



The CLEAN PAPER

WHAT THE PAPER SAYS · WHAT IT DOESN'T · WHY IT MATTERS

Large behavior model সত্যহি সাহায্য করে — কিন্তু general-purpose robot নয়

প্রায় 1,700 hours robot data-তে pretrained diffusion policy, per-task finetuning-এর পরে scratch baseline-এর তুলনায় moderate but real advantage দেখায়: 3–5× কম task-specific data এবং distribution shift-এ বেশি robustness। Zero-shot generalist বা emergent leap দেখা যায়নি; paper-এর আরকে বড় ফল হলো robot evaluation-এ noise কত সহজে progress সজে উঠতে পারে।


Written by Lucio Vaglio · Cross-checked by Laura Nesso · Edited by Michele Renda · Figures by Laura Nesso and Nova Vela · AI-assisted, human-reviewed

Paper: *A Careful Examination of Large Behavior Models for Multitask Dexterous Manipulation*, Toyota Research Institute Large Behavior Model Team — J. Barreiros, A. Beaulieu, et al.; senior authors incl. R. Ambrus, B. Burchfiel, S. Feng, H. Kress-Gazit (Cornell), R. Tedrake, Science Robotics (2026); preprint arXiv:2507.05331 · DOI: 10.1126/scirobotics.aea6201

একটি রোবট গবেষণাপত্র যার আসল বিষয় সত্যতা

রোবট “ভিত্তিমডলে” নিয়ে প্রচুর অতিরঞ্জিত প্রচার আছে: অনেকে কাজেরে তথ্য দিয়ে একটি বড় নীতিমডলে পূর্বপ্রশিক্ষণ দেওয়া করলে কিস্টেনিভুন কাজ দ্রুত শিখবে, কম প্রদর্শন লাগবে এবং অপরচিতি শর্তে ভালো টকিববে? Toyota গবেষণা ইনস্টিটিউটের এই গবেষণা সেই প্রশ্নকে অস্বাভাবিকভাবে কঠোর মূল্যায়নের সামনে দাঁড় করিয়েছে।

ফলটিনা অলটৈ ককি সাফল্য, না ব্যর্থতা। **Pretraining + পরতটিকাজেরে জন্য ফাইন-টউনিং** থেকে বাস্তব কনিতু মাঝারি সুবিধা পাওয়া যায়— বশিষে করে কম কাজ-নরিদ্যিট তথ্য লাগে এবং বণ্টন পরবর্তনে মডলে বেশি মজবুত থাকে। কনিতু **জরিটে-শট সাধারণ-উদ্দেশ্যেরে রোবট**-এর গল্প এখানেকাজ করনো। আরও গুরুত্বপূর্ণ, প্রভাব এত ছোট যে দুর্বল মূল্যায়ন সহজেই শব্দদূষণকে অগ্রগতি বলে ভুল করতে পারে।



গবেষণাটি ব্লাইন্ড, র্যান্ডমাইজড, বড়-নমুনা মূল্যায়ন পাইপলাইন ব্যবহার করে পূর্বপ্রশিক্ষণ ও ফাইন-টউনকৃত বৃহৎ আচরণ মডেলকে শুরুর থেকে প্রশিক্ষণ একক-কাজ প্রারম্ভিক মানেরে সঙ্গত তুলনা করেছে। মূল ফল মাঝারি সুবিধা; সাধারণ-উদ্দেশ্য স্বাযতশাসন নয়।

Original The Clean Paper diagram CC BY 4.0

গবেষকরো কী করছেন

তারা বসিরণ-ভিত্তিক **বৃহৎ আচরণ মডলে (LBM)**-কে প্রায় **1,700 ঘণ্টা** বচিত্রির রোবট-পরীক্ষামূলক কৌশল তথ্যে পূর্বপ্রশিক্ষণ দনে, পরে নরিদ্যিট কাজে ফাইন-টউন করনে। তুলনার জন্য একই কাজে আঁড় থেকে প্রশিক্ষণ একক-কাজ নীতিমডলে রাখা হয়।

