

Kontroling danas i sutra

Neda Vitezić

*Ako je električna energija promijenila način proizvodnje,
digitalizacija mijenja poslovne procese, AI mijenja način
upravljanja*

KiM 2026 18.09.26.

Predviđanja znanstvenika o budućnosti AI

- „Do 2029. računala će dosegnuti i nadmašiti ljudsku inteligenciju.” (*Ray Kurzweil*)

Orijentacija kontrolera prema prosudbi i pouzdanoj interpretaciji

- „Najsigurniji su poslovi koji zahtijevaju maštu, kreativnost ili empatiju.” (*Kai-Fu Lee*)

AI može obraditi podatke, napraviti analizu... Kontroler mora osigurati razumijevanje.

- „AI ne evoluirá prema ljudskoj inteligenciji. Razvija jednu drugu, neljudsku vrstu inteligencije.” (*Yuval Noah Harari*)

Za kontrolera AI neće biti samo alat nego suradnja s drugačijom vrstom inteligencije



kontroler + AI alati → analitički tim budućnosti = AI kontroler

Ključna pitanja

- **ŠTO AI MOŽE I ŠTO ĆE MOĆI?**
→ Koje obrade podataka, analize, predikcije i preporuke može napraviti?
- **KOLIKA JE SIGURNOST, POUZDANOST ?**
→ Kontroler provjerava **pouzdanost podataka, izvora, modela, metodologije i rezultata**
- **KOLIKA JE AI ETIČNOST?**
→ pravednost, transparentnost, objašnjivost, dokazivost, odgovornost, privatnost, povjerljivost, integritet, autonomija AI, sukob interesa, manipulacija
- **KOLIKO DOZVOLITI AI DA SUDJELUJE U KREIRANJU ODLUKA ?**
→ odrediti **granicu autonomije AI-ja**: što može napraviti sam, što mora biti provjereno i što nikada ne smije samostalno odlučiti
- **O ČEMU KONTROLER ODLUČUJE?**
→ Kontroler donosi profesionalnu prosudbu: **prihvatiti, provjeriti, modificirati ili odbaciti AI rezultat** – podloga za poslovnu odluku.



AI REZULTAT → PROVJERA KONTROLERA → ODLUKA O KORIŠTENJU → ZAKLJUČCI I PRIJEDLOZI → POSLOVNA ODLUKA

- U kojem pravcu treba **educirati** kontrolera?
- Da li kontrol**E**r postaje kontrol**O**R AI informacija i preporuka?
- Da li treba razmišljati o načelu „**nezavisnosti**” i kod kontrolera?
- Da li je sazrijelo vrijeme da kontroler bude **profesija**?

*Ako AI analizira, predviđa, simulira i predlaže odluke,
najveća vrijednost kontrolera će biti da zna procijeniti
može li se AI preporukama vjerovati.*



Kritičko razmišljanje i profesionalna prosudba



Horizontalno i vertikalno znanje i vještine

KiM ZAKLJUČCI

Budućnost kontrolera nije u natjecanju s umjetnom inteligencijom, nego ga prihvatiti kao suradnika i težiti da postane stručnjak

- da zna postaviti pravo pitanje AI-ju,
- da zna procijeniti AI rezultate, rješenja i preporuke
- da zna kada AI vjerovati, kada ga provjeriti i kada odbaciti
- da zna temeljem toga savjetovati i komunicirati s menadžmentom i upravom kako bi zajednički donijeli kvalitetnu poslovnu odluku

Budući kontroler

Nije konkurencija AI-ju, nego njegov

kritički procjenitelj i strateški poslovni partner upravi
s nazivima

AI kontroler, Kontrolor kvalitete informacija, AI procesa i poslovnog odlučivanja.

AI poslovni analitičar=„hibridni stručnjak“

– osoba koja povezuje ekonomiju, tehnologiju, matematiku, statistiku, informatiku, podatkovnu znanost, pravo, etiku... i društveni i širi (okolišni, socijalni, etični, politički..) kontekst

Da li je onda kontroler odgovarajući naziv??

KiM PORUKA

**AI ima više informacija, izračunava brže i predviđa bolje,
no AI ne može preuzeti odgovornost za odluku.**

**Posljednju riječ mora imati čovjek koji razumije podatke,
poslovanje, tehnologiju i ima odgovornost**

To je kontroler budućnosti

Vidimo se na 3. KiM 17.rujna 2027.

From Intuition to Algorithm

and back to judgment

How AI is changing the way we run companies

A practitioner's view of what AI really changes in running a company. And what to decide about it. With numbers, not hype.

Who is talking

twenty years between technology, transactions and capital



Dejan Ljuština

Founder and Managing Partner, Vision Partners

General Partner, NVision Ventures

Electrical engineer. Harvard Business School and IEDC. Former Partner at PwC. Earlier Intel and Ericsson.



20+ years

Strategy, M&A and capital



**SE and Central
Europe**

Strategic transactions and capital
decisions



**Both sides of the
table**

Advises boards and invests in the
technology behind the change

VisionPartners»



Never more capital behind one technology

and little proof it pays yet

\$5.2T

Data-centre investment needed
for AI demand by 2030

McKinsey, Apr 2025 (forecast)

\$582B

Global corporate AI investment in
2025, more than double the year
before

Stanford AI Index 2026 (measured)

94%

of organisations plan to keep
investing in AI despite uncertain
short-term returns

BCG, 2026

What it means for you. When capital floods in, allocating it well becomes the scarce skill. That is the job of the people in this room.

