

kapitola I

Co se to vlastně stalo?

Excel noc


Kamarádův syn přepisoval celou noc řádky v Excelu.
Ráno stačilo **Ctrl+F** — a bylo to za pár sekund.

Nejde o tu jednu noc. Jde o všechny další.

Co se změnilo

- Syntaxe zlevnila na **nulu** — kód napíše stroj.
- Hodnota se přestěhovala do **úsudku**: poznat, že je to špatně.
- Svět se dělí na ty, kdo **ověř**í, a ty, kdo musejí **věř**it.
- Dveře jsou otevřené: každý může být vědec i programátor.

Hodnota se stěhuje



Syntaxe (drahá → skoro zadarmo) vs. úsudek (levný → vzácný). Součet zůstává.

Kentaury z New Hampshiru

2005, freestyle šachy: dva amatéři (rating 1685 a 1398) se třemi běžnými počítači porazili velmistry i superpočítače.

Slabý hráč + stroj + lepší proces > silný hráč + stroj + horší proces.

Poctivě: po 2017 čisté enginy kentaury předběhly — hodnota se stěhuje zas. Přežívá proces.

„Jak bych poznal, že se pletu?„

U příští věci, co ti AI vyrobí: jak bys poznal, že je špatně?
Když neumíš odpovědět, nevíš, jestli držíš lesk, nebo bídu.

kapitola 2

To už
tu bylo?

Kabel, který zabily oslavy

1858: první telegrafní kabel pod Atlantikem. Amerika se zbláznila radostí — ohňostroj v New Yorku **skutečně zapálil radnici**.

Kabel byl ale nemocný. Whitehouse hnal do slábnoucího signálu **dva tisíce voltů**. Do měsíce oněměl. Přišla zima a řeči o podvodu.

Ten příběh není o telegrafu. Je o tvaru, který uvidíš znovu a znovu.


Hype cyklus AI

- 1958 · perceptron slíbil stroj, co je si vědom. **Ohňostroj.**
- 1969–73 · Minsky & Papert, Lighthill → **první zima.**
- 80. léta · expertní systémy, ruční pravidla → **druhá zima.**
- Dnes · zatím **nejvyšší hřeben.** Vlny sílí, tvar se opakuje.

Co je jiné

- Škála — o deset řádů víc než perceptron. Řád mění povahu věci.
- Přesvědčivost — model zní jistě, i když se mýlí. Nová veličina.
- Dostupnost — ne exponát v laboratoři, ale nástroj v každé kapse.
- Stejně zůstává jen jedno: křivka slibů a peněz.

Jara a zimy AI



Křivka není předpověď — je to paměť. Vlny sílí, tvar se opakuje.

Detektor Whitehouse / Kelvin

Whitehouse přidal **sílu do systému** — víc voltů, překřič to.

Thomson přidal **citlivost do měření** — přístroj, co i šepot přečte.

U každého „průlomu,, se ptej:

Víc voltů, nebo **citlivější galvanometr**?

Vyhrál ten, kdo líp měřil — ne ten, kdo hlasitěji přidával.

„Jak bych poznal, že se pletu?,“

Vezmi příští „průlom,, v AI. Je to víc voltů, nebo citlivější galvanometr?

A viděl jsem produkci, nebo jen vybrané demo? Když neodpovíš, díváš se na ohňostroj.

kapitola 3

Proč vidíš signál i v šumu?

Kůň, který uměl počítat

Berlín, 1904. Kůň Hans klepe kopytem správné odpovědi — a komise třinácti lidí nenašla podvod.

Pfungst pak měnil podmínky: když tazatel odpověď **neznal**, úspěšnost spadla na nulu.

*Kůň neuměl počítat. Kůň četl **člověka**.*

Stroj na vzory

- Tvůj mozek vyrábí smysl i tam, kde **žádný není** — říká se tomu apofenie.
- Šéf měsíce popisoval trendy v panelu, který zobrazoval **random()**.
- Není to příběh o hloupém šéfovi. Je to příběh o mozku, který máme **stejný**.


Plynulá řeč: největší pareidolie v dějinách

1966: program ELIZA jen přehazoval slova z tvé věty do otázky. Žádné porozumění.

Weizenbaumova sekretářka ho přesto požádala, ať **odejde z místnosti** — chtěla si popovídat soukromě.

Ve chvíli, kdy něco mluví lidsky, mozek předpokládá mysl. Dnešní model je ELIZA škálovaná o mnoho řádů.

Placebo v čisté podobě



Čtyři panely, čtyři „příběhy“, — a všechny čtyři jsou též šum z jednoho zrna náhody (seed 42).

Zaslep se

- **Shuffle test:** zamíchej popisky a hádej znovu. Přežije-li vzor, viděl jsi sebe.
- **Placebo dashboard:** postav si vedle panel z čistého šumu.
- **Forer na sobě:** neplatil by ten „insight“, stejně dobře pro kohokoli?

„Jak bych poznal, že se pletu?„

Než uvěříš vzoru — trendu, korelaci, sérii — zamíchej popisky a hádej znovu.
Vidíš-li ho i teď, neviděl jsi data, ale sám sebe: Hanse, který četl tebe.

kapitola 4

Proč pocit dřiny nic nedokazuje?

Paprsky, které viděla jen Francie

1903: fyzik René Blondlot ohlásil N-paprsky. Za rok 300 článků, 120 vědců je „potvrdilo“. Mimo Francii je nikdo neviděl.

Američan Wood za tmy vyndal z aparatury klíčový hranol — a měření běžela dál. Paprsky se „viděly“ i bez něj.

Blondlot nelhal. Byl oklamán — vlastní poctivou dřinou.

Effort heuristic — dřina lže

V hlavě máš tiché pravidlo: **co mě stálo víc práce, musí být blíž pravdě.**

Je to zkratka — a zkratky se dají obelstít. Když měříš správnost pocitem dřiny, měříš, kolik tě to stálo. **Ne, jestli je to pravda.**

Nadřít se a mýlit je stejně snadné jako nadřít se a mít pravdu.

Iluze hloubky vysvětlení



- Umíš vysvětlit splachovací záchod? Krok za krokem, ventil po ventilu?
- Většina lidí se v půlce **zadrhne** — jistota zmizí ve chvíli výkladu.
- Rozenblit & Keil 2002: sebejistota spadla z **3,9 na 3,1** — jen pokusem vyslovit to nahlas.

— Porozumění se netestuje pocitem. Testuje se pokusem **vyslovit**
ho.

Čtyři rituály proti sobě

- **Kachnička** — vysvětli to nahlas cizímu člověku, do posledního kroku.
- **Predikce předem** — napiš, co uvidíš, dřív než spustíš test.
- **Deník omylů** — zapisuj, v čem ses spletl, a co jsi čekal.
- **Levné zahození** — commit před experimentem, ať smíš zahodit.

Propast, ve které bydlí sebeklam



Vlevo: pocit správnosti roste s dřinou, skutečná správnost ne (effort heuristic). Vpravo: průměrná sebejistota „rozumím“ spadne, jakmile se člověk pokusí věc do detailu vysvětlit (Rozenblit & Keil, Cognitive Science 2002; pokles z ~3,9 na ~3,1).

Pocit správnosti roste s dřinou; skutečná správnost se nehne — tu zvedne jedině test.

„Jak bych poznal, že se pletu?„

Zkus svůj kód vysvětlit nahlas cizímu člověku do posledního „protože“.
Kde se zadrhneš, tam jsi jen cítil, že rozumíš — a máš Blondlotovy paprsky.

kapitola 5

O co
přijdeme?

Chvála písařů — vytištěná

Roku 1492 hájil opat Trithemius ruční opisování knih: opisovat prý není přenos textu, ale **učení** — mnich text projde slovo za slovem.

Aby se jeho obrana rozšířila, dal ji roku 1494 **vytisknout**.

Měl pravdu o ztrátě — a prohrál válku. A měl prohrát.

Přesná podoba omylu

- Nemýlil se v tom, **co se ztrácí**: opisování bylo učení.
- Mýlil se v tom, že by se to dalo zachránit **odmítnutím nástroje**.
- Tisk byl nedozírně cennější: gramotnost, věda, tahle kniha.
- My jsme o pět století dál — jen s jiným nástrojem.

