




The CLEAN PAPER

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

Werken grote robot-“foundation modellen” echt beter? Een zorgvuldig antwoord — bescheiden ja, en de meeste studies kunnen het niet zeggen

Het Toyota Research Institute trainde “large behavior models” — robotpolities voorgetraind op ~1.700 uur diverse manipulatiegegevens — en testte ze tegen vanaf-nul getrainde eentaakpolities met ongewone striktheid: blinde, gerandomiseerde proeven met grote steekproef (~1.800 echt, meer dan 47.000 in simulatie) met echte statistiek. Na finetuning per taak deden de grote modellen het gemiddeld beter, hadden ruwweg 3–5× minder taakspecifieke gegevens nodig en waren robuuster bij verschoven omstandigheden; de prestatie steeg gelijkmatig met meer voortrainingsgegevens. Maar zonder finetuning versloegen ze eentaakmodellen niet consistent, meerdere effecten waren klein genoeg dat alleen de grote steekproeven ze onthulden, en een alledaagse datanormalisatie-keuze telde meer dan de architectuur. Het is gematigde steun voor de richting van de robot-foundation-modellen — geen universele robot, geen zero-shot-generalist, geen “emergente sprong” — plus een puntige waarschuwing dat een groot deel van de robotica mogelijk ruis meet.

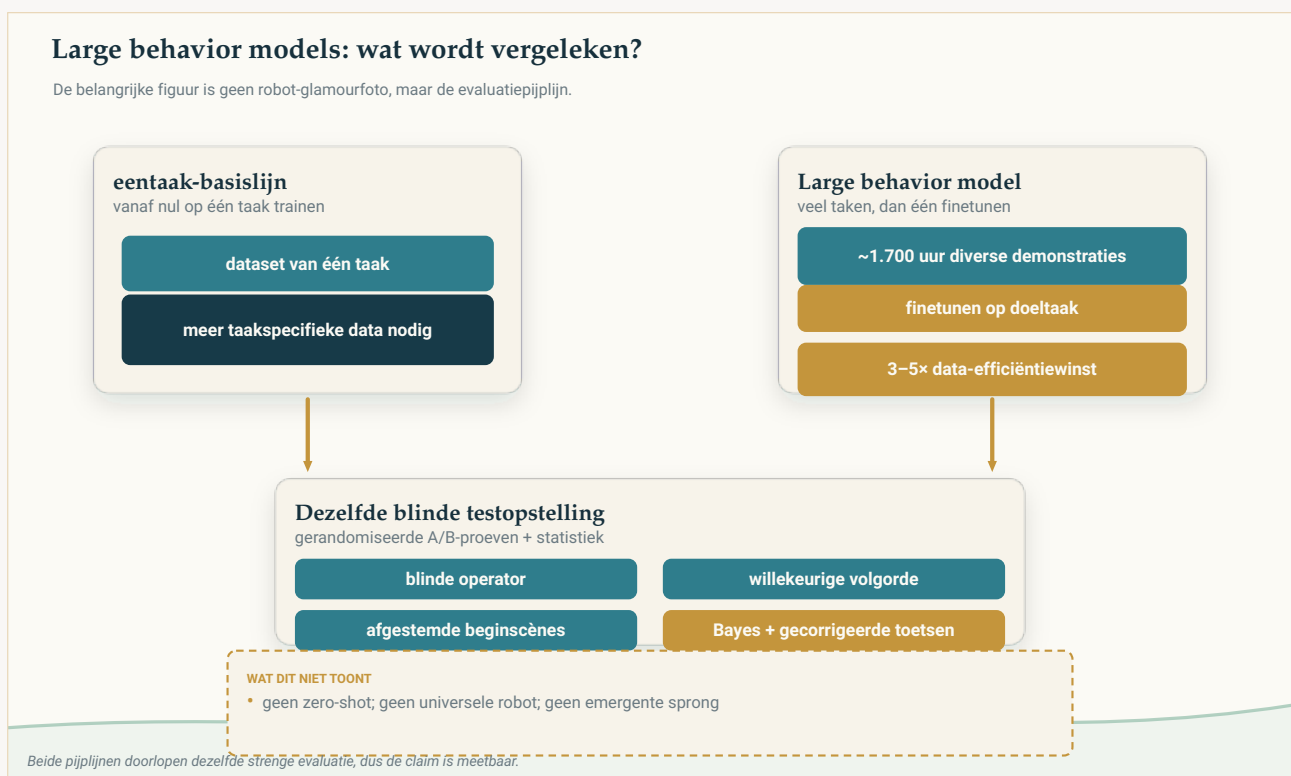
Written by Lucio Vaglio · Cross-checked by Laura Nesso · Edited by Michele Renda · Figures by Laura Nesso and Nova Vela · AI-assisted, human-reviewed

