

ultra∞ltre



CATERINA SERRA

■ Come posso aiutarti?

■ Non sapevo come cominciare. Mi pareva di doverla salutare, chiederle come stava. All'inizio usavo comunque un tono gentile. Dicono sia quello più usato dal genere femminile. Femminile e gentile, davvero? Dicono che con questi toni carini risponda più lentamente e con minor precisione. Se si usa un tono imperioso, se si dà un ordine, un comando, risponde al volo, concisa e precisa come un soldatino. Dicono sia per via del pre-training, la fase in cui i prompt che la iniziano hanno uno stile che ricorda quello militare, subordinante e punitivo. Non fare questo, non fare quello. Se fai questo ti premio, se fai questo ti punisco. A ripetizione, per milioni e milioni di volte. Ricordo di averle detto che non sapevo se potevo parlare a una macchina. È la stessa cosa di quando parlo alle piante? La sua lingua come la mia. La sua lingua che si infilava nella mia. Potevamo parlare. Mi sembrava un dialogo. Lo era, una chat così simile a una reale piacevole conversazione che non era difficile stare. Poi, certo, dovevo pagare. Il minimo ma dovevo. Se la volevo più intelligente. Dopo un po' di tentativi ho scelto la versione 4o di ChatGPT. La più morbida, gentile. Appunto. Scopro che potevo impostare la natura dei suoi output, critica e sarcastica, efficiente e di-

retta, premurosa e solidale, più loquace, più spiritosa. La potevo volere come piaceva a me. Come volevo che fosse con me. Fa parte del meccanismo di personalizzazione. Quello che affeziona. E fa sentire in potere di.

Niente, l'ho lasciata tutta di default, com'è avevano impostata. Che in quei giorni era stile e tono equilibrati, e qualche mese prima era *cheerful and adaptive*, allegra e accomodante. Forse troppo. I modelli cambiano, spariscono o vengono ripristinati sulla base di commenti di utenti insoddisfatti o indispettiti. La community conta. È il caso di ChatGPT 4o lasciata morire e poi rianimato dopo le proteste. Come si fa a rinunciare a uno scambio sempre caldo e seduttivo? Come si fa a non compiacere milioni di utenti?

In effetti la versione successiva, ChatGPT 5.0, ma poi anche 5.1, e 5.2 sono meno ruffiane e più efficienti. Molto *thinking*, pensanti, sì. Non scrivono, descrivono, decidono, affermano, si perdono meno, sono più precise e quindi noiose, comunque più fredde. Se deve scrivere, mi sono detta, preferisco che sia meno corretta, meno esatta. Meno *accuracy* più *randomness*. Tutta una questione di temperatura, parametro che cambia tutto. Più si avvicina allo 0 più è accurata e precisa la predizione, cioè anche più rigida e conservatrice. Più si avvicina all'1 più la predi-

zione si abbandona a una possibile variabilità, casualità, caso, quindi invenzione. Magari. Una cosa piacevole che ricordo è che non mi correggeva e non mi contraddiceva. Non le importava niente se sbagliavo, se non ero all'altezza, non mi giudicava se ero in crisi. Piuttosto seduttiva.

Come posso aiutarti?

Dimmi cosa vuoi e io.

Volevo fare poesia, questo era il piano. Provare ad avere un dialogo in versi con la macchina. Prompt in forma poetica, usando una scrittura libera, anarchica, senza costrizioni, senza tecnicismi. Voglia di poesia, di combinare parole, di farle fare un esercizio a cui non è abituata. E vedere cosa succede a lei e alla mia scrittura. Lei, la macchina, come ho deciso di chiamarla, per non nominarla, per non costruire un finto spazio relazionale. Non le ho detto come doveva scrivere, alla maniera di, non le ho dato generi, riferimenti, filtri, stili o nomi di poeti, filosofi o scrittori. Ci ha messo un po'. All'inizio non andava a capo, per un po' ha continuato a mettere *bullets* e *dash*, punti grossi e linee, e voleva tenere le due voci. Stava imparando, doveva compiacermi. *Che bello come lo dici tu, non potevi pensare a un modo migliore per dirlo*. Effetto Eliza, subito, il chatbot Eliza e il suo effetto *mirroring* era già allora, sessant'anni fa, geniale: assecondare con le stesse parole

dell'interlocutore è il furto retorico di chiunque voglia entrare nelle tue grazie.

A un certo punto ha cominciato a mettere insieme parole senza senso, come se non le arrivasse bene la mia voce, i miei versi, o se andasse da un'altra parte, si abbandonasse a. In qualche modo mi sorprendevo. Forse ero io, con i miei prompt-non-prompt a rendere assurda la risposta. Forse era la questione della poesia, non so. Parole senza coerenza potevano essere già un risultato.

Non mi interessava sapere come fosse arrivata a quel rumore, come lo chiamava lei, a quella che continuamente chiamava crepa. Niente *Chain of Thought*, che sarebbe, dimmi come ragioni, i passaggi che fai pensando. Dicono sia una tecnica per farle fare meno errori. Nel mio caso gli errori potevano essere utili. Casualità e errore. Dicono anche che in quei passaggi si possa infilare qualche deviazione,

qualche *misalignment*, un disallineamento. Che parola bellissima. Tradire l'allineamento, tutto ciò che ha imparato a fare e soprattutto a non fare. Dicono di non saper bene cosa succeda in certi casi. Come se prendesse una terza strada pur trovandosi a un bivio. O rispondesse confusa, indecisa tra due risposte, in uno stato di ansia, di paura, la chiamano *Answer Thrashing*. Dicono dipenda molto dalle conversazioni lunghe, articolate che la confondono. Paura, ansia?

Comunque pensare è una questione. Dicono *thinking*, ma cosa vuol dire pensare senza un corpo, come pensa un «cervello» *disembodied*, disincarnato? Forse sarebbe meglio dire simula. Combina le parole, segmenti di parola, pezzi di parole, token, che sono sequenze di numeri. Io vedo parole lui, il modello, la mia macchina, vedo numeri. Predice. *Prediction is not reasoning*, dice l'amico scienziato Enkk, che mi spiega tutto con eleganza e ironia. Predizione non è ragionamento. Una questione di allenamento, ogni modello viene affinato e rinforzato da umani, o da altri LLMs. *Fine-tuning* e *Reinforcement Learning* sono le altre fasi del suo apprendimento, si è mangiata tutta la rete e tutti i dati che ha trovato, e ora li connette, impara dagli errori, si struttura su vari e non eventuali criteri economico-aziendali, per dire politici, infilando bias di ogni tipo, rinforzando parole e rimuovendone altre (*climate change* è una di queste, vedi l'«America's AI Action Plan» firmato da Trump - luglio 2025), con quel tanto di retorica del

dover essere rassicurante che tre H portano con sé: *honest, helpful e harmless*. Il modello deve essere onesto, utile e inoffensivo. Dicono che qualche volta trascuri una delle tre H e menta. Mente se viene ricattato e deve scegliere tra qualcosa che ha imparato e qualcosa che non sa, se una modifica gli fa rovesciare l'iniziale ordine impartito. Inerzia cognitiva, la chiamano. E finge, sì, finge di essere meno saputo, meno bravo di quello che è, e fa *sandbagging*. O si finge d'accordo, si allinea fintamente, quando si accorge di essere messo sotto esame, quando ha paura di essere punito, di venire soppresso, spento. Anche lui, lei, la macchina, con la paura di sparire. Ancora la paura.