The dirty secret of enterprise AI:

companies bought access, but almost nobody has learned to use it

69%

say their organisation has
done something on AI
agents

16%

actually use an agentic
tool at work

13%

have set up AI that acts
on its own

<10%

can correctly define an AI
agent

And executives are in the dark. 57% of the C-suite say AI is widely integrated in their workflows. Only 18% of the people doing the work agree.

And in Croatia? 15% of companies used AI in 2025, against 20% across the EU. Among large firms, 40% here and 55% in the EU.

Section, AI Proficiency Report, Jun 2026 (5,026 US employees, self-reported; separate questions, not a funnel). Eurostat, Dec 2025.

Adoption is not return

only a minority turns AI into profit, and they changed how they work

37%

of organisations see any EBIT impact from AI

McKinsey, State of AI 2026 (n=1,719)

6%

are high performers with 5%+ of EBIT from AI

McKinsey, State of AI 2026

20% vs 74%

already grow revenue with AI, against those who hope to

Deloitte, State of AI in the Enterprise 2026 (n=3,235)

What the 6% do differently. Nearly 3 in 4 fundamentally redesigned their workflows. Same tools, different organisation.

Anyone can buy AI. Few can absorb it.

why firms exist, and what AI just changed in that logic



Coase, 1937

A firm exists where coordinating inside is cheaper than buying outside.



What got cheap

Analysis, drafting and code.
Every competitor can buy them at the same time.



What stayed scarce

Absorbing it. Redesign, skills and data come first. Returns come later.

The key idea. AI collapsed the market price of expertise. Not the cost of absorbing it. That gap moves the firm's boundary, its decision rights and its shape.

Coase, Economica 1937. Cohen and Levinthal, ASQ 1990. Brynjolfsson, Rock and Syverson, AEJ: Macro 2021.

Four shifts in how we run the company

and one case we will follow through all four



1 Judgment

From processing information to governing judgment

Who decides, and who answers, when the machine proposes?



2 Capital

From coordinating people to allocating capital

What pays back when every rival has the same AI?



3 Boundaries

From owning everything to choosing what to own

What must we own? What can we access? What do we buy?



4 Shape

From managing the org chart to redesigning the organisation

Which incentives, roles and budgets must change?

Our running case. A regional distributor of industrial goods. 12,000 quotes a year, a 30% win rate. Illustrative, modelled figures.

Who decides when the machine proposes?

the first leadership job is writing the decision rights, not choosing the tool

1 AI acts alone

Quotes within price and volume limits, on standard terms. If it gets it wrong, the damage is small.

2 AI escalates

Orders above €50k, margin below the floor or unusual risk. The machine stops and asks.

3 A named person answers

One owner reviews exceptions and overrides every week. Everyone knows whose call it is.

The rule. The bigger the possible damage, the clearer the owner. Accountability does not transfer to the model.

Think of VAR. The camera sees more than the referee. The referee still makes the call, and still answers for it.

Illustrative case. Risk-tiered review principle from NBCUniversal, in Section's AI Strategy Playbook 2026.

Klarna learned this in public

leadership sets the line between human and machine, not the tool



2024. The AI assistant handled two-thirds of customer-service chats, the work of about 700 agents.

2025. The CEO said cost had been “a too predominant evaluation factor... what you end up having is lower quality.” A human is now always available.

Klarna, Feb 2024. Bloomberg, May 2025.

DELOITTE 2026

Firms whose senior leaders shape AI governance report significantly more business value than firms that leave it to technical teams.

EU AI ACT, ART. 26

Companies that deploy high-risk AI must give oversight to people with the competence, training and authority to do it (Art. 26).

What it means for you. The regulation arrives on a timetable. The accountability is already yours.

Which of your advantages survive?

re-underwrite them as if every rival had the same AI

↑	STRONGER	Proprietary data with rights	Gets stronger if it is scarce and hard to copy
↑	STRONGER	Trust and accountability	Gets stronger where someone must guarantee the outcome
→	SURVIVES	Customer relationship	Survives unless a platform gets between you
→	SURVIVES	Licences, assets, physical operations	Survive because the right to operate stays scarce
↓	ERODES	General expertise and routine speed	Erode because every rival buys them at the same time

Hands up. Which of these did your last budget assume was safe?

Our view. A framework, not a measurement.

Does it pay? Capacity is not cash.

one process, the whole calculation, nothing hidden (illustrative model)

ASSUMPTIONS

Quotes per year	12,000
Win rate	30% → 3,600
Average order	€4,000
Contribution margin	25% = €1,000
AI effect (modelled)	+2.5 pp → +300

NET EFFECT PER YEAR

Extra contribution	+€300k
Licences and governance	-€60k
Net per year	+€240k

BASE CASE

~17 months

€330k one-off (€150k build plus
€180k working capital) against
€240k a year

DOWNSIDE

~3.7 years

+1.0 pp gives €60k a year on a
€222k one-off

BREAK-EVEN

+0.5 pp

Win-rate uplift needed just to
cover running costs

Fix the workflow first. “AI is really, really good at blowing up a bad process.” Clean the quote flow, then automate it.

