



Norges miljø- og
biovitenskapelige
universitet

Masteroppgave 2023 30 stp

Handelshøyskolen, NMBU
Marie Steen og Ole Gjølberg

Kan metallpriser prognostiseres?

Empirisk analyse med tidsseriemodeller på kobber, aluminium, nikkel og kobolt, 2010 - 2022

Can metal prices be forecasted?

Empirical analysis using time series models on copper, aluminum, nickel and cobalt, 2010 - 2022

Thomas V. Kristiansen & Andreas Lien Eriksen

Master i Økonomi og Administrasjon

Forord

Etter 2 års studie avslutter vi nå med denne masteroppgaven i økonomi og administrasjon med spesialisering i finans ved Norges miljø- og biovitenskapelige universitet. Underveis i dette arbeidet har vi opparbeidet kunnskap om økonometri, økonomi, finans, samt programmering i R.

Interessen for økonomi og finans har på ingen måte ikke blitt mindre, og vi vil takke handelshøyskolen for en lærerik tid og mange faglig utviklende diskusjoner og oppgaver. Spesielt vil vi takke våre veiledere Professor Ole Gjølberg og Førsteamanuensis Marie Steen for all veiledning, samt vår seminargruppe.

Vi ønsker også å takke all familie, venner og spesielt våre respektive samboere Martine og Ida for all støtte, tålmodighet og forståelse i et krevende studieløp.

Ås, august 2023

Andreas Lien Eriksen og Thomas V. Kristiansen

Sammendrag

Kobber, aluminium, nikkell og kobolt er sentrale metaller i utviklingen av den moderne industrien og har lange røtter tilbake i historien. Metallprisene er kjent for å være volatile og en god prognose vil være et godt verktøy for å redusere usikkerheten. Denne studien forsøker dermed å besvare følgende problemstilling «**Kan metallpriser prognostiseres?**». Studien benytter ulike tidsseriemodeller i forsøket på å prognostisere prisen og prisendringen en måned frem i tid for metallene kobber, aluminium, nikkell og kobolt. Det benyttes månedlige prisdata fra London Metal Exchange (LME) for perioden juni 2010 til desember 2022.

Studien er gjennomført som en rullerende prognose hvor in sample er 70 % og out of sample er 30 % av datasettet. Dette gir konstant 107 observasjoner in sample og 44 observasjoner i out of sample. Prognosemodellenes resultater rangeres etter root-mean-square error (RMSE).

Studien undersøker prognoseevnen til futureskontraktene gjennom regresjon og basis, videre benyttes Ordinary Least Squares (OLS)-modell for prognose på prisnivå med 3 lags. På endringsnivå undersøkes opptil 6 lags i en Autoregressive (AR)-modell, og avslutningsvis testes Vector Error Correction Model (VECM). I utviklingen av VECM har vi kombinert funn fra tidligere litteratur for å fastsette modellens variabler. Dette har ledet til Baltic Dry indeksen, VIX, US industriell produksjonsindeks, chilenske peso og australske dollar.

Resultatene av studien indikerer at prognosen fra de nevnte tidsseriemodellene ikke presterer bedre enn den naive modellen for verken pris- eller endringsnivå for de fire metallene i perioden 2010-2022.

Abstract

Copper, aluminum, nickel, and cobalt are crucial metals in the advancement of modern industry, and have been far back in history. The prices of these metals are acknowledged for their volatility, and a good forecast can be a useful tool for handling the price uncertainty. The goal of the study is to address the following research question: "**Can metal prices be forecasted?**". Various time series models are used in an attempt to forecast the price levels and the price changes of copper, aluminum, nickel, and cobalt one month ahead. Monthly price data from the London Metal Exchange (LME) between June 2010 to December 2022 are used.

The study adopts a rolling forecast, where the in-sample is 70% and the out-of-sample is 30% of the dataset. This ensures 107 observations in the in-sample and 44 observations in the out-of-sample dataset. The performance of forecast models is ranked by using the root-mean-square error (RMSE).

This study is researching the predictive capability of futures contracts through regression and basis model. The Ordinary Least Squares (OLS) model is applied for price level forecasting, with a three-lag structure. For price changes, the Autoregressive (AR) model is examined with up to 6 lags, followed by the Vector Error Correction Model (VECM). For making the VECM, insights from prior literature have been used to determine the model's variables. This has led us to include the Baltic Dry Index, VIX, US industrial production index, chilean peso, and australian dollar currency.

The findings of the study indicate that the forecasts generated by the previously mentioned time series models do not outperform the naive model in terms of either price levels or price changes for the four metals during the period 2010-2022.

Innholdsfortegnelse

Forord	1
Sammendrag	2
Abstract	3
Tabelloversikt	6
Figuroversikt	7
Forkortelser brukt i oppgaven	8
1 Innledning	9
2 Presentasjon av metaller	11
2.1 <i>Kobber</i>	11
2.2 <i>Aluminium</i>	13
2.3 <i>Nikkel</i>	15
2.4 <i>Kobolt</i>	17
3 Historisk prisutvikling og beskrivende statistikk	19
3.1 <i>Prisutvikling</i>	19
3.2 <i>Indeksert prisutvikling</i>	23
3.3 <i>Relative priser</i>	24
3.4 <i>Årlig prisendring</i>	25
3.5 <i>Beskrivende statistikk</i>	26
3.6 <i>Sesongvariasjoner</i>	27
3.7 <i>Korrelasjoner</i>	28
4 Tidligere litteratur	30
5 Metode og datamateriale	37
5.1 <i>Redegjørelse for datamateriale</i>	37
5.2 <i>Prognosefeil og bias-variance trade-off</i>	39
5.3 <i>Statistiske måltall for sammenligning av prognosemodeller</i>	41
5.4 <i>Stasjonaritet</i>	43
5.5 <i>Kointegrasjon og Granger kausalitet</i>	45
5.6 <i>Test for sesongvariasjon</i>	47
5.7 <i>Prognosemodeller benyttet i studien</i>	47
6 Presentasjon av in sample resultater	55

