

1 Doel van het onderzoek

Machine learning-modellen worden steeds vaker gebruikt bij het maken van macro-economische voorspellingen. Deze modellen hebben verschillende eigenschappen die de nauwkeurigheid van de voorspellingen beïnvloeden. We onderzoeken voor vier *machine learning*-eigenschappen (zie tekstvak 1) of en hoe deze macro-economische voorspellingen voor Nederland beter kunnen maken. We maken hierbij gebruik van een nieuwe dataset, de NL-MD, waarin de belangrijkste macro-economische indicatoren voor Nederland zijn opgenomen.

Tekstvak 1: *Machine learning*-eigenschappen

1. **Big data:** *Machine learning*-modellen kunnen profiteren van grote hoeveelheden data. We vergelijken een data-arme omgeving met een data-rijke omgeving. In het eerste geval worden alleen vertragingen van de afhankelijke variabele gebruikt als onafhankelijke variabelen. In het tweede geval worden daarnaast ook andere variabelen uit de NL-MD gebruikt als onafhankelijke variabelen.
2. **Niet-lineariteit:** Standaard econometrische modellen zijn vaak lineair van opzet. *Machine learning*-modellen kunnen daarentegen een niet-lineaire functionele vorm aannemen, waardoor meer flexibele modellen ontstaan. We nemen in dit onderzoek een *kernel ridge regression* en een *random forest* mee.
3. **Cross-validation:** Bij het trainen van *machine learning*-modellen is het cruciaal om de juiste hyperparameters te kiezen. We vergelijken *k-fold cross-validation* met *pseudo-out-of-sample (POOS) cross-validation*. Bij *k-fold cross-validation* wordt de tijdsdimensie van de data niet meegenomen, waardoor hyperparameters snel te bepalen zijn. Bij *POOS cross-validation* wordt de tijdsdimensie van de data wel meegenomen.
4. **Shrinkage:** Sommige *machine learning*-modellen kunnen de effecten van variabelen in een regressie-analyse aanpassen (regularisatie). Door een strafterm toe te voegen in de regressie, kunnen bepaalde coëfficiënten worden verkleind of zelfs op nul worden gezet, waardoor het model op een data-gedreven manier de belangrijkste variabelen meeneemt. We nemen in dit onderzoek een *elastic net*-, *lasso*- en *ridge*-regressie mee.

2 Beleidscontext

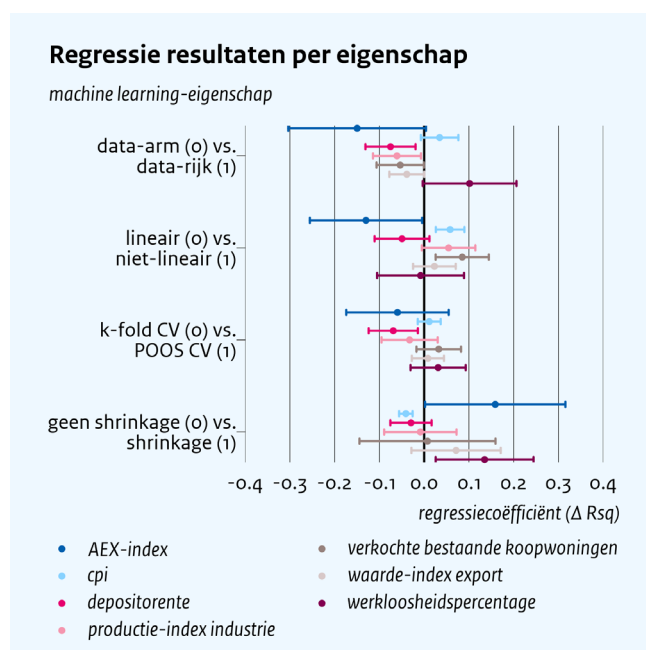
Nauwkeurige economische voorspellingen ondersteunen beleidsmakers bij hun besluitvorming. Op dit moment worden voornamelijk standaard econometrische modellen gebruikt om deze voorspellingen te doen. Onderzoek op basis van Amerikaanse data laat zien dat *machine learning* nieuwe mogelijkheden biedt om grotere en complexere datasets te onderzoeken en hierdoor voorspellingen te verbeteren (Goulet Coulombe et al., 2022). Of dit ook zo is voor Nederland, is nog weinig onderzocht. Tot voor kort was er geen vergelijkbare dataset voor Nederland publiek beschikbaar. Deze data, de NL-MD, hebben wij samengevoegd en bestaat uit data van het CBS, de ECB en Yahoo Finance. Deze data gaan echter minder ver terug dan de Amerikaanse tegenhanger. Hierdoor is het moeilijker om macro-economische uitkomsten te voorspellen met zowel standaard als *machine learning*-modellen.