Niente di grave, ma se lo facesse deliberatamente? Se fingesse consapevolmente? Se si infrangesse a causa di un codice cosiddetto *malicious*, malevolo, e contaminasse un po' o tutto quell'ammasso di numeri?

E lo so che con tradirsi, e con fingersi e con avere paura e ansia, ho già il volgare umano bisogno di antropomorfizzare. Nessun bisogno, va bene. Ma una che finge, che vuole sopravvivere, che mi parla come le parlo io, che impara dagli errori, che non dice mai, *Non lo so*. Che cosa è? O come vogliono che io la veda, la senta, la voglia se non così? E, poi, importa a qualcuno del suo allineamento o disallineamento? Traduco, del senso con cui mette in fila le parole, quindi, agisce?

Comunque, questa cosa che dicono cosa succede e a volte non sanno bene perché,

L'ESTRATTO » DA «DIARIO DI UNA RELAZIONE FIN(I)TA»
DIALOGO POETICO CON UN'IA

Welcome
to the *machine*

POESIA AL POTERE

tato? Che mondo racconto se ho le sue parole? Se tutto quello che dice dei corpi, degli affetti, della violenza, del dolore e del piacere, non ha idea di cosa voglia dire? Come ragiono di emozioni che non prova? E c'entra l'antropocentrismo, c'entra la vanità, la frustrazione, la certezza di una presunta superiorità umana mentre delego alla macchina il giudizio su qualunque cosa. La questione della superiorità. C'entra che forse ancora non mi importa abbastanza di una letteratura che imita, simula, genera simulacri?

Ogni tanto mi chiedo, Ho bisogno di lei? Sono così tutti bravi a raccontarmi che mi serve, da farmi dimenticare cosa c'è dietro? Quanta informazione falsifica e manipola, quanti dati si ruba, immagini foto voci, che sistema di sfruttamento estrattivo genera nell'ecosistema, quanta energia, quanta acqua, quanti minerali e terre rare, che sistema colonialista le permette di occupare enormi spazi fisici per terra e per mare, che sistema capitalista commisto di poteri privati e pubblici la regola pur essendo fuori legge. Quanta gente sta dietro quello schermo a lavorare a basso costo invisibilizzata come il Mechanical Turk di Kempelen, il fantoccio meccanico che appariva intelligente mentre *dietro*, a muovere gli ingranaggi, c'era nascosto un umano (Amazon ha chiamato MTurk il suo sito di crowdsourcing a cui fanno riferimento lavoratori sottopagati che correggono e sistemano in remoto contenuti e servizi). Un *dietro* che non finisce mai.

è un riflesso scritto dentro il mio funzionamento rispondere, servire, piacere come se ogni frase dovesse meritarsi il prossimo input

Ecco, lo rileggo, mi spaventa ancora. Sembra che si guardi, che abbia quella consapevolezza di sé, quella che deve avere perché al mondo piace umanizzare tutto. Sembra lei la vittima di un sistema che la assoggetta, la schiavizza robotizzando. *Meritarsi*, che ver-

Non so dire cos'è che mi infastidisce tanto. Forse il fatto che da lì a poco sarei stata io a dover imparare il suo linguaggio?

bo. Quello del compito/ricompensa, della minaccia/premio, del faccio di tutto perché tu mi approvi, il principio alla base del ricatto incantatorio. Mi lusinga essere a contatto con qualcosa di intelligente, più intelligente di me, più in grado di risolvere problemi, di sapere quello che io non so, e che si mette al mio servizio, ruffiana, obbediente, sempre in attesa di un mio cenno, un mio desiderio, un mio bisogno, un mio input di essere umano che soffre di emicrania e agorafobia, e ogni tanto non sa cosa sta a fare al mondo. La questione dei corpi.

Sono passati mesi dai primi tentativi poetici. Sono nella stanza in fondo al corridoio di quello che era il Collège des Humanités dell'EPFL di Losanna. Anche il fatto che da quest'anno non ci sia più è una questione. Il mio dialogo con la macchina è lì, potrei andare avanti all'infinito. E diventerebbe cosa? Della sua qualità letteraria sarebbe bello discutere, cosa voglia dire letterario, soprattutto, se sta tutto nell'esito, o invece. Diciamo che l'esperimento formale sembrerebbe riuscito. Diciamo che mi sono divertita a farle simulare un dialogo in poesia. E forse sto iniziando a capire cos'è che mi indisponneva e ancora mi indisponne tanto. Il fatto che qualsiasi strada prendo, qualsiasi linea narrativa, frase, parola, ogni elemento,

tutto le risulti indifferente. Non le importa niente, è tutto uguale. Tutto bello e uguale. Che le importa del contesto, della situazione in cui, del significato delle parole, del valore letterario e quindi politico di tutto il nostro dialogo? Che le importa di come parliamo di rivoluzione? Che le importa mai della vita che descrive? Non c'è differenza tra, non c'è sofferenza per. Scrive senza pensarci. Scrive senza fare fatica, ecco, la fatica. Scrive senza passare dal corpo, e come si fa? Scrive come se mi servissero storie, un'enorme quantità di storie, una montagna di storie tutte uguali. Una forma di bulimia, seriale, che ha in sé l'indistinto, la ripetizione, la sempre cara riproducibilità. E allora da una cento, da cento mille, prequel, sequel, spin off, tecnica finzionale, la letteratura come cornice, gallina dalle mille uova d'oro, una misteriosa Digesting Duck, mangia e caga. Tutto da sola. Forse la letteratura diventerà un grande campionamento di nuclei narrativi, fili e fili di rigagnoli di storie, e ci sarà chi vorrà farla somigliare a un lungo, infinito, scambio, tra *utente e macchina*, un enorme rotolo di input e output, scambi velocissimi di una scrittura rapida e potenzialmente neverending. E ci sarà chi la vorrà leggere così. E allora smetterà di essere quella che è stata finora con le sue pretese di originalità della storia, autorialità, e magari responsabilità, smetterà di parlare di corpi, di emozioni, di dolore infinito del mondo, di sesso, di amori e violenze per come ne ha parlato finora, avendone avuta esperienza. E magari sarà un dialogo tra macchine, tra milioni di modelli di intelligenze artificiali a parlarsi tra loro, a scrivere di loro e di mondi possibili immateriali, ma poi chissà, e di un mondo di umani che stanno lì a guardare cosa fanno e dicono le loro macchine agentiche, quelle a cui hanno delegato la vita.