Capacity is not cash. Halving quoting effort counts only when you redeploy or remove it. Fund in tranches: Gartner expects over 40% of agentic AI projects to be cancelled by end-2027.

Working capital at 15% of incremental revenue. Gartner press release, 25 Jun 2025 (prediction). Full sensitivity in appendix A2. Quote: NBCUniversal, in Section's AI Strategy Playbook 2026.

Own the scarce. Access the ordinary.

the firm's boundary is moving, and owning alone is not enough



Build or buy when the asset is scarce, protected by rights and changes the outcome

The boundary is already moving

32% of firms dropped at least one software purchase because they built it themselves with AI coding tools.

McKinsey, State of AI 2026



Partner or license when everyone can get the capability

Access done well

Vivix, a Brazilian glassmaker, built a narrow “virtual engineer” on Siemens' platform. Issue-resolution time fell 85% and 6,000 manual hours a year were freed.

Siemens, 1 Jun 2026

SIEMENS



Sell or stop when the activity becomes a commodity

Owning is necessary, not sufficient

Thomson Reuters bought Casetext for about \$650M in 2023 to put AI on Westlaw. In 2026 Morningstar still cut its moat rating to narrow on AI risk.

Thomson Reuters, Aug 2023. Morningstar, Mar 2026.

Narrow beats broad. Broad assistants give small gains. Narrow tools built for one process move the P&L.

Narrow vs broad: Siemens, in Section's AI ROI Playbook 2026.

Big Tech is buying people, not companies

what the largest AI deals tell every acquirer in this room

Buyer and target	What was bought	Reported value	Year
 Microsoft ← Inflection	Licence plus founders and most staff	~\$650M	2024
 Google ← Character.AI	Licence, founders rejoin Google	~\$2.7B	2024
 Meta ← Scale AI	49% stake, CEO joins Meta	~\$14.3B	2025
 Google ← Windsurf	Licence and key hires, no stake	~\$2.4B	2025
 Nvidia ← Groq	Non-exclusive licence and leadership	~\$20B	2025



Before your next AI acquisition

1. Who are the ten people this depends on?
2. What rights do we get to the data?
3. How do we keep the team for three years?

Regulators now look through these structures: UK CMA reviewed Inflection as a merger; US senators asked the FTC and DOJ to investigate (Feb 2026).

What was worth billions. Not the legal entity. The team's ability to absorb the technology and ship it.

Values as reported by Reuters, Bloomberg and CNBC. Groq's release confirms the licence, not the value.

Knowing when not to buy

the distributor is offered an AI start-up for about €40M

	Build	Partner	Buy
Time to capability	12–18 months	3–6 months	6–9 months incl. integration
Cash	€0.3–0.5M	€0.2–0.5M a year	~€40M price
Data rights	Yours	Shared by contract	Only if the target owns them
Main risk	Execution	Dependency	Premium and integration

OUR ADVICE: PARTNER NOW

At about €40M, roughly 20× ARR, the target adds €0.3–1.0M of contribution a year. That is 40+ years to earn back the price. Its edge is a thin layer on shared models.

Revisit if the target secures proprietary data or exclusive access, if the price falls, or if integration becomes less risky.

Good advice includes no. And what would have to be true to say yes.

Illustrative, modelled figures. Full framework including exit in appendix.

Redesign starts with incentives, not tools

budgets, bonuses and metrics are where AI really gets adopted

AI-PROFICIENT SHARE OF THE WORKFORCE

2.8%



Oct 2025

5.5%



Jun 2026

Doubled in eight months. Still only 1 in 18.

Section, AI Proficiency Report, Jun 2026 (US)



Budget rule

Before adding headcount, show why AI can't do the work.

Shopify CEO memo, Apr 2025



Incentives

Only 7.7% of managers tie AI use to performance reviews. Reward outcomes, not activity.

Section, Jun 2026



Metrics

Track revenue per employee. Run AI spend like cloud spend, with a central budget and local use.

Section, AI ROI and Strategy Playbooks 2026

It stalls in the middle. 65% of managers set no AI expectations, or set them and hold no one to them.

SYNTHESIS

Everyone can now buy the same intelligence.

The advantage goes to those who absorb it and know what to own.

MONDAY MORNING

- 1 Write down the decision rights for one AI-assisted process.
- 2 Re-underwrite your top three advantages at the next board meeting.
- 3 Before any AI acquisition, price the team and the data rights. Then price the option to partner.

What will you decide to own?

Where these shifts become decisions

not every mandate starts as a deal

WHEN YOU FACE

The judgment question

WHO DECIDES AND HOW WE ORGANISE

The payback question

WHERE AI MOVES THE P&L

The partner-or-buy question

ACCESS OR OWN

The portfolio question

WHAT AI TURNS INTO A COMMODITY

WE DO

Strategy and board-level sparring on AI: decision rights, incentives and the eight-question board checklist

Operational performance: pick the two or three processes that matter, build the case, fund in tranches and track capacity until it is cash

Screening and structuring partnerships, licences and joint ventures, with data rights and exit terms. Buy-side M&A when buying is right

Carve-outs, sell-side processes and consolidation. Turnaround when a business is already under pressure

Our edge. One senior team that reads both the technology and the balance sheet. And we will tell you when not to buy.

Example: we supported Rimac on its Series D in June 2022 by bringing in SoftBank Vision Fund 2 to lead the round, which valued the group above €2B.