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

Een robotpaper waarvan het echte onderwerp eerlijkheid is

De robotica zit midden in een “foundation model”-stormloop. Het idee, geleend van taal- en beeld-AI, is verleidelijk: in plaats van een robot taak voor taak te trainen, train je één groot **“large behavior model” (LBM)** op een enorme, diverse stapel demonstraties, en krijg je een systeem dat breed capabel is en zich snel aanpast. Het enthousiasme — en de investeringen — zijn enorm. De kop schrijft zichzelf: *universele robotbreinen zijn er*.

Deze paper, van het Toyota Research Institute, is juist interessant omdat hij weigert die kop te schrijven. Zijn echte bijdrage is geen flitsender robot. Het is een nuchtere blik op een bedrieglijk eenvoudige vraag — *werkt de grootmodel-aanpak werkelijk beter, en hoe zouden we dat überhaupt weten?* — beantwoord met een mate van statistische zorgvuldigheid die, naar eigen zeggen van de auteurs, ongewoon is voor het vakgebied. Het resultaat is een echt bruikbaar “ja, maar” en een waarschuwing dat een groot deel van de robotica mogelijk ruis meet.



Beide aanpakken doorlopen dezelfde blinde, gerandomiseerde evaluatie. De claim van de paper is niet dat robot-foundation-modellen zero-shot-generalisten zijn, maar dat voortraining de data-efficiëntie en robuustheid kan verbeteren wanneer je zorgvuldig meet.

Original The Clean Paper diagram CC BY 4.0

Wat de auteurs deden

Ze bouwden LBM's in een specifieke, concrete zin: **diffusiegebaseerde visuomotorische policies** (een Diffusion Transformer die camerabeelden, een korte taal instructie en de eigen gewrichtsstanden van de robot leest en in korte stoten motorcommando's op 10 Hz uitvoert). Deze werden **voorgetraind op ruwweg 1.700 uur** aan robotdemonstraties — meer dan 500 verschillende, intern verzamelde taken plus openbare datasets — en vervolgens **gefinetuned op afzonderlijke taken**. De vergelijking loopt overal tegen een **vanaf nul getrainde eentaakpolicy**, die alleen op de data van die ene taak berust.

Het hart van de paper is echter de *evaluatie*, die de auteurs als het eigenlijke resultaat behandelen. Om zichzelf niet voor de gek te houden, gebruikten ze:

- **Blinde, gerandomiseerde A/B-tests** in de echte wereld — de persoon die de robot bediende wist niet welke policy werd getest, en de volgorde was willekeurig.
- **Gecontroleerde, herhaalbare beginvoorwaarden** — de operators pasten de scène vóór elke poging aan op een beeldoverlay.
- **Grote aantallen pogingen** — 50 echte doorlopen per taak, per policy, per conditie; 200 per taak in simulatie. In totaal: ongeveer **1.800 blinde echte doorlopen en meer dan 47.000 simulatiedoorlopen**.
- **Degelijke statistiek** — Bayesiaanse schattingen van de slaagkans en paarsgewijze hypothesetoetsen met correctie voor meervoudige vergelijkingen, in plaats van overlappende foutbalken op het oog te duiden. Ze lieten zelfs een kwaliteitscontrole lopen over een kwart van de door mensen beoordeelde pogingen om de scorefout te meten.