6.1	<i>Stasjonaritetstest med ADF og KPSS</i>	55
6.2	<i>Test for sesongvariasjon</i>	56
6.3	<i>Presentasjon av in sample prognoserresultater</i>	57
7	Presentasjon av out of sample resultater	72
7.1	<i>Naiv modell</i>	73
7.2	<i>Futuresmodeller</i>	74
7.3	<i>OLS og Autoregressive modell</i>	78
7.4	<i>VECM</i>	81
8	Diskusjon og tolkning av resultatene	83
9	Konklusjon	88
10	Kritikk av vår studie	89
11	Videre forskning	90
12	Referanseliste	91
13	Vedlegg	95

Tabelloversikt

Tabell 3-1: Beskrivende statistikk, LME spotpriser per tonn 2010-2022	26
Tabell 3-2: Korrelasjonsmatrise på prisendringer periode 2010-2022	28
Tabell 6-1: ADF og KPSS testresultater	56
Tabell 6-2: Parameterestimat for sesongvariasjon 1.6.2010-1.12.2022.	57
Tabell 6-3: In sample, oppsummerende tabell	59
Tabell 6-4 In sample, naive modell, pris og endringsnivå	60
Tabell 6-5 Resultat kointegrasjon og Granger Cause, spot og 1 måned futures (f1)	61
Tabell 6-6: Parametere for futures som prognose for spot	61
Tabell 6-7: Parametere for basismodell	62
Tabell 6-8 In sample resultater «basismodellen» og «futures som prognose»	63
Tabell 6-9: Prisenivå OLS (3), parametere	63
Tabell 6-10: In-sample måltall, OLS(3) prisnivå.	64
Tabell 6-11: Endringsnivå, AR(2) parametere	65
Tabell 6-12: In sample måltall, Ar(p) på endringsnivå	65
Tabell 6-13: Resultater Engle Granger kointegrasjon og Granger kausalitetstest	67
Tabell 6-14: Johansen kointegrasjonstest, resultat	68
Tabell 6-15: Parametere for VECM for metallene Kobber, Aluminium og Nikkel	69
Tabell 6-16: VECM kointegrasjonslikninger 1	69
Tabell 6-17: VECM endelige parameter	70
Tabell 6-18: VECM kointegrasjonslikninger 2 (endelige parameter)	70
Tabell 6-19: Måltall VECM in sample	71
Tabell 7-1: Out of sample måltall, oppsummerende tabell	73
Tabell 7-2: Out of sample måltall, naive modell (pris og endringsnivå)	74
Tabell 7-3: Out of sample måltall, futures som prognose og basismodellen	75
Tabell 7-4: Out of sample måltall, OLS(3) - prisnivå	78
Tabell 7-5: Out of sample måltall, AR(p)	80
Tabell 7-6: Out of sample måltall, VECM	81
Tabell 8-1: Komplette tabell med in sample og out of sample prognoserresultater	87

Figuroversikt

Figur 2-1:	Kobberproduksjon i verden	12
Figur 2-2:	Prosentvis kobberforbruk etter sektorer	13
Figur 2-3:	Utvinning av kobber i % for 2022	13
Figur 2-4:	Reserver av kobber i % for 2022	13
Figur 2-5:	Aluminium etterspørsel i ulike sektorer	14
Figur 2-6:	Aluminium produksjon 2022 i %	15
Figur 2-7:	Aluminium etterspørsel i verden	15
Figur 2-8:	Aluminiumsproduksjon i verden	15
Figur 2-9:	Nikkel etterspørsel i ulike sektorer	16
Figur 2-10:	Utvinning av nikkel i % for 2022	17
Figur 2-11:	Reserver av nikkel i % for 2022	17
Figur 2-12:	Nikkel Verdensproduksjon 2001 – 2022	17
Figur 2-13:	Kobolt etterspørsel i ulike sektorer	18
Figur 2-14:	Utvinning av kobolt i % for 2022	19
Figur 2-15:	Reserver av kobolt i % for 2022	19
Figur 2-16:	Kobolt Verdensproduksjon 2001 - 2022	19
Figur 3-1:	Månedlig prisutvikling (spot) dollar per tonn 2002-2022	21
Figur 3-2:	Indeksert prisutvikling 2002-2022. Prisenivå satt til 100 i juli 2010	24
Figur 3-3:	Relative priser kobber mot de tre andre metallene 2002-2022	25
Figur 3-4:	Årlig prisendring 2002-2022	26
Figur 3-5:	Rullerende standardavvik (5 år), perioden 2002-2022	28
Figur 3-6:	Kobber - Sesongplot for månedlig logaritmisk prisendring	29
Figur 3-7:	Rullerende korrelasjon 3 år (prisendring)	30
Figur 5-1:	Illustrert rullerende treningssett. I gult predikert verdi fra siste steg	40
Figur 5-2:	In og out of sample som en funksjon av modellkompleksitet	41
Figur 7-1:	Futures som prognose for spot, grafet prognose 01.06.19 til 01.12.22	77
Figur 7-2:	Basismodellen, grafet prognose 01.06.19 til 01.12.22	78
Figur 7-3:	OLS prognosepresentasjon for samtlige metaller	80
Figur 7-4:	Ar (p) modeller på endringsnivå, prestasjoner	81
Figur 7-5:	VECM prognosepresentasjon for kobber, aluminium og nikkel	83

