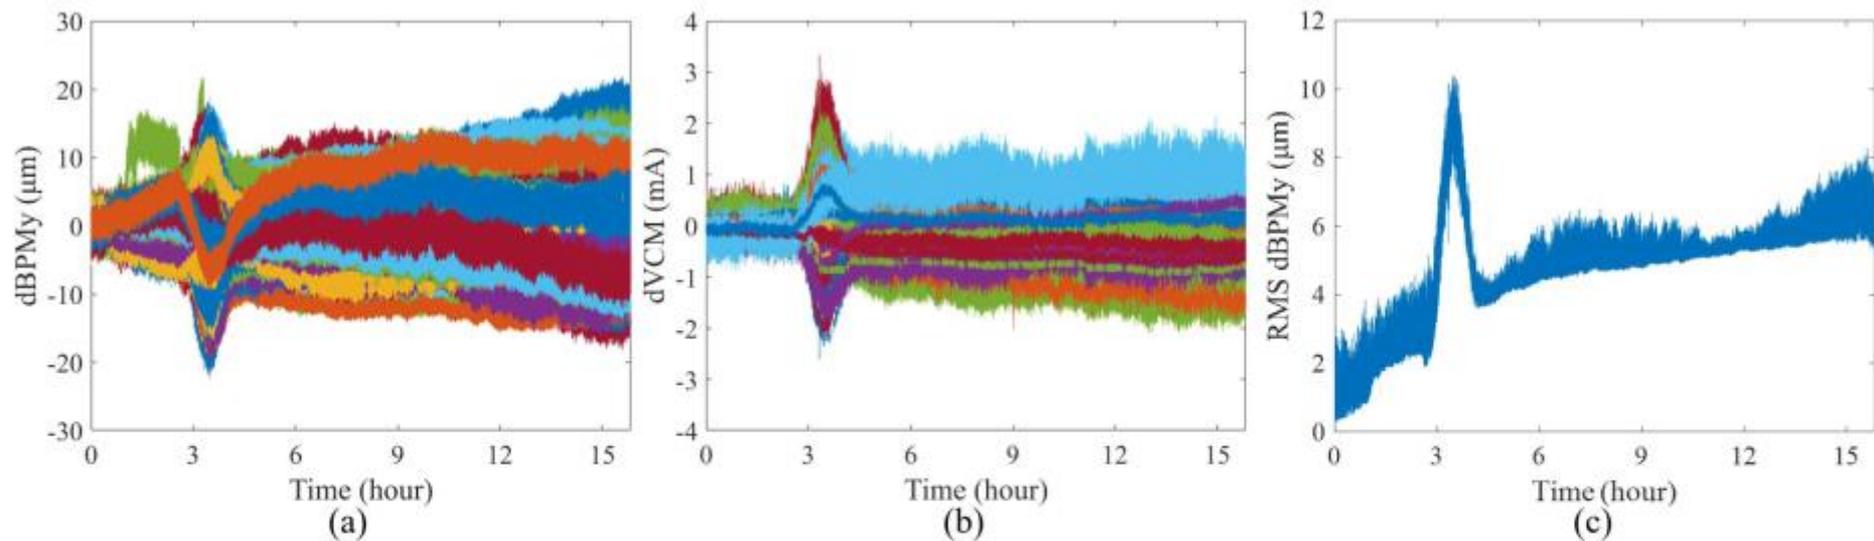
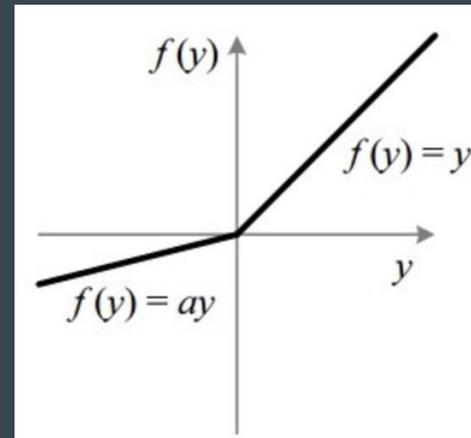
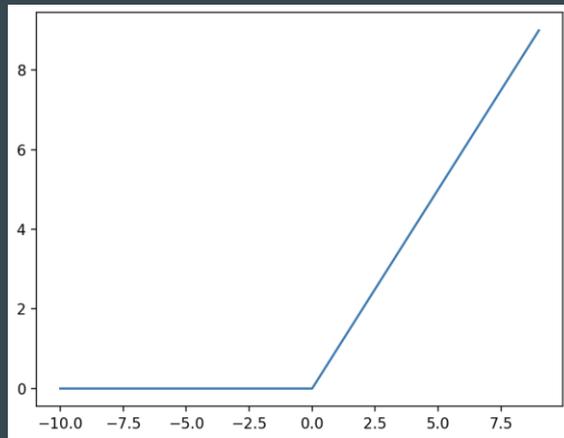
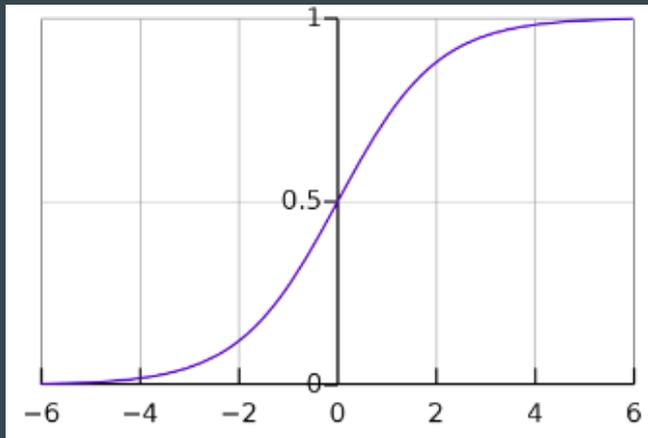


FIG. 11. The variations of vertical orbit, VCM strength, vertical orbit RMS and RF frequency with the machine learning-based feedback program turned on. (a) the variations of vertical orbit, (b) the variations of VCM strength and (c) the variations of vertical orbit RMS.

Почему так можно

- Нейронные сети - универсальные аппроксиматоры
- Цыбенко, 1989
 - при бесконечной ширине, сигмоидной функции активации и хотя бы двух слоях
- Zhou Lu et al, 2017
 - дополнительно для ReLU активации и ширине $n+4$, где n - число входов
- Если сможете выучить параметры



Какую проблему решили

- Черный ящик, быстро аппроксимирует поведение установки
- Можно доучивать в течение дня
- Работает

Что можно было бы

- Добавить температуры в данные
- Добавить данные за полные сутки
- Учить на видеокarte
- Доучить до нулевой ошибки
- Adam и расписание скорости обучения
- Байесовские нейронные сети - более гладкая аппроксимация

IV. Conclusion

This paper investigates the machine learning-based new method and the experiments are done at the SSRF storage ring. Our study demonstrates that this new machine learning-based method can be used for a closed orbit feedback. We compare the effects of the new method and the traditional SOFB orbit feedback through experiments. The experimental results show that the closed orbit feedback based on machine learning is better than the SOFB based on the response matrix in terms of convergence and convergence speed. One important difference is that the traditional SOFB system leaves the residual values of the correctors' currents variations during the feedback process, while this situation does not happen with the machine learning-based method. This new method can accurately pinpoint and correct the correctors. We also did experiments to demonstrate that this machine learning-based feedback program remains effective over a long period of time and the achieved orbit stability meets our expectations. In addition, valuable machine study time for measuring the response matrix can be saved if the new method is adopted. This new method provides a new way for orbit feedback of light sources and its feasibility is demonstrated, which is of great significance for improving the orbit stability of the storage ring in daily operation.

