

Inflation in Croatia: A New Era of Forecasting with Machine Learning

Jakov Čorak[†] Mihael Brusani[‡]

[†] Croatian National Bank, Zagreb
jakov.corak@gmail.com

[‡] Faculty of Economics and Business Zagreb
brusanmihael@gmail.com

Svibanj 2026.

Public Sector Economics, Vol. 50, No. 1 (2026)

[†] Izneseni stavovi su osobni stavovi autora i ne odražavaju nužno službeno stajalište Hrvatske narodne banke.

Motivacija

Zašto je tema ponovno važna?

- Inflacija se vratila u središte makroekonomskih rasprava nakon dugog razdoblja niske i stabilne inflacije
- Središnje banke moraju djelovati anticipativno jer monetarna transmisija djeluje sa zadržkom
- Veliki šokovi nakon 2020. povećali su pogreške standardnih prognoza i pokazali koliko je prognoziranje inflacije zahtjevno (Mederios et al, 2021)

Zašto ML?

- hvata nelinearnosti i složene interakcije
- radi s bogatijim skupovima prediktora
- može biti bolji u nestabilnim režimima
- aktualno

Sadržaj

1 Uvod

- Jednostrani sažetak
- Kratki pregled literature
- Doprinos rada
- Istraživački ciljevi

2 Metodologija i podaci

- Što je strojno učenje?
- Podaci i ulazne varijable
- Transformacija značajki
- Modeli
- Postupak prognoziranja
- Metrike uspješnosti

3 Rezultati

- Rezultati prije COVID-a
- Rezultati nakon COVID-a
- Rezultati za cijeli uzorak
- Usporedba s prognozama Europske komisije
- Rasprava
- Ograničenja rada

4 Zaključak

- Zaključak

Jednostrani sažetak

Istraživačko pitanje

Može li strojno učenje poboljšati prognoziranje inflacije u Hrvatskoj u odnosu na *SARIMA* benchmark?

Podaci

Mjesečna HICP inflacija i 10 dodatnih varijabli, razdoblje 2006M1–2025M3, četiri skupa značajki i 215 upotrebljivih opažanja.

Metodologija

10 modela, horizonti prognoze 3/6/9 mjeseci, prije COVID-19 vs. nakon COVID-19 i konačna usporedba s prognozama Europske komisije.

Ključni nalazi

SARIMA je najstabilniji ukupno, dok je **LightGBM** najjači ML model; tree-based pristupi dobivaju na važnosti u volatilnijim razdobljima.

Kratki pregled literature

Od klasičnih prema novim pristupima

- Phillipsova krivulja dugo je imala središnje mjesto u empirijskim modelima predviđanja inflacije, no dio literature dovodi u pitanje njezinu prognostičku moć (Atkeson i Ohanian, 2001).
- ARMA modeli i ankete često nadmašuju Phillips-curve pristupe (Ang, Bekaert i Wei, 2005).
- Faktorski modeli koriste informacije iz velikih baza podataka, ali njihova kvaliteta ovisi o odabiru varijabli (i.e. *targeting predictors*, Bai i Ng, 2008).

Suvremeni okvir

- Nakamura (2004): neuronske mreže bolje su od AR-a na kratkim horizontima.
- Medeiros i Mendes (2016); Garcia, Medeiros i Vasconcelos (2017): LASSO nadmašuje AR i faktorske modele u SAD-u i Brazilu.
- Medeiros et al. (2021); Ülke, Sahin i Subasi (2018): RF daje najmanje pogreške i dobro radi u volatilnim uvjetima.
- Naghi, O'Neill i Zaharieva (2024): RF je najbolji prije COVID-a, ali tijekom pandemije SVM i GBM postaju točniji.
- Araujo i Gaglianone (2023): ML je općenito bolji od ARMA, posebno RF i XGBoost na duljim horizontima.
- Ivašcu (2023): jednostavni AR modeli ostaju konkurentni u malim uzorcima i ekonomijama s malo podataka.