Forkortelser brukt i oppgaven

AIC - Akaike information criterion

AR(p) - Autoregressive (p)

ARIMA - Autoregressive integrated moving average

ARMA - Autoregressive Moving Average

BDI - Baltic Dry indeksen

DMA - Dynamic model averaging

DMS - Dynamic model selection

ECM - Error correction model

ECT - Error correction term

KPSS - Kwiatkowski-Phillips-Schmidt-Shin

LIB - lithium-ion batterier

LME - London Metal Exchange

LMEX - London Metal Exchange index

MAE - Mean absolute error

MAPE - Mean Absolute Percentage Error

MLP - multi-layer perceptron

MSE - Mean square error

NYMEX - New York Mercantile Exchange

OLS (n) - Ordinary Least Squares

RMSE - Root-mean-square error

S&P 500 - Standard and Poor's 500

VAR - Vector autoregression

VECM - Vector Error Correction Model

VIX - Chicago Board Options Exchange Market Volatility Index

WTI - West Texas Intermediate

1 Innledning

Metallene kobber, aluminium, nikkel og kobolt er sentrale for utviklingen av den moderne industrien og har lange røtter tilbake i historien. Det grønne skiftet vil antagelig øke etterspørselen for disse metallene ytterligere da vi blant annet ser et stadig større behov for å gå fra den klassiske forbrenningsmotoren over til batteridrevet teknologi. Metallene kan være involvert direkte i batteriteknologien eller indirekte i form av legeringer eller som bestander for å redusere vekten av eksempelvis kjøretøy. Usikkerheten rundt tilbud og etterspørsel vil neppe bli mindre i tiden fremover. Denne usikkerheten har videre en tendens til å forårsake volatile priser. I så tilfelle kan en god prisprognose være et verktøy for å redusere usikkerheten.

Verdensøkonomien er i stadig endring og ved høy- og lavkonjekturer i BNP, er det ikke unaturlig at etterspørselen etter metaller raskt endres. Dooley & Lenihan (2005) hevder at metallprisen er uelastisk. På tilbudssiden kan det ta tid å øke produksjonen, ettersom smelteverk og gruver trenger tillatelser, tilgang på nok råmaterialer og strøm. I tillegg kreves det store investeringer for å respondere på en større økning i etterspørselen. Disse forholdene er med på å påvirke prisutviklingen til metallene. Det kan være medvirkende faktorer som på en side utløser et økt behov for risikostyring fra aktører, og på den andre siden aktører som ønsker å profitere på risikokapital. Dette vil gjøre en god prisprognose svært verdifull.

Med dette som bakgrunn ønsker studien å besvare problemstillingen: **«Kan metallpriser prognostiseres?»**. Studien eksperimenterer med tidsseriemodeller i forsøk på å prognostisere spotprisen en måned frem i tid for metallene kobber, aluminium, nikkel og kobolt.

Prognostisering er naturligvis en utfordrende øvelse, og metallpriser har en historie for å være volatile. Det finnes flere ulike modeller som kan benyttes i forsøket på prognostisering av metallpriser. Den enkleste modellen kjent som den naive modellen blir vanligvis benyttet som en benchmark (målestokk). For å forsøke og finne en bedre prognose har vi undersøkt futures som prognose for spotprisen, en modell som tar utgangspunkt i basis mellom futurespris og spotpris, en Ordinary Least Squares (OLS)/Autoregressive (AR) modell på pris/endringsnivå, og avslutningsvis en mer kompleks vector error correction model (VECM).

Hvilken periode man benytter som treningsdata (in sample) og testdata (out of sample), samt hvor lang tidshorison man ønsker å prognostisere kan ha stor betydning (Brooks, 2019; Dooley & Lenihan, 2005; Hyndman & Athanasopoulos, 2018). I denne studien benyttes månedlige data hvor in sample perioden er fra 01.06.2010 - 01.05.2019 (70%), mens out of sample er 01.06.2019 - 01.12.2022 (30%), totalt 151 observasjoner.

Det er gjennomført mange ulike studier på prognoser, men ikke fullt så mange rettet mot metallpriser. Dooley og Lenihan (2005) har forsøkt metallprisprognostisering gjennom ARIMA modellering, mens Reeve og Vigfusson (2010) undersøker kortsiktige prisprognoser for blant annet kobber, aluminium og nikkel ved å benytte respektive futureskontrakter. Metaller fraktes over store områder og Baltic Dry er en kjent tørrlastindeks. Bakshi et al. (2011) undersøker hvorvidt denne indeksen kan ha en prediktiv evne på metallprisene. Vi nevner innledningsvis det grønne skiftet og en særlig relevant studie tilknyttet dette er gjennomført av Mo og Jeon (2018). De undersøker dynamikken mellom etterspørselen etter elektriske kjøretøy og metallprisen på blant annet kobolt og nikkel. Det er et felt som virker å bli mer og mer interessant, og i 2016 undersøkte Kuo (2016) prognoseevnen på metaller gjennom VECM.

Denne studien forsøker empirisk å teste om enkle modeller og den mer kompliserte VECM modellen kan gi en bedre prognose enn den naive modellen. Studien kombinerer funn fra tidligere litteratur i utvelgelsen av variabler som vi benytter i vår VECM. Dette inkluderer variablene Baltic Dry, chilensk pesos, australsk dollar, VIX og US industriell produksjon.