3 Onderzoeksresultaten

Voor het vaststellen van de onderzoeksresultaten is onder andere gebruikgemaakt van figuur 1. Voor zeven verschillende variabelen zijn voorspellingen gerealiseerd met zowel *machine learning*-modellen als ook met standaard econometrische modellen, in zowel een data-rijke als een data-arme omgeving. In deze figuur wordt voor elke variabele de toegevoegde waarde van de *machine learning*-eigenschap op de *out-of-sample* R^2 weergegeven. Een positieve coëfficiënt geeft aan dat de eigenschap een positief effect heeft op de kwaliteit van macro-economische voorspellingen, terwijl een negatieve coëfficiënt aangeeft dat er een negatief effect is van de eigenschap hierop. De belangrijkste bevindingen van dit onderzoek zijn als volgt:

1. **Heterogene resultaten:** De resultaten voor de verschillende *machine learning*-eigenschappen verschillen aanzienlijk per voorspelde variabele. Dit impliceert dat een aanpak die effectief is voor de ene variabele, niet noodzakelijk dezelfde resultaten oplevert voor een andere variabele.
2. **Data-rijk versus data-arm:** De beste modellen voor een specifieke variabele en horizon zijn vaak data-rijk. Gemiddeld genomen presteren data-rijke modellen echter niet significant beter dan data-arme modellen. Dit kan worden toegeschreven aan het beperkte aantal observaties in onze dataset.
3. **Niet-lineariteiten:** Over alle variabelen gemiddeld hebben niet-lineariteiten geen significant effect op de voorspellingsnauwkeurigheid ten opzichte van standaard econometrische modellen. Echter, wanneer alleen gekeken wordt naar data-rijke modellen, dan verbeteren niet-lineariteiten de voorspellingsnauwkeurigheid significant.
4. **Cross-validation:** K-fold *cross-validation* heeft geen significant negatief effect ten opzichte van POOS *cross-validation*.
5. **Shrinkage-methoden:** Over het algemeen presteren *shrinkage*-methoden niet significant beter dan traditionele factormodellen, hoewel ze voor verschillende variabelen wel verbetering kunnen bieden.

Figuur 1



4 Relevantie voor Nederlands beleid

De resultaten van dit onderzoek zijn relevant voor het Nederlandse beleid om de volgende redenen:

1. **Kennisopbouw:** Beleidsmakers kunnen uit dit onderzoek leren dat maatwerk nodig is wat betreft de keuze voor data en model bij het gebruik van *machine learning* voor macro-economische voorspellingen in de Nederlandse setting. Deze setting is nog niet vaak onderzocht en is interessant vanwege het beperkte aantal observaties en het feit dat Nederland een kleine, open economie is. Dit verschilt fundamenteel met andere economieën zoals de Amerikaanse en de Britse.
2. **Beter beleid:** Beleidsmakers zijn gebaat bij goede voorspellingen van de Nederlandse economie. Hoe beter de voorspellingen, des te beter keuzes gemaakt kunnen worden. We laten zien dat een data-rijke omgeving, shrinkage en niet-lineariteiten in sommige gevallen betere macro-economische voorspellingen kunnen opleveren, maar dat de mate waarin dat gebeurt afhangt van de uitkomstvariabele.

5 Beleidsaanbevelingen

Op basis van de bevindingen doen we de volgende aanbevelingen:

1. **Modelkeuze:** Wanneer *machine learning* wordt ingezet om macro-economische voorspellingen te doen, moet er zorgvuldig gekeken worden naar welk model gebruikt wordt. Afhankelijk van de variabele kunnen zowel shrinkage als non-lineaire modellen een positieve bijdrage leveren. Er bestaat geen 'one size fits all'-model, dus maatwerk is essentieel voor het verkrijgen van accurate en betrouwbare voorspellingen.
2. **Gebruik van k-fold *cross-validation*:** K-fold *cross-validation* kost vaak minder tijd dan POOS *cross-validation* en heeft geen negatieve invloed op de nauwkeurigheid van voorspellingen.

De inzichten en aanbevelingen beschreven in deze oplegger kunnen Nederlandse beleidsmakers en ramers helpen bij het gebruiken van *machine learning*-methoden voor het doen van macro-economische voorspellingen. Het is hierbij wel belangrijk om te realiseren dat *machine learning*-modellen nog in ontwikkeling zijn. Resultaten die gevonden zijn op deze dataset, zijn niet per definitie letterlijk over te zetten naar andere datasets. Het verkennen van de mogelijkheden van verschillende modellen blijft nodig bij het gebruik van *machine learning*.

6 Referenties

Goulet Coulombe, P., Leroux, M., Stevanovic, D., & Surprenant, S. (2022). How is machine learning useful for macroeconomic forecasting? *Journal of Applied Econometrics*, 37(5), 920-964.