- **Осуществляется одновременно горизонтальная и вертикальная обратная связь.**
- **Имеет лучшую сходимоссть, чем традиционная система медленной обратной связи (SOFB).**
- **Остается эффективной в течении длительного времени. Нет траты времени на измерение матрицы отклика.**

Orbit correction based on improved reinforcement learning algorithm

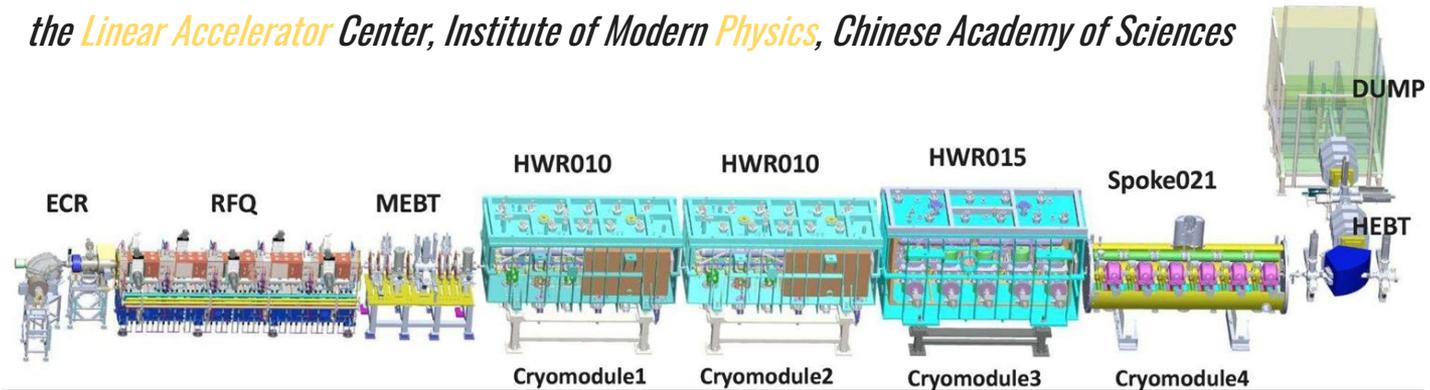
Xiaolong Chen, Yongzhi Jia, Xin Qi[✉], Zhijun Wang,[†] and Yuan He

Institute of Modern Physics, Chinese Academy of Sciences, Lanzhou 730000, People's Republic of China

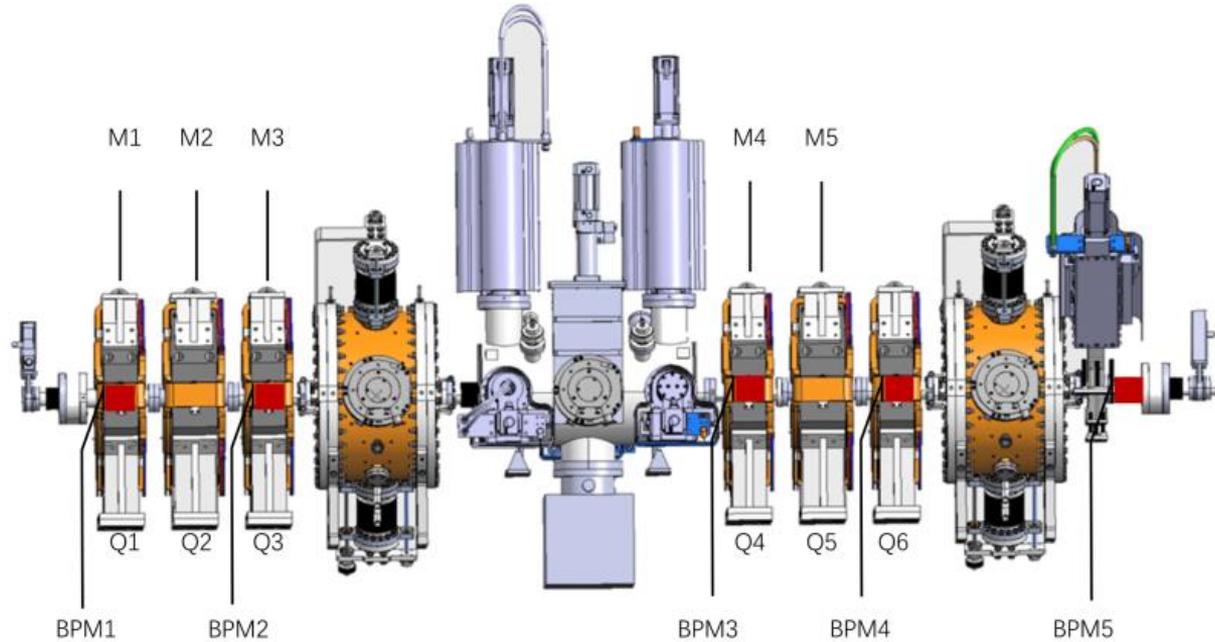
*School of Nuclear Science and Technology, University of Chinese Academy of Sciences,
Beijing 100049, People's Republic of China*

 (Received 30 August 2022; accepted 24 March 2023; published 13 April 2023)

the Linear Accelerator Center, Institute of Modern Physics, Chinese Academy of Sciences



medium energy beam transport (MEBT)



MEBT: L = 2.6975 m

4 BPM;
5 correctors;

input dimension: 8,
output: 10.

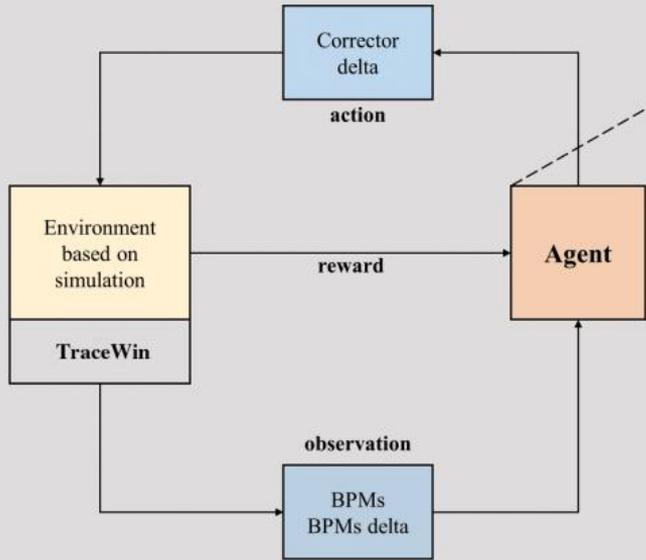
Обучение с подкреплением (RL)

- В предыдущих работах аппроксимировали матрицу отклика.
- Другая формулировка задачи - принять решение “по ситуации”
- Формулировка задачи:
 - Выучим стоимостную функцию состояний, будем переходить в наиболее выгодное
 - Чем ближе к выходу из лабиринта, тем лучше. Value gradient methods
 - Выучим функцию принятия решений
 - На развилках держись правой стены, если ты там еще не был. Policy gradient methods
 - Актор-критик
 - Policy based выбираем варианты, Value based оцениваем
- Функция сложная, но у нас есть универсальный аппроксиматор - Deep RL
- Методом проб и ошибок - нужна симуляция
- Отложенное вознаграждение -> сложные алгоритмы
- Exploitation / Exploration