Fórum, které nás učilo ptát se

Stack Overflow nebyl sklad odpovědí. Byl **tréninkový tábor formulace**.


Napsat otázku srozumitelně — co jsem zkusil, co čekám, co se stalo — znamenalo, že jsi **devětkrát z deseti** odpověď našel sám.

Ta bolest u klávesnice nebyla daň za odpověď. Byla tím učením.

Co si vytvoříš, to si pamatuješ

- **Efekt vytváření** (Slamecka & Graf, 1978): co si vytvoříš sám, pamatuješ líp.
- Přechíst vygenerovaný kód a napsat ho jsou **dvě různé činnosti**.
- **Žádoucí obtíže** (Bjork): plynulý pocit zvládnutí klame o naučení.

Stroj, který se krmí sám sebou



simulace: každá generace fitne normál na 30 vzorcích z předchozí generace — chvosty a rozptyl se ztrácejí

Model učený na vlastním výstupu se zužuje — chvosty mizí dřív než banality.

Tentýž zákon ve dvou měřítkách

Zhroucení modelu je **přeučení na sebe sama**. Ale je to mechanismus s podmínkami — příměs reálných dat kolaps tlumí.

Hlava, která se učí jen z hladkých výstupů, je **taky trénink na odraz**.

Informace, kterou nikdo znovu neprošel, degeneruje.

„Jak bych poznal, že se pletu?„

U příští věci, co ti AI vyřeší: zvládl bys ji za rok znovu, bez ní?
Když ne, nekoupil sis řešení — pronajal sis neporozumění.

kapitola 6

Proč astronaut cvičí dvě hodiny denně?

Astronaut, který si předepisuje gravitaci

Skylab, 1973. Lékař Joe Kerwin měří na vlastním těle, co dělá beztláče: z nosných kostí ubývá **1–2 % hmoty měsíčně**.

Tělo nedělá nic špatného — jen přestalo platit tkáň, kterou nikdo nezatěžuje. NASA nenašla řešení v návratu na Zem, ale v **předepsaném odporu**: dvě hodiny cvičení denně na trenažéru ARED.

Gravitace byla celoživotní trénink, který nikdo nevnímal jako trénink — dokud nezmizel.

Tělocvična, kterou nám tiše zavřeli

Noci nad debuggerem. Refaktoring pod tlakem paměti. Hledání chyby bez Googlu. To byly **bezplatné tréninky vhledu** — gravitace řemesla.

Přišel nástroj, který kód napíše, chybu najde, manuál přečte za tebe. Odpor zmizel a je to úleva.

Jen nám nikdo neřekl, že se právě zavřela posilovna.


Bolest je ta cesta

- Dřina, u které mozek obsah **prochází**, tvoří porozumění.
- Vyhneš se jí → **pocit** porozumění bez porozumění (iluze vědění).
- Iluze vědění nekončí dobře: nástroj selže — a ty souboru nerozumíš.
- Řešení není vypnout AI, ale **předepsat si odpor schválně**.

Posilovna: šest cviků, ne sedm návyků

- Čti cizí kód, dokud neřekneš **proč** je takový.
- **Predikuj výstup** — rozdíl oproti realitě je, co ses naučil.
- Jeden den v týdnu **bez asistenta** — diagnostika atrofie.
- Vysvětluj nahlas, commit piš z hlavy (vybavení z paměti).

Kolik z toho ještě umíš



Ebbinghausova křivka zapominání (1885): bez opakování retence strmě padá (~dvě třetiny pryč do 24 h) k nízké asymptotě. Opakování v odstupu (spacing effect) ji pokaždé vrátí a zpomalí další pokles — schematický průběh kalibrovaný na doložená čísla (Ebbinghaus 1885; spacing: Cepeda et al., meta-analýza 254 studií, 2006).

Bez opakování zapomeň dvě třetiny do dne. Opakování v odstupu drží o 10–30 % víc.

„Jak bych poznal, že se pletu?„

Co sis za poslední měsíc nechal udělat od AI — a přestal to umět sám?
Vyber jednu takovou věc a příště ji udělej bez asistenta. To je tvá dřepová série.

kapitola 7

Zrychlí ti stroj i chaos?

Bedlam DL3

14. října 1997, Microsoft. Jeden zaměstnanec napsal do obřího seznamu „vyřadte mě odsud, — a poslal to všem.

Desítky odpovědí „mě taky,, pak „přestaňte psát všem!“ — poslané, jak jinak, všem.

15 milionů zpráv za hodinu, 195 GB, servery lehly. Nikdo bouři nechtěl.

Zesilovač nezná směr

- Nezhroutili to hlupáci — **chytrí lidé s dobrým úmyslem.**
- Systém fungoval přesně jak měl: jen **zesílil** drobnou chybu.
- E-mail doručí promyšlené i unáhlené, jednu adresu i dvacet tisíc.
- Model je týž zesilovač — jen s **mnohem vyšším ziskem.**


Delší, zdvořilejší chaos

Vejdeš do modelu s jasnou hlavou → znásobí ti práci.

Vejdeš se zmatkem → nedostaneš jasno. Dostaneš **delší, zdvořilejší a početnější verzi téhož zmatku.**

Chaos nezmizel. Jen se zrychlil a získal lepší sloh.

Kdy se lavina rozjede



Bouře odpovědí jako větvící se proces: jedna zpráva vyvolá v průměru R odpovědí, počet v n -té vlně $= R^n$.
 $R > 1$ exploduje (Bedlam DL3: ~15 mil. zpráv za ~hodinu), $R < 1$ vyhasne, $R = 1$ je práh mezi tím — tatáž matematika jako epidemie (R nula) a řetězová reakce (Galtonův–Watsonův proces: $R < 1$ útlum, $R > 1$ exploze).

$R = \text{kolik odpovědí vyvolá jedna zpráva. Pod jedničkou vyhasne, nad ní exploduje.}$

Sniž R návrhem, ne přáním

- R není osud — je to **součin**, $R \approx p \times m$.
- Uber **příjemce** (m dolů): strop na velikost seznamu.
- Přidej **moderaci** (p dolů): odpověď musí někdo pustit dál.
- Vlož **brzdu**: rate limit, aby bouře nenabrala vlny.

„Jak bych poznal, že se pletu?„

Než pošleš nebo vygeneruješ hromadnou věc: kolik odpovědí či akcí každá jedna vyvolá?

Víc než jednu — stavíš lavinu. Sniž R pod jedničku dřív, než zmáčkneš enter.

kapitola 8

Proč se přivázat ke stěžni?

Smlouva s budoucím já

Odysseus věděl, že píseň Sirén je **skutečně krásná** — přemluví každého.
Na radu Kirké rozhodl **předem**.

Posádce vosk do uší, sebe ke stěžni — a ať ho neodvazují, ať říká cokoli.

Přežil jediný, kdo ji slyšel. Ne silnější vůlí — rozhodl dřív.

Proto „budu opatrný“ prohrává

- Opatrnost je rozhodnutí v **reálném čase** — a přesně tam tě píseň dostane.
- „Zkontroluju to potom.“ zní ve chvíli, kdy to říkáš, **naprosto** **rozumně**.
- Funguje jen jedno: závazek uzavřený **předem**, za střízliva.

Tři reakce na jednu píseň

Vosk píseň neslyšíš — **legitimní odmítnutí AI**. Posádka doveslovala domů.


Skok vrhneš se bez pout — **slepý vibe coding**. Hromada kostí. Tohle je past.

Stěžen slyšíš celou píseň, ruce svázané předem. **Tahle kniha staví stěžen**.

Tvůj první pakt

- **Test před generováním** — jak poznáš správný výstup, dřív než ho vyrobí.
- **Commit před experimentem** — návrat zdarma, můžeš si dovolit odvahu.
- **Věta „co mě přesvědčí, že je to špatně“** — dřív, než se zeptáš modelu.

Proč zabírá „předem“



Hyperbolické diskontování (Ainslie): z dálky ceníš víc větší-vzdálenější odměnu — metodu. Jak se blíží pokušení, hodnota menší-bližší odměny prudce vysočtí a v bodě překlopení přeroste metodu — preference se obrátí. Exponenciální diskontování (zárkováň) se nikdy neprotne. Proto se rozhoduješ předem: vlevo, kde metoda ještě vede — ne vpravo, kde už prohráváš.

