



Bank of Russia

ДИСКУССИЯ «ПРОГНОЗИРОВАНИЕ ИНФЛЯЦИИ: ИСПОЛЬЗОВАНИЕ ML ИЛИ СТАРАЯ ДОБРАЯ ЭКОНОМЕТРИКА»

Сергей Селезнев

Департамент исследований и прогнозирования, Банк России

Новые подходы к измерению, изучению и прогнозированию цен

Банк России, Москва

26 марта, 2024

Disclaimer

Настоящий доклад отражает личную позицию авторов. Содержание и результаты данного доклада не следует рассматривать, в том числе цитировать в каких-либо изданиях, как официальную позицию Банка России или указание на официальную политику или решения регулятора. Любые ошибки в данном материале являются исключительно авторскими.

Машинное обучение в макроэкономических задачах

Машинное обучение **вместо** классических моделей

- Машинное обучение для замены (прогнозных) моделей (например, Chakraborty and Joseph (2017), Huber et al. (2023), Hauzenberger et al. (2022,2023));

Машинное обучение **вместе** с классическими моделями

- Использование алгоритмов машинного обучения для построения индикаторов характеризующих экономическую динамику или дополнительных признаков для прогноза (например, Thorsrud (2020));
- Ускорение/улучшение качества уже существующих вычислительных алгоритмов (например, Maliar et al. (2021), Kase et al. (2022), Dyer et al. (2022), Khabibullin and Seleznev (2022)).

ML/эконометрика или интерпретируемость/не интерпретируемость?

1 Introduction 1

I Foundations 29

2 Probability: Univariate Models 31
 3 Probability: Multivariate Models 75
 4 Statistics 101
 5 Decision Theory 161
 6 Information Theory 197
 7 Linear Algebra 219
 8 Optimization 265

II Linear models 315

9 Linear Discriminant Analysis 317
 10 Logistic regression 333
 11 Linear Regression 363
 12 Generalized Linear Models 405

III Deep neural networks 413

13 Neural Networks for Structured Data 415
 14 Neural Networks for Images 457
 15 Neural networks for sequences 491

IV Nonparametric models 533

16 Exemplar-based Methods 533
 17 Kernel Methods 553
 18 Trees, Forests, Bagging and Boosting 591

V Beyond supervised learning

19 Learning with Fewer Labeled Examples
 20 Dimensionality Reduction 645
 21 Clustering 703
 22 Recommender Systems 729
 23 Graph Embeddings 741

VI Appendix 763

A Notation 765

1 Introduction 1

I Fundamentals 3

2 Probability 5
 3 Statistics 69
 4 Graphical models 143
 5 Information theory 217
 6 Optimization 255

II Inference 341

7 Inference algorithms: an overview 343
 8 Gaussian filtering and smoothing 355
 9 Message passing algorithms 397
 10 Variational inference 435
 11 Monte Carlo methods 477
 12 Markov chain Monte Carlo 493
 13 Sequential Monte Carlo 537

III Prediction 567

14 Predictive models: an overview 569
 15 Generalized linear models 583
 16 Deep neural networks 621
 17 Bayesian neural networks 637
 18 Gaussian processes 671
 19 Beyond the iid assumption 725

IV Generation 761

20 Generative models: an overview 763
 21 Variational autoencoders 779
 22 Autoregressive models 815
 23 Normalizing flows 823
 24 Energy-based models 843
 25 Diffusion models 861
 26 Generative adversarial networks 887

V Discovery 921

27 Discovery methods: an overview 923
 28 Latent factor models 925
 29 State-space models 975
 30 Graph learning 1039
 31 Nonparametric Bayesian models 1043
 32 Representation learning 1045
 33 Interpretability 1069

VI Action 1099

34 Decision making under uncertainty 1101
 35 Reinforcement learning 1137
 36 Causality 1175

Гибкость моделей машинного обучения это не всегда хорошо

Машинное обучение показывает хорошие результаты в ситуациях, когда имеется достаточное количество данных

- Успех ML моделей во многих областях идет рука об руку с наличием больших массивов данных;
- У макроэкономистов данных не так много (во временном разрезе).

Модели машинного обучения плохо работают вне покрытия (в ситуациях, когда прогнозы наиболее важны)

- В регионах пространства признаков, где модели не видели реальных данных, они проводят экстраполяцию исходя из своих внутренних (не всегда понятных и логичных) правил;
- Нейронные сети работают по «остаточному принципу» и могут при одинаковых прогнозах внутри покрытия, выдавать абсолютно разные значения вне его (см. Lakshminarayanan et al. (2017));
- Классические модели на деревьях (см. Brieman (2001), Friedman (2001)) не выходят за значения внутри выборки.

ML-модели еще больше подвержены снупингу

Снупинг (дреджинг)

- Получение случайных со статистической точки зрения результатов из-за перебора большого количества моделей, признаков и т.д. (см., например, White (2000));

Поле для снупинга при прогнозировании инфляции

Не более 20 лет данных для России!!!

- Тестовый период;
- Преобразование данных (PoP/YoY, прирост/индекс, процедура сезонной корректировки);
- Набор признаков;
- Модели;

Дополнительные опции в ML

- Архитектуры моделей;
- Гиперпараметры;
- Процедуры валидации;
- ...

Список литературы

Breiman L. (2001). Random Forests. *Machine Learning*. 45: 5-32.

Chakraborty, C. and A. Joseph (2017). Machine learning at central banks," Bank of England working papers, 674.

Dyer, J., Cannon, P., Farmer, J.D. and S.M. Schmon (2022). Black-box Bayesian Inference for Economic Agent-Based Models. arXiv: 2202.00625.

Friedman J.H. (2001). Greedy Function Approximation: A Gradient Boosting Machine. *Institute of Mathematical Statistics*, 29: 1189-1232

Hauzenberger, N., F. Huber, K. Klieber and M. Marcellino (2022). Enhanced Bayesian Neural Networks for Macroeconomics and Finance. arXiv:2211.04752.

Hauzenberger, N., F. Huber, G. Koop and J. Mitchell (2023). Bayesian Modeling of Time-Varying Parameters Using Regression Trees., FRB of Cleveland Working Papers 23-05.

Huber, F., G. Koop, L. Onorante, M. Pfarrhofer and J. Schreiner (2024). Nowcasting in a pandemic using non-parametric mixed frequency VARs. *Journal of Econometrics*, 232(1): 52-69.



Список литературы (2)

Kase H., L. Melosi and M. Rottner (2022). Estimating Nonlinear Heterogeneous Agents Models with Neural Networks. FRB of Chicago Working Paper, 2022-26.

Khabibullin, R. and S. Seleznev (2022). Fast Estimation of Bayesian State Space Models Using Amortized Simulation-Based Inference. Bank of Russia Working Paper Series, №104.

Lakshminarayanan B., A. Pritzel, C. Blundell (2016). Simple and Scalable Predictive Uncertainty Estimation using Deep Ensemble. Neural Information Processing Systems.

Murphy K. (2022). Probabilistic Machine Learning: An introduction. MIT Press.

Murphy K. (2023). Probabilistic Machine Learning: Advanced Topics. MIT Press.

Thorsrud, L.A. (2020). Words are the New Numbers: A Newsy Coincident Index of the Business Cycle. Journal of Business & Economic Statistics, 38(2): 393-409.

White H. (2000). A Reality Check for Data Snooping. Econometrica, 68(5): 1097-1126.