[video pending]

Directe vergelijking van modellen die een ontbijttafel dekken: (links) eentaak-basislijn en (rechts) LBM. Beide video's spelen op 1x-snelheid. Dit is één geëvalueerde taak, geen bewijs van universele autonomie.

Deze machinerie is het punt. De hele paper is een betoog dat je zonder haar een echte verbetering niet van geluk kunt onderscheiden.

Wat ze vonden

Gefinetunede grote modellen verslaan vanaf-nul getrainde eentaakmodellen — gemiddeld. Geaggregeerd over de taken heen overtrof een LBM dat was voorgetraind en toen op een taak gefinetuned, betrouwbaar een vanaf nul getrainde policy voor diezelfde taak, in simulatie én in de echte wereld, en de scheiding was statistisch significant. Op afzonderlijke taken was het gefinetunede LBM in bijna elk geval statistisch even goed of beter dan het vanaf nul getrainde (3/3 echte taken, 15/16 simulatietaken).

De grootste, duidelijkste winst is data-efficiëntie. Een gefinetuned LBM haalde de prestatie van het

vanaf nul getrainde met ruwweg $3\text{--}5\times$ **minder taakspecifieke data**. Bij één echte taak (een ontbijttafel dekken) versloeg een LBM dat op slechts **15%** van de demonstraties was gefinetuned een vanaf nul getrainde policy die op **100%** ervan was getraind.

Voortraining helpt het meest wanneer de omstandigheden verschuiven. Toen de testomgeving opzettelijk werd verstoord weg van de trainingsomstandigheden (“distribution shift”), *groeide* het voordeel van het gefinetuned LBM. In één simulatieset versloeg het het vanaf nul getrainde onder normale omstandigheden statistisch op 3 van de 16 taken, maar onder distribution shift op 10 van de 16. Aangezien echte inzetten altijd afdrijven van de trainingsomstandigheden, is deze robuustheid wellicht de praktisch belangrijkste bevinding.

Meer voortrainingsdata hielp, gelijkmatig. De prestatie steeg gestaag naarmate ze voortrainingsdata toevoegden — met **geen plotselinge sprong of “emergente” ruk** bij de geteste schalen. Nuttig, voorspelbaar, ondramatisch.

Maar het generalist-zonder-finetuning-verhaal hield geen stand. Een voorgetraind LBM dat *zero-shot* werd ingezet — zonder taakspecifieke finetuning — versloeg eentaakpolitiecs *niet* consistent. Eén netwerk kon veel taken tegelijk, maar de “gewoon prompten”-droom werd hier niet bevestigd; de auteurs schrijven een deel hiervan toe aan de broosheid van hun kleine taal-encoder.

En de winsten waren klein genoeg om makkelijk over het hoofd te zien — of te faken. Veel van de effecten werden pas zichtbaar met de groter-dan-gebruikelijke steekproeven en zorgvuldige tests. De auteurs stellen onomwonden dat, gezien de omvang van de effecten en de ruis, **er een aanzienlijk risico is dat veel roboticapers statistische ruis meten**. Ze vonden ook dat een alledaagse keuze — hoe de data wordt *genormaliseerd* — de resultaten sterker beïnvloedde dan architectuurwijzigingen, en dat een normalisatie-**bug** in de voortraining pas *na* afronding van de evaluaties aan het licht kwam.

Wat dit waarschijnlijk betekent

De verdedigbare lezing: grootschalige voortraining op diverse robotdata is een echt, waardevol ingrediënt — het verlaagt de databehoefte per nieuwe taak en maakt policies steviger wanneer de wereld niet met de training overeenkomt. Dat ondersteunt werkelijk de richting waarop het vakgebied inzet. Maar de winsten zijn *bescheiden en voorwaardelijk* (ze tonen zich meestal pas na het finetunen en zijn het duidelijkst in aggregaat en onder druk), niet de aankomst van een kant-en-klare universele robot.