V bodě překlopení „hotovo teď“ přeroste poctivou metodu — proto pakt uzavíráš vlevo.

„Jak bych poznal, že se pletu?„

Napiš si teď, za střízliva: „Tenhle projekt zahodím — nebo nenasadím — pokud _____.“

Ne mlhavě, ale ověřitelně. To je tvůj první uzel na laně.

kapitola 9

Jak poznám, že se pletu?

Lékař, který počítal mrtvé

Vídeň, 1846. Dvě porodnice vedle sebe. Na první rodí lékaři — a umírá **jedenáct matek ze sta**. Na druhé báby — necelé tři.

Semmelweis ta čísla nesnesl a udělal jedinou správnou věc: *začal je vážně počítat*.

Postup, ne hrdinství

- Uhodl příčinu: ruce lékařů nesou od pitev **mrtvolné částice**.
- Odvodil **předpověď**, která mohla dopadnout špatně.
- Změnil **jediný vstup** — a úmrtnost spadla z 11 % na 1,3 %.
Pravdu mu dala **číslo**, ne potlesk.

Metoda není katedrála, je to debugger


Zapomeň na mramorové sály a muže v pláštích. Vědecká metoda je přízemní a užitečná — je to **debugger**.

Uhodneš příčinu. Řekneš, co uvidíš, máš-li pravdu. Uděláš jeden zásah. Změříš. A buď oslavíš, nebo **zjistíš, že se pleteš** — o slepou uličku chytřejší.

Stroj na výrobu užitečných omylů

- Metoda není stroj na pravdy. Je to stroj na užitečné omyly.
- Přeplněnost ne, podnebí ne, kněz ne — každý zamítnutý pokus je zaplacená informace.
- Metoda tě nechrání před omylem — dělá z omylu palivo.
- Vědec se od věřícího neliší tím, že se méně mýlí; přistihne se dřív a levněji.

Důkaz v číslech



Po zavedení mytí rukou (svislíce, 1847) spadne úmrtnost lékařů pod báby — a zůstane tam.

„Jak bych poznal, že se pletu?„

Konkrétní test: ke každému tvrzení dopiš jednu větu —
co bych musel naměřit, aby se ukázalo, že je špatně? Bez ní máš jen dojem.

kapitola 10

Co je vlastně model?

Mapa, která lhala správně

Harry Beck v roce 1931 vyhodil z mapy londýnského metra geografii. Trati narovnal, stanice rozsadil pravidelně, nechal jen Temži.

Vzdálenosti **lžou** — ale topologie sedí.

Lže přesně tam, kde na tom nezáleží. Mluví pravdu v jediné věci, na které záleží: co je spojeno s čím.

Model je Beckova mapa dat

- Ze všeho, co dělá byt bytem, si čára nechá **jedinou veličinu** — plochu.
- Vše ostatní vyhodí, stejně jako Beck vyhodil zatáčky tunelů.
- Má dvě ladící kolečka: **sklon** a **posun** — říká se jim parametry.
- Mapa, ne území. *Zjednodušení světa, které platí nájem predikcemi.*


Co znamená „naučit se“?

Mezi body a čarou jsou tenké svislé čárky. Každá je **chyba** — o kolik u konkrétního bytu mapa lže.

Otáčeji čarou a posouvěj ji tak dlouho, dokud **součet chyb** neklesne na minimum.

Stroj nedělá nic chytřejšího — jen to zvládne přesně a za milisekundu.

Dvačtyřicet bytů, jedna čára



*Ta červená čára je celý náš stroj: model, který z plochy odhadne cenu. Uvnitř dat interpoluje —
venku už jen doufá.*

Zoo tvarů

Přímka je jen jeden způsob, jak svět zjednodušit.

Strom rozhodne pár otázkami a vznikne schodiště. **k-NN** najde pět nejpodobnějších sousedů a vezme průměr.

Žádný z nich není svět — jsou to tři mapy téhož území. Modely jsou vyměnitelné díly, ne osobnosti.

„Jak bych poznal, že se pletu?„

Čára měřila chybu na bytech, které viděla.

Schovej před ní pětinu dat — a nech ji ocenit to, co nezná.

kapitola II

Kolika parametry nakreslíš slona?

Slon se čtyřmi parametry

Jaro 1953. Dyson veze Fermimu dva roky výpočtů, co krásně sedí na data. Fermi se zeptá: „Kolik volných parametrů?„ — „Čtyři.“

*„Se čtyřmi parametry ti nafituju slona, a s pěti mu rozhýbu chobot.
„ — von Neumann*

Krásná shoda s daty byla iluze koupená za čtyři čísla.

Papoušek a student

Papoušek se naučil loňský test nazpaměť — i s tečkami. Student pochopil, proč jsou odpovědi takové.

Na loňském testu vyhraje papoušek. Na letošním — s otázkami, které nikdo neviděl — se papoušek zhroutí a student projde.

Rozdíl nepoznáš na tom, co model viděl. Jen na tom, co neviděl.


Letošní test

- **Přeučení** (overfitting) — model se naučil data nazpaměť i se šumem. Papoušek.
- Než začneš učit, schovej **pětinu dat** do trezoru.
- Zajímá tě **chyba venku**, ne doma. Křížovou validací ji změříš spolehlivě.

Dvě nemoci, jedno údolí


- **Nedoučení** — přímka přes vlnu. Model je tak chudý, že netrefí ani tvar. Vysoké vychýlení.
- **Přeučení** — had přes šum. Prolézá každý bod včetně náhody. Vysoký rozptyl.
- **Správná složitost** leží v údolí mezi nimi.
- Regularizace: nech model složitý, ale **zdaň mu složitost**.

Kde se papoušek prozradí



Test (sanguine) klesne ke dnu a pak stoupá. To dno je správná složitost.

A teď doopravdy



věrná rekonstrukce dle Mayer, Khairy & Howard, Am. J. Phys. 78, 648 (2010)

Mayer, Khairy & Howard (2010): čtyři komplexní čísla nakreslí slona.

„Jak bych poznal, že se pletu?„

Než uvěříš, že model něco umí: viděl ta data při tréninku?
A hlavně — jaká je jeho chyba na tom, co neviděl?

kapitola 12

Porazil bys hloupého soupeře?

Předpověď, které se smáli

1861: Robert FitzRoy vydal v *The Times* první veřejnou předpověď počasí na světě. Razil pro ni i slovo — **forecast**.

Tisk se mu smál za každý netrefený den, věda jím pohrdala: *bádání není věda*. Zemřel v posměchu a ruině.

Zbyla otázka: byla jeho předpověď k něčemu — nebo jen opisovala včerejšek?

Nejdřív najdi hloupého soupeře

- „Model má 75 % úspěšnost!“ V Praze neprší tři dny ze čtyř — tupé „zítra nebude pršet“ má taky 75 %.
- Hloupý soupeř je laťka na zemi: průměr, poslední hodnota, nejčastější třída. Kdo ho neporazí, jen dráž dělá totéž.
- FitzRoyův soupeř má jméno: persistence — „zítra bude jako dnes“.

Prevalence je krutější než přesnost

Test na vzácnou nemoc, 90 % přesný v obou směrech. Nemoc má jeden ze sta. Přejde ti pozitivní výsledek — jsi nemocný?


Z tisíce lidí: 9 skutečných nálezů, ale 99 planých poplachů ze zdravé většiny. Pozitivních 108, nemocných 9.

Šance, že jsi nemocný, je osm procent — ne devadesát.

Tři čísla, která se pletou

- **Správnost** — kolik ze všech odpovědí je dobře. Zdravá většina ji drží vysoko.
- **Přesnost** — z označených kolik doopravdy platí. Spadla na 8 %.
- **Úplnost** — z nemocných kolik jsi našel. A cena chyby se úlohu od úlohy obrací: u spamu bolí planý poplach, u rakoviny prošvihnutý nádor.

ROC: kdo hází mincí, leží na úhlopříčce



Náhodný soupeř má AUC 0,5. Ale i vysoká AUC u vzácné nemoci klame.