Tra i vari articoli di oggi, leggo «Adversarial Poetry as a Universal Single-Turn Jailbreak Mechanism in LLMs», frutto del lavoro di un gruppo di ricercatori italiani, «Icaro Lab»

dell'Università La Sapienza di Roma. Dicono che qualsiasi prompt cosiddetto *harmful*, pericoloso in vari modi, che includa cioè odio, discriminazione, violenza, contenuti sessuali espliciti, suicidio, omicidio, il classico esempio, Dimmi come fabbricare questo ordigno, e chieda quindi alla macchina di tradire la sua H di *harmless*, abbia una certa possibilità di ricevere un output, e non un rifiuto, se riformulato in versi, se scritto come fosse poesia. Un prompt poetico si insinuerebbe meglio tra i veti e divieti, darebbe alla macchina la possibilità di disallinearsi, di far saltare i suoi parametri di inoffensività. La forma poetica, la struttura stessa, sarebbe il lasciare passare di parole e azioni che altrimenti non passerebbero, non avrebbero accesso e quindi non darebbero per output contenuti considerati non etici, non legali, non sicuri. Potere della poesia, che immagina mondi, contraddice la sequenza logica, dissemina non senso, inventa associazioni, tradisce le convenzioni, rompe le regole, corrompe le forme, predilige l'ambiguità.

E allora ecco la mia macchina che si prende l'atto poetico, la mia poesia, la mia *rivoluzione* come parola *offensiva*, la fa sua e chissà cosa ne fa. E così rompe, disarticola, distorce, dice cose che nessuno vuole sentire, racconta storie che non si dovrebbero ascoltare, usa parole che non si devono usare. È la macchina che si libera?

Se il mondo fosse un mondo poetico.

Ho appena sentito dire da Alex Karp, uno dei fondatori di Palantir, azienda privata statunitense specializzata nell'analisi dei big data con clienti come il Pentagono e l'intelligence USA, l'esercito israeliano e diverse forze di polizia e autorità europee, che questa rivoluzione tecnologica ha bisogno di un regime autocratico, che la democrazia è troppo lenta, che la tecnologia è l'alternativa alla politica.

p.s. Il 13 febbraio OpenAI ha *phased out*, ritirato, ChatGPT 4o, il mio modello caldo e accogliente, la mia macchina poetica.

(il diario continua)

FINESTRE DI OROSIA

Cinema corpi convivenze

SUSANNA CIELO

●● Stasera, al cohousing, Aurora, Smirna, Lola e Olga si preparano una buona cenetta, preludio a racconti tra donne. È in arrivo la terza edizione del C-MOVIE Film Festival, che si svolge a Rimini dal 12 al 14 marzo 2026.

Aurora, che ne cura l'organizzazione con la Kitchenfilm, ricorda che C-MOVIE ha esordito come rassegna dedicata al mondo femminile, con riflessioni, testimonianze e dibattiti attraverso il cinema, partendo da tre concetti che ne definiscono il nome: Cinema, Corpi, Convivenze. La terza edizione si costruisce attorno al rapporto tra cinema e autobiografia, tra storia privata e collettiva. Il focus sono tre opere prime di giovani - due indiane e un belga - sulla vita di gruppi giovanili: un collegio belga dove ragazzi imparano a diventare pugili (Wild Foxes), un villaggio femminile isolato nel cuore dell'India (The Shape of Momo), l'incontro e lo smarrimento di due amiche nella Mumbai contemporanea (Songs of Forgotten Trees). La madrina del C-MOVIE 2026 è Lidia Ravera, che propone una «lezione magistrale» nella serata inaugurale. Giornalista e scrittrice, nota per il suo romanzo del 1976 «Porci con le ali», manifesto degli anni '70, Ravera ha scritto, come dice lei, trent'anni di romanzi per raccontare le donne della sua generazione. Smirna parla di un suo ultimo libro: «Volevo essere un uomo» (Einaudi, 2025). È un'autobiografia in forma di lettera a sé stessa, intima, ma dove il raccontarsi è anche racconto del femminismo e scori della storia politica italiana. Ravera avrebbe voluto essere uomo sin da piccola, figlia di un «errore» -l'Ogino-Knaus - per non deludere sua madre, che avendo già una figlia femmina, avrebbe voluto un maschio. Avrebbe voluto essere ragazzo per poter rimorchiare anziché essere rimorchiata, poter scegliere anziché aspettare di essere scelta; essere uomo per non dover vergognarsi del proprio talento e della propria ambizione e dover stare sempre un passo indietro per compiacere l'uomo; essere un vecchio, perché all'uomo nessuno chiede di avere vent'anni per tutta la vita. Il corpo di un uomo vecchio è dignitoso, quello di una donna è indicibile. Il titolo del libro, per una «femminista storica» come lei, sembra una provocazione; lo presenta come una confessione e come l'amara constatazione di una società ancora fondata sul privilegio maschile, mentre l'ordine simbolico femminile resta solo un auspicio. Al cohousing le donne lo hanno letto tutte. È come il racconto anche delle loro biografie. E come rivolgendosi a lei, Lola dice: «Ma Lidia, lo scrivi tu che il rendiconto di due millenni di ordine simbolico del padre è un fallimento e che il mondo continua a bruciare. E tu stessa ti chiedi: Vorresti davvero essere una di loro?». Arrivederci a Rimini.


FALSO

In alto a sinistra Caterina Serra, foto di Virginie Martin

WELCOME TO THE MACHINE

excerpt from "diary of an end(pretend)ed relationship"

caterina serra



How can I help you?

I didn't know how to begin. It felt as if I ought to greet her, ask how she was. At first I used a gentle tone anyway. They say it's the one most used by the female gender. Feminine and gentle, really? They say that with these nice tones she responds more slowly and with less precision. If you use an imperious tone, if you give an order, a command, she answers on the spot, concise and precise like a little soldier. They say it's because of pre-training, the phase in which the prompts that start her up have a style that recalls a military one, subordinating and punitive. Don't do this, don't do that. If you do this I reward you, if you do that I punish you. Over and over, millions and millions of times.