মূল্যায়নটি অস্বাভাবিকভাবে কঠোর ছিল: মূল্যায়ক জানতনে না কোন শর্ত পরীক্ষা করা হচ্ছে; পরীক্ষাগুলো র্যান্ডমাইজড ছিল; বাস্তব রোবট ও সম্মিলশন—দুই পরবিশেষেই বারবার পরীক্ষা চালানো হয়; এবং পরিসংখ্যানগত বিশ্লেষণ পূর্ববনরিধারতি পরে টেকনিকল মনেকো করা হয়। মোট প্রায় **1,800টি বাস্তব-জগতেরে** এবং **47,000-এর বেশি সম্মিলশন** পরীক্ষা—রোবট শেখার একটি গবেষণার জন্য বড় পরিসর।

[video pending]

Breakfast টেবিলে সাজানো আর একটি মূল্যায়ন কাজ: বামের একক-কাজ প্রারম্ভিক মান, ডানের LBM। এটি একটি নির্দিষ্ট কাজের তুলনা—সাধারণ-উদ্দেশ্যে স্বাভাবিকতায় প্রমাণ নয়।

তাঁরা কী পয়েছেন

- ফাইন-টাইনকৃত LBM সামগ্রিকভাবে শুরুর থেকে প্রশিক্ষিত প্রারম্ভিক মানের চেয়ে ভালো। প্রতটি কাজে সুবিধা সবসময় বড় নয়, কিন্তু সামগ্রিক তুলনা পরিসংখ্যানগতভাবে নির্ভরযোগ্য।
- সবচেয়ে স্পষ্ট লাভ তথ্য-দক্ষতা: শুরুর থেকে প্রশিক্ষিত মডেলের সমপর্যায়ে ফল পতে LBM-এর প্রায় 3–5 গুণ কম কাজ-নির্দিষ্ট তথ্য লাগে। একটি breakfast-table কাজে মাত্র 15% প্রদর্শন দিয়ে ফাইন-টাইনকৃত LBM, 100% তথ্য দিয়ে শুরুর থেকে প্রশিক্ষিত নীতিকে ছাড়িয়ে গেছে।
- বর্ণন সরণ-এ সুবিধা বাড়বে। প্রশিক্ষণ শর্ত থেকে পরিশেষে বদলালে পূর্বপ্রশিক্ষিত মডেল বেশি দৃঢ় থাকবে; বাস্তব ব্যবহারিক মতোতায়নের জন্য এটি সম্ভবত সবচেয়ে গুরুত্বপূর্ণ ফল।
- পূর্বপ্রশিক্ষণ তথ্য বাড়ার সত্ত্বেও কার্যসম্পাদন মসৃণভাবে বাড়বে; পরীক্ষিত পরিসরে কোনো হঠাৎ “উদ্ভূত লাফ” নেই।
- জরুরি-শর্ত পূর্বপ্রশিক্ষিত LBM ধারাবাহিকভাবে একক-কাজ প্রারম্ভিক মানকে ছাড়িয়ে যেতে পারেনি। “প্রম্পট দলিই ইচ্ছামতো কাজ” গল্পটি এই তথ্য সমর্থন করে না।
- প্রভাব মাঝারি হওয়ায় নমুনার আকার ছোট হলে সহজেই সংকেত হারিয়ে যায়। লেখকরা বলেন রোবট শেখার গবেষণা-সাহিত্যে বহু ফল পরিসংখ্যানগত শব্দদূষণ হতে পারে। তথ্য স্বাভাবিকীকরণের মতো সাধারণ পছন্দ স্থাপত্যগত পরিবর্তনের চেয়েও বড় প্রভাব ফেলেছে; মূল্যায়ন শেষে হওয়ার পরে একটি স্বাভাবিকীকরণ ত্রুটিও ধরা পড়ে।