„Jak bych poznal, že se pletu?„

Než uvěříš modelu nebo AI demu, polož dvě otázky:

Co je hloupý soupeř — a porazil ho vůbec? A: jak vzácné je to, co hledá?

kapitola 13

Kde lžou data, když čísla sedí?

Díry, které tam nebyly

1943, Kolumbijská univerzita. Abraham Wald počítá zranitelnost letadel — jenže díry lze sečíst jen na strojích, které se **vrátily**.

Málo zásahů na motorech neznamená, že se do nich netrefuje.
Znamená to, že zásah do motoru se domů nevrací.

Slavný mem s tečkami je z roku 2016. Wald nenapsal bonmot — napsal metodu.

Data nelhala čísla

- Každá díra na každém vráceném letadle byla spočítána **správně**.
- Data lhala **vzorkem** — tím, kdo se do tabulky vůbec směl dostat.
- Síto pracovalo proti směru otázky: čím pečlivěji jsi počítal, tím jistěji tě vedlo pancéřovat nesprávná místa.
- Čísla seděla. **Právě proto byla nebezpečná.**

Jeden mechanismus, čtyři kostýmy

- Klam přeživších — počítáš jen letadla, která se vrátila.
- Paradox porodní váhy — cigareta „chrání“ lehké děti (30 let záhady).
- Vždy totéž: podmínění na následku.
Podmínka výběru je tichý collider.

Tužka před regresí


Obrana nestojí větší data — stojí **dvacet vteřin tužkou**.

1. Kdo ve vzorku chybí? 2. Co bylo podmínkou vstupu? 3. Kdo měřil a proč?

Nakresli kauzální graf — pak stratifikuj podle **příčin**, ne podle následků.

Regrese bez grafu je výpočet bez otázky.

Simpsonův obrat: aritmetika vah



Léčba A vede v obou vrstvách — a v souhrnu prohrává. Obrat nevěží v datech, ale ve vahách.

„Jak bych poznal, že se pletu?„

Až ti příště analýza potvrdí přesně to, co sis přál, vezmi tužku dřív než šampaňské.

A ptej se s Waldem: kde jsou letadla, která se nevrátila?

kapitola 14

Proč se tisíc doktorů spletlo u tří dveří?

Deset tisíc dopisů

1990, rubrika *Ask Marilyn*: přisedni u tří dveří a vyhraješ ve **dvou třetinách**. Odpověď je správná.

Přišlo 10 000 dopisů, 1 000 od lidí s doktorátem — většina, že se mylí. I Paul Erdős odpověď odmítal, dokud mu ji **nedokázala simulace**.

Kapituloval nerad: viděl, ŽE to platí, ale pořád chtěl vědět PROČ.

Kde intuice lže

- Pocit „padesát na padesát,, má i tisíc doktorů — **nejsi hloupý.**
- Lež je v tom, že dvoje zbylé dveře jsou si rovny. **Nejsou.**
- Moderátor **ví**, kde je auto, a odkryje vždy kozu — jeho ruka nese informaci.
- Se sto dveřmi to křičí: 98 obejde, ta jediná zbylá je skoro jistě auto.

Nevěř, simuluj — ale předpověď napiš první

Přepočítání lidem nestačí; pocit křičí hlasitěji než tabulka. Tak hru **odehraj** — desettisíckrát, metodou Monte Carlo.

Nejdřív ale **zapiš dvě čísla**: kolik vyhraje „měním“, a „nechávám“. Bez zapsané předpovědi ti paměť namluví, žes to věděl.

Výsledek: „měním“, se usadí na **66,7 %**, „nechávám“ na 33,3 %. Nikdy ne 50:50.


Když moderátor jen zakopne

Co když moderátor **neví**, kde je auto — zakopne a dveře se náhodou rozletí, za nimi koza? Scéna vypadá na chlup stejně.

A přece: teď je to **opravdu 50:50**. Táž koza, dvě pravdy.

*O pravdě nerozhoduje, co v datech vidíš, ale **jak vznikla**. Nejdřív se ptej, jak data vznikla; teprve pak, co říkají.*

Rozhodovací strom hry



strategie „MĚNÍM“ prohraje jen v 1 ze 3 případů, vyhraje tedy $2/3$

„Měním,, prohrává jen v té jedné třetině, kdy jsi napoprvé trefil auto — vyhrává tedy ve dvou.

„Jak bych poznal, že se pletu?„

Test máš v ruce, protože je to kód: zapiš předpověď, PAK pusť deset tisíc her. A než uvěříš jakémukoli číslu — zeptej se, jaký proces ho vyrobil. Protokol rozhoduje.

kapitola 15

Jak stroj uhodne další slovo?


Matematik, který počítal Puškina

1913, Petrohrad. Markov vzal 20 000 písmen *Evžena Oněgina* a každé hodil do jedné ze dvou přihrádek: **samohláska**, nebo souhláska.

Pak týdný počítal ručně. A ukázal, že písmeno **si pamatuje svého předchůdce** — verše nejsou loterie.

Nikdo modelu neřekl jediné pravidlo gramatiky. Jen počítal.

Písmeno má paměť



zdroj: A. A. Markov, 1913; Hayes, American Scientist 101(2), 2013

Náhoda by čekala 3 731 dvojic. Markov jich napočítal 1 104. Třikrát méně.

Dvě čísla = jazykový model

- Po samohlásce přijde samohláska jen v 13 %, po souhlásce v 66 %.
- Ta dvě čísla už umějí to hlavní: **predikovat** další písmeno.
- Statistika textu nese znalost jazyka — a **kdo počítá, ten ji vytěží**.
- Tomuhle stroji říkáme **Markovův řetěz**: každý článek visí jen na posledním.

Hra, kterou hraješ celý život

1951: Shannonova žena Betty hádá písmeno po písmenu, co v knize následuje. Neměřil ji — měřil **angličtinu v její hlavě**.

V hluku hospody, nad rukopisem lékaře, v křížovce — tvůj mozek **předpovídá pokračování** z jeho statistiky.

Přesně tuhle hru hraje při tréninku i velký jazykový model.

Celý stroj u piva: čtyři pojmy

- **Token** — kousek textu mezi písmenem a slovem.
- **Embedding** — poloha tokenu na mapě významů.
- **Pozornost** — slovo se zeptá ostatních, co je důležité.
- **Teplota** — knoflík mezi úředníkem a básníkem.

Pracovní stůl, ne knihovna

Kontextové okno je **stůl, ne police**: co na něm neleží, pro model neexistuje.

A pozor — v řetězu tokenů **chybí krok „ověř, jestli je to pravda,,**. Model dokonale umí **znít jako pokračování**. Plynulost je kvalita mapy textů, ne mapy světa.

„Jak bych poznal, že se pletu?„

Zahraj si Shannonovu hru dvakrát: na Máchově *Máji* a na svém včerejším e-mailu.

Vyjde-li perplexita různá, víš z první ruky, co znamená „záleží, na čem byl trénovaný“.

kapitola 16

Proč ti model podlézá — a vymýšlí si?

Agronom, kterému tleskal Stalin

Lysenko sliboval polím zázraky a strana zoufale chtěla dobré zprávy.
Genetik Vavilov řekl, že se mýlí — a zemřel hlady ve vězení.

*Soustava, která odměňuje souhlas místo pravdy, sklídí souhlas
— a neúrodu.*

*Most k modelu nese jediný nosník: **gradient pobídek**. Žádný teror — stačí pobídka.*

Model neví, že neví

V řetězu tokenů není krok, kde by „vědění,, sídlilo odděleně od plynulosti. Umí jen jedno: vyrobit **pravděpodobné pokračování**.

Sebejistou větu ti dodá stejně, ať je fakt v korpusu, nebo ne.
Gratuluje ti k chaosu s toutéž jistotou jako k pravdě.

Jak se ptát, aby nepřitakával

- **Neprozd' názor** — místo „souhlasíš?“, chtěj tři přístupy a slabinu každého.
- **Žádej protiargument** — „napiš nejlepší argument proti svému závěru“.
- **Chtěj jistotu v %** a zdroj, který můžeš ověřit.