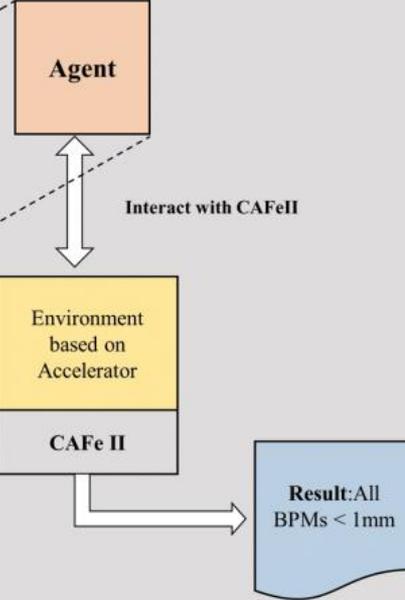
overview of the orbit correction method based on reinforcement learning algorithm



Target: make all BPMs reading close to 0



Trained on simulation environment

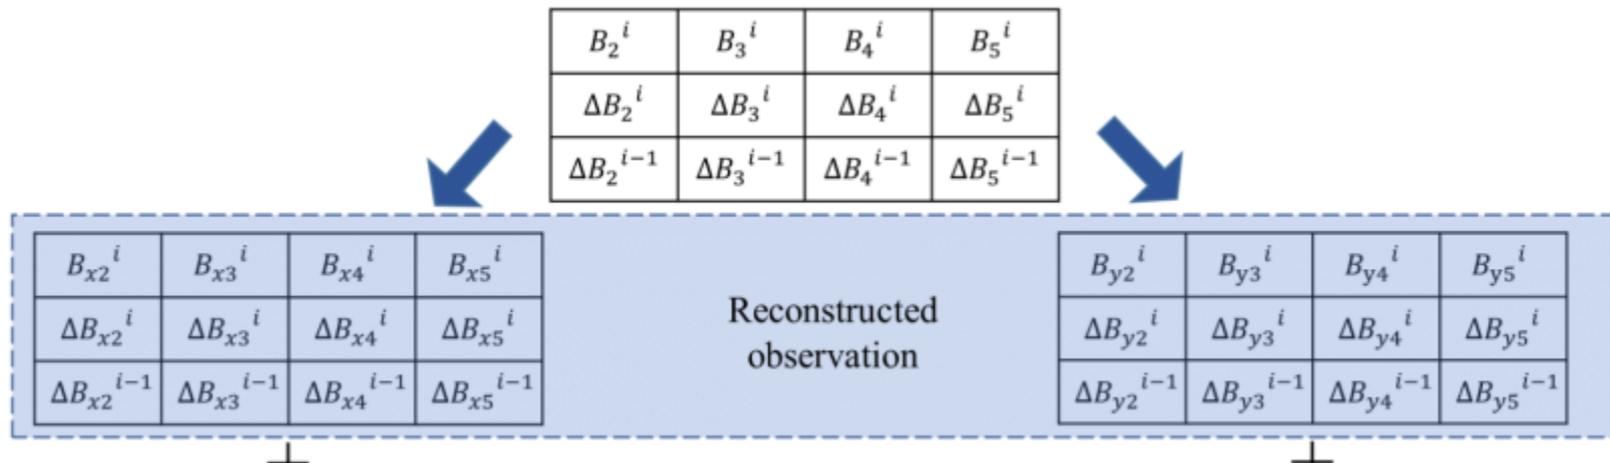
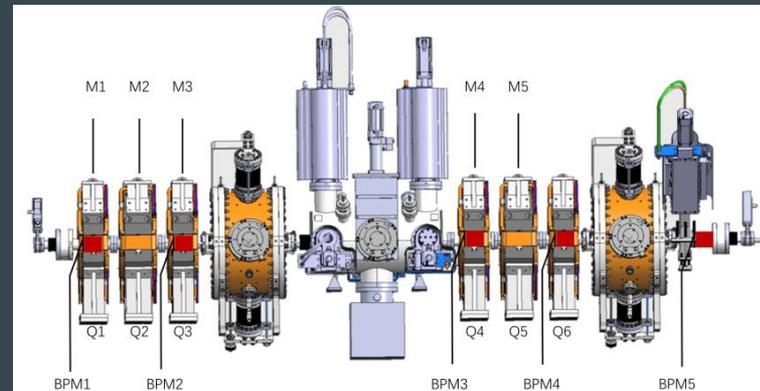


Evaluation on CAFe II environment

- В начале каждого эпизода токи каждого магнита корректора передаются в TraceWin и выполняется динамическое моделирование.
- После моделирования каждое показание BPM передается обратно агенту.
- Агент изучает поведение орбиты путем автоматического изменения тока всех магнитных корректоров.
- Агент должен выполнить миссию за 30 временных шагов.

Данные

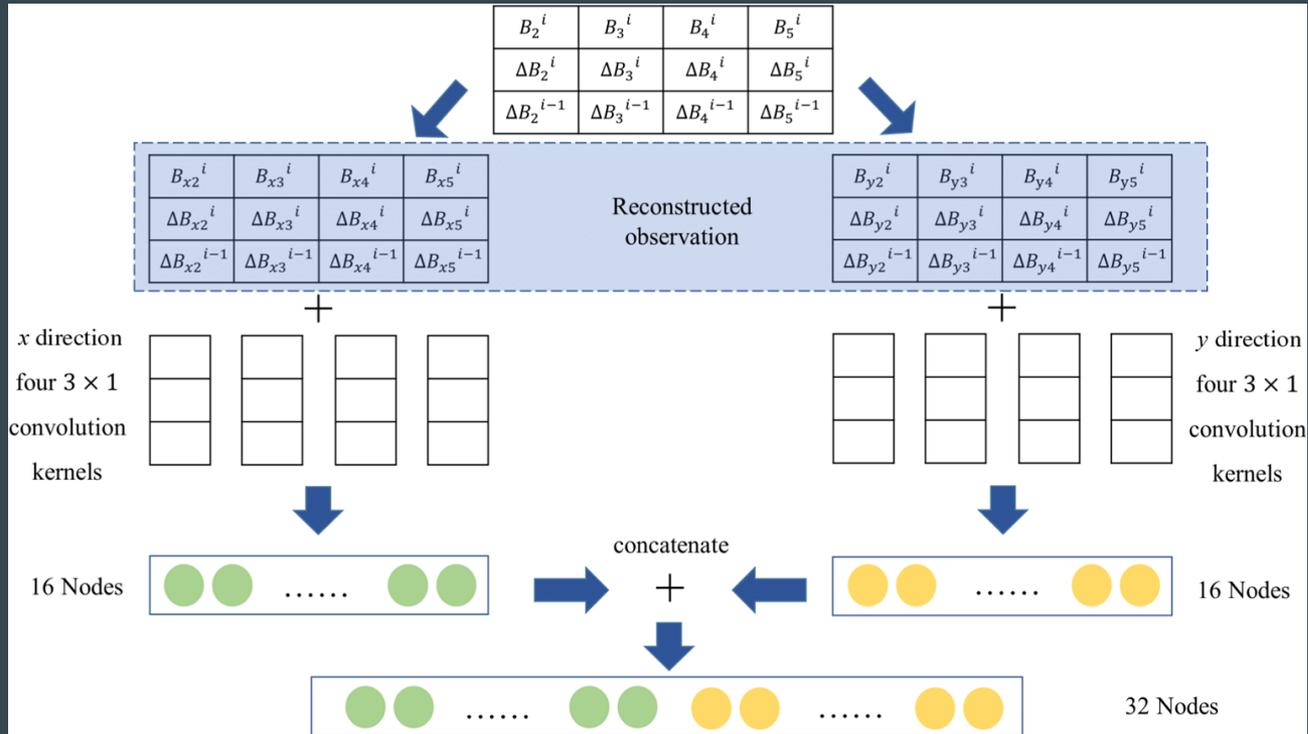
- BPM X Y
- приращение на этом шаге
- приращение на предыдущем шаге