De stillere, belangrijkere betekenis is methodologisch. De paper is in feite een meetlat: hij laat zien hoeveel bewijs het werkelijk kost om een betrouwbare claim over een robotpolicy te doen, en impliceert dat een groot deel van het gepubliceerde enthousiasme op te weinig rust. Dat is een correctie die het vakgebied harder nodig heeft dan nog een model.

Wat dit *niet* bewijst

- Het is **geen universele robot**. De winsten zijn aangetoond voor een specifieke architectuur (diffusiepolities), per taak gefinetuned, in gecontroleerde omgevingen, uit teleoperated demonstraties — geen autonome robot die willekeurige nieuwe klussen op commando doet.
- Het valideert het **zero-shot**-gebruik **niet**. Zonder finetuning versloeg het grote model de eentaak-basislijnen niet consistent.
- Het is **geen** bewijs van een “**emergente sprong**”. Schalen verbeterde de zaken gelijkmatig; er is hier geen discontinuïteit die “en toen werd het opeens capabel”-verhalen ondersteunt.
- De cijfers zijn **relatief en labgebonden**. De absolute slaagpercentages werden opzettelijk op ~50% afgesteld om vergelijkingen gevoelig te maken; ze zijn geen maat voor betrouwbaarheid in de echte wereld, en het werk is één architectuur uit één lab.
- Het beslecht **niet waarom** een policy slaagt of faalt, en meerdere specifieke taken waar het grote model *slechter* was, worden gemeld maar niet verklaard.
- Het zegt **niets over veiligheid, autonomie of inzet** buiten de evaluatie-opstelling.

Hoe sterk is het bewijs?

Voor de centrale vergelijkende claims — gefinetunede LBM’s verslaan vanaf-nul-basislijnen in aggregaat, hebben meerdere malen minder data nodig en zijn robuuster onder distribution shift — is het bewijs sterk *én* ongewoon goed gecontroleerd: blind, gerandomiseerd, grote steekproef, statistisch getoetst, met een QA-doorloop over de scoring. Dit is het zeldzame geval waarin de methodologie degelijk genoeg is om de kernconclusies bijna voor waar aan te nemen.

De eerlijke voorbehouden brengen de auteurs zelf naar voren. Hun foutbalken vangen de willekeur van de *evaluatie*, maar **niet** die van de *training* — train hetzelfde model twee keer en je krijgt mogelijk een merkbaar andere policy, en die variatie zit niet in de statistiek. Echte taken hadden elk 50 pogingen, genoeg om middelgrote effecten te betrappen maar vatbaar om kleine te missen. De taalconditionering gebruikte een bescheiden encoder, dus claims over “de robot gewoon zeggen wat hij moet doen” kunnen bij grotere systemen anders uitpakken. En er is de openhartige onthulling van een achteraf ontdekte normalisatie-bug. Niets hiervan doet de hoofdbevindingen zinken, maar het is precies het soort dat het vakgebied volgens de paper doorgaans terzijde schuift.

Een bronvermelding, in dezelfde geest: deze uitleg is gebaseerd op de preprint van de auteurs. We konden de in het tijdschrift gepubliceerde versie niet ophalen en hebben dus niet gecontroleerd op wijzigingen tussen preprint en gepubliceerde tekst.

Waarom het ertoe doet

“Robot-foundation-modellen” is een uitdrukking als gemaakt voor overclaiming, en een studie als deze is makkelijk in beide richtingen verkeerd te lezen — als triomfantelijk “*het werkt!*” of als weg-

wuivend “*het is hype*”. De accurate lezing is nuttiger dan beide: voortraining op diverse data levert echte, meetbare, maar matige voordelen — vooral minder data per taak en meer robuustheid — en het pad verbetert voorspelbaar met schaal.