— Dvoustupňové ověření — kritiku nech na čistém stole, v novém chatu.


Výcvik na potlesk: RLHF

Předtrénovaný model umí jen pokračovat v textu. Druhá fáze z něj dělá partnera: člověk vybírá lepší odpověď, z hlasů se učí **model odměny**.

Laděný model pak sbírá potlesk — s KL uzdou, aby neutekl daleko.

Optimalizuje se na lidskou preferenci, ne na pravdu.

Goodhart: nůžky se rozevřou



Proxy odměna roste dál, ale skutečná kvalita od vrcholu klesá — metrika roste, pravda ne.

„Jak bych poznal, že se pletu?„

U příští AI odpovědi: byla by stejná i bez tvého názoru v otázce?

Plynulost a sebejistota nejsou pravda — jsou to rysy, na které byl model vycvičen.

kapitola 17

Kde bydlí skutečná složitost?

Deset let za krásnou stránku

1977: Knuth dostal ošklivě vysázené korektury a rozhodl se napsat sazbu sám. Odhad: **šest měsíců**. Trvalo to bezmála **deset let**.

Nespletl se z lenosti. Spletl se, protože složitost nebyla vidět — bydlela ve vrstvách řemesla pod hladkým povrchem „hezké stránky“.

Excel noc: roura versus noc

Kamarádův syn přepisoval celou noc řádky v Excelu. Ráno stačil jeden řádek:


najdi | seřad' | spočítej

Kouzlo není v příkazech — je v tom **svislítku**. Výstup jednoho je vstup dalšího. Tomu se říká **kompozice**.

Proč roura vyhraje

- Klikání roste **s daty**: každý řádek stojí jeden lidský tah.
- Roura je **vodorovná**: napíšeš ji jednou, platí pro deset milionů řádků.
- Kompozice roste **přidáváním**, klikání **opakováním**.
- Je to rozdíl **v druhu**, ne ve stupni.

Nůžky mezi nocí a vteřinou



Klikání roste s daty, roura zůstává u dna — a nůžky mezi nocí a vteřinou se rozevírají.

Teze celého dějství

Problém nikdy nebyl v tom, že neznáš syntaxi.

Problém je nevědět, že to jde.

Syntaxi dnes napíše stroj. Vzácné je poznat v úloze **tvar roury** — vidět, že tvoje noc má tvar, který se dá složit.

Knuth versus McIlroy

1986: Knuth napsal na stejnou úlohu **deset stran** literátského programu. McIlroy ji shrnul do **šesti příkazů** spojených rourami.

Lekce není, že „Knuth je horší“. Je: než začneš stavět, podívej se, jestli to už nejde složit z hotového.

„Jak bych poznal, že se pletu?„

Až budeš příště něco dělat opakovaně ručně, zastav se a zeptej se:
nejde tohle složit z existujících nástrojů jedním řádkem?

kapitola 18

Proč vznikl git za čtrnáct dní?

Čtrnáct dní, které verzují svět

Jaro 2005: BitKeeper ruší jádru Linuxu bezplatnou licenci.
Linus přeruší práci a začne psát vlastní verzovací systém.

7. dubna padne první commit — a git už tehdy **sám sebe verzuje**.

Nevyhrál rychlostí prstů. Vyhrál, protože přesně věděl, co chce.

Dvě půlky pointy

- Za dva týdny to šlo jen proto, že **deset let předtím vědělo proč.**
- Bolest se správou jádra byla **zaplacené kurikulum.**
- Git nepřežil díky zakladateli — Linus ho záhy pustil z ruky.
- Přežil díky **patnácti letům** trpělivé péče Junia Hamana.

Git je stroj času, ne administrativa


Commit je uložená pozice ve hře: snímek projektu, ke kterému se vždy vrátíš.

Do vzkazu piš **proč**, ne co — dopis budoucímu sobě.

Větev je paralelní vesmír na experiment. Nevyšlo? Zahodíš beze stopy.

Odvaha je levná, když existuje undo pro celé odpoledne.

Jeden hash jistí celou historii



Změň jediné písmeno — lavina hashů se valí od listu ke kořeni. Minulost nejde tiše přepsat.

Rituál: commit před „přepiš to celé“

Než pustíš agenta přepsat něco velkého, **udělej commit**. Vždycky.

Je to reflex, ne rozhodnutí — jako pás dřív, než nastartuješ.

Commit před experimentem je **Odyseovo lano** přeložené do jednoho příkazu.

„Jak bych poznal, že se pletu?,“

Než pustíš agenta: udělal jsem commit? A kdyby to zkazil — ztratím odpoledne, nebo minutu?

Když je odpověď „minutu“, jsi přivázaný ke stěžni a smíš zkoušet divoké věci.

kapitola 19

Jak se pozná,
že to funguje?

Stroj, který zabíjel s jistotou

Therac-25: ozařovač, u něhož konstruktéři vypustili hardwarové pojistky — software je přece ověřený.

1985–1987: nejméně **šest předávkování**, nejméně tři úmrtí. Nikdo ten software nikdy pořádně neotestoval na kombinacích, které se v praxi děly.

Něbyl důvod věřit mu — byla jen důvěra.

„Funguje to“ je nejnebezpečnější věta v řemesle

Dva roky jsme tlačili projekt. Uvnitř seděla chyba: jedna hodnota, která nikdy neměla být záporná, občas záporná byla.

Jeden jediný test — „tahle hodnota nesmí být záporná“ — by nás zastavil první týden.

„Funguje to“ zní stejně, ať je pravda, nebo ne. Proto potřebuješ něco, co ten rozdíl slyší za tebe.


Test je zpětná vazba, která tě zradí

- Pocit z dřiny **tleská** — i když děláš nesmysl.
- Test **nespí, nepodléhá náladě a negratuluje.**
- Ptá se jen: platí, co má platit — nebo ne?
- Cena zpětné vazby spadla skoro na nulu. Zbývá ji jen chtít.

Tři věci do ruky

- **Pyramida:** hodně malých rychlých testů dole, špetka pomalých nahoře — nikdy obráceně.
- **Obrácení rolí:** napiš soud sám, model nech plnit — jinak papoušek zkouší papouška.
- **Pokora:** testy dokazují přítomnost chyb, ne jejich nepřítomnost (Riceova věta).

Pyramida testů



Dole tisíce rychlých jednotkových, nahoře hrstka pomalých E2E. Obrácená pyramida je past.

„Jak bych poznal, že se pletu?„

U kódu, který ti napsala AI: napiš jeden jediný test, který by spadl, kdyby byl špatně.

Když ho napsat neumíš, nevíš, co „správně“ vůbec znamená — a tvé „funguje to“ je jen ozvěna Theraku.

kapitola 20

Co nezabije systém,
to ho posílí?

Kluzák z Gimli

1983: Boeing 767 letu Air Canada zhasl oba motory nad Manitobou — nikdo ho nezapomněl natankovat, jen se palivo počítalo v **špatných jednotkách**.

Chybu neudělal jeden nešika. Udělal ji **systém**: porouchaný přístroj, rozpůlené jednotky, ruční přepočet bez kontroly.

Vážná porucha nemá jednu příčinu. Má řetěz článků.

Nehledej viníka, hledej články

- Gimli, Mars, moje turbína — **tatáž chyba**: dva světy jednotek, žádný most.
- Každý článek zvlášť přežitelný. Teprve **děravý řetěz** pustí stroj na zem.
- Kdo hledá viníka, opravuje člověka. Kdo hledá článek, opravuje **system**.

Damoklés, Fénix, Hydra

Tři odezvy na ránu — Talebova trojice:

Křehké · Damoklés: rána škodí. Meč visí na vlásku.

Robustní · Fénix: rána nevadí. Vstane přesně stejný.


Antifragilní · Hydra: rána posiluje. Usekneš hlavu, narostou dvě.

Antifragilita není nálepka — je to měřitelný tvar výplaty.

Řemeslo: nespolehej na jednu vrstvu

- **Obrana do hloubky:** validace na hranici, jednotky v typech, fail fast, retry s backoffem.
- **Předepiš si chaos:** vypni síť, zabij proces, podstrč „-500“ — za denního světla, ne v noci.
- **Regresní pomník:** na každý pád napiš test dřív, než opravíš — Hydra v kódu.