Doprinos rada

Dva glavna doprinosa

- 1 Prva primjena ML-a na prognoziranje inflacije u Hrvatskoj u dostupnoj domaćoj literaturi.
- 2 Usporedba kroz ekonomske režime i skupove značajki, što pokazuje kada i zašto pojedini modeli rade bolje.

Zašto je to relevantno?

Rad ne testira samo „tko pobjeđuje”, nego i „u kojim uvjetima pobjeđuje”: prije i nakon COVID-a, uz različite informacije i različite klase modela.

Istraživački ciljevi

Što rad želi odgovoriti?

- Koji ML model daje najbolje prognoze i kako stoji u odnosu na **SARIMA** benchmark?
- Mijenja li se poredak modela između **pre-COVID** i **post-COVID** razdoblja?
- Koji skupovi značajki nose najviše korisnih informacija za prognozu inflacije?
- Jesu li odabrani modeli precizniji od prognoza **Europske komisije**?

Što je strojno učenje?

Definicija koju rad koristi

„Machine learning is the combination of automated computer algorithms with powerful statistical methods to discover hidden patterns in rich datasets.” (Masini et al., 2021)

Svaki ML algoritam sastoji se od tri ključna elementa:

- **Model** – skup (familija) mogućih funkcija (hipoteza) koji opisujemo hiperparametrima (hiperparametar određuje model, a parametri određuju hipotezu); cilj je pronaći onaj koji najbolje generalizira.
- **Funkcija gubitka** – numerička procjena kvalitete modela, poput RMSE-a, MAE-a ili MAPE-a, koja govori koliko je hipoteza dobra.
- **Optimizacijski postupak** – postupak koji pretražuje prostor parametara (optimizator) i hiperparametara (npr. grid search) te pronalazi kombinaciju koja minimizira gubitak.

Podaci i ulazne varijable


Okvir podataka

Ciljna varijabla je **mjesečna promjena HICP-a**; nizovi počinju u **2006M1**, preuzeti su u **2025M3**, a nakon transformacija ostaje **215 opažanja**.

Grupa	Varijabla	Izvor
Cilj / lag	MoM stopa inflacije	Eurostat
Konvencionalne	Stopa nezaposlenosti	DZS
	Industrijska proizvodnja	DZS
	Realni promet u maloprodaji	DZS
	Spread US 10Y – 2Y	FRED
	Brent/WTI cijene nafte	EIA
	Baltic Dry Index	Bloomberg
Nekonvencionalne	Indeks potrošačkog pouzdanja	HNB
	EPU indeks	Sorić & Lolić (2017)
	GT: „Urlaub in Kroatien”	Google Trends
	GT: „Inflation”	Google Trends

Tablica rekonstruirana prema tablici 1 u Čorak i Brusan (2026).

Transformacija značajki



Svrha transformacija

- smanjiti kratkoročnu volatilnost
- naglasiti novije informacije
- postići stacionarnost
- proširiti vremensku memoriju modela

Ishod

11 → 440 → 215
11 baznih varijabli, do 440 značajki i 215 uporabljivih opažanja

Modeli

- **Glavna relacija prognoze:** $\pi_{t+h} = G_h(x_t) + u_{t+h}$

Linearni

- Ridge
- LASSO
- Elastic Net

Nelinearni

- SVR
- Neural Network


Tree-based

- Random Forest
- XGBoost
- LightGBM

Benchmark

- SARIMA
- Prophet

Postupak prognoziranja



Zašto ovakav postupak?