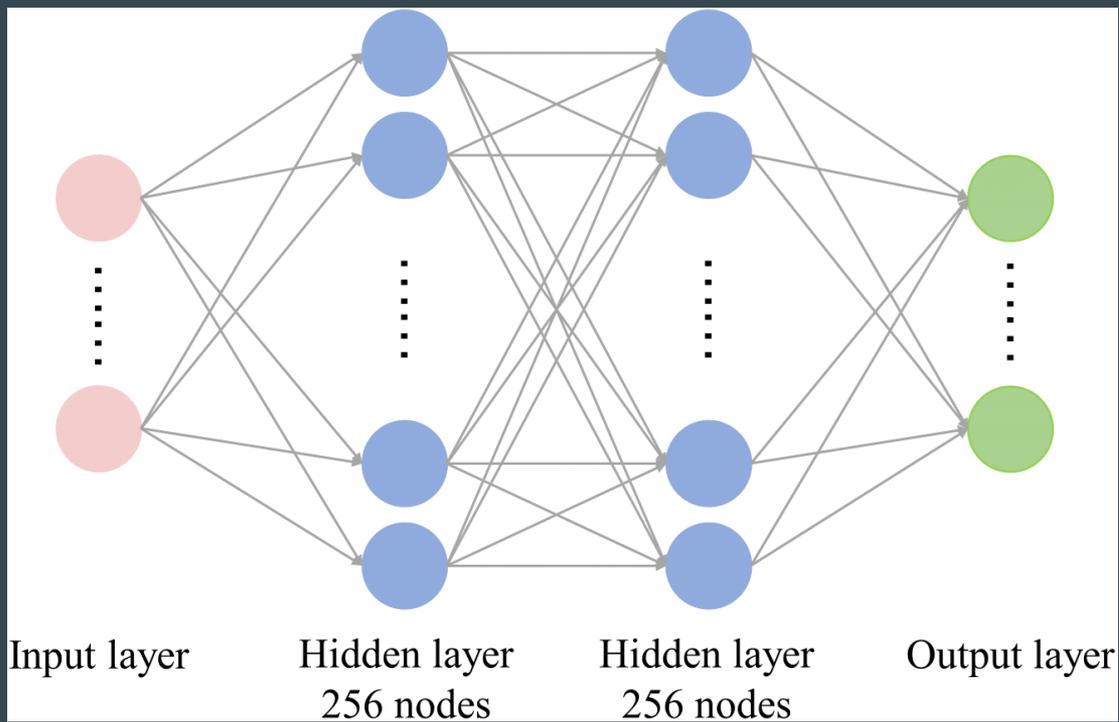
Симуляция и реальный ускоритель

- TraceWin
- OpenAI gym framework
- Магниты случайно “сбивали” в диапазоне $\pm 0,5$ мм, пучок уходил ± 9 мм
- Цель - rms < 0.5 мм
- Ограничение - шаг в секунду, должен справиться за 30 шагов
- РУЕРИС -> CATe II

Нейронная сеть - первый сверточный слой



Нейронная сеть 24 x 32 x 256 x 256 x 10



Функция вознаграждения Reward Function

- r_{distance} отклонение пучка к
- r_{trend} $\Delta B < 0$
- r_{value} В близко к 1 (?)

$$r_{\text{distance}} = -\frac{1}{2N} \sqrt{\sum_{j=0}^N [(B_{xj})^2 + (B_{yj})^2]}.$$

$$r_{\text{trend_single}} = \begin{cases} 1/N, & \Delta b < 0, \\ -3/2N, & \Delta b \geq 0. \end{cases}$$

$$\Delta B_{\text{abs}} = |B^i| - |B^{i-1}|.$$

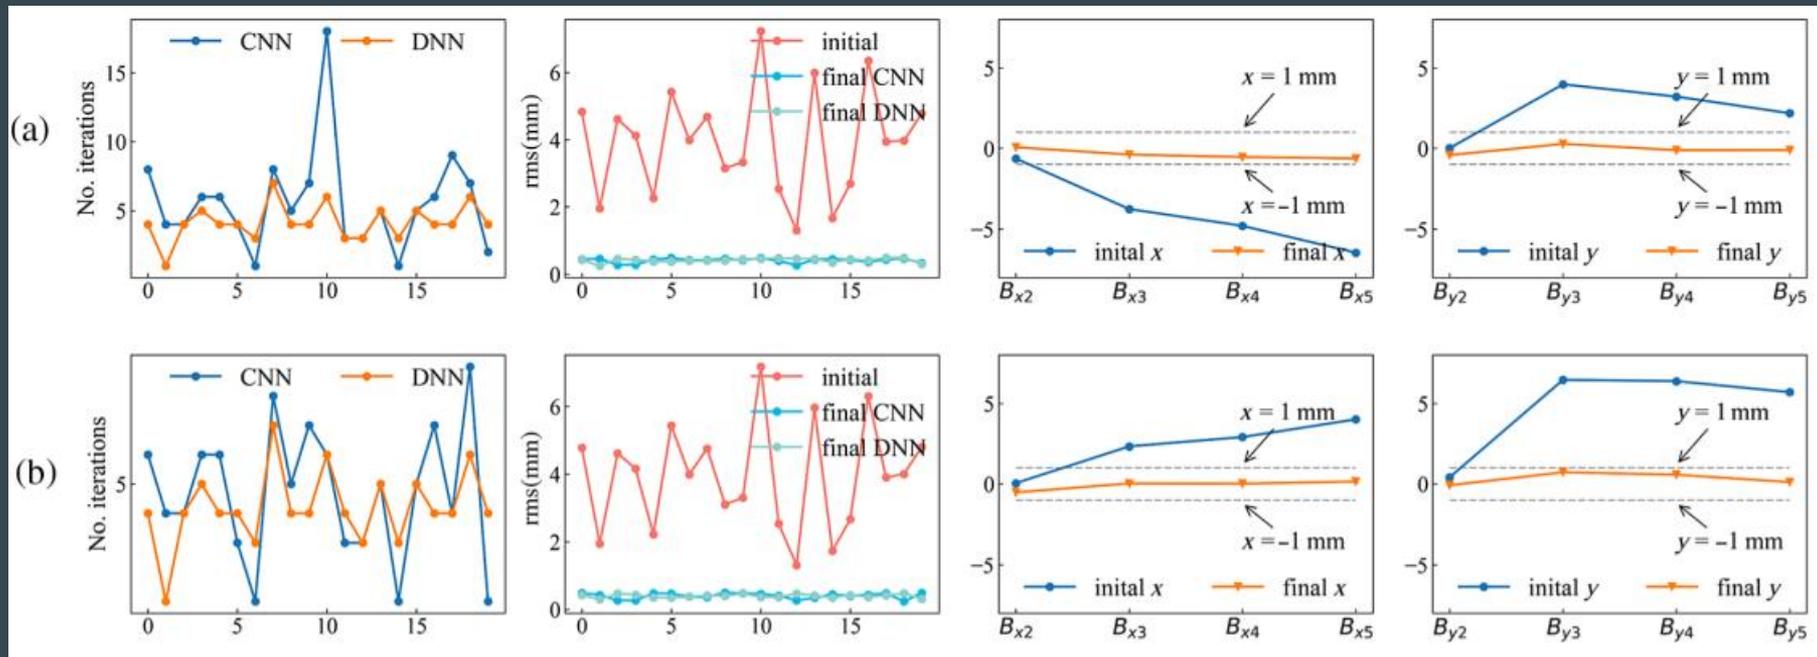
$$r_{\text{value_single}} = \begin{cases} -|b| \times 2, & |b| > 1, \\ (1 - |b|) \times 2, & |b| \leq 1, \end{cases}$$