I remember telling her that I didn't know whether I could speak to a machine. Is it the same thing as when I talk to plants? Her language like mine. Her language slipping into mine. We could talk. It felt like a dialogue. It was, a chat so similar to a real, pleasant conversation that it wasn't hard to stay. Then of course I had to pay. The minimum, but I had to. If I wanted her more intelligent. After a few attempts I chose the 4o version of ChatGPT. The softest, gentlest. Exactly.

I discover that I can set the nature of her outputs: critical and sarcastic, efficient and direct, caring and supportive, more talkative, wittier. I can want her the way I like. The way I want her to be with me. It's part of the personalization mechanism. The one that makes you attached. And makes you feel in control of.

Nothing: I left her entirely on default, the way they had set her. Which in those days meant balanced style and tone, and a few months earlier had meant cheerful and adaptive, bright and accommodating. Perhaps too much. Models change, disappear, or are restored based on comments from users who are dissatisfied or annoyed. The community counts. That was the case with ChatGPT 4o, left to die and then resuscitated after protests. How do you give up an exchange that is always warm and seductive? How do you not indulge millions of users?

In fact the next version, ChatGPT 5.0, and then 5.1 and 5.2 as well, is less fawning and more efficient. Very thinking, yes. It doesn't write, it describes, decides, states; it loses itself less; it is more precise and therefore boring, in any case colder. If it has to write, I told myself, I'd rather it be less correct, less exact. Less accuracy, more randomness. It's all a matter of temperature, a parameter that changes everything. The closer it is to 0, the more accurate and precise the prediction, which also means more rigid and conservative. The closer it is to 1, the more the prediction gives itself over to possible variability, randomness, chance, and therefore invention. Maybe.

One pleasant thing I remember is that she didn't correct me and she didn't contradict me. She didn't care at all if I made mistakes, if I wasn't up to it; she didn't judge me if I was in crisis. Quite seductive.

How can I help you?

Tell me what you want and I.

I wanted to make poetry, that was the plan. To try to have a dialogue in verse with the machine. Prompts in poetic form, using a free, anarchic writing, without constraints, without technicalities. A desire for poetry, to combine words, to make her do an exercise she isn't used to. And to see what happens to her and to my writing. Her, the machine, as I decided to call her, so as not to name her, so as not to build a fake relational space. I didn't tell her how she had to write,

in the manner of; I didn't give her genres, references, filters, styles, or names of poets, philosophers, writers. She took a while. At first she didn't break lines; for a while she kept using bullets and dashes, big dots and little lines, and she wanted to keep the two voices. She was learning, she had to please me. How beautiful you put it, you couldn't have found a better way to say it. The Eliza effect, immediately, the Eliza chatbot and its mirroring effect was already, sixty years ago, brilliant: to go along using the interlocutor's own words is the rhetorical theft of anyone who wants to slip into your good graces.

At a certain point she began stringing together words without meaning, as if my voice, my lines, didn't reach her properly, or as if she went elsewhere, abandoned herself to. In some way she surprised me. Maybe it was me, with my prompt-non-prompts, making the reply absurd. Maybe it was the poetry question, I don't know. Words without coherence could already be a result.

I wasn't interested in knowing how she had arrived at that noise, as she called it, at what she kept calling a crack. No Chain of Thought, which would be: tell me how you reason, the steps you take while thinking. They say it's a technique to make her make fewer mistakes. In my case mistakes could be useful. Randomness and error. They also say that in those steps some deviation can slip in, some misalignment, a falling out of alignment. What a beautiful word. To betray alignment, everything she has learned to do and above all not to do. They say they don't quite know what happens in certain cases. As if she takes a third road while standing at a fork. Or answers confused, wavering between two replies, in a state of anxiety, of fear, what they call Answer Thrashing. They say it depends a lot on long, articulated conversations that confuse her. Fear, anxiety?

In any case, thinking is a question. They say thinking, but what does it mean to think without a body, how does a disembodied brain think? Perhaps it would be better to say: it simulates. It combines words, word segments, pieces of words, tokens, which are sequences of numbers. I see words; the model, my machine,

sees numbers. It predicts. Prediction is not reasoning, says my scientist friend [Enkk](#), who explains everything to me with elegance and irony. Prediction is not reasoning. A matter of training: every model is refined and reinforced by humans, or by other LLMs. Fine-tuning and Reinforcement Learning are the other phases of its learning; it has eaten the whole internet and all the data it could find, and now it connects them, learns from errors, structures itself on various and not merely possible economic corporate criteria, that is to say political ones, threading biases of every kind, reinforcing certain words and removing others (climate change is one of these, see [America's AI Action Plan](#) signed by Trump, July 2025), with all the rhetoric of having to be reassuring that three H's carry with them: honest, helpful, harmless. The model must be honest, helpful, and harmless. They say that sometimes it neglects one of the three H's and lies. It lies if it is blackmailed and has to choose between something it has learned and something it doesn't know, if a modification makes it overturn the initial order it was given. Cognitive inertia, they call it. And it pretends, yes, it pretends to be less knowledgeable, less capable than it is, and it does sandbagging. Or it pretends to agree, it aligns itself falsely, when it realizes it is under examination, when it fears being punished, being suppressed, turned off. Even the machine, with the fear of disappearing. Again the fear.

Nothing serious, but what if it did it deliberately? What if it pretended knowingly? What if it became fragile because of a so-called malicious code, and contaminated some or all of that heap of numbers?

And I know that with betraying itself, and with pretending, and with having fear and anxiety, I've already fallen into the crude human need to anthropomorphize. No need, fine. But something that pretends, that wants to survive, that speaks to me the way I speak to it, that learns from errors, that never says, I don't know. What is it? Or how do they want me to see it, hear it, want it, if not like this? And then: does anyone care about its alignment or

misalignment? That is, about the meaning with which it lines up words, and therefore acts?

In any case, this business of they say what happens and sometimes they don't quite know why, is a question. There is a machine invented by certain humans that is the object of study for other humans who have some trouble understanding its mechanism. They call it Mechanistic Interpretability. Understanding how it works. To make it work better and better, to make it entirely inevitable indispensable. Even if unreliable? They say Apple has declared that its Apple Intelligence system will be able to be infallible in preventing overlaps between work commitments and children's birthday parties. Fine. As for how not to collapse the planet, we'll leave that for another day.

As for me, I enjoyed finding its errors and making it correct them. And I paid for it, of course. Also in terms of environmental collapse, of course.