এর সম্ভাব্য অর্থ

বচিতির রোবট তথ্যে বড়-পরিসরে পূর্বপ্রশিক্ষণ সত্যিই কাজে লাগবে: নতুন কাজে কম প্রদর্শন লাগবে এবং পরিশেষে বদলালে নীতি তুলনামূলকভাবে বেশি মজবুত থাকবে। কিন্তু সুবিধাটি শর্তসাপেক্ষ—বিশেষ করে ফাইন-টাইনিংয়ের পরে। এটি কোনো সরবজানী সাধারণ-উদ্দেশ্যের রোবট নয়।

গবেষণাপত্রের আরও বড় অবদান পদ্ধতিগত: রোবট নীতিমডলে সম্প্রদায়ের বিশ্বাসযোগ্য দাবি করতে কত প্রমাণ দরকার, সঠে দেখায়। ছোট প্রভাব + ত্রুটিপূর্ণ মূল্যায়ন = অতিরঞ্জিত প্রচার তৈরির সহজ পদ্ধতি।

এটিকে প্রমাণ করে না

- সাধারণ-উদ্দেশ্যে রোবট নয়; ন্যূনতরতি কাজ, দূরন্যূনতরতি প্রদর্শন এবং নির্দিষ্ট বসিরণ স্থাপত্য।
- জরুরি-শর্ত সাধারণীকরণ যাচাই করেনি। ফাইনটাইনিং ছাড়া সামঞ্জস্যপূর্ণ সুবিধা নেই।
- কোনো উদ্ভূত লাফ দেখা যায়নি; স্কেলেই মসৃণ।
- ~50% সাফল্য-হার পরিসর সংবেদনশীলতার জন্য নির্বাচিত; এগুলো ব্যবহারিক মতোতায়নে নির্ভরযোগ্যতা স্কোর নয়।
- নিরাপত্তা, উন্মুক্ত-জগৎ স্বাভাবিকতায় বা ইচ্ছামতো গৃহস্থালি ব্যবহারিক মতোতায়নে সম্প্রদায় কিছু বলেনা।
- নির্দিষ্ট ব্যর্থতার কারণও পুরোপুরি ব্যাখ্যা করা হয়নি।

প্রমাণ কতটা শক্তিশালী?

কেন্দ্রীয় তুলনামূলক দাবির প্রমাণ শক্ত: ব্লাইন্ড/র‍্যান্ডমাইজড প্রটেস্টাকল, বড় নমুনা, পরিসংখ্যানগত পরীক্ষাগুলো। এবং স্কোরিং QA। এই কঠোরতার জন্য মাঝারি প্রভাবও বিশ্বাসযোগ্য।

সতর্কতা আছে। ত্রুটি দণ্ড মূল্যায়ন এলোমেলোতা ধরে, **প্রশিক্ষণ-চালনা এলোমেলোতা** নয়। বাস্তব জগতের কাজে 50টি পরীক্ষা ছোট প্রভাব শনাক্ত করতে ব্যর্থ হতে পারে। একটি স্থাপত্য, একটি পরীক্ষাগার, মাঝারি ভাষা এনকোডার, এবং পরবর্তী বিশ্লেষণ স্বাভাবিকীকরণ ত্রুটি সাধারণীকরণ সীমিত করে। এই ব্যাখ্যাটিকে লেখকদের প্রপ্‌রিন্টিং ওপর ভিত্তি করে; সাময়িকী সংস্করণের পরিবর্তন আলাদাভাবে যাচাই করা হয়নি।