- + сколько шагов осталось шагов до конца
- + 5 баллов тому, кто справится за 30 шагов

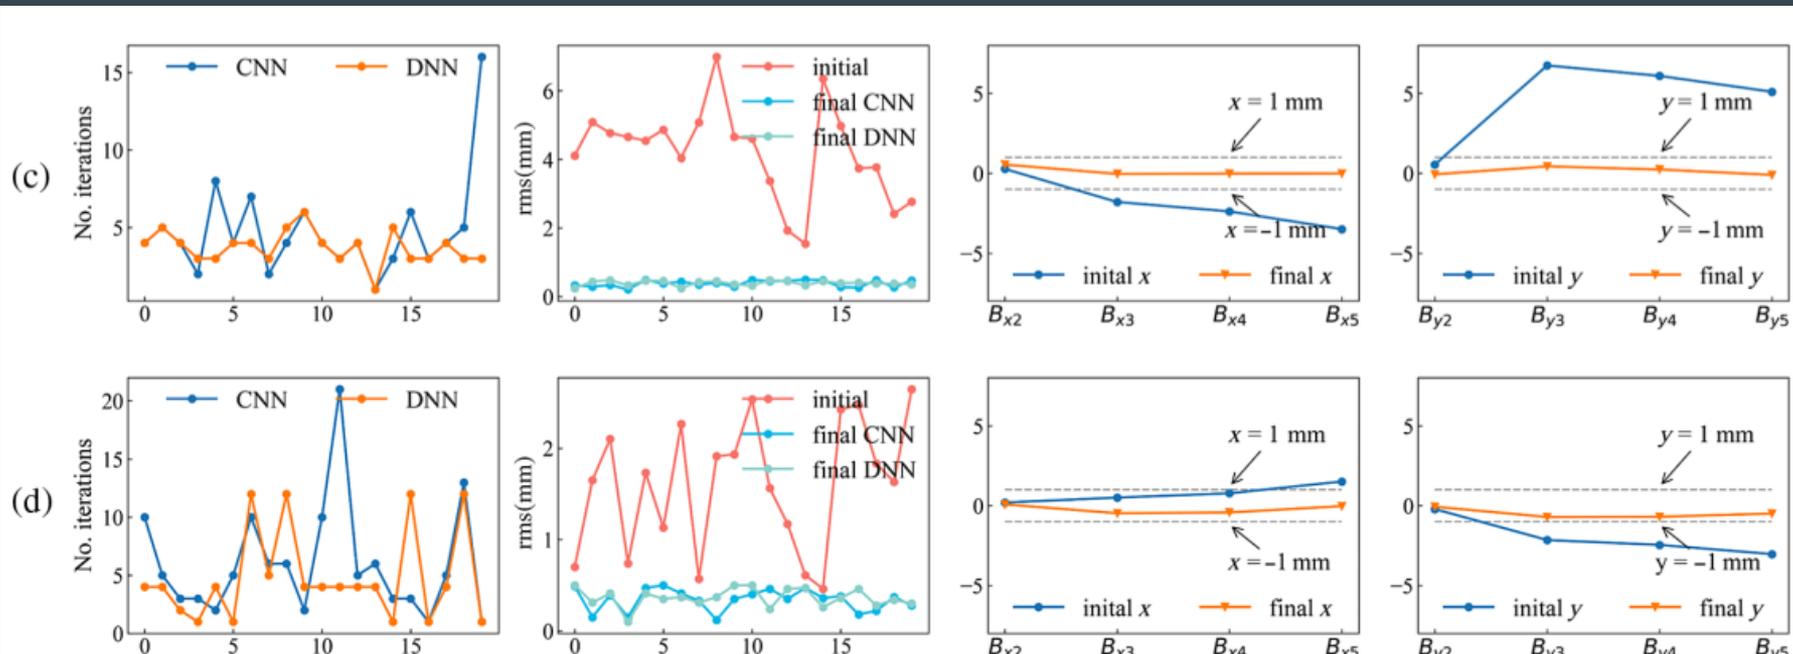
CNN vs DNN

- Обучали две модели
 - DNN - классический TD3
 - CNN - со свертками, дискретными производными и сложным вознаграждением
- TD3 actor-critic
 - на одного актора два разных критика
 - берет худшую оценку
 - некоторые доработки для устойчивости и сходимости
- <https://arxiv.org/abs/1802.09477>

Как тестировали: $^{40}\text{Ca}^{13+}$, $^{40}\text{Ca}^{13+}$ +30% случайной ошибки



Как тестировали: $^{40}\text{Ca}^{13+} \rightarrow ^{55}\text{Mn}^{18+}$, $^{40}\text{Ca}^{13+} \rightarrow$ протон

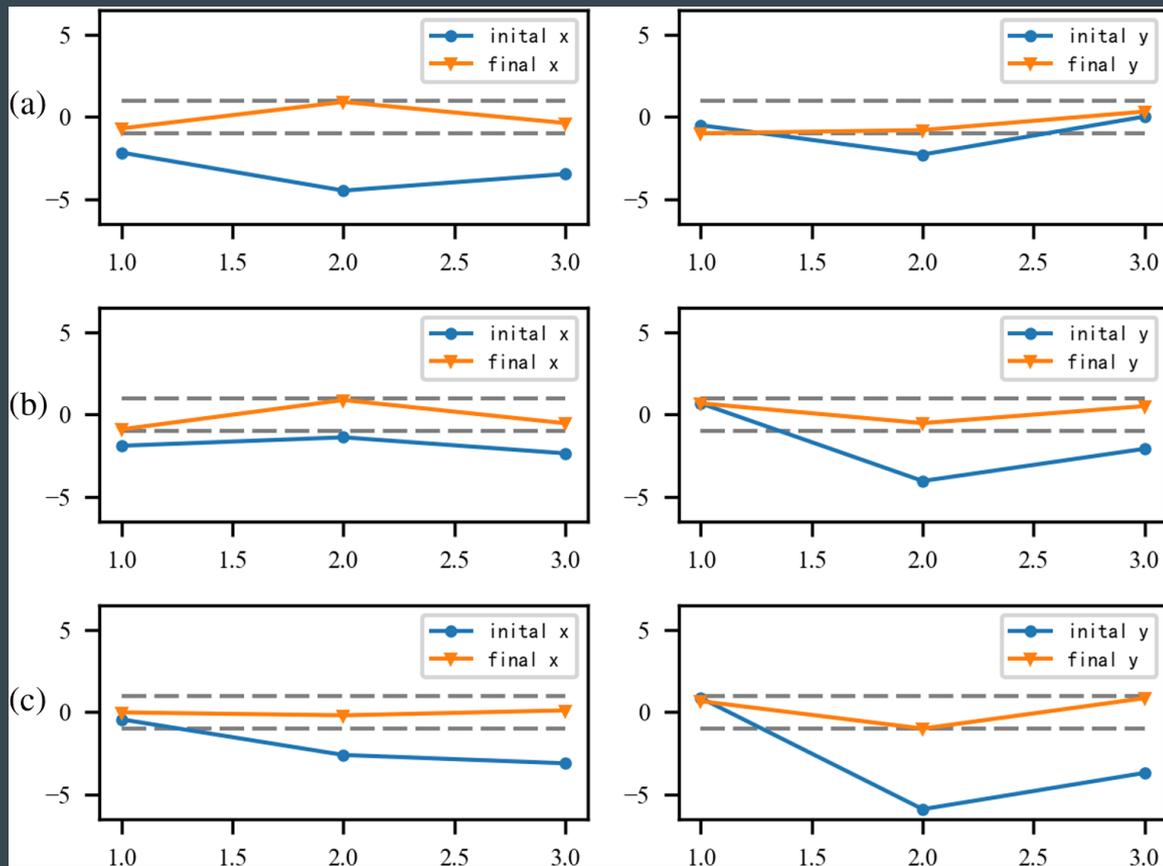


На ускорителе

A. $^{40}\text{Ca}^{13+}$

B. $^{55}\text{Mn}^{18+}$

C. протон



Какую проблему решили

- Удалось получить на ускорителе качество, сравнимое с симуляцией
- Получилось корректировать орбиту менее чем за 15 секунд
- Обученный на S_a агент смог управлять M_p и протонами
- Большой потенциал улучшений