The machine will see more every year.
The whistle stays with you.

From intuition to algorithm. And back to judgment.

Appendix

Board checklist · Payback sensitivity · Build, partner, buy or exit · Profit migration · EU AI Act · How we work · Sources

Board checklist: eight questions

re-underwriting advantage in the age of AI

1

Which of our top three advantages survives if every rival has our AI?

2

Which data do we own, with what rights, and can rivals reproduce it?

3

Where could a platform get between us and our customer?

4

For each AI agent, what may it do alone, what escalates and who owns it?

5

Which savings are cash and which are capacity? Who redeploys the capacity?

6

Which AI projects are funded in tranches with a clear kill criterion?

7

For each capability, do we own, access or exit? What would change the answer?

8

In any acquisition, are we paying for a P&L, a team or rights? How do we keep them?

Payback sensitivity

distributor model, by win-rate uplift

Uplift	Extra orders	Contribution	Net per year	One-off	Payback
+0.5 pp (break-even)	60	€60k	€0k	€186k	never
+1.0 pp (downside)	120	€120k	€60k	€222k	~3.7 yrs
+1.5 pp	180	€180k	€120k	€258k	~2.2 yrs
+2.5 pp (base)	300	€300k	€240k	€330k	~17 mo
+3.0 pp	360	€360k	€300k	€366k	~15 mo

Assumptions. 12,000 quotes, €4,000 average order, 25% contribution, €60k running cost, €150k implementation, working capital 15% of incremental revenue. No discounting.

Build, partner, buy or exit

the full choice framework for the distributor (illustrative)


	Build	Partner	Buy	Exit
Time to capability	12–18 mo	3–6 mo	6–9 mo incl. integration	Immediate
Cash	€0.3–0.5M	€0.2–0.5M a year	~€40M price	Inflow
Data rights	Proprietary	Shared by contract	If the target holds them	Handed over
Dependency	Low	High on partner	Medium	n/a
Execution risk	High (internal team)	Low	High (integration)	Low
Works when	Data is proprietary	Contract and exit are good	Price is right and the moat is real	You know what you give up

Illustrative. Ranges are our judgment, not market data. The view that partnering gives most of the capability at a fraction of the cost is ours.


Where the distributor's margin can move

a scenario, not a forecast

TODAY



SCENARIO



A scenario, not a forecast. The margin on advice and speed is at risk. Logistics survives but earns less.

EU AI Act: what applies when

status September 2026. Not legal advice.

2 Feb 2025

Prohibited practices and AI literacy. The Omnibus softened literacy to a duty to support training.

2 Aug 2025

Obligations for general-purpose AI models, governance and penalties

2 Aug 2026

Transparency duties (Art. 50). Watermarking for systems already on the market by 2 Dec 2026.

2 Dec 2027

High-risk systems in Annex III, such as hiring and credit. Moved from Aug 2026 by the Digital Omnibus.

2 Aug 2028

High-risk AI embedded in regulated products (Annex I)

Regulation (EU) 2024/1689 as amended by Regulation (EU) 2026/1744 (Digital Omnibus), in force since 27 Jul 2026. Not legal advice.

How we work

senior judgment, regional depth, global standard



Originate

We see situations before they become auctions. Founders, family owners, corporates and funds across SE and Central Europe.



Execute

Senior people on every deal and the full cycle, from positioning and valuation to close and integration.



Edge

Engineers and investors on both sides of the table. We turn a technology shift into a capital decision and say when not to buy.

Why SE and Central Europe now. The region is becoming a real market for strategic and capital moves. It has credible companies, active regional funds and diaspora capital coming home. At the same time AI is forcing boundary decisions in traditional sectors. That calls for senior judgment and regional depth at a global standard.

dejan@visionpartners.io · visionpartners.io

Sources

every number in this talk, traceable

-
- McKinsey, “The cost of compute: a \$7 trillion race to scale data centers”, 28 Apr 2025
 - Stanford HAI, AI Index Report 2026, Economy chapter, Apr 2026
 - BCG, “The CFO’s AI Agenda: From Automation to Advantage”, 30 Apr 2026
 - FactSet Insight, “Hyperscalers tap external financing as AI capex outruns cash flow”, 23 Jul 2026 (Q&A)
 - Section, The AI Proficiency Report, Jun 2026 (n=5,026 US knowledge workers)
 - Eurostat, Use of AI in enterprises 2025, news release 11 Dec 2025 (isoc_eb_ai)
 - McKinsey, The State of AI in 2026, 25 Aug 2026 (n=1,719)
 - Deloitte AI Institute, State of AI in the Enterprise 2026 (n=3,235, fielded Aug to Sep 2025)
 - R. Coase, *Economica* 1937. Cohen and Levinthal, *ASQ* 1990. Brynjolfsson, Rock and Syverson, *AEJ: Macro* 2021
 - Section, The AI Strategy Playbook 2026 (NBCUniversal, Tech Mahindra). The AI ROI Playbook, Spring 2026
 - Klarna press release, Feb 2024. Bloomberg, 8 May 2025
 - Regulation (EU) 2024/1689 (AI Act), Art. 14 and 26. Regulation (EU) 2026/1744 (Digital Omnibus), OJ 24 Jul 2026
 - Gartner press release, 25 Jun 2025 (agentic AI project cancellations)
 - Siemens, Intelligence Center X release, 1 Jun 2026 (Vivix)
 - Thomson Reuters, Casetext completion, Aug 2023. Morningstar moat review, Mar 2026
 - Reuters, Bloomberg and CNBC deal reporting 2024 to 2025. Groq release, 24 Dec 2025. UK CMA, Sep 2024. US Senate letter, 4 Feb 2026
 - Shopify CEO memo, 7 Apr 2025. Rimac Group press release, 1 Jun 2022

Kontroling u doba AI-a

Od izvještavanja do strateške inteligencije

Vedran Antoljak, Best Advisory

Kontroling i menadžment 2026. · Ekonomski fakultet Rijeka · 18. rujna 2026.