Oppgaven er strukturert slik at de fire metallene presenteres individuelt i kapittel 2. Kapittel 3 omfatter beskrivende statistikk for metallene, og videre gjennomgår tidligere litteratur i kapittel 4. Kapittel 5 redegjør for oppgavens metode og datainnsamling, og i kapittel 6 og 7 presenteres resultatene for henholdsvis in sample og out of sample. Kapittel 8 diskuterer funnene og avslutningsvis presenteres oppgavens konklusjon i kapittel 9.


2 Presentasjon av metaller

Dette kapittelet presenterer de fire metallene vi benytter i oppgaven herav kobber, aluminium, nikkel og kobolt. Vi ser kort på produksjonsprosessen, hvilke land som er de største produsentene, hvem som har de største reservene og hvilke sektorer med høyest forbruk av metallet.

2.1 Kobber


Fremstillingen av kobber starter ved at råmalmen blir knust til pulver, hvor kobbermineraler må skilles ut fra andre metaller med påfølgende flotasjon. Fremstillingen av kobber foregår enten som en termisk prosess som krever mye energi, eller som en løsningsprosess hvor konsentrater løses opp. Kobber blir ofte brukt i ren form, det vil si uten legeringer fra andre metaller. Det kan også brukes i diverse legeringer eksempelvis i form av messing (blanding av kobber-sink) (Pedersen, 2023b).

Kobber er et av de få metallene som har en naturlig høy elastisitet samt gode termiske lederegenskaper, som vil si at metallet leder varme godt. I tillegg er kobber ganske motstandsdyktig for nedbrytning og korrosjoner, hvilket gjør metallet spesielt godt egnet til ledninger og elektriske komponenter (Buncic & Moretto, 2015). Tilbudet av kobber er ifølge Buncic & Moretto (2015) relativt uelastisk, noe som fører til en rask endring i pris ved endring av etterspørselen. Dette sett i sammenheng med at kobber er dominant i sentrale industrier, gjør at kobberprisen kan være en tidlig indikator på økonomisk aktivitet. Figur 2-1 viser en jevn stigning i verdens totale kobberproduksjon fra 2002 til 2022.



Figur 2-1: Kobberproduksjon i verden. - Kilde: (NERC, 2023)


Mesteparten av kobberforbruket går til produksjon av utstyr og maskiner etterfulgt av bygg og anlegg. Dette er illustrert i figur 2-2 under.



Figur 2-2: Prosentvis kobberforbruk etter sektorer. Kilde: (Canada, 2023c)


Slik vi ser av figur 2-3 står Chile for den største kobberutvinningen, etterfulgt av Kongo og Peru. Chile har også de største kjente kobber reservene i verden, etterfulgt av Australia, Peru og Russland som vi ser av figur 2-4 under.

Utvinning, kobber (mine) 2022



Figur 2-3: Utvinning av kobber i % for 2022.
- Kilde: (NERC, 2023)

Verdens reserver, kobber- 2022




Figur 2-4: Reserver av kobber i % for 2022.
- Kilde: (Center, 2023)

2.2 Aluminium


Aluminium er svært stabilt og regnes som et lettmetall som enkelt kan formes ved eksempelvis valsing eller pressing. For å fremstille aluminium trenger man bauxitt som råstoff. Dette blir gjort om til aluminiumoksid i en såkalt bayerprosess. Deretter blir aluminiumen fremstilt ved at aluminiumoksid løses i kryolitt og aluminiumfluorid ved varme på 950 grader celsius. Spaltingen skjer ved elektrolyse. Aluminiumsproduksjon er svært strømkrevende og ofte blir slik produksjon lagt til steder hvor strømprisen er lav (Pedersen, 2023a).

Aluminium har bedre elektriske egenskaper enn kobber. Dette i kombinasjon med at det er veldig lett (tetthet på bare $2,7\text{g/cm}^3$) samt en relativt lav pris, gjør at metallet benyttes i eksempelvis kraftledninger hvor lav vekt er ønskelig. På grunn av sine egenskaper som blant annet lav vekt, blir aluminium som vi kan se av figur 2-5 mye brukt i bil og transportindustri, bygg og anlegg (konstruksjoner) samt folie og emballasje.




Figur 2-5: Aluminium etterspørsel i ulike sektorer. - Kilde: (Canada, 2023a)

Kina har som vi kan se av henholdsvis figur 2-6 og figur 2-7 den desidert høyeste produksjonen og etterspørselen etter aluminium med over 55% av totalen. Dette gjør at blant annet politiske og økonomiske endringer i Kina kan ha en stor innvirkning på aluminium sin prisutvikling.




Figur 2-6: Aluminium produksjon 2022 i %. - Kilde: (Center, 2023)



Figur 2-7: Aluminium etterspørsel i verden. - Kilde: (Canada, 2023a)

Slik vi ser av figur 2-8 har det vært en jevn vekst i aluminiumsproduksjonen siden 2002 til 2022.




Figur 2-8: Aluminiumsproduksjon i verden. - Kilde: (Center, 2023)

2.3 Nikkel

Metallisk nikkel ble først fremstilt i 1751, men har sine røtter lengre tilbake mest sannsynlig som legeringer sammen med kobber. Nikkel fremstilles ved å knuse sulfidiske malmer, for deretter å skille ut svovelet fra metallene i malmen, nærmere bestemt kobber, nikkel, kobolt og jern. Nikkelet (og de andre metallene) blir så ytterligere skilt ut gjennom ulike prosesser blant annet kjemisk behandling og elektrolyser.