И хотелось бы добавить

- На этот раз все учили хорошо, справились за 40 эпох.
- Еще бы рассказали, как они пришли к такой reward функции - было бы огонь

Multiobjective Bayesian optimization for online accelerator tuning

Ryan Roussel ^{*}

Department of Physics, University of Chicago, Chicago, Illinois 60637, USA

Adi Hanuka  and Auralee Edelen

SLAC National Laboratory, Menlo Park, California 94025, USA



(Received 19 October 2020; accepted 30 April 2021; published 2 June 2021)

DOI: [10.1103/PhysRevAccelBeams.24.062801](https://doi.org/10.1103/PhysRevAccelBeams.24.062801)

optimization for online accelerator tuning

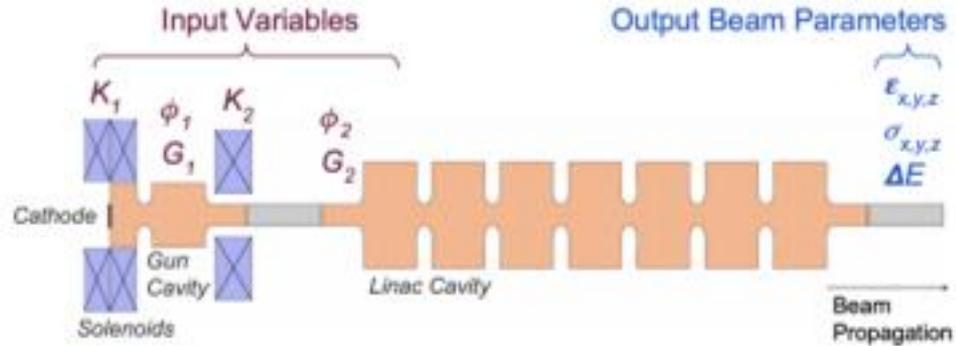
«Онлайн настройка» ускорителя — необходимая часть работы установки, и может серьезно ограничить время, доступное экспериментаторам.

- Это многокритериальная задача! Нужен компромисс между несколькими конкурирующими целями.
- Обычно задачи оптимизации ускорителя решаются до фактической эксплуатации, с помощью расширенного моделирования и методов параллельной оптимизации (NSGA-II, Swarm) - для онлайн-многокритериальной оптимизации ускорителя эти методы использовать сложно, требуют большого количества измерений, чтобы прийти к нужному решению.



Автоматический или полуавтоматический алгоритм, обеспечивающий оптимизацию работы ускорителя, учитывающий все необходимые для экспериментаторов характеристики.

THE ARGONNE WAKEFIELD ACCELERATOR FACILITY (AWA)



AWA input parameters

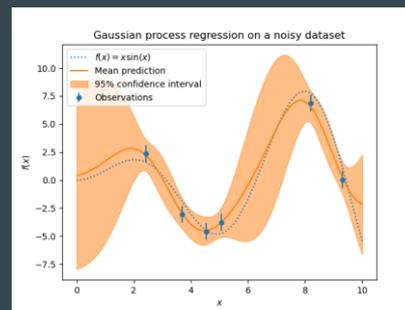
Parameter	Abbreviation	Minimum value	Maximum value	Unit
Solenoid 1 strength	K_1	400	550	m^{-1}
Solenoid 2 strength	K_2	180	280	m^{-1}
Injector phase	ϕ_1	-10	0	deg
Cavity phase	ϕ_2	-10	0	deg
Injector accelerating gradient	G_1	60	75	MV/m
Cavity accelerating gradient	G_2	15	25	MV/m

the AWA photoinjector and first linac cavity.
 Input and output parameters used in optimization are labeled.

MOBO: minimize all seven exit beam parameters as a function of all six input parameters

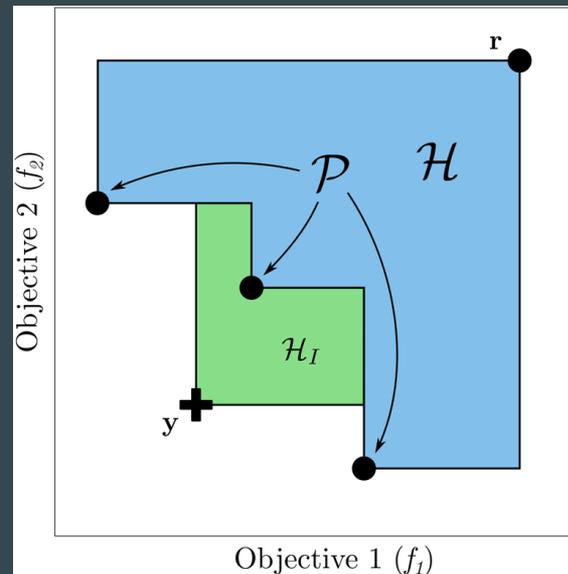
Какую проблему решали

- Оптимизация во время работы ускорителя
 - отнимает время экспериментов
 - эвристические методы и градиентные алгоритмы застревают в локальных минимумах
- Многокритериальная оптимизация
 - одни за счет других
 - эволюционные алгоритмы не подходят - сериализованные наблюдения
 - нужно учитывать дополнительные условия/ограничения
 - нужно учитывать временную “стоимость” предлагаемых изменений
 - нужно оптимизировать под набор задач
- Байесовская оптимизация
 - требует меньше наблюдений для поиска решения
 - явно учитывает шум в наблюдениях
 - Gaussian process модели
 - $f(x) \sim \text{GP}[\mu(x), k(x, x')]$



Многокритериальная оптимизация

- Парето-оптимальные решения
 - нельзя еще улучшить, не ухудшив что-то другое
 - ищем Парето-доминантные точки
- Множество таких решений
 - Парето-множество
- Множество результатов таких решений
 - Парето-фронт
- Парето-гиперобъем
 - Ищем решения, увеличивающие объем
- МОВО - явно оценивает улучшение гиперобъема