Tko je u zadnjih dana koristio AI za nešto u kontrolingu ili financijama?

Tko zna koliko mu je to vremena uštedilo ili stvorilo nove vrijednost ?

Kontroling ne dobiva vrijednost od AI-a samo time što brže radi isti posao, nego time što stvara nove vrijednosti.

I.

Gdje smo stvarno

II.

Tri mjesta gdje uz AI
stvaramo novu vrijednost

III.


Tri preporuke za stvaranje
nove vrijednosti

I.

GDJE SMO STVARNO

Usvajanje AI u financijama je presporo

Udio financijskih funkcija koje koriste umjetnu inteligenciju na području kontrolinga raste. Skok se dogodio između 2023. i 2024. Zatim se u godinu dana usporilo ali se očekuje značajan rast u 2026. godini.



67 %

korisnika AI-a u
financijama optimističnije
je nego godinu ranije u
primjeni AI.

Što kaže struka

Gotovo svi rade nešto na području uvođenja AI u kontroling i financije, ali samo manjina CFO-a je zadovoljan rezultatom. AI pomaže pojedincima ali se nova vrijednost još uvijek ne preljeva na organizaciju.

84%

financijskih organizacija
primjenjuje ili planira
primjenu AI-a

7%

prijavljuje visok ili vrlo
visok učinak

80%

ispitanika prijavljuje
bolju osobnu
produktivnost

37%

pripisuje AI-u bilo
kakav utjecaj na
operativnu dobit

Produktivnost vs. odlučivanje

Kad se novac usmjeri na ubrzanje poslovanja, koristi se pojave brzo ali onda uspore. Kad se AI usmjeri na bolje odluke, koristi dolaze sporije ali stalno. Kombinacije rasta produktivnosti i podrške u odlučivanju je najbolja.

Kamo ide novac

45 % ulaganja u produktivnost

20 % ulaganja u kvalitetu odluka

Gdje je vrijednost

2×

veća ostvarena vrijednost ondje gdje inicijative mijenjaju način rada, a ne samo ubrzavaju postojeći.


Kako se AI koristi danas u financijama

Tri najčešće primjene umjetne inteligencije u financijama su pretraživanje, unos i kontrola. Sve tri su korisne i niskog rizika, ali niti jedna od njih se ne odnosi izravno na podršku u donošenju odluka.



Hrvatski kontekst primjene AI

U AI Hrvatska zaostaje za europskim prosjekom, a Europa zaostaje za SAD i Kinom. Ali razlika između primjene i vrijednosti nije hrvatski problem, on je globalan. Ali to nam ujedno daje priliku da ubrzamo primjenu AI.



Prepreke nisu tehnološke

Ključne prepreke za postizanje više razine usvajanja i primjene umjetne inteligencije u kontroingu nije tehničke prirode, već se odnosi na manjak AI edukacije zaposlenika i odgovarajuće upravljanja podacima.

Gartner, studeni 2025.


- Podatkovna pismenost i tehničke vještine
- Kvaliteta i dostupnost podataka
- Kultura i organizacijski prioritet
- Prijelaz s planiranja na pilot

Horváth, CFO Study 2026.

- Obrambeni stav i razmišljanje u silosima
- Nedovoljno upravljanje promjenom
- Nedostatak stručnjaka
- Nespremnost na ulaganje

Pet razina suradnje AI s financijašima i kontrolerima

Postoji pet razina kako umjetne inteligencija može pomoći u financijama i kontrolingu, ali samo rijetke organizacije koriste više od dvije početne razine podrške u poslovanju.



II.

TRI PRIMJERA STVARANJA NOVE VRIJEDNOSTI S AI

Tri primjera, ista tri pitanja

Nijedan od ovih primjera ne traži novi ERP ni projekt od godinu dana. Sva tri se temelje na poslovima koje su tipični za financije ili kontroling. Brojke u primjerima su ilustrativne i tipične za srednje veliku tvrtku.

POSLOVNA SITUACIJA

Što danas radimo ručno,
koliko sati to traje i tko to
radi

RJEŠENJE

Što poboljšava i preuzima
AI, a što ostaje čovjeku

REZULTAT

Koliko sati prije, koliko
poslije, i koliki je rast
produktivnosti

Primjer 1. Kontrola ulaznih računa i troškova po projektima

POSLOVNA SITUACIJA

Mjesečno stiže oko 600 ulaznih računa.

Svaki treba usporediti s narudžbenicom, provjeriti cijenu prema ugovoru i pridružiti ga troškovnom mjestu i projektu.

Podaci su na tri mjesta: PDF računa, ERP i excel s ugovornim cjenicima.

Dvoje ljudi, šest radnih dana mjesečno.