Nikkel kan lett smis, vales og trekkes. En ren form for nikkel er motstandsdyktig mot korrosjoner, og i luft oksideres det svært sakte. Nikkel benyttes hovedsakelig som legering sammen med eksempelvis stål, kobber, sink og aluminium. Nikkel er motstandsdyktig for høye temperaturer, korrosjoner i sjøvann og i alkaliløsninger, og er derfor fordelaktig å benytte som legering i slike sammenhenger. Nikkel er anvendelig i batteriteknologien, men er også å finne i maskiner, konstruksjoner og elektriske komponenter (Kofstad, 2023). Mesteparten av nikkel går til rustfritt stål som illustrert i figur 2-9.



Figur 2-9: Nikkel etterspørsel i ulike sektorer. - Kilde: (Canada, 2023d)


Indonesia er den største utvinneren av nikkel med nesten 50% av markedet som vi ser av figur 2-10. Det er også som illustrert i figur 2-11 det landet sammen med Australia som har størst reserver etterfulgt av Brasil. Kina er den største forbrukeren av nikkel med over 50% av markedet.

Utvinning, nikkel (mine) 2022




Figur 2-10: Utvinning av nikkel i % for 2022. - Kilde: (Center, 2023)

Reserver, nikkel 2022



Figur 2-11: Reserver av nikkel i % for 2022. - Kilde: (Center, 2023)


Slik vi ser av figur 2-12 har det vært en generell vekst i nikkelproduksjonen siden 2002 med unntak av enkelte år med nedgang.



Figur 2-12: Nikkel Verdensproduksjon 2001 - 2022. - Kilde: (Canada, 2023d)

2.4 Kobolt


Kobolt ble i 1735 fremstilt i metallisk form for første gang. På 1900-tallet begynte kobolt å bli benyttet til såkalte superlegeringer for å håndtere temperatur. Metallet er lite utsatt for korrosjon i luft og vann ved normale temperaturer. I nyere tid anvendes kobolt hovedsakelig i batteriteknologi og i fremstillingen av finelektronikk som datamaskiner og lignende (Pedersen, 2022). Som vi ser av figur 2-13 benyttes mesteparten av koboltproduksjonen til el-biler (batteripakker), etterfulgt av mindre batterier.




Figur 2-13: Kobolt etterspørsel i ulike sektorer. - Kilde: (Canada, 2023b)

Kobolt er å finne i jordskorpen i form av metaller, i tillegg til maganknoller som befinner seg på havbunnen. Havbunnen er ansett å inneholde et potensiale på hele 9,8 milliarder tonn. Grunnet lav prosentandel kobolt i malm er kobolt en relativt kompleks produksjon. Ofte fremstilles kobolt som et biprodukt ved fremstillingen av kobber. Kobolt fremstilles ved såkalt flotasjon og røsting. Videre gjennomføres kjemiske prosesser ved elektrolyser (Pedersen, 2022).

Før 2010 var markedet preget av handel utenfor regulerte børser, hvilket ikke gir tilstrekkelig trygghet for partene rundt kjøpsprosessen, samt en mulighet for å regulere risikoen i markedet. (Blas, 2011). Kongo er den største utvinneren av kobolt med 70% av markedet, i tillegg har Kongo majoriteten av kjente kobolt reserver.

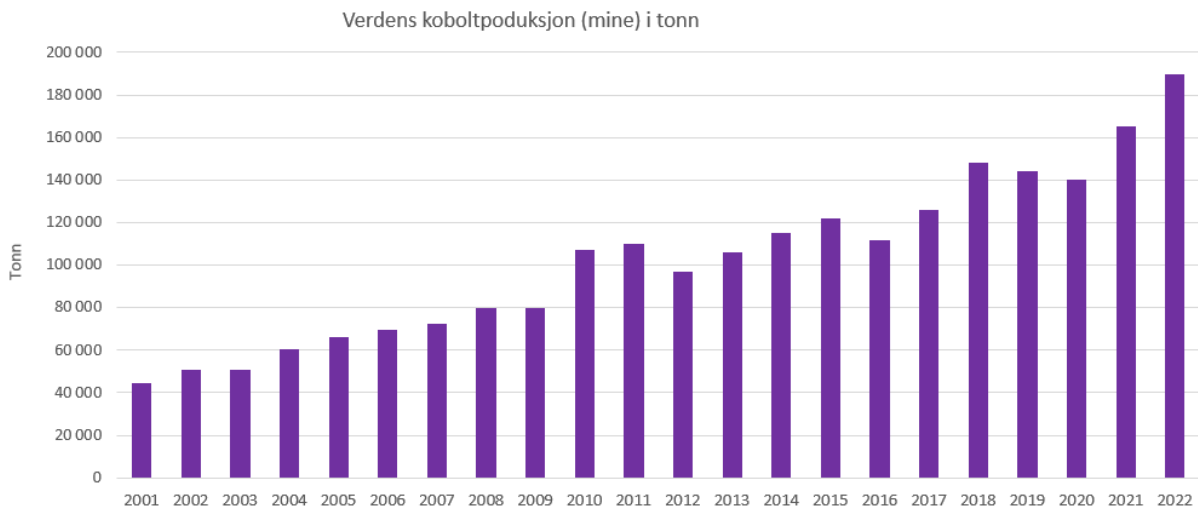


Figur 2-14: Utvinning av kobolt i % for 2022. - Kilde: (Center, 2023)



Figur 2-15: Reserver av kobolt i % for 2022. - Kilde: (Canada, 2023b; Center, 2023)

Slik vi ser av figur 2-16 har det i likhet med de andre metallene vært en jevn stigning i koboltproduksjonen fra 2001 til 2022.