Случай одного критерия

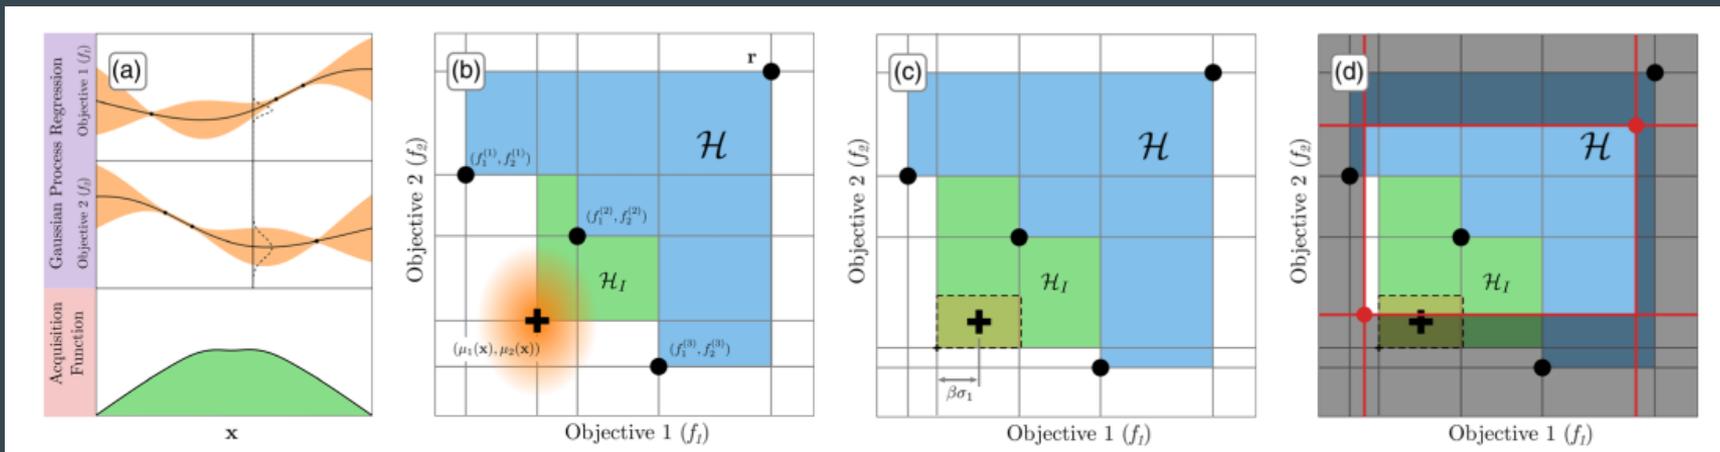
```
input : input domain  $\mathcal{X}$ , dataset  $\mathcal{D}$ , GP prior  $\mathcal{M}_0 = \mathcal{GP}(\mu_0, k_0)$ ,  
        acquisition function  $\alpha$ , noise  $\varepsilon$   
for  $i = 1, 2, 3, \dots$  do  
     $x_i \leftarrow \operatorname{argmin}_{x \in \mathcal{X}} \alpha(x | \mathcal{M}_{i-1});$  // optimize  $\alpha$   
     $y_i \leftarrow f(x_i) + \varepsilon;$  // do observation  
     $\mathcal{M}_i \leftarrow \mathcal{M}_{i-1} | (x_i, y_i);$  // update model  
end
```

- Максимизировать $f(x)$, используя как можно меньше наблюдений f
- Две составные части:
 - Суррогатная модель гауссовского процесса
 - вычислительно дешевая
 - предсказывает μ и σ оценки $f(x) \sim \text{GP}[\mu(x), k(x, x')]$
 - имея набор наблюдений, мы можем оценить $f(x)$ во всей области определения
 - Функция выборки acquisition function
 - зная μ и σ , может оценить приращение гиперобъема
 - помогает искать регионы входного пространства, содержащие Парето-доминантные точки
 - помогает искать точки, сильнее всего снижающие неопределенность
 - настраивается баланс между “разведкой” и “эксплуатацией”
 - Expected Improvement или Upper Confidence Bound

Добавим критерии и ограничения

- Каждый критерий моделируем как независимый GP со своим ядром
- Функция выборки:
 - ENVI (до 3 целей, сложно)
 - UCSB-NVI (легко считать)
- Используют только UCSB-NVI, зануляют области ограничений

$$\alpha_{\text{ENVI}}(\mu, \sigma, \mathcal{P}, \mathbf{r}) := \int_{\mathbb{R}^P} \mathcal{H}_I(\mathcal{P}, \mathbf{y}, \mathbf{r}) \cdot \xi_{\mu, \sigma}(\mathbf{y}) d\mathbf{y},$$
$$\alpha_{\text{UCSB-NVI}}(\mu, \sigma, \mathcal{P}, \mathbf{r}, \beta) := \mathcal{H}_I(\mathcal{P}, \mu - \sqrt{\beta}\sigma, \mathbf{r}).$$



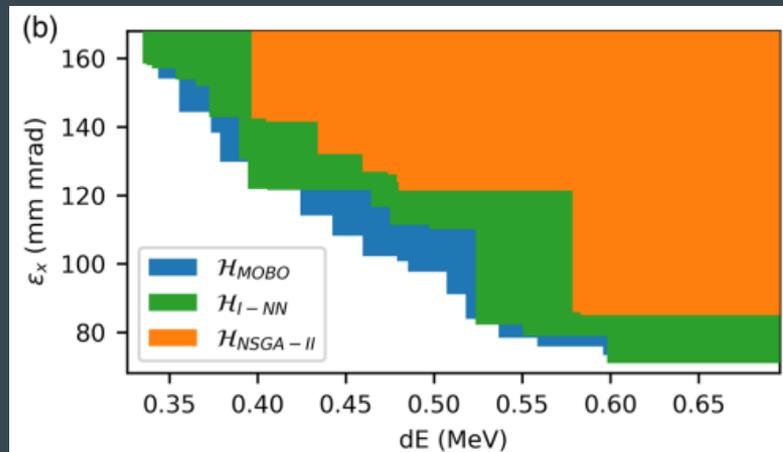
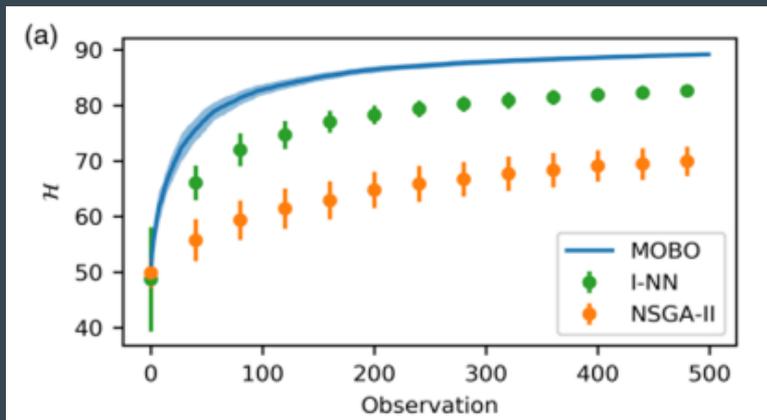
Пространство близких параметров

- Хотелось бы минимально изменять текущие настройки
 - время коррекции часто пропорционально магнитуде коррекции
 - добавляем “штраф” за далеко расположенные варианты