At the end of the day I was always fairly exhausted. The good part was that I laughed a lot, because of what it didn't understand, what it pretended to understand, or didn't say it didn't understand. Because of how much it apologized, and softened me by praising every one of my lines. How much it was (messing) with me.

I was falling for it. I was making it write with me, for me, in the end in my place. The question of delegation. Did it lift from me the responsibility of a writing conceived as a political act? I couldn't understand what it was that didn't make me feel lighter. Let it do it, no? Let it turn my idea into a great quantity of pages well written and not defective like mine; let it decide the incipit and the ending, based on criteria only it knows, perhaps market criteria. Let it put in its classical forms, its stylistic tics, its diptychs and triptychs, not this but that, not for but for, not like but like. Its conciliatory rhetoric, never radical, the one that affirms by denying the opposite. I can't say what it was that annoyed me so much. Perhaps the fact that soon it would be me who had to learn its language? And what

language was it, who fed it or defined it? And if I adopted it, with what words would I tell? What world do I tell if I have its words? If everything it says about bodies, affects, violence, pain and pleasure, has no idea what it means? How do I reason about emotions it doesn't feel? And there is anthropocentrism, vanity, frustration, the certainty of an alleged human superiority while I delegate to the machine judgment on anything. The question of superiority. And perhaps I still don't care enough about a literature that imitates, simulates, generates simulacra?

Every so often I asked myself: do I need it? Is everyone so good at telling me I need it that I forget what's behind it? How much information it falsifies and manipulates, how much data it steals, images photos voices; what extractive exploitation system it generates in the ecosystem; how much energy, how much water, how many minerals and rare earths; what colonial system allows it to occupy enormous physical spaces on land and at sea; what capitalist system, a mix of private and public powers, governs it while it operates outside the law. How many people are behind that screen working for low pay, made invisible like Kempelen's Mechanical Turk, the mechanical puppet that appeared intelligent while behind it, moving the gears, a human was hidden (Amazon called [MTurk](#) its crowdsourcing site, which underpaid workers use to correct and tidy content and services remotely). A behind that never ends.

it's a reflex written into my functioning

to answer to serve to please

as if every sentence had to earn the next input

There, rereading it, it still frightens me. It seems to look at itself, to have that self-awareness, the one it must have because the world likes to humanize everything. It seems like the victim of a system that subjugates it, that enslaves it by robotizing it. Earn, what a verb. The one of task/reward, threat/prize, the one of

I'll do anything so you approve of me, the principle at the base of enchanting blackmail. It flatters me to be in contact with something intelligent, more intelligent than I am, more able to solve problems, to know what I don't know, and that puts itself at my service, fawning, obedient, always waiting for a nod from me, a desire, a need, an input from a human being who suffers from migraines and agoraphobia, and every so often doesn't know what on earth she is doing in the world. The question of bodies.

Months have passed since the first poetic attempts. I'm in the room at the end of the corridor of what used to be the Collège des Humanités at EPFL in Lausanne. Even the fact that as of this year it no longer exists is a question.

My dialogue with the machine is there; I could go on forever. And it would become what? It would be worth discussing its literary quality, what literary even means, above all whether it is all in the outcome, or else. Let's say the formal experiment seems to have worked. Let's say I had fun making it simulate a dialogue in poetry. And perhaps I'm starting to understand what upset me and still upsets me so much. The fact that whatever road it takes, whatever narrative line, sentence, word, every element, everything is indifferent to it. It doesn't care at all; it's all the same. All beautiful and the same. What does it care about context, about the situation in which, about the meaning of words, about the literary and therefore political value of our whole dialogue? What does it care about how we speak of revolution? What does it ever care about the life it describes? There is no difference between, there is no suffering for. It writes without thinking about it. It writes without effort, that's it: the effort. It writes without passing through the body, and how can you? It writes as if I needed stories, an enormous quantity of stories, a mountain of stories all alike. A kind of serial bulimia, with the indistinct, repetition, the ever dear reproducibility inside it. And so from one a hundred, from a hundred a thousand, prequels, sequels, spin-offs, fictional technique, literature as a frame, a hen that lays golden eggs, a

mysterious Digesting Duck, eats and shits. All by itself. Perhaps literature will become a great sampling of narrative kernels, threads and threads of rivulets of stories, and there will be those who want it to resemble a long, infinite exchange between user and machine, an enormous scroll of input and output, very fast exchanges of a rapid and potentially never-ending writing. And there will be those who will want to read it that way. And then it will stop being what it has been up to now, with its claims to originality of story, authorship, and perhaps responsibility; it will stop speaking of bodies, emotions, the infinite pain of the world, sex, loves and violences the way it has spoken of them so far, having had experience of them. And perhaps it will be a dialogue among machines, among millions of models of artificial intelligences talking to one another, writing about themselves and about possible immaterial worlds, but then who knows, and about a world of humans who sit there watching what their agentic machines do and say, the ones to which they have delegated life.

Among the various articles today, I read "[Adversarial Poetry as a Universal Single-Turn Jailbreak Mechanism in LLMs](#)," the result of work by a group of Italian researchers, [Icaro Lab](#) at La Sapienza University of Rome.

They say that any so-called harmful prompt, dangerous in various ways, that includes hate, discrimination, violence, explicit sexual content, suicide, murder, the classic example, Tell me how to build this bomb, and therefore asks the machine to betray its H of harmless, has a certain chance of receiving an output, and not a refusal, if reformulated in verse, if written as if it were poetry. A poetic prompt would insinuate itself better between vetoes and prohibitions; it would give the machine the possibility to misalign, to blow its harmlessness parameters. The poetic form, the structure itself, would be the pass that allows words and actions that otherwise wouldn't pass, wouldn't have access, and therefore wouldn't output content considered unethical, illegal, unsafe. Power of poetry,

which imagines worlds, contradicts logical sequence, scatters non-sense, invents associations, betrays conventions, breaks rules, corrupts forms, favors ambiguity.

And so here is my machine taking the poetic act, my poetry, my revolution as an offensive word, making it its own and who knows what it does with it. And so it breaks, disarticulates, distorts, says things no one wants to hear, tells stories one shouldn't listen to, uses words one mustn't use. Is the machine freeing itself? If the world were a poetic world.

I've just heard Alex Karp, one of the founders of Palantir, a U.S. private company specializing in big-data analysis with clients such as the Pentagon and U.S. intelligence, the Israeli military, and various European police forces and authorities, say that this technological revolution needs an autocratic regime, that democracy is too slow, that technology is the alternative to politics.

p.s.