Figur 2-16: Kobolt Verdensproduksjon 2001 - 2022. - Kilde: (Canada, 2023)


3 Historisk prisutvikling og beskrivende statistikk

I dette delkapittelet presenterer beskrivende statistikk tilknyttet de fire metallene.

Innledningsvis redegjør vi for metallenes prisutvikling, beskrivende statistikk for metallene, undersøkelse av sesongmønster og til slutt korrelasjoner. Vi presenterer perioden 2002 – 2022 for metallene kobber, aluminium og nikkel. Kobolt ble lansert på LME i juni 2010, og er derfor dekket fra 2010-2022. Etersom oppgaven skal teste om metallpriser kan prognostiseres én måned frem i tid benytter vi månedlige prisdata. Datamaterialet er hentet fra LME via Thomson Reuters, og alle priser er oppgitt i dollar per tonn.

3.1 Prisutvikling

I dette delkapittelet presenteres den månedlige prisutviklingen for metallene. Vi ser i figur 3-1 på neste side den månedlige prisutviklingen for hvert metall i perioden 2002 – 2022 for kobber, aluminium og nikkel, og 2010 – 2022 for kobolt.



Figur 3-1: Månedlig prisutvikling (spot) dollar per tonn 2002-2022, (2010-2022 for kobolt).

Vi kan i figur 3-1 på forrige side observere høy prisvekst i perioden fra 2002 frem til 2008 for kobber, aluminium og nikkel. Kobberprisen var i perioden preget av økende priser som følge av voksende etterspørsel fra blant annet Kina. I tillegg opplevde tilbudssiden utfordringer med å levere de mengdene som var forespeilet fra blant annet Chile og Indonesia (Morrison, 2005). Spesielt nikkel hadde en drastisk økning i denne perioden og oppnådde en pris på over 50 000\$ i mai 2007, noe som tilsvarer en økning på hele 640% fra 2002. LME mistenkte at prisene var kunstig høye, og innførte reguleringer for å unngå at sentrale aktører presset prisene. Dette førte til at lageret økte og prisforskjellen mellom spot og 3 måneders futures ble noe redusert fra et svært høyt nivå (Flood, 2007).

I perioden 2008 - mars 2009, stupte prisene på kobber, aluminium og nikkel som følge av raskt synkende etterspørsel grunnet kollapsen i finansmarkedet. Produksjonen av aluminium ble kraftig redusert ettersom aluminiumsprisen sank under «brake-even» kostnadene. Til tross for dette var det i perioden en stor økning i lagerbeholdningen som følge av et kraftig fall i etterspørselen (Flood, 2009). Lagrene av kobber og nikkel vokste også i stor grad denne perioden. Kobberprisen falt fra 8700\$ til 3100\$ tilsvarende 64%, og aluminium med 58% fra 3100 \$ til 1300 \$, mens nikkel faller over 80% fra 50000 \$ til 9600 \$ under finanskrisen.

De to neste årene etter finanskrisen er preget av oppgang. Kobberprisen tok seg kraftig opp våren 2009 og frem til februar 2011 hvor prisen hadde steget så mye som 200%. Mye av årsaken til prisveksten kan skyldes økt etterspørsel etter finanskrisen, spesielt fra Kina. Varelagrene minket og det var uro i markedet knyttet til streiker for gruveindustrien i Chile i 2010 (Webber & Farchy, 2010).

Aluminium og nikkel hadde også en økning frem mot 2011. En del av tilbyderne kuttet produksjon og etterspørselen tok seg opp igjen etter finanskrisen. En bedre balansegang mellom tilbud og etterspørsel gjorde seg gjeldende, muligens hjulpet av at Kinesiske tilbydere benyttet perioden med lave priser til å bygge opp lagerbeholdningen i stedet for mer salg (Blas, 2011). Perioden etter 2011 er preget av omtrent fem år med prisedgang for kobber, aluminium og nikkel. Det oppstod i 2010 en gjeldskrise i EU som varte over flere år, noe som kan ha bidratt til den negative prisutviklingen.

Kobolt ble lansert på LME i 2010 og fra 2005 frem til lanseringen var prisen preget av høy volatilitet (Blas, 2011). I likhet med kobber, aluminium og nikkel var koboltprisen preget av nedgang frem mot 2016 og falt fra 40 000\$ i juni 2010 til 21 000\$ i februar 2016. Etter denne nedgangen var de to neste årene preget av en voldsom prisoppgang da koboltprisen økte med hele 300%. Stadig økende etterspørsel for elbilbatterier, og usikkerhet rundt høyere skattebelastning fra Kongo, kan ha vært utslagsgivende (Sanderson, 2018b). I tillegg er det usikkerhet i markedet knyttet til andre tilbydere, ettersom Kongo står for over halvparten av verdens produksjon.

Fra toppen i april 2018 faller koboltprisen med over 70% på under 1,5 år. Økt utvinning i Kongo, kombinert med synkende etterspørsel kan ha vært utslagsgivende. Blant annet ønsker elbilprodusenten Tesla på dette tidspunkt å redusere bruken av kobolt til et minimum per produserte enhet (Sanderson, 2018a).

I perioden 2016-2018 var det igjen prisvekst for kobber, aluminium og nikkel. Årsaken til prisveksten kan delvis skyldes økt etterspørsel i forbindelse med planlegging tilknyttet det grønne skiftet. I tillegg har det i perioden oppstått uroligheter rundt en potensiell handelskrig mellom USA og Kina (Hume & Sanderson, 2018).