- **Expanding window cross-validation**
- sprječava **data leakage**
- oponaša **real-time** prognoziranje (i.e. *pseudo out-of-sample evaluation*)
- model se ponovno trenira nakon svakog novog mjeseca podataka

Metrike uspješnosti

MSE

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n (\hat{\pi}_t - \pi_t)^2$$

- Koristi se za pronalazak optimalnih hiperparametara u CV-u

RMSE

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (\hat{\pi}_t - \pi_t)^2}$$

- Glavna metrika u rezultatima

OMASE

$$\text{OMASE} = \frac{\frac{1}{n} \sum_{t=1}^n |\pi_t - \hat{\pi}_t|}{\frac{1}{n-m} \sum_{t=m+1}^n |\pi_t - \pi_{t-m}|}, \quad m = 12$$

- OMASE < 1: model nadmašuje sezonski naivni benchmark izvan uzorka
- RMSE i MAE ovise o skali podataka
- MAPE je problematičan kod vrijednosti blizu nule
- MASE uvodi skaliranu pogrešku → forecast error se uspoređuje s naive benchmarkom (izračunatom na in-sample dijelu Hyndman i Koehler, 2006), čime metrika postaje skalno "neovisna" i interpretabilna
- Seasonal MASE koristi seasonal naive benchmark → prikladnije/smislenije za mjesčne podatke (alternativa: data leakage ili flat line forecast)
- OMASE koristi out-of-sample seasonal naive pogrešku u nazivniku → omogućuje direktnu usporedbu modela i benchmarka u istom tržišnom režimu te bolje reflektira forecasting performanse

Rezultati prije COVID-a

Model	h=3			h=6			h=9					
	lag	unc. conv.	all	lag	unc. conv.	all	lag	unc. conv.	all			
SARIMA	100,0	-	-	-	100,0	-	-	-	100,0	-	-	
RIDGE	109,9	108,4	111,2	106,5	112,6	109,4	113,2	108,7	109,0	106,6	108,2	103,5
LASSO	113,9	118,0	114,0	111,7	118,4	129,6	125,1	126,5	114,1	115,6	115,5	116,0
ENET	114,3	117,2	113,9	111,9	121,7	129,7	126,6	125,1	115,3	118,1	115,8	116,1
PROPHET	119,3	215,6	567,4	304,8	131,5	218,6	803,2	368,1	122,3	249,5	523,9	273,0
NN	110,1	131,1	111,1	116,8	112,7	123,3	138,9	126,1	105,7	111,8	111,0	114,9
SVR	116,3	120,2	121,7	123,2	117,7	122,8	121,3	141,4	117,2	111,0	111,4	123,4
RF	122,7	127,2	131,7	123,2	118,6	131,8	161,1	141,4	105,6	110,1	152,5	123,4
XGBOOST	116,3	107,7	125,1	103,3	104,1	108,3	111,7	113,8	90,9	102,7	99,6	101,4
LGBM	108,1	117,9	111,7	109,2	94,9	119,3	134,6	108,9	102,0	105,6	90,6	96,5

lag = bez vanjskih značajki; unc. = nekonvencionalne; conv. = konvencionalne; all = lag + vanjske značajke.

tamnije → manji RMSE; **boldano** → OMASE > 1; **crveno označeno** → najmanji RMSE u danom stupcu.

Ključni uvid

- Tree-based modeli (LightGBM i XGBoost) postižu iznadprosječnu točnost u razdoblju niske volatilnosti prije COVID-19 pandemije.
- Na horizontima od 6 i 9 mjeseci LightGBM i XGBoost konzistentno nadmašuju SARIMA model.
- U nekim slučajevima uključivanje eksternih varijabli dodatno poboljšava performanse tree-based modela.
- Ridge je jedini linearni model s OMASE < 1 na svim horizontima prognoziranja.
- ENet i Lasso ostvaruju slabije rezultate od Ridge modela.
- L1 penalizacija i selekcija varijabli nisu doprinijele poboljšanju prognozne točnosti.
- Prophet ne uspijeva nadmašiti naivni model ni u jednoj specifikaciji.
- Prophet je model kod kojeg uključivanje eksternih varijabli najviše pogoršava performanse.
- Nema jasnog obrasca prema kojem nekonvencionalne varijable sustavno poboljšavaju prognoze u odnosu na konvencionalne.