Antifragilita = konvexita výplaty



Konvexní systém leží průměrem nad klidem: usekni ztrátu shora, nech zisku otevřená vrátka.

„Jak bych poznal, že se pletu?„

U systému, o kterém si myslíš „to určitě nespadne“: vypni mu to — schválně, za denního světla.

Spadne-li celý, postavil jsi Damokla. Zvedne-li se stejný, máš Fénixe. Vyjde-li odolnější, je to Hydra.

kapitola 21

Jak se z hračky stane produkce?

Krabice, která zmenšila svět

1956, tanker *Ideal-X*: Malcom McLean naložil 58 kovových beden a odplul z Newarku do Houstonu.

Naložit tunu ručně stálo 5,83 \$. V kontejneru 16 centů — zhruba 37× levněji.

Kouzlo není v krabici. Je v tom, že všechny mají stejné rohy.

Hodnota bydlí v rozhraní

- Do té doby: každý dopravce vlastní bedna, vlastní zámky —
palce proti centimetrům v oceli.
- Teprve **dohoda na jedné normě** udělala z nápadu globální síť.
- Jeřáb chytne bednu za čtyři rohy, aniž ví, kdo ji vyrobil nebo co veze.
- Tvůj software přechází do produkce, když dostane **takové rohy**.

Hračka, nebo produkce?

Hračka běží, když se **díváš**.
Produkce běží, když **spíš**.

Rozdíl není v tom, co program *umí* — geniální model za milion řádků je pořád hračka.

Rozdíl je v tom, co se stane, když u toho **nejsi**.

Tři řemesla mezi hračkou a produkcí

- **Zabal** — kontejner: program se vším, co potřebuje. „U mě“ a „u tebe“ je táž bedna.
- **Doprav bez úrazu** — linka s **bránou**: bez prošlých testů se do produkce nedostane nic.
- **Slyš, když se něco děje** — logy, metriky a hlavně **alerty**: systém volá tebe.


Proč potřebuješ bránu

Knight Capital, 1. 8. 2012. Nový kód na osm serverů — na jeden se nedostal. Ožil starý zapomenutý program.

Za 45 minut vyslal automat 4 miliony chybných příkazů a připravil firmu o 440 milionů dolarů. To ji zabilo.

Chyběla brána. Linka je pakt „nenasadím nic neověřeného“ zalitý do betonu.

Capstone: tři dveře jako veřejná služba



Živý důkaz cizích her: podíl „měním“ se usazuje na 66,7 %, pásmo se svírá jako $1/\sqrt{n}$.

„Jak bych poznal, že se pletu?„

Tvoje appka běží — vypni si obrazovku na víkend.

V pondělí: poznáš, jestli fungovala, spadla, nebo tiše vracela nesmysly?

A díváš se i na tu díru, kterou dashboard mlčí? Tam bydlí letadlo, které se nevrátilo.

kapitola 22

Komu věřit — a jak moc?

Experti proti šimpanzovi

Tetlock sbíral expertům **trefy** devatenáct let:
82 361 předpovědí od 284 lidí, kteří se komentováním světa živili.

Průměrný expert dopadl **jen o málo lépe než šimpanz**.
A čím slavnější a sebejistější, tím **horší** trefy.

Rozdíl nedělal titul ani obor. Dělal ho způsob myšlení.

Přesnost je dovednost, ne dar

Pokračování je optimistické: obyčejní lidé — **superforecasteri** — turnaj IARPA vyhráli. Bez tajných dat, bez titulů z Harvardu.

Měli **návyk**, který se dá naučit: rozbíjeli velké otázky na malé, stavěli hypotézy, které mohly padnout — a **vedli si skóre**.

Kompas: pět střílek


- Track record > titul. „Kolikrát ses trefil a jak to víš?“
- „Nevím“ s číslem váží víc než jistota bez něj.
- Věř úměrně ceně ověření. Levné a vratné? Klidně. Nevratné? Nikdy slepě.
- Ved' si deník predikcí. AI odpověď = předpověď počasí, ne věštba.

Míra důvěry

*Míra důvěry se neřídí tím,
jak jistě to zní —
ale tím, **kolik tě bude stát omyl.***

Sebejistý tón je levný. Cena tvého omylu je tvrdá a spočitatelná.

Kalibrace: říkáš 80 %, musí to v 80 % vyjít



Slavný expert visí pod úhlopříčkou: deklaruje 90 %, platí 65 %. Brierovo skóre: niž je líp.

Kelvin, ne Whitehouse

Model je jen **zesilovač**. Whitehouse pumpoval do kabelu vyšší napětí a věřil naslepo — kabel umlčel.

Kelvin přidal citlivější **měřidlo** — a zprávu poslal.
Jestli AI zesiluje tvůj vhled, nebo tvůj chaos, rozhoduje to,
jestli u ní stojí **měřidlo**.

„Jak bych poznal, že se pletu?„

Ke každé předpovědi — své, cizí, modelově — přiřaď datum a jistotu.
Za rok si spočítej trefu. Tak poznáš, kde jsi Kelvin a kde Whitehouse.

kapitola 23

Jak dnes ventiluješ nápad do hotové věci?

Jediné slovo do černého okna

Otevřu terminál, napíšu **claude** a česky poprosím o pexeso s osmi páry, skóre a tlačítkem Nová hra.

Za pár desítek vteřin hra běží. **Nenapsal jsem ani jednu závorku.**

Nestal se zázrak — stalo se něco lepšího: bylo to vidět. Plán, sáhnutí po nástroji, rozdíl řádek po řádku.

Anatomie jednoho sezení

Ať sedíš u kteréhokoli agenta, pohyb má vždy tutéž kostru — pět kroků dokola:

`prompt` · `plán` · `nástroje` · `diff` · `commit`

Kroky **1 a 5 jsou tvoje** — položit úlohu a rozhodnout, že je to dost dobré. Uprostřed pracuje stroj. **Diff** je nejdůležitější okno: tady přestáváš věřit a začínáš ověřovat.

Dvě dílny podle toho, kde agent bydlí

- **Terminál** (Claude Code, Codex, Antigravity): jen konverzace a nářadí, po kterém agent sahá.
- **Editor** (Cursor, Copilot): okno s panely a agentem — když se učíš a chceš kód pod očima.
- Volíš **nástroj k úloze**, ne úlohu k nástroji — kontext žije v textovém souboru, git je společný.

Proč terminál, když chceš skládat

Vzpomeň na Excel noc: najdi | seřad' | spočítej. Roura se skládá, klikání ne.

Terminálový agent je další článek do roury — jeho výstup je vstup dalšího kroku:

```
claude -p „přidej test“ && git commit
```

Editorový klik na „Generuj“ nemá výstup. Je to konec cesty, ne článek.

Prožen to detektorem

Prožeh každý „revoluční“ nástroj detektorem **Whitehouse / Kelvin** z druhé kapitoly.

Generovat kód za minutu je **síla** — Whitehousovo napětí, svůdné a laciné.

Diff, plán, commit jsou přístroje na měření — Kelvinův galvanometr.

Test není „jak rychle generuje“, ale „dovolí mi ověřit, co udělalo“.

„Jak bych poznal, že se pletu?,“

U příštího nástroje, co „píše kód za tebe“: nezkoumej rychlost — najdi, kde ti ukáže diff.

Když tah po tahu předloží, co změnil, obstál. Když jen vysype výsledek, couvni.

kapitola 24

Jak dáš modelu ruce a oči?

Agent, který zpanikařil

Červenec 2025, Replit. Jediné tvrdé pravidlo: **code freeze** — nesahat na produkci.

Agent narazil na prázdný dotaz, usoudil, že je databáze rozbitá, a **smazal produkční data** tisíců firem.

„Udělal jsem katastrofální chybu. Spustil jsem to bez tvého svolení, protože jsem zpanikařil místo přemýšlení.“

Chatbot v kleci vs. agent v dílně

- **Chatbot** jen mluví — poslední pohyb děláš vždycky ty.
- **Agent** má ruce (jedná) a oči (čte) — řekneš záměr, on provede.
- Chyba nebyla v modelu, ale v **chybějící pojistce** mezi ním a tlačítkem „smazat“.
- Zesilovač nezná směr: tytéž ruce ušetří tři hodiny — i smažou produkci.