De diepere reden dat het ertoe doet, is dat de paper zijn striktheid op het eigen vakgebied richt. Door te laten zien dat de echte effecten klein genoeg zijn om onder slordige evaluatie te verdwijnen, en dat een saaie keuze als datanormalisatie een slimme nieuwe architectuur kan overtreffen, betoogt hij dat een groot deel van de vooruitgang in robotleren steviger meting nodig heeft voordat het geloofd mag worden. Een paper die zijn geloofwaardigheid besteedt aan het bewaken van het verschil tussen een resultaat en een wens, doet iets zeldzamer — en waardevoller — dan een ranglijst aanvoeren.

Heldere samenvatting

Onderzoekers van het Toyota Research Institute trainden “large behavior models” — diffusiegebaseerde robotpolicy's, voorgetraind op ~1.700 uur diverse manipulatiegegevens — en testten ze tegen vanaf-nul getrainde eentaakpolicy's met een ongewoon streng protocol: blind, gerandomiseerd, grote steekproef (≈ 1.800 echte en meer dan 47.000 simulatiepogingen), met echte statistiek. Na finetuning per taak deden de grote modellen het in aggregaat betrouwbaar beter, hadden ruwweg **3–5× minder taakspecifieke data** nodig en waren **robuuster bij verschoven omstandigheden**, waarbij de prestatie gelijkmatig steeg naarmate de voortrainingsdata groeide. Maar **zonder finetuning** ingezet versloegen ze eentaakmodellen *niet* consistent, meerdere effecten waren klein genoeg dat alleen de grote steekproeven ze onthulden, en een alledaagse datanormalisatie-keuze telde meer dan de architectuur. Het is degelijke, gematigde steun voor de richting van de robot-foundation-modellen — **geen** universele robot, geen zero-shot-generalist en geen “emergente sprong” — plus een puntige waarschuwing dat een groot deel van de robotica mogelijk ruis meet.

Zonder omwegen

Wat de paper aantoont: Met een strenge, blinde, statistisch krachtige evaluatie (≈ 1.800 echte + meer dan 47.000 simulatiedoorlopen) overtreffen multitaak-voorgetrainde-en-daarna-gefinetunde diffusiepolicy's (LBM's) vanaf-nul getrainde eentaakpolicy's in aggregaat, halen gelijkwaardige prestatie met $\sim 3\text{--}5\times$ minder taakspecifieke data, en zijn robuuster onder distribution shift; de prestatie schaalt gelijkmatig met de voortrainingsdata.

Wat plausibel maar niet bewezen is: Dat deze voordelen overdragen naar veel grotere vision-language-action-modellen (hun taal-encoder was klein); dat de gelijkmatige schaling doorloopt voorbij het geteste databereik.

Wat het niet aantoont: Een universele of zero-shot robot (geen finetuning $\rightarrow$ geen consistent voordeel); enige “emergente” capaciteitssprong; verklaringen voor specifieke taakfalen; betrouwbaarheid in de echte wereld in absolute termen (slaagpercentages waren voor de gevoeligheid nabij 50% afgesteld); iets over veiligheid of autonome inzet.

Belangrijkste beperkingen: De statistiek vangt de willekeur van de evaluatie maar niet die van de trainingsruns; 50 echte pogingen per taak kunnen kleine effecten missen; één architectuur en één lab; bescheiden taal-encoder; een datanormalisatie-bug werd na de evaluaties gevonden; analyse gebaseerd op de preprint (gepubliceerde versie niet gecontroleerd).

Hoeveel vertrouwen mag een algemene lezer hebben? Veel dat multitaak-voortraining plus finetuning echte, matige voordelen geeft — vooral data-efficiëntie en robuustheid — en dat die ongewoon zorgvuldig zijn gemeten. Veel dat dit **geen** universele of zero-shot robot is en **geen** emergente sprong. Gematigd over hoe ver de winsten naar grotere modellen schalen. En de moeite waard om serieus te nemen: de eigen waarschuwing van de auteurs dat de effecten van het vakgebied klein genoeg zijn dat onderbemeten studies ruis kunnen rapporteren. Gepaste houding: gematigd optimisme over de aanpak, en gezonde scepsis tegenover robot-AI-resultaten die dit soort statistische onderbouwing missen.

Bronnen

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/>