Rezultati nakon COVID-a

Model	h=3			h=6			h=9					
	lag	unc. conv.	all	lag	unc. conv.	all	lag	unc. conv.	all			
SARIMA	100,0	-	-	-	100,0	-	-	-	100,0	-	-	
RIDGE	107,6	118,7	116,4	112,5	100,4	138,1	113,5	123,6	99,2	150,9	110,2	131,3
LASSO	105,3	112,0	107,3	109,8	102,8	112,1	104,9	104,7	101,6	102,5	108,3	104,5
ENET	103,8	112,2	109,8	110,9	101,0	111,5	106,3	108,9	101,2	104,1	108,3	105,1
PROPHET	102,1	149,2	160,8	577,7	104,7	159,3	218,2	603,6	102,7	202,6	188,8	1298,5
NN	109,4	127,3	116,3	109,9	102,5	158,2	117,2	136,1	103,0	181,0	115,0	138,9
SVR	112,6	113,8	107,2	118,5	108,7	114,6	109,7	119,3	109,2	112,2	111,9	117,6
RF	112,1	111,1	119,7	118,5	112,4	111,8	122,8	119,3	107,4	113,2	119,9	117,6
XGBOOST	117,4	119,8	104,3	102,4	113,5	120,8	104,6	116,5	111,2	112,8	110,0	109,9
LGBM	111,3	104,8	101,1	101,6	113,1	103,3	108,3	104,3	109,6	101,6	102,8	105,0

lag = bez vanjskih značajki; unc. = nekonvencionalne; conv. = konvencionalne; all = lag + vanjske značajke.

tamnije → manji RMSE; **boldano** → OMASE > 1; **crveno označeno** → najmanji RMSE u danom stupcu.

Ključni uvid

- SARIMA ostvaruje najniži RMSE na svim horizontima prognoziranja.
- LightGBM je najbolji ML model i najbliži konkurent SARIMA-i.
- LightGBM na kraćim horizontima profitira od konvencionalnih, a na duljima od nekonvencionalnih varijabli.
- Ridge bez eksternih varijabli pokazuje najveću stabilnost među linearnim modelima.
- Lasso i ENet ostvaruju sličnu razinu točnosti kao Ridge.
- Prophet postiže OMASE < 1 samo uz lagove ciljne varijable.
- Neuralne mreže također najbolje funkcioniraju samo s lagovima ciljne varijable.
- Eksterne varijable imaju ograničenu dodatnu informacijsku vrijednost za Prophet i neuralne mreže.
- U post-COVID razdoblju modeli češće nadmašuju naivni benchmark (OMASE < 1).
- RMSE svih modela značajno raste zbog veće nepredvidivosti inflacije.

Rezultati za cijeli uzorak

Model	h=3			h=6			h=9					
	lag	unc. conv.	all	lag	unc. conv.	all	lag	unc. conv.	all			
SARIMA	100,0	-	-	100,0	-	-	100,0	-	-			
RIDGE	108,2	117,5	115,9	111,9	102,4	134,9	113,7	122,0	100,8	145,9	110,5	128,5
LASSO	107,4	113,0	108,8	110,7	106,1	115,9	108,8	109,0	103,6	104,6	109,9	106,7
ENET	105,7	113,3	111,1	111,8	104,3	115,4	110,3	112,3	103,5	106,4	109,9	107,2
PROPHET	105,1	161,1	249,1	547,2	108,9	168,9	358,3	578,9	105,8	210,1	262,1	1217,9
NN	109,8	128,1	115,8	111,1	104,1	154,3	120,6	135,0	103,5	173,4	115,1	136,6
SVR	113,4	115,0	109,7	119,4	110,2	116,0	111,6	122,8	110,5	112,3	112,4	119,0
RF	113,9	113,9	121,8	119,4	113,5	115,0	128,9	122,8	107,4	113,0	125,5	119,0
XGBOOST	117,5	118,3	107,8	102,7	112,5	119,5	105,8	116,4	108,8	111,7	109,2	109,4
LGBM	111,1	107,0	103,0	103,0	111,1	105,8	112,4	105,1	108,8	102,4	101,7	104,4

lag = bez vanjskih značajki; unc. = nekonvencionalne; conv. = konvencionalne; all = lag + vanjske značajke.


tamnije → manji RMSE; **boldano** → OMASE > 1; **crveno označeno** → najmanji RMSE u danom stupcu.