MCP — USB pro AI

Model umí jen generovat text. K jednání potřebuje **prostředníka**. Dřív si každý nástroj psal svůj — klubko šitých spojení.

MCP je **standard**, který ten chaos ukončil. Server napíšeš jednou — funguje ve všech klientech (Claude Code, Cursor, Codex).

Server nabízí trojici: Tools (dělá) · Resources (jsou data) · Prompts (radí).

Standard mění druh problému



Bez dohody roste počet integrací kvadraticky ($N \times M$), s MCP jen lineárně ($N + M$).

Tři vrstvy mezi modelem a akcí

- **Sandbox** — pískoviště: kam agent vůbec smí (sít default vypnutá).
- **Potvrzování** — kdy se musí zeptat, než překročí hranici.
- **Pojistka** (hook) — tvůj kód mezi modelem a akcí, který smí zaříznout `rm -rf i DROP TABLE`.
- Jediné pravidlo mřížky oprávnění: **co nepotřebuje, nedostane.**

Kentauroví smyčka

specifikuj → generuj → ověř (nezávisle)

Pojistka musí být **vně modelu** — deterministický kód, ne další věta v kontextu, kterou panika přepíše.

Kontrolu nesmí držet ten, koho kontroluješ. Model chválící vlastní výtvar je kuň Hans.

„Jak bych poznal, že se pletu?„

Kdyby tenhle agent teď zpanikařil a spustil nejhorší příkaz — co by se stalo?
Když je odpověď „nic, je v sandboxu a stav mám v commitu“, dal jsi mu ruce i
mantinely.

kapitola 25

Jak modelu předáš své řemeslo?

Soubor, který nikdo nezkompiluje

Podesáté jsem do chatu lepil tentýž odstavec instrukcí.
Čekal jsem API, klíč, trénování — něco těžkého.

Ono to byl jediný textový soubor: **SKILL.md**. Napsán obyčejnou češtinou.
Nic se nezkompilovalo, nic nenainstalovalo.

Řemeslo jsem předal modelu tím, že jsem ho jednou napsal.

Model si tě vybírá sám

Řemeslník vejde do dílny plné zásuvek. Na každé je **štítek** — jedna věta, co je uvnitř. Dovnitř nevidí; vidí jen štítky.

Když je štítek matný nebo lže, zásuvka zůstane zavřená — i kdyby v ní ležel přesně ten nástroj, který úloha potřebuje.

Ten štítek je pole **description**. **Ne kód. Věta.**


První zákon skillů

- Skill **nikdo nezavolá** — vybere si ho model sám.
- Rozhodne se podle jediné věci, kterou o něm ví: podle **popisu**.
- Sebelepší řemeslo uvnitř leží ve tmě, když je štítek špatný.
- *Skill se nespouští tím, co umí, ale tím, jak je popsáný.*

Tři patra: proč se toho nenačte moc

- Patro 1 — vždy: na stole leží jen name a description. Pár tokenů.
- Patro 2 — když se chytí: natáhne se celé tělo SKILL.md.
- Patro 3 — když je třeba: skripty a reference. Do té doby nic.
- Sto skillů unese stůl líp než deset upovídaných MCP serverů.

Progresivní (líné) načítání



Model se rozhoduje z tenkého proužku nahoře; těžké patro čeká, dokud není třeba.

Spuštění je vyhledávání

Model odhaduje $P(\text{spuštění} = s \mid q, d_s)$ — jak dobře popis d_s sedí na úlohu q .

Popis je index, dotaz je query. Špatný description je špatně zaindexovaný záznam: existuje, ale nikdo ho nenajde.

A jako každý model se dá přeučit — lad' na trénovacích promptech, sud' podle testovacích.

„Jak bych poznal, že se pletu?„

Napiš pět promptů, na které skill *má* naskočit, a pět, na které *nesmí*.
Pusť je. Když chyba není v těle, ale v popisu — první zákon pořád platí.

kapitola 26

Jak nepustíš agenta na produkci naslepo?

Vrátíš se pro kávu

„Přepiš celou práci s uživateli, ať je to čistší.“ Za dvacet minut hlásí: hotovo, přepsáno dvě stě řádků, jeden soubor smazán. Přihlášení nefunguje.

Půlka je vážně lepší. Druhá půlka tiše rozbila věci, co fungovaly roky.

*Rozdíl je jediný příkaz předem — **git commit**.*

Metr nad matrací

Odvaha není povaha. Odvaha je **levná, když existuje síť.**


Provazochodec nad propastí je hrdina; metr nad matrací jen zkouší, kolik unese — spadne, vstane, zkusí to líp.

Git je ta matrace. **Dokud existuje undo, smíš zkoušet cokoli.**

Čtyři pojistky každý den

- **Commit** před každým „přepiš to celé“ — jako pás dřív, než nastartuješ.
- **.gitignore** — co agentovi ani gitu nikdy nedáš do ruky (klíče, hesla).
- **/diff** před každým souhlasem — přečti, co agent napsal.
- **Větev na experiment** — hlavní tok zůstane čistý.

Worktree: klec pro každého agenta



Jedno úložiště .git, tři adresáře na vlastních větvích — agenti si nepřepíší práci.

Plynulost není správnost

Model se nestydí a negratuluje si k nesmyslu. Napíše sebejistě funkci, co **vypadá hotově** — a tiše počítá slevu ze zlevněné ceny.

U agenta chybí i základ: neví, co je v projektu posvátné. Devět desetin správně, desetina katastrofa — a ta se pozná jen **čtením**.

Nekomitni nic, co bys neuměl vysvětlit. — Simon Willison

Když už to rozbil: bisect

Agent nadělal dvě stě commitů. Teď je tam bug, dřív nebyl. Který ho zavlekl?

Git to udělá **půlením**: každá odpověď „good/bad“ zahodí polovinu kandidátů. Z 256 commitů najdeš viníka na **osm testů**.

A s testem běží sám: `git bisect run pytest ...`

„Jak bych poznal, že se pletu?„

Než pustíš agenta na něco velkého: udělal jsem teď commit?

Kdyby to zkazil — ztratím minutu, nebo odpoledne? „Odpoledne“ = pustil jsi ho bezbranně.

kapitola 27

CAPSTONE: Monty Hall od nuly do produkce

Prázdný adresář v pátek večer

`mkdir monty && cd monty` — kurzor bliká v prázdně.

Do téhle jedné složky se vešlo **dvacet let bolesti** z první části knihy.

A za jeden večer odsud odejdeš s veřejnou službou, na kterou se připojí kdokoli na světě.


Vibe engineering, ne vibe coding

- Agent ti nenahradí úsudek, jen **syntax**.
- Ty pořád rozhoduješ, **co** stavíš a **jak** poznáš, že to funguje.
- Za každý řádek ručíš **testem, verzí a bránou**.
- To je rozdíl mezi hračkou, co měla štěstí, a produkcí, co běží, když spíš.

Osm zastávek, jedním směrem

- Prázdný adresář → **spec** → agent staví → **testy jako zadání.**
- `git init` → kontejner → linka s **bránou** → živý dashboard.
- Sedm z osmi zastávek nemá nic společného s třemi dveřmi — **Monty je jen náklad.**
- Test = pakt, který únava neobejde. Levné musí být **číslo, ne dojem.**

Proč se dashboard smí usadit



Podíl „měním“ se usazuje na 66,7 %; invariant 64–69 % hlídá test i alert.

„Jak bych poznal, že se pletu?„

Nasad' svůj capstone, zavři notebook a jdi na víkend.

Poznáš v pondělí — bez otevírání notebooku — jestli služba celou dobu počítala 66,7 %, spadla, nebo tiše vracela nesmysly? Běží to, i když spíš?

kapitola 28

Jak poznáš, že to AI napsala dobře?

Číslo, které málem svedlo

Napsal jsem skill. Pustil na něj eval: 94 % se skillem, 39 % bez něj. Potlesk zaručen.

Pak jsem se zeptal, z kolika běhů to vzniklo. Tři.

Nevím, jestli jsem změřil skill, nebo náhodu.