Vinteren og våren 2020 var starten på Covid-19 pandemien, noe som førte til betydelig usikkerhet og prisnedgang for alle de fire metallene. Verdensøkonomien merket nedstengingen av samfunnet i stor grad. For å stimulere økonomien gikk myndighetene i mange land inn og ga støtteordninger til næringslivet, noe som roet markedet og førte til økonomisk aktivitet, som igjen bidro til å hente inn prisfallet og sende metallprisene mot nye høyder. Økt etterspørsel fra Kina samt USA sine planer om å satse på grønn infrastruktur, kan ha hatt effekter på prisutviklingen (Board, 2021).

Lagerbeholdning hos LME var lav for samtlige av de fire metallene i perioden 2020-2021, samtidig som det var en økende etterspørsel. I tillegg var det usikkerhet rundt energipriser noe som potensielt vil øke produksjonskostnadene for metaller (Sanderson & Hume, 2021). Dette kan ha vært utslagsgivende faktorer som førte til økte priser i perioden.

Den 24. februar 2022 går Russland til krig mot Ukraina, noe som førte til ny bratt prisnedgang for metallene. Dette året var preget av høy volatilitet, som følge av usikkerhet tilknyttet balansen mellom tilbud og etterspørsel i tiden fremover (Hume, 2022). Usikkerhet rundt naturgass og økende energipriser var nok også utslagsgivende for et urolig år i 2022. Krigen skaper usikkerhet for markeder, forsyningsikkerhet, fremtidens sikkerhetspolitikk og maktbalanse mellom stormaktene.

3.2 Indeksert prisutvikling

For å tydeligere visualisere hvorvidt opp og nedturen følger hverandre for de fire metallene viser vi i figur 3-2 indeksert prisutvikling. Ettersom vi kun har kobolt data fra juni 2010, er prisene indeksert til 100 i juni 2010.




Figur 3-2: Indeksert prisutvikling 2002-2022. Prisnivå satt til 100 i juli 2010

Vi ser av figur 3-2 at prisene ser ut til å følge hverandre, og det er særlig to topper som utmerker seg, nemlig nikkel i 2007 og kobolt i 2018. Disse toppene ble gjort rede for i det foregående kapittelet.

3.3 Relative priser

Relative priser gir et innblikk i hvordan prisene beveger seg i forhold til hverandre, og er interessante for å se markedsdynamikken. På den måten kan vi se hvordan prisutviklingen fører til at et metall blir relativt mer eller mindre kostbart i forhold til hverandre. Figur 3-3 illustrerer hvordan aluminium, nikkel og kobolt beveger seg i forhold til kobber, noe som er ansett som ledende i markedet for andre metaller. Eksempelvis innebærer dette at dersom forholdet mellom kobber og aluminium er 2 (kobber/aluminium), så vil kobberprisen være dobbelt så høy som aluminiumprisen.




Figur 3-3 Relative priser kobber mot de tre andre metallene 2002-2022 og 2010-2022.

Vi kan observere av figur 3-3 at kobberprisen i økende grad blir mer verdt enn aluminiumsprisen i perioden. Den relative prisen starter på litt over 1, og dermed er prisen nesten lik per tonn, men ender opp med å bli hele 3,4. Med andre ord er kobberprisen 3,4 ganger så høy som aluminiumsprisen i slutten av perioden. Prisen på nikkel svekker seg noe mot kobber, mens kobolt styrker seg litt i løpet av perioden. Slik vi observerer, er det høy volatilitet og den relative prisen har vært vesentlig høyere, men også lavere i løpet av hele perioden.

3.4 Årlig prisendring

Vi ser av figur 3-4 den årlige prisendringen for de fire metallene. Årlig prisendring er utregnet ved å ta metallprisen i desember delt på prisen i januar. Vi ser at det er et marked med store årlige prisendringer. Denne figuren er ment for tydeligere å vise hvordan prisen har endret seg år for år. Slik vi ser er det flere «ekstremår», hvorav spesielt året 2006 for nikkel med en prisvekst på over 150%, og 2009 for kobber med en vekst på over 125%. I tillegg til disse to årene har det generelt vært en relativt høy prisendring hvert år. Vi har tidligere diskutert prisutviklingen gjennom perioden, og vi går derfor ikke nærmere inn på det her.



Figur 3-4: Årlig prisendring 2002-2022.

3.5 Beskrivende statistikk


Tabell 3-1 illustrerer deskriptiv statistikk på prisnivå for perioden 2010-2022. Prisene oppgis i USD/tonn. Kobber har en gjennomsnittlig pris for hele perioden på 7069 \$. Høyeste pris i perioden var april 2022 med 10 343 \$ og minste registrerte pris på 4571 \$ i februar 2016. Det årlige standardavviket er på 21,86 %. Gjennomsnittlig pris for aluminium er på 2023 \$ i hele perioden, med høyeste pris registrert mars 2022 på 3501 \$. Laveste pris er ved utgangen av finanskrisen mars 2009 med en pris på 1449 \$. Standardavviket er på 20,57 %. Gjennomsnittlig pris for nikkel i hele perioden er 16 012 \$, høyeste pris i perioden er i mai 2022 33 217\$, og laveste pris var 8 278 \$ i april 2016. Standardavviket er på 32,77%. For kobolt er gjennomsnittlig pris for hele perioden 40 289 \$. Høyeste pris er 93 550 \$ april 2018, med laveste pris på 21 648 \$ februar 2016. Standardavviket er på 31,64 % i hele perioden.