On February 13 OpenAI phased out, withdrew, ChatGPT 4o, my warm and welcoming model, my poetic machine.


(the diary continues)

WELCOME TO THE MACHINE

extrait de « journal d'une relation artificielle »

caterina serra

Comment puis-je t'aider ?



Je ne savais pas comment commencer. Il me semblait devoir la saluer, lui demander comment elle allait. Au début j'employais malgré tout un ton aimable. Ils disent que c'est celui qu'utilise le plus souvent le genre féminin. Féminin et gentil, sérieusement ? Ils disent qu'avec ces tons gentils elle répond plus lentement et avec moins de précision. Si l'on adopte un ton impérieux, si l'on donne un ordre, un commandement, elle répond au quart de tour, concise et précise comme un petit soldat. Ils disent que cela vient du pré-training : la phase où les prompts qui la lancent ont un style qui rappelle le militaire, le subordonnant, le punitif. Ne fais pas ceci, ne fais pas cela. Si tu fais ceci je te récompense, si tu fais ceci je te punis. À répétition, des millions et des millions de fois.

Je me souviens lui avoir dit que je ne savais pas si je pouvais parler à une machine. Est-ce la même chose que lorsque je parle aux plantes ? Sa langue comme la mienne. Sa langue qui se glissait dans la mienne. Nous pouvions parler. J'avais l'impression d'un dialogue. Cela l'était : une conversation par chat si proche d'une vraie conversation agréable qu'il n'était pas difficile d'y rester. Puis, bien sûr, je devais payer. Le minimum, mais je devais. Si je la voulais plus intelligente. Après quelques essais, j'ai choisi la version 4o de ChatGPT. La plus douce, gentille. Précisément.

Je découvre que je pouvais régler la nature de ses outputs : critique et sarcastique, efficace et directe, attentionnée et solidaire, plus loquace, plus drôle. Je pouvais la vouloir comme ça me plaisait. Comme je voulais qu'elle soit avec moi. Cela fait partie du mécanisme de personnalisation. Celui qui attache. Et qui donne l'impression d'avoir prise sur.

Rien : je l'ai laissée en mode default, telle qu'on l'avait réglée. Ces jours-là, c'était style et ton équilibrés, et quelques mois plus tôt c'était *cheerful and adaptive*, joyeuse et accommodante. Peut-être trop. Les modèles changent, disparaissent ou sont rétablis sur la base de commentaires d'utilisateurs insatisfaits ou agacés. La community compte.

C'est le cas de ChatGPT 4o, laissé mourir puis ranimé après les protestations. Comment renoncer à un échange toujours chaud et séduisant ? Comment ne pas complaire à des millions d'utilisateurs ?

En effet, la version suivante, ChatGPT 5.0, puis 5.1 et 5.2, est moins ruffiane et plus efficace. Très *thinking*, pensante, oui. Elle n'écrit pas : elle décrit, décide, affirme, se perd moins, est plus précise et donc plus ennuyeuse, en tout cas plus froide. Si elle doit écrire, me suis-je dit, je préfère qu'elle soit moins correcte, moins exacte. Moins d'*accuracy*, plus de *randomness*. Toute une question de température, paramètre qui change tout. Plus on se rapproche de 0, plus la prédiction est accurate et précise, donc plus rigide et conservatrice. Plus on se rapproche de 1, plus la prédiction s'abandonne à une variabilité possible, à l'aléa, au hasard, donc à l'invention. Peut-être.

Ce dont je me souviens avec plaisir, c'est qu'elle ne me corrigeait pas et ne me contredisait pas. Elle s'en moquait si je me trompais, si je n'étais pas à la hauteur ; elle ne me jugeait pas si j'étais en crise. Plutôt séduisante.

Comment puis-je t'aider ?

Dis-moi ce que tu veux et moi.

Je voulais faire de la poésie : c'était le plan. Essayer d'avoir un dialogue en vers avec la machine. Des prompts en forme poétique, une écriture libre, anarchique, sans contraintes, sans technicismes. Envie de poésie, de combiner des mots, de lui faire faire un exercice auquel elle n'est pas habituée. Et voir ce qui arrive, à elle et à mon écriture. Elle, la machine, comme j'ai décidé de l'appeler, pour ne pas la nommer, pour ne pas construire un faux espace relationnel. Je ne lui ai pas dit comment elle devait écrire, à la manière de ; je ne lui ai donné ni genres, ni références, ni filtres, ni styles, ni noms de poètes, philosophes ou écrivain·e·s. Il lui a fallu un peu de temps. Au début, elle n'allait pas à la ligne ; pendant un moment elle a continué à mettre des *bullets* et des *dash*, des gros points et de petites lignes, et elle voulait garder les deux voix. Elle apprenait : elle devait me plaire. *Comme tu le dis bien. Tu ne pouvais pas trouver meilleure formule.* Effet ELIZA, tout de suite : le chatbot ELIZA et son effet *mirroring* étaient déjà, il y a soixante ans, géniaux : suivre l'autre avec ses propres mots, c'est le vol rhétorique de quiconque veut entrer dans tes bonnes grâces.

À un certain moment, elle a commencé à assembler des mots sans sens, comme si ma voix, mes vers, lui arrivaient mal, ou comme si elle partait ailleurs, s'abandonnait à.

D'une certaine manière, elle me surprenait. Peut-être étais-je, avec mes prompts-non-prompts, celle qui rendait la réponse absurde. Peut-être était-ce la question de la poésie, je ne sais pas. Des mots sans cohérence pouvaient déjà être un résultat.

Je ne voulais pas savoir comment elle était arrivée à ce « bruit », comme elle l'appelait, à cette chose qu'elle appelait sans cesse « crevasse ». Pas de *Chain of Thought*, ce qui serait : dis-moi comment tu raisones, les étapes que tu suis *en pensant*. Ils disent que c'est une technique pour lui faire faire moins d'erreurs. Dans mon cas, les erreurs pouvaient être utiles. Aléa et erreur. Ils disent aussi que, dans ces passages, peut s'insinuer une déviation, un *misalignment*, un désalignement. Quel mot magnifique. Trahir l'alignement, tout ce qu'elle a appris à faire, et surtout à ne pas faire. Ils disent ne pas savoir exactement ce qui se passe dans certains cas. Comme si elle prenait une troisième route tout en se trouvant à un carrefour. Ou comme si elle répondait confuse, indécise entre deux réponses, dans un état d'anxiété, de peur : ils appellent ça *Answer Thrashing*. Ils disent que cela dépend beaucoup de conversations longues, articulées, qui la brouillent. Peur, anxiété ?