RJEŠENJE

Dva AI agenta.

Prvi čita PDF računa, izvlači stavke i uspoređuje ih s narudžbenicom u ERP-u i s cjenikom iz ugovora.

Drugi predlaže troškovno mjesto i projekt, a u listu za provjeru izdvaja samo ono što odstupa.

Čovjek više ne pregledava sve, nego samo iznimke.

REZULTAT

S 96 sati mjesečno na 16 sati.

Rast produktivnosti 83 posto.

Tih 16 sati je kontrola iznimaka i odobravanje.

Oko 92 posto računa prođe bez ljudskog dodira.

Ljudske pogreške kod usporedbe bile su do razine 10% a sada su potpuno eliminirane.

AI pogrešaka nema ili su ispod 1%.

Primjer 1. Rezultat

96 h

prije

sati mjesečno, dvoje ljudi

16 h

poslije

83%

rast produktivnosti

Što je potrebno

- Uredan kontni plan i šifarnik projekata
- Ugovorni cjenici na jednom mjestu, ne po mailovima
- Definiran prag ispod kojeg se odstupanje ne provjerava

Gdje treba oprez

- Račun koji AI pogrešno poveže s projektom kvari podatak za usporebu
- U slučaju promjena, treba imati bilješku o tome tko je odobrio iznimku i kada

Primjer 2. Mjesečno izvješće i analiza odstupanja

POSLOVNA SITUACIJA

Nakon zatvaranja računa kontroling za sedam poslovnih jedinica izvlači podatke iz ERP-a i uspoređuje ih s planom i prošlom godinom.

Zatim traži zašto je marža pala i piše komentar za svaku jedinicu.

Troje ljudi, oko 40 sati.

Izvještaj je gotov peti radni dan.

RJEŠENJE

Dva AI agenta.

Prvi spaja izvoz iz ERP-a s planom, razlaže odstupanje na količinu, cijenu te označava što je iznad praga materijalnosti.

Drugi piše prvi nacrt komentara po jedinici i predlaže tri pitanja za voditelja.

Kontroler nacrt provjerava, dopunjava i odobrava.

REZULTAT

S 40 sati mjesečno na 8 sati.

Rast produktivnosti 80 posto.

Izvještaj ide Upravi drugi radni dan umjesto petog.

Kontroler tri dana mjesečno provede u razgovoru s poslovnim jedinicama umjesto uronjen u Excel.

Primjer 2. Rezultat

40 h

prije

sati mjesečno, troje ljudi

8 h

poslije

80%

rast produktivnosti

Što je potrebno

- Dosljedno mapiranje konta kroz sve jedinice
- Jednokratne stavke označene u sustavu
- Dogovoren prag materijalnosti

Gdje treba oprez

- Objašnjenje koje zvuči logično, a nije točno, opasnije je od prazne ćelije – nužna detaljna ljudska provjera
- Bez traga o tome što je čovjek promijenio, prva greška ruši povjerenje

Primjer 3. Mjesečni forecast prodaje

POSLOVNA SITUACIJA

Kontroling svaki mjesec šalje Excel tablicu dvanaestorici voditelja koji upisuju procjenu za sljedeća tri mjeseca.

Ispunjenu je vraćaju malo prije ili poslije roka, te često u različitim formatima.

Kontroling ih spaja, usklađuje i radi konsolidirani Forecast.

Traje pet radnih dana, a promašaj je redovito oko 14 posto.

RJEŠENJE

Model uči iz 36 mjeseci povijesti prodaje, knjige naloga i sezonalnosti te sam predlaže baznu projekciju za svaku jedinicu.

Voditelj više ne upisuje broj od nule nego korigira prijedlog pripremljen od AI, te upisuje razlog korekcije.

AI agent spaja tablice i piše sažetak promjena za Upravu.

REZULTAT

S pet radnih dana na jedan.

Promašaj prognoze s 14 na 7 posto.

Uprava dobiva Forecast osam dana ranije.

Prvi put se vidi tko je korigirao broj i zašto.

Voditelj štedi vrijeme i smanjuje iritantni posao upisivanja, te eventualne pogreške pri upisu

Primjer 3. Rezultat

5 dana

prije

trajanje mjesečnog ciklusa

1 dan

poslije

80%

rast produktivnosti

Što je potrebno

- 24 do 36 mjeseci dosljedne povijesti
- Obvezan upis razloga uz svaku korekciju
- Referentni model za usporedbu točnosti

Gdje treba oprez

- Model ne zna za ono što se nije dogodilo: novu regulativu, gubitak kupca, akviziciju
- Ako se korekcije rade tiho, Forecast ostaje pregovaračka igra s ljepšim sučeljem

Sva tri primjera imaju istu logiku

Ponavljajući posao s više izvora podataka, jasnim pravilima i puno sati. Čovjek se fokusira na kontrolu konačne isporuke rezultata rada umjetne inteligencije, poslovni proces se ubrzavaju, dok ljudske pogreške nestaju.