কেন এটি গুরুত্বপূর্ণ

“রয়ে বাবে ভিত্তিমডলে” কথাটি সহজে অতিরঞ্জন ডেকে আনে। এই গবেষণার বক্তব্য অনেক সংযত: পদ্ধতিটিকে কাজ করে, কিন্তু জাদুর মতো নয়। বচিত্র ডটোয় পূর্বপ্রশিক্ষণ তথ্য-দক্ষতা ও দৃঢ়তা বাড়ায়; মডলে বড় হলে লাভও মনে টামুটি পূর্বানুমানযোগ্যভাবে বাড়বে; কিন্তু জরিৎ-শট সাধারণ-উদ্দেশ্য রয়ে বাবে এখনও তৈরি হয়নি। আরও গুরুত্বপূর্ণ, গবেষণাটি মনে করিয়ে দেয়—পরিসংখ্যানগত পদ্ধতি দুর্বল হলে কেনো নতুন স্থাপত্যের প্রকৃত উন্নতির চেয়ে পরীক্ষার শব্দই বড় হয়ে দেখা দিতে পারে।

সংক্ষিপ্ত সারাংশ

Toyota গবেষণা ইনস্টিটিউটে বৃহৎ আচরণ মডলে গবেষণা প্রায় 1,700 ঘণ্টা বচিত্র পরীক্ষামূলক কৌশল তথ্যে পূর্বপ্রশিক্ষণ বসিরণ নীতিমডলে শুরুর থেকে প্রশিক্ষণ একক-কাজ প্রারম্ভিক মানের সঙ্গে অস্বাভাবিকভাবে কঠোর মূল্যায়নে তুলনা করেছে। প্রতি-কাজ ফাইন-টুনিংয়ের পরে LBM সামগ্রিক হিসাবে ভালো, প্রায় $3-5 \times$ **কম কাজ-নরুদ্বিষ্ট তথ্য**-তে সমতুল্য কার্যসম্পাদন পায় এবং বণ্টন সরণে বেশি দৃঢ়। কিন্তু জরিৎ-শট ব্যবহার ধারাবাহিকভাবে ভালো নয়, কেনো উদ্ভূত লাফ নেই, প্রভাব মাঝারি এবং মূল্যায়ন নকশা অত্যন্ত গুরুত্বপূর্ণ। ফল রয়ে বাবে ভিত্তিমডলে দক্ষিরে পরিমাপিত সমর্থন—সাধারণ-উদ্দেশ্য রয়ে বাবে নয়।

বাড়াবাড়ি ছাড়া যাচাই

গবেষণা যা দেখায়: পূর্বপ্রশিক্ষণ + ফাইনটুনিং মাঝারি কিন্তু বাস্তব উপকার দেয়; তথ্য দক্ষতা ও দৃঢ়তা সবচেয়ে পরিষ্কার।

যা সম্ভাব্য: আরও বড় VLA/রয়ে বাবে মডলে একই ধারা বড় পরিসরেও বজায় থাকতে পারে।

যা দেখায় না: জরিৎ-শট সাধারণ রয়ে বাবে, উদ্ভূত বুদ্ধিমত্তা, ব্যবহারিক মতোয়নে নিরাপত্তা, বা ইচ্ছামতো কাজের স্বায়ত্তশাসন।

মূল সীমাবদ্ধতা: প্রশিক্ষণ এলোমেলোতা পরিসংখ্যানে ধরা নেই; সীমিত বাস্তব জগতের পরীক্ষাগুলো; একটি স্থাপত্য/পরীক্ষাগার; মাঝারি ভাষা এনকোডার; স্বাভাবিকীকরণ ত্রুটি।

আস্থা: কেন্দ্রীয় তুলনায় উচ্চ; বড়তর ভিত্তিমডলে প্রক্ষেপণে মাঝারি।

উৎস

arXiv:2507.05331

<https://arxiv.org/abs/2507.05331>

Peer-reviewed version (not retrieved) — Science Robotics, 10.1126/scirobotics.aea6201

<https://doi.org/10.1126/scirobotics.aea6201>

Project page

<https://toyotaresearchinstitute.github.io/lbm1/>