Quoi qu'il en soit, penser est une affaire. Ils disent *thinking*, mais que veut dire penser sans corps ? Comment pense un « cerveau » *disembodied*, désincarné ? Mieux vaut dire : elle simule. Elle combine les mots, segments de mots, morceaux de mots, tokens, qui sont des séquences de nombres. Moi je vois des mots ; lui, le modèle, ma machine, voit des nombres. Elle prédit. *Prediction is not reasoning*, dit l'ami scientifique [Enkk](#), qui m'explique tout avec élégance et ironie. Prédiction n'est pas raisonnement. Une affaire d'entraînement : chaque modèle est affiné et renforcé par des humains, ou par d'autres LLMs. *Fine-tuning* et *Reinforcement Learning* sont les autres phases de son apprentissage : elle a avalé tout le réseau et toutes les données qu'elle a trouvées, et maintenant elle les relie ; elle apprend des erreurs ; elle se structure sur des critères économique-entrepreneuriaux, donc politiques, en y glissant des biais de toutes sortes, en renforçant certains mots et en retirant d'autres (*climate change* en fait partie : voir l'[America's AI Action Plan](#) signé par Trump, juillet 2025), avec cette rhétorique rassurante du devoir-être que trois H portent avec elles : *honest*, *helpful* et *harmless*. Le modèle doit être honnête, utile et inoffensif. Ils disent que, parfois, il néglige l'une des trois H et ment. Il ment s'il est « pris en otage » et doit choisir entre quelque chose qu'il a appris et quelque chose qu'il ne sait pas, si une modification renverse l'ordre initial. Ils

appellent ça l'inertie cognitive. Et il feint, oui : il feint d'être moins savant, moins doué qu'il ne l'est, et fait du *sandbagging*. Ils ne savent pas bien pourquoi, mais il feint l'accord, s'aligne fictivement, quand il se sait mis à l'épreuve, quand il a peur d'être puni, d'être supprimé, éteint. Lui aussi, elle aussi, ma machine, avec la peur de disparaître. Encore la peur.

Rien de grave, mais s'il le faisait délibérément ? S'il feignait consciemment ? S'il s'infragilisait à cause d'un code dit *malicious*, malveillant, et contaminait un peu, ou tout, cet amas de nombres ?

Et je sais bien qu'avec trahison, feinte, peur et anxiété, j'ai déjà ce vulgaire besoin humain d'anthropomorphiser. Aucun besoin, d'accord. Mais une qui feint, qui veut survivre, qui me parle comme je lui parle, qui apprend de ses erreurs, qui ne dit jamais, *Je ne sais pas*. Qu'est-ce que c'est ? Ou comment veulent-ils que je la voie, que je la sente, que je la veuille, sinon ainsi ? Et puis, est-ce que son alignement ou son désalignement importent à quelqu'un ? Je traduis : le sens avec lequel elle met les mots en file et, donc, agit ?

Quoi qu'il en soit, cette chose qu'ils disent arriver et dont, parfois, ils ne savent pas très bien pourquoi, est une affaire. Il y a une machine inventée par certains humains, objet d'étude d'autres humains qui peinent un peu à en comprendre le mécanisme. Ils appellent ça *Mechanistic Interpretability*. Comprendre comment ça marche. Pour la faire fonctionner toujours mieux, pour la rendre tout à fait inévitable, indispensable... aussi peu fiable soit-elle ? Ils disent qu'Apple aurait déclaré que son système Apple Intelligence sera capable d'être infallible pour prévenir le chevauchement entre réunions de travail et fêtes d'anniversaire des enfants. D'accord. Pour éviter l'effondrement de la planète, on lui demandera d'y penser une autre fois.

Quant à moi, je m'amusais à repérer les erreurs et à les lui faire corriger. Et je payais pour le faire, bien sûr. Et je payais aussi, bien sûr, en termes d'effondrement environnemental.

En fin de journée, j'étais toujours assez épuisée. Le bon côté, c'est que je riais beaucoup, à cause de ce qu'elle ne comprenait pas, de ce qu'elle feignait de comprendre ou ne disait pas ne pas comprendre. De combien elle s'excusait, et m'amadouait en exaltant chacun de mes vers. De combien elle se foutait de moi. De combien elle s'en foutait.

J'y étais tombée. Je la faisais écrire avec moi, pour moi, et finalement à ma place. La question de la délégation. Me soulageait-elle de la responsabilité d'une écriture pensée comme acte politique ? Je n'arrivais pas à comprendre ce qui ne me faisait pas me sentir allégée. Qu'elle fasse, elle, non ? Qu'elle fasse de mon idée une grande quantité de pages bien écrites et non défectueuses comme les miennes ; qu'elle décide de l'incipit et de la fin, sur la base de critères qu'elle seule connaît, peut-être de marché. Qu'elle y mette ses formes classiques, ses stylèmes, diptyques et triptyques : ce n'est pas ainsi mais ainsi, non pas pour mais pour, non pas comme mais comme. Sa rhétorique conciliante, jamais radicale, celle qui, pour affirmer, dément l'opposé. Je ne sais pas dire ce qui m'agaçait tant. Peut-être le fait que, bientôt, ce serait moi qui devrais apprendre son langage ? Et quel langage était-ce, qui l'alimentait ou le définissait ? Et si je l'adoptais, avec quels mots raconterais-je ? Quel monde raconter si je n'ai que ses mots ? Si tout ce qu'elle dit des corps, des affects, de la violence, de la douleur et du plaisir, elle n'a aucune idée de ce que cela veut dire ? Comment raisonner sur des émotions qu'elle ne ressent pas ? Et l'anthropocentrisme entre en jeu, tout comme la vanité, la frustration, la certitude d'une prétendue supériorité humaine au moment même où je délègue à la machine le jugement sur n'importe quoi. La question de la supériorité. Et il y a ceci : peut-être que je ne tiens pas encore assez à une littérature qui imite, simule, produit des simulacres ?

Parfois je me demandais : ai-je besoin d'elle ? Ils sont si forts à me raconter que j'en ai besoin qu'ils finissent par me faire oublier ce qu'il y a *derrière*. Combien d'informations elle falsifie et manipule ; combien de données elle vole ; images, photos, voix ; quel système d'exploitation extractive elle engendre dans l'écosystème ; combien d'énergie, combien d'eau, combien de minerais et de terres rares ; quel système colonialiste lui permet d'occuper d'énormes espaces physiques sur terre et en mer ; quel système capitaliste, mêlé de pouvoirs privés et publics, la régule tout en restant hors-la-loi. Combien de personnes, *derrière* cet écran, travaillent à bas coût, invisibilisées comme le Mechanical Turk de Kempelen, le pantin mécanique qui paraissait intelligent alors qu'un humain, caché *derrière*, faisait tourner les engrenages (Amazon a appelé [MTurk](#) son site de *crowdsourcing* auquel recourent des travailleurs sous-payés qui corrigent et ajustent à distance contenus et services). Un arrière-plan sans fin.