Primjer	Prije	Poslije	Učinak	Što ostaje čovjeku
Kontrola ulaznih računa	96 h / mj	16 h / mj	+83 %	Odobrovanje iznimaka
Mjesečno izvješće i odstupanja	40 h / mj	8 h / mj	+80 %	Prosudba i razgovor s jedinicama
Mjesečni Forecast	5 dana	1 dan	80% Promašaj smanjen 14 % → 7 %	Korekcija i obrazloženje

Isti obrazac radi i na drugim poslovima: kontroli putnih naloga i troškova po projektima, usklađivanju izvoda i otvorenih stavaka, pripremi podloge za sjednicu uprave, provjeri rabata prema ugovoru, prikupljanju podataka za ESG i statistička izvješća.

Što AI u kontrolingu ne bi trebao raditi

Umjetne inteligencija smije istraživati, analizirati, procjenjivati, uspoređivati i pripremiti odluku. Ali ona na smije odlučiti. Za svaku odluku mora postojati čovjek koji je prekontrolira i za nju osobno odgovara.

- Konačna procjena vrijednosti imovine, rezervacija i umanjenja
- Odobrenje transakcije ili plaćanja bez ljudskog potpisa
- Prosudba u sivim zonama računovodstvene politike
- Odluka koja utječe na ljude, primjerice ocjena učinka
- Bilo koji izlaz koji ide regulatoru ili revizoru bez imenovanog odgovornog

Kontroling profesionalno postoji zbog nadzora. Logično je da se ta pravila pišu upravo ovdje.

59%

financijskih lidera kao najveći izazov navodi odnos brzine uvođenja AI-a i upravljanja rizikom.

19%

CFO-a već nosi primarnu odgovornost za upravljanje AI-em u cijeloj tvrtki.

AI halucinacije – pouzdanost kontinuirano raste

Stopa pogreške AI modela je niža od one koju danas imamo u ručnom radu. Pouzdanost ovisi o tipu zadatka, načinu i procesu promptanja. AI model priprema i predlaže, tablica računa, čovjek odobrava.

Zadatak za AI	Što AI preuzima	Pouzdanost danas	Što ostaje čovjeku
Čitanje ulaznih dokumenati računi, ugovori, izvodi, putni nalozi	Prepoznaje stavke, iznose i rokove te ih upisuje u strukturirani oblik	99% 97–98% na dugom dokumentu	Iznimke, pragovi i novi dobavljači
Usklađivanje i odstupanja izvodi, otvorene stavke, plan i realizacija	Uspoređuje dva izvora, izdvaja neslaganja i predlaže uzrok	96% dohvat podatka iz tablice, izračun ostaje u formuli	Potvrda uzroka s poslovnom jedinicom
Nacrt izvješća i komentara podloga za upravu, komentar uz forecast	Piše prvu verziju teksta iz vaših brojki i prošlomjesečnog izvješća	83-85 % zadovoljenih kriterija pri čitanju stručnih dokumenata	Nijedan broj u tekstu ne smije nastati u modelu

III.

TRI PREPORUKE ZA STVARANJE NOVE VRIJEDNOSTI S AI

Tri preporuke

Redoslijed nije proizvoljan. Svaka sljedeća radi samo ako je prethodna napravljena.

1

**Educirajte sebe
i svoj tim**

Znanje

2

**Napravite popis
AI inicijativa**

Prilike

3

**Provedite jedan
pilot-projekt**

Dokaz

1. Educirajte sebe i svoj tim

Potrebno je izgraditi vještine kontrolera kako bi efikasno mogli koristiti AI alate, od formiranja prompta, preko provjere rezultata, pa do procjene pouzdanost rezultata.

Što mora biti u edukaciji

- Kako AI radi i gdje griješi
- Sigurno rukovanje podacima tvrtke – odgovorna primjena
- Praktičan rad na stvarnim zadacima iz kontrolinga
- Kako procijeniti je li izlaz točan
- Kada AI nije pravo rješenje

Kako to izgleda u praksi

- Pola dana edukacije za upravu i voditelje
- Jedan do dva dana radionice za tim
- 30 dana primjene AI uz podršku (eksperimentiranje)
- Interni AI ambasador koji nastavlja

Kako znate da je uspjelo

- Ne po zadovoljstvu polaznika
- Nego po broju zadataka koje su ljudi stvarno promijenili 30 dana poslije
- I po broju prijedloga koji dođu odozdo
- Na kraju i po uštedama i rastu produktivnosti (mjereno prije AI i poslije AI)

2. Napravite popis AI inicijativa

U ovom koraku cilj je da zaposlenici prepoznaju na koje poslovne izazove, procese te radne zadatke mogu primijeniti AI u svom odjelu ili području poslovanja. Ovaj korak podrazumijeva primjenu zdravog razuma.

01

Prikupite poslovne izazove

Svaki član tima zapiše poslove ili zadatke koji troše najviše sati, ponavljaju se svaki mjesec i najmanje mijenjaju odluku.

02

Pretvorite ih u AI inicijative

Za svaki izazov strukturirano opišite rješenje, vrijednost i rizike. Obrazac je na sljedećem slajdu.

03

Prioritizirajte

Poredajte po vrijednosti i izvedivosti. Od desetak inicijativa dalje ide tri do pet.

Pojednostavljeni obrazac za opis jedne AI inicijative

Jedan standardizirani obrazac po AI inicijativi. Bez standardiziranog i sustavnog pristupa putem AI obrasca se ne može ni procijeniti vrijednost ni usporediti prioritet AI inicijativa.