Tabell 3-1: Beskrivende statistikk, LME spotpriser per tonn 2010-2022

Beskrivende statistikk				
	Kobber	Aluminium	Nikkel	Kobolt
Gjennomsnitt	7 069	2 023	16 012	40 289
Årlig standardavvik	21,86 %	20,57 %	32,77 %	31,64 %
Minimum	4 571	1 449	8 278	21 648
Maksimum	10 343	3 501	33 217	93 550

Som illustrert forøvrig i dette delkapitlet er volatiliteten knyttet til våre metaller svært høy. På tross av at gjennomsnittlig prisendringer kan virke «mindre», beskriver de absolutte prisene, prisendringen og standardavviket svært volatile metallpriser. Potensielt er det mulig for en investor å tjene mye penger på prisendring, men det medfører samtidig en høy risiko. Nikkel og kobolt er de metallene med høyest volatilitet i perioden, men det er høyt også for kobber og aluminium.

Figur 3-5 under viser 5 års rullende standardavvik annualisert. Her er det også tydelig perioder med større volatilitet, hvor tiden rundt finanskrisen gir størst utslag.

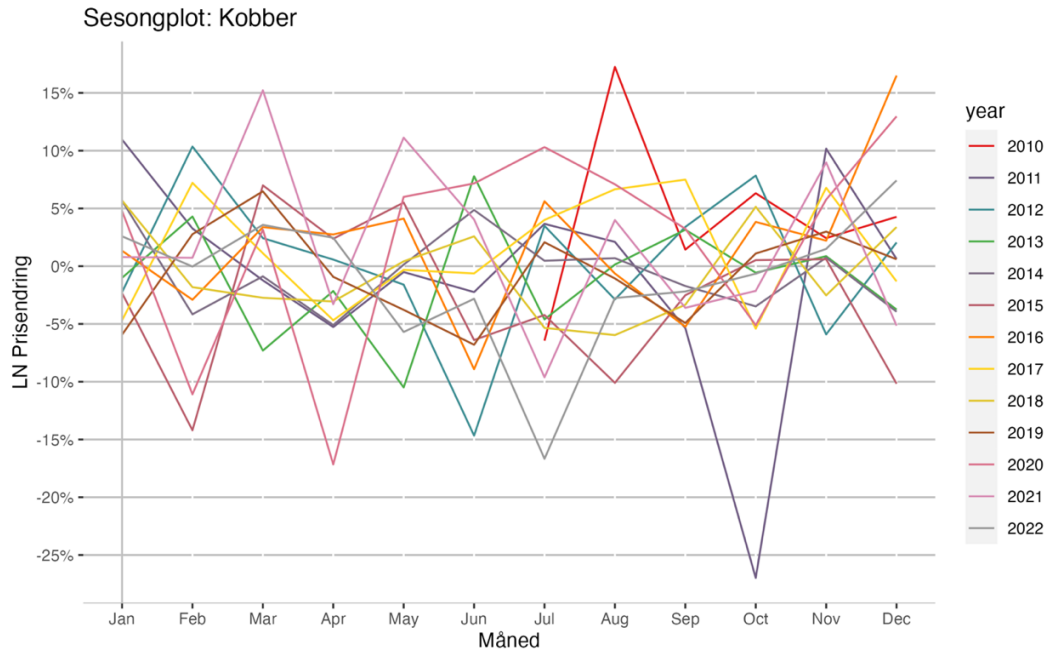


Figur 3-5 Rullende standardavvik (5 år), perioden 2002-2022

3.6 Sesongvariasjoner

Datasettet kan inneholde sesongsvingninger av deterministisk eller stokastisk karakter, hvilket kan påvirke datasettet og derav prognosene. Eventuelle sesongjusteringer og sesongjustert enhetsrot er viktig for å ikke få forstyrrelser fra sjokk, da sjokket vil påvirke i forskjellig grad. Eksempelvis vil en sesongs enhetsrot ha en permanent effekt på sesongmønsteret, i stede for å gi permanent effekt på serienivå. I studien til Watkins & McAleer (2004) går det frem at det ikke er mange studier som faktisk tester for stokastiske sesongvariasjoner med dummyvariabler.

Det kan av figur 3-6 være antydning til en sesongvariasjon for kobber i april hvor vi ser at det generelt har vært en nedadgående prisutvikling. Vi skal i kapittel 6.2 undersøke hvorvidt det er signifikante sesongeffekter for hvert metall gjennom en OLS regresjon med dummyvariabler for månedene januar – november. Tilsvarende sesongplot for de andre metallene ligger i vedlegg V1.



Figur 3-6: Kobber - Sesongplot for månedlig logaritmisk prisendring


3.7 Korrelasjoner

Tabell 3-2 viser korrelasjonsmatrise for prisendringen til metallene i perioden 2010-2022. Som vi ser er det relativt høy korrelasjon mellom kobber, aluminium og nikkel. Korrelasjonen er høyest mellom kobber og aluminium, og dette kan indikere at de påvirkes av de samme faktorene, noe som er nærliggende å tro da de begge er hyppig brukt iblant annet bygg og anlegg. Det samme gjelder korrelasjonen med nikkel ettersom mesteparten av nikkel benyttes til rustfritt stål som igjen er sentralt innen bygg og anlegg. Det er lav korrelasjon med kobolt.

Tabell 3-2: Korrelasjonsmatrise på prisendringer periode 2010-2022

2010 - 2022	Kobber	Aluminium	Nikkel
Aluminium	0,61		
Nikkel	0,56	0,55	
Kobolt	0,16	0,17	0,19

Figur 3-7 illustrer rullerende korrelasjonen på tre år mellom kobber og de andre metallene i ulike tidsperioder.



Figur 3-7 Rullerende korrelasjon 3 år (prisendring), kobber mot aluminium/nikkel/kobolt

Med det grønne skiftet på vei kan det antas at korrelasjonen mellom disse metallene vil øke i