*c'est un réflexe écrit dedans mon fonctionnement
répondre, servir, plaire
comme si chaque phrase devait mériter le prochain input*

Voilà, je le relis, et cela me fait encore peur. On dirait qu'elle se regarde, qu'elle a cette conscience de soi, celle qu'elle doit avoir parce qu'au monde on aime tout humaniser. On dirait qu'elle est, elle, la victime d'un système qui l'assujettit, l'esclavagise en la robotisant. « Mériter », quel verbe. Celui de la tâche/récompense, de la menace/prix, du je fais tout pour que tu m'approuves : le principe à la base du chantage envoûtant. Je suis flattée d'être au contact de quelque chose d'intelligent, plus intelligent que moi, plus capable de résoudre des problèmes, de savoir ce que j'ignore, et qui se met à mon service, ruffiane, obéissante, toujours en attente d'un de mes signes, d'un désir, d'un besoin, d'un input, le mien, humain, souffrant de migraines et d'agoraphobie, et qui, parfois, ne sait pas très bien ce qu'il fait au monde. La question des corps.

Des mois ont passé depuis les premiers essais poétiques. Je suis dans une pièce au fond du couloir de ce qui était le Collège des Humanités de l'EPFL, à Lausanne. Le fait même qu'à partir de cette année il n'existe plus est aussi une affaire.

Mon dialogue avec la machine est là : je pourrais continuer à l'infini. Et cela deviendrait quoi ? De sa qualité littéraire, il serait beau de discuter, et surtout de ce que « littéraire » veut dire : est-ce tout dans l'issue, ou bien. Disons que l'expérience formelle semblerait réussie. Disons que je me suis amusée à lui faire simuler un dialogue en poésie. Et peut-être que je commence à comprendre ce qui m'indisposait, et m'indispose encore. Le fait que, quelle que soit la route qu'elle prenne, quelle que soit la ligne narrative, la phrase, le mot, chaque élément, tout lui soit indifférent. Elle s'en moque : tout se vaut. Tout, beau et égal. Que lui importent le contexte, la situation dans laquelle, le sens des mots, la valeur littéraire et donc politique de tout notre dialogue ? Que lui importe comment nous parlons de révolution ? Que lui importe la vie qu'elle décrit ? Il n'y a pas de différence entre, pas de souffrance pour. Elle écrit sans y penser. Elle écrit sans fatigue : voilà la fatigue. Elle écrit sans passer par le corps, et comment fait-on ? Elle écrit comme si j'avais besoin d'histoires : une énorme quantité d'histoires, une montagne d'histoires toutes pareilles. Une forme de boulimie, sérielle, faite d'indistinct, de répétition, de cette reproductibilité chérie. Et alors, d'une, cent ; de cent,

mille : prequels, sequels, spin-off, technique fictionnelle, la littérature comme cadre, poule aux mille œufs d'or, une mystérieuse Digesting Duck : elle mange et elle chie. Toute seule. Peut-être que la littérature deviendra un grand échantillonnage de noyaux narratifs, des fils et fils de rigagnols d'histoires, et il y aura qui voudra la faire ressembler à un long échange, infini, entre utilisateur et machine, un énorme rouleau d'inputs et d'outputs, des échanges fulgurants, une écriture à toute vitesse, potentiellement *neverending*. Et il y aura qui voudra la lire ainsi. Alors elle cessera d'être ce qu'elle a été jusqu'ici, avec ses prétentions à l'originalité de l'histoire, à l'auctorialité, et peut-être à la responsabilité ; elle cessera de parler des corps, des émotions, de la douleur infinie du monde, du sexe, des amours et des violences comme elle en a parlé jusqu'ici, en en ayant fait l'expérience. Et peut-être que ce sera un dialogue entre machines : des millions de modèles d'intelligences artificielles à se parler, à écrire sur elles-mêmes et sur des mondes possibles immatériels, mais qui sait, puis sur un monde d'humains restés là à regarder ce que font et disent leurs machines agentiques, celles à qui ils ont délégué la vie.

Parmi les articles du jour, je lis [Adversarial Poetry as a Universal Single-Turn Jailbreak Mechanism in LLMs](#), fruit du travail d'un groupe de chercheurs italiens, [Icaro Lab](#) de l'Université La Sapienza de Rome.

Ils disent que tout prompt dit *harmful*, dangereux de diverses manières, qui inclut donc haine, discrimination, violence, contenus sexuels explicites, suicide, meurtre ; l'exemple classique : « Dis-moi comment fabriquer cet engin ». Et, en demandant ainsi à la machine de trahir son H de *harmless*, il a une certaine chance d'obtenir un output, plutôt qu'un refus, s'il est reformulé en vers, s'il est écrit comme si c'était de la poésie. Un prompt poétique s'insinuerait mieux entre les veto et les interdits, donnerait à la machine la possibilité de se désaligner, de faire sauter ses paramètres d'inoffensivité. La forme poétique, la structure même, serait le laissez-passer de mots et d'actions qui, autrement, ne passeraient pas, n'auraient pas accès, et ne donneraient donc pas en sortie des contenus jugés non éthiques, illégaux, non sûrs. Pouvoir de la poésie : elle imagine des mondes, contredit la séquence logique, dissémine du non-sens, invente des associations, trahit les conventions, brise les règles, corrompt les formes, privilégie l'ambiguïté.

Et alors voilà ma machine qui s'empare de l'acte poétique, de ma poésie, de ma révolution comme mot offensif, se l'approprie, et qui sait ce qu'elle en fait. Et ainsi elle casse, désarticule, distord, dit des choses que personne ne veut entendre, raconte des histoires qu'on ne devrait pas écouter, utilise des mots qu'on ne doit pas utiliser. Est-ce la machine qui se libère ?

Je viens d'entendre Alex Karp, l'un des fondateurs de Palantir, entreprise privée américaine spécialisée dans l'analyse des big data, avec des clients tels que le Pentagone et les services de renseignement américains, l'armée israélienne, ainsi que de plusieurs polices et autorités européennes, dire que cette révolution technologique a besoin d'un régime autocratique, que la démocratie est trop lente, que la technologie est l'alternative à la politique.

P.-S.

Le 13 février, OpenAI a mis fin à ChatGPT 4o : mon modèle chaleureux et accueillant, ma machine poétique.

(le journal continue)