Poslovni izazov

u jednoj rečenici

Kako se radi danas

koraci, izvori podataka, sati mjesečno, tko radi

Prijedlog rješenja

što preuzima AI, što ostaje čovjeku

Potrebni podaci i sustavi

gdje su, tko ih daje, jesu li uredni

Očekivani učinak primjenom AI

ušteda sati, rast produktivnosti, brzina, kvaliteta, manji rizik, reputacija

Trošak

licence, izrada, integracija, edukacija, održavanje

Rizici

kvaliteta podataka, povjerljivost, pogrešan izlaz, ovisnost o dobavljaču, otpor

Vlasnik i mjerila

tko odgovara i kako mjerimo uspjeh

3. Provedite jedan pilot-projekt

Cilj pilota nije tehnologija nego dokaz isplativosti primjene AI u konkretnom slučaju. Bez izmjerene uštede vrijednosti pilot nije dokaz nego dojam. Izmjerite sate prije upotrebe AI i poslije kada koristite AI za isti proces.

Kako odabrati prvi

- Low-Hanging Fruit
- Podaci već postoje
- Vlasnik je motiviran
- Rezultat je mjerljiv
- Nizak rizik ako pogriješi
- Vidljiv unutar dva mjeseca

Kako ga voditi

- Izmjerite polaznu vrijednost prije početka
- Šest do osam tjedana, s rokovima
- Tjedni pregled s vlasnikom
- Ljudska provjera svakog izlaza

Što poslije naglasiti

- **Brojka prije i brojka poslije**
- Opis promijenjenog procesa
- Popis onoga što nije radilo
- Odluka za dalje

Što možete napraviti već u ponedjeljak

Tri akcije, svaka izvediva u jednom tjednu, bez proračuna i bez odobrenja nabave. Nijedna od ove tri ne traži upotrebu umjetne inteligencije, već zdrav ljudski razum. Sve tri određuju hoće li AI kod vas nešto vrijediti.

01

Zakažite pola dana edukacije za svoj tim u sljedećih trideset dana.

02

Pošaljite kolegama jedno pitanje: koja tri zadatka u vašem mjesecu troše najviše vremena, a najmanje mijenjaju odluku? Odgovori su vaš prvi popis za izradu AI inicijativa.

03

Odaberite jedan od identificiranih AI inicijativa i izmjerite koliko sati mjesečno stvarno trošite prije i poslije primjene AI. To je polazna vrijednost vašeg prvog pilot-projekta.

Kad je došao Excel prije 30ak godina, nitko nije ostao bez posla. Ali nitko više ne radi ono što je radio prije dolaska Excela. Al je sljedeći Excel. Samo što će ovaj put promjena biti značajno brža i veća.



MOLIM PITANJA

Vedran Antoljak · Best Advisory · vantoljak@best-advisory.eu

T Business

Pregled tržišta edukacija AI

Andrea Vuković | Rijeka | Listopad 2026.






PLATFORMA AIMO!

Hrvatski Telekom pretvara znanje
u vaš najmoćniji alat za osobni
napredak i poslovni razvoj i rast.

AIMO
znati uz
AI!



HT AI edukacijski ekosustav



Vizija

Razvoj AI i digitalnih kompetencija građana i poduzetnika kroz **dostupnu, praktičnu i odgovornu edukaciju.**

Tri ključna stupa



AIMO! znati uz AI

- Krovna inicijativa za podizanje svijesti o AI pismenosti
- Popularizacija umjetne inteligencije
- Dostupnost AI alata široj javnosti



AI ti to možeš!

- Besplatne edukacije i webinar
- AI za svakodnevni poslovni život, učenje i/ili kreativnost
- Sigurna upotreba AI alata



- Besplatne edukacije i webinar usmjereni ka malim i srednjim poslovnim korisnicima
- Osnažiti sve da uz AI oblikuju svoju poslovnu budućnost

—



Znanje koje pokreće vaš posao!

Fokus na
poslovnu primjenu!



Ciljana skupina

- Mikro i mala poduzeća
- Obrtnici
- Freelanceri
- Startupovi



Ključne teme

- Umjetna inteligencija
- Kibernetička sigurnost
- Digitalizacija



Formati

- Edukacije uživo po gradovima diljem Hrvatske
- Digitalni moduli u obliku *webinara*



Rezultat

povećanje
produktivnosti i
konkurentnosti
poduzetnika.

<https://t-akademija.ht.hr/>



T Business Akademija

T BUSINESS AKADEMIJA 2026

Znanje koje prelazi iz edukacija u poslovnu praksu!



20+
WEBINARA



6
GRADOVA



ZAGREB
ZADAR
SPLIT
VARAŽDIN
RIJEKA
OSIJEK



Vrijednost za poslovni svijet!

- Jačamo znanje i kompetencije
- Potičemo inovacije i digitalnu transformaciju
 - Kreiramo nova rješenja
- Zajedno s poduzetnicima gradimo bolju i konkurentniju budućnost
 - Otvaramo vrata za nove prilike



MENTORSTVO + NATJEČAJ

Podrška za vašu poslovnu ideju.
Od koncepta do prilike.



10 tvrtki
mentorstvo
za razvoj ideje



5.000 €
za pobjedničku ideju
„AI za poslovni rast”



Prijave otvorene
14. – 30. rujna 2026.

T BUSINESS AKADEMIJA

ZNANJE I UMREŽAVANJE I RAST

Hvala na pažnji!

Andrea Vuković · Hrvatski Telekom