Ključni uvid

- SARIMA ostvaruje najniže prognozne pogreške na svim promatranim horizontima.
- LightGBM je najčešće najbolji model nakon SARIMA-e.
- LightGBM ostvaruje niske RMSE i OMASE vrijednosti kroz različite kombinacije varijabli i horizonte prognoziranja.
- XGBoost se također ističe među nelinearnim modelima, ali s manje konzistentnim performansama u različitim specifikacijama eksternih varijabli.
- Među nelinearnim modelima LightGBM s eksternim varijablama pokazuje najstabilniju i najbolju izvedbu.
- Linearni modeli najčešće postižu najbolje rezultate koristeći samo lagove ciljane varijable.


Usporedba s prognozama Europske komisije

- **SARIMA ostvaruje najniže prognostičke pogreške na većini horizonata i razdoblja.**
- **LightGBM je najuspješniji i najkonzistentniji ML model izuzev SARIMA-e.**
- **Za završno prognoziranje odabrani su SARIMA i LightGBM.**
- Modeli prognoziraju mjesečnu inflaciju za 14 horizonata.
- Prognoze modela agregiraju se iz mjesečne u godišnju inflaciju radi usporedbe s prognozama Europske komisije.
- Rezultati se uspoređuju s prognozama Europske komisije kroz tri ciklusa prognoziranja.
- Proljetna prognoza EK (cut-off: kraj travnja) uključuje prognozu za preostalih 8 mjeseci tekuće godine ($h = 1-8$).
- Jesenska prognoza EK za tekuću godinu (cut-off: kraj listopada) uključuje prognozu za posljednja 2 mjeseca godine ($h = 1-2$).
- Jesenska prognoza EK za sljedeću godinu (cut-off: kraj listopada) uključuje prognozu za preostala 2 mjeseca tekuće i svih 12 mjeseci sljedeće godine (ukupno $h = 1-14$).


Jesen – trenutna godina ($h = 1, 2$)

..... European Commission - - - SARIMA - . - LightGBM — Actual

Proljeće – trenutna godina ($h = 1, \dots, 8$)



..... European Commission - - - SARIMA - . - LightGBM — Actual

Jesen – sljedeća godina ($h = 1, \dots, 14$)

..... European Commission - - - SARIMA - . - LightGBM — Actual

Rasprava

- LightGBM nadmašuje prognoze Europske komisije u post-COVID razdoblju, dok SARIMA ostvaruje najbolje rezultate u pre-COVID razdoblju.
- Unatoč ograničenom broju prediktora, LightGBM ostaje konkurentan SARIMA modelu.
- Hrvatsko podatkovno okruženje ograničeno je kratkim vremenskim nizovima i manjkom visokofrekventnih indikatora.
- Visoka perzistentnost i sezonalnost inflacije objašnjavaju snažne rezultate SARIMA modela (nizozemska bolest).
- Moguća uporaba “forward guidance” u službenim prognozama otežava izravnu usporedbu s EK prognozama.

Ograničenja rada

- Google Trends podaci mogu varirati između različitih ekstrakcija istog upita (vidi Cebrián i Domenech, 2024), a rad koristi samo jednu ekstrakciju po varijabli.
- Pretraga optimalnih hiperparametara bila je ograničena dostupnim računalnim resursima.
- SARIMA i ML modeli evaluirani su različitim metodologijama (AIC vs. expanding-window cross-validation), što može ograničiti usporedivost rezultata.

Zaključak

Take-home poruke

- Ne postoji univerzalno najbolji model za sve horizonte, režime i skupove podataka.
- **SARIMA** je i dalje go-to model.
- **LightGBM** je najperspektivniji ML model.
- Potencijal ML-a raste s bogatijim podacima i duljim vremenskim nizovima.

Hvala na pažnji!

Pitanja?