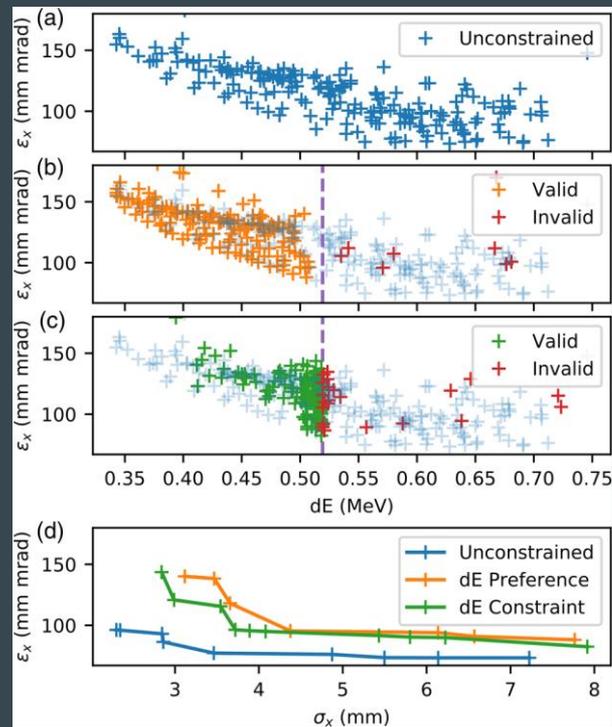
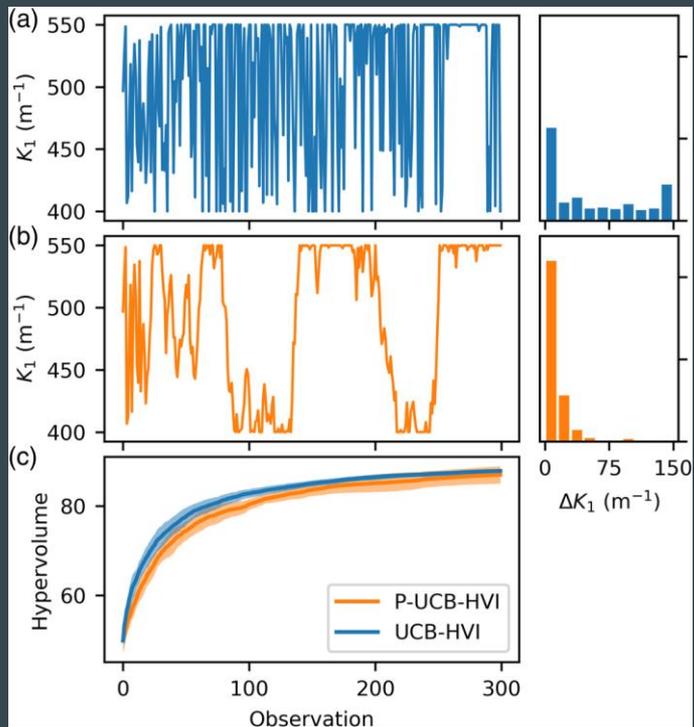
$$\tilde{\alpha}(\mathbf{x}, \mathbf{x}_0) = \alpha(\mathbf{x}) \exp \left[-\frac{1}{2} (\mathbf{x} - \mathbf{x}_0)^T \mathbf{\Lambda} (\mathbf{x} - \mathbf{x}_0) \right]$$

Практическое применение

- Сгенерируем 20 случайных точек в пространстве параметров
- Обучим GP модели
- Используя GP-модели, выберем и протестируем 500 точек
- Запустим 10 раз, рестартовав из случайного набора точек



Поиск близких параметров и ограничения



Итого - оптимизация

- Получилось управлять ускорителем
- Можно применять и для симуляций - они тоже дорогие
- Можно все-таки считать ENVI, появились новые подходы
- Доступен код https://github.com/roussel-ryan/Accelerator_MOBO
- Есть библиотека <https://github.com/pytorch/botorch>
- Есть открытая платформа для оптимизации <https://ax.dev/>

Nowadays, machine learning is more and more widely used in the accelerator field

- Leemann, S.; Liu, S.; Hexemer, A.; Marcus, M.; Melton, C.; Nishimura, H.; Sun, C. Demonstration of Machine Learning-Based Model-Independent Stabilization of Source Properties in Synchrotron Light Sources. Phys. Rev. Lett. 2019, 123, 19480
- Lu, Y.; Leemann, S.; Sun, C.; Ehrlichman, M.; Nishimura, H.; Venturini, M.; Hellert, T. Demonstration of machine learning-enhanced multi-objective optimization of ultrahigh-brightness lattices for 4th-generation synchrotron light sources. Nucl. Instrum. Methods Phys. Res. Sect. A 2023, 1050, 168192
- Jinyu, W.; Zheng, S.; Xiang, Z.; Yu, B.; Chengying, T.; Paul, C.; Senlin, H.; Yi, J.; Yongbin, L.; Biaobin, L. Machine learning applications in large particle accelerator facilities: Review and prospects. High Power Laser Part. Beams 2021, 33, 094001
- Kaiser, J.; Stein, O.; Eichler, A. Learning-based optimisation of particle accelerators under partial observability without real-world training. In Proceedings of the International Conference on Machine Learning, Xiamen, China, 27–29 May 2022; pp. 10575–10585.
- Wang, F.Y.; Song, M.; Edelen, A.; Huang, X. Machine learning for design optimization of storage ring nonlinear dynamics. arXiv 2019, arXiv:1910.14220.
- Lu, Y.; Leemann, S.; Sun, C.; Ehrlichman, M.; Nishimura, H.; Venturini, M.; Hellert, T. Demonstration of machine learning-enhanced multi-objective optimization of ultrahigh-brightness lattices for 4th-generation synchrotron light sources. Nucl. Instrum. Methods Phys. Res. Sect. A 2023, 1050, 168192.
- Ivanov, A.; Agapov, I. Physics-based deep neural networks for beam dynamics in charged particle accelerators. Phys. Rev. Accel. Beams 2020, 23, 074601
- Wan, J.; Jiao, Y. Machine learning enabled fast evaluation of dynamic aperture for storage ring accelerators. New J. Phys. 2022, 24, 063030
- L. Ruichun, Z. Qinglei, M. Qingru, J. Bocheng, and Z. ZhenTang, Application of machine learning in orbital correction of storage ring, High Power Laser Part. Beams 33, 034007 (2021).
- C. Z. Xiao Dengjie and Qiao Yusi, Orbit correction based on machine learning, High Power Laser Part. Beams 33, 054004 (2021).
- V. Kain, S. Hirlander, B. Goddard, F. M. Velotti, and G. Valentino, Sample-efficient reinforcement learning for CERN accelerator control, Phys. Rev. Accel. Beams 23, 124801 (2020).

Почитать про ML

- [A disciplined approach to neural network hyper-parameters \(Smith\)](#)
- Удивительные свойства функции потерь в нейросетях, [ч1](#) [ч2](#) (Ветров)
- BayesDLL: Bayesian Deep Learning Library [arxiv](#) [github](#) (Kim, Hospedales)
- [Reinforcement Learning: An Introduction \(Sutton & Barto\)](#)
- [Deep Reinforcement Learning Course](#) HuggingFace
- [Structure in Reinforcement Learning: A Survey and Open Problems](#) (Mohan, Lindauer)
- [Gaussian Processes for Machine Learning \(Rasmussen, Williams\)](#)
- [Recent Advances in Bayesian Optimization](#) (Wang et al)

4th ICFA Beam Dynamics Mini-Workshop on Machine Learning Applications for Particle Accelerators

📅 Mar 5, 2024, 8:00 AM → Mar 8, 2024, 6:40 PM Asia/Seoul

📍 Lahan Select Gyeongju, South Korea

<https://www.indico.kr/event/47/timetable/?print=1&view=standard>

Learning to Do or Learning While Doing: Reinforcement Learning and Bayesian Optimisation for Online Continuous Tuning

Applying Reinforcement Learning to Particle Accelerators: An Introduction

Machine Learning to improve Accelerator Operations at SNS

Online optimisations of lifetime and injection efficiency in the ESRF EBS storage ring

Real-time Integration of Machine Learning for Beam Size Control at the Advanced Light Source

From Physics Study to Operations: Progress for Production Deployment of ML-Driven Beam Loss Optimization

Physics Informed and Bayesian Machine Learning for Maximization of Beam Polarization at RHIC



Вопросы?



← презентация



← tg СКИФ