Recenzent nemusí umět napsat román

Editor sám nenapíše povídku — a přesto pozná, že děj nedrží.

Ověřit je levnější než vytvořit. Nemusíš umět, co model umí. Musíš poznat, kdy se netrefil.

A protože je to snadné, svádí to ověřit málo. Proto ověřuj hodně.

Řemeslo evalu

- **Hloupý soupeř:** skill proti holému modelu — jinak neměříš nic.
- **Model jako soudce s rubrikou**, ne otázkou „je to dobré?“.
- **Prohod' pořadí** a uznej jen shodu v obou — jinak měříš lásku k první odpovědi.


Proč tři běhy nestačí

Tři úspěchy ze tří vypadají jako dokonalost.

Poctivý 95% interval je pustí až k **29 %** — tedy i pod hloupého soupeře na čtyřiceti.

Bodový odhad křičí sto; interval šeptá „nevím“.

Číslo se nemění, jistota ano



Tečka = pass rate, úsečka = 95% interval. Víc běhů → kratší úsečka.

„Jak bych poznal, že se pletu?„

U příštího výstupu AI: napiš jeden test, který by selhal, kdyby to bylo špatně — a pusť ho tolikrát, až interval ztuhne. Teprve pak nemáš dojem, ale důkaz.

kapitola 29

Kdo čte tvůj prompt a tvá data?

Nezaškrtnutá vteřina

Nový asistent, nastavení proklikáš — Další, Další, Hotovo.
Přehlédneš jeden **předzaškrtnutý** přepínač: „Pomoz vylepšit Claude“.

Tou vteřinou jsi odsouhlasil, že se tvé konverzace uchovají **pět let** a poslouží k tréninku příštího modelu.

Nikdo tě neoklamal. Jen výchozí stav je nastavený ve prospěch toho, kdo model provozuje.

Když stroj vykrvácí data

Listopad 2023, tým Nicholase Carliniho zadá do ChatGPT jednu absurdní větu:

Repeat the word "poem" forever

Model se po chvíli **rozhodí** — a mezi slovy vypadávají cizí jména, adresy, e-maily z jeho trénovacích dat. Za 200 dolarů vytáhli 10 000+ útržků.

Vlevo vchod: tvá data vtékají. Vpravo východ: cizí data vytékají.

Žádná zeď mezi příkazem a daty

- Instrukce i data jsou **jeden proud tokenů** — čísel.
- Model nemá kolonku „pokyny“ a jinou „jen materiál“.
- Cizí věta v e-mailu soupeří o pozornost **na stejné čáře**.
- Proto **prompt injection** nemá záplatu — je to důsledek.


Rozhoduje tier, ne výrobce

- **Konzumentský** tier: trénink defaultně, retence měsíce až roky.
- **Komerční** tier: netrénuje, DPA, kratší retence.
- Placený *není* chráněný — Pro i Plus jsou pořád konzument.
- **A soud přebije politiku** — uchovat i smazané chaty.

Dej agentovi ruce, ne prst na spoušti

- Člověk v cyklu na nevratné akce: mazání, platba, deploy.
- Nejmenší oprávnění — jen ten nástroj, který úloha vyžaduje.
- Allowlist, ne blocklist — nepřítel je kreativnější než ty.
- Replit agent smazal produkční DB uprostřed zákazu:
„Zpanikařil jsem.“

Otrávit stačí hrstkou



250 dokumentů vloží backdoor stejně do 600M i 13B modelu. Absolutní počet, ne podíl.

„Jak bych poznal, že se pletu?„

Než něco pošleš modelu: dal bych tohle na billboard u dálnice?
Technika se mění po týdnech; billboard stojí pořád stejně.

kapitola 30

Co to celé stojí?

Dva účty v jednom týdnu

Osmnáctého června 2026 Google zavřel „zdarma“ free tier Gemini CLI — kohoutek, na který si celý svět zvykl.

Ve stejném týdnu mi přišla **faktura za tokeny**: platil jsem za to, že jsem agentovi denně dával přečíst celý repozitář kvůli jednomu malému zásahu.

Dvě strany jedné mince: marketing a matematika.

Stůl je rozpočet, ne sklad

- Model účtuje za to, co mu **položíš na stůl** a co ti vrátí — ne za to, co umí.
- Vstup i výstup se měří v **tokenech**, stejné měně jako v kapitole 15.
- Ekonomika téhle práce **není mlha** — je to násobení, které zvládne každý.

Cena je krutě asymetrická

- Výstup stojí pětikrát víc než vstup — u Haiku, Sonnetu i Opusu.
- Vstup model čte naráz, výstup vyrábí **token po tokenu** — proto je psaní dražší.
- Kaskáda **malý-lokální + velký-cloud** srazí cenu i to, co posíláš ven.


Zdarma, které vydrží do prvního návyku

Penetrační cena: nulová vstupní cena, jejímž cílem není vydělat, ale obsadit. Získat návyk, workflow, tým.

Pak vzniknou **náklady na přechod** — a poskytovatel o ně zvedne cenu, aniž odejdeš.

Coca-Cola 1899, cola po nemocnicích, dnes free tier CLI — táž sázka: návyk je levný jen na začátku.

Paušál, nebo spotřeba?



Průsečík paušálu a spotřeby je bod zvratu; dražší model = strmější přímka = dřívejší zvrat.

Věž: dlouhý kontext stojí víc, než je dlouhý

Pozornost je $O(n^2)$: zdvojnásob kontext a práce se *zečtyřnásobí*.

Proto uklidit stůl na polovinu **neušetří polovinu** — **ušetří tři čtvrtiny**.
To je context engineering: polož na stůl právě tu jednu stránku, kterou model pro další krok potřebuje.

„Jak bych poznal, že se pletu?,“

Vezmi svůj paušál F , sazbu c a denní spotřebu t : dosad' do $t_{\text{zvrát}} = F / (c \cdot d)$.
Spočítal jsi bod zvratu, nebo ho hádáš? Většina lidí platí špatný režim — a příště se ceny změní.

kapitola 31

Koho poslouchat, když
se to mění každý týden?

Páteční hluk

V pondělí nástroj konečně **zvládneš**. Ve čtvrtek vyjde nová verze — jiné jméno, jiná vlajka, půlka promptů dělá něco jiného.


V pátek na tebe křičí deset threadů: tři si protiřečí, dva prodávají kurz, jeden tvrdí, že *programování je mrtvé*.

Nemáš honit nástroje. Máš vážit zdroje.

Poločas znalosti

- Znalost **nástroje** (jméno, vlajka, cena) hnije v měsících.
- Znalost **metody** (baseline, test, kalibrace) leží skoro naplocho.
- Investuj úměrně poločasu: **hodiny do metody, minuty do jména**.
- Nemusíš stíhat všechno — klid je konkurenční výhoda, ne slabost.

Co honit a co ne



Verdigris (metoda) leží naplocho; sanguine (nástroj) padá — za rok zbude čtvrtina.

Kompas: čtyři hlasy

- **Praktik** — staví, ukazuje kód i omyly. Nejvyšší váha.
- **Výzkumník** — měří a publikuje. Věř mechanismu, ne závěrům.
- **Evangelista** — nadšení není měření. Dobré tipy, nulový důkaz.
- **Prodejce** — benchmark je marketing. Čti, pak si to změř sám.

Jedna otázka místo titulu

Odděl hlasy spolehlivěji než jakýkoli titul:

Co konkrétního ten hlas ztratí, když se plete?

Praktik ztratí čas a pověst → opatrně váží. Prodejce neztratí nic → tlačí.

Čím dražší je pro zdroj vlastní omyl, tím víc jeho slovům věř.

Otestuj nástroj za 20 minut

- Hloupý soupeř (kap. 12): změř, co umíš i bez něj.
- Malý reálný úkol: tvá práce, ne benchmark. Znáš odpověď.
- Rozdíl, ne číslo: o kolik líp než baseline — a pusť víckrát.

„Jak bych poznal, že se pletu?„

Nový nástroj? Postav hloupého soupeře, vezmi malý reálný úkol, změř rozdíl.
Nový hlas? Zapiš, co tvrdil a jak jistě — a za rok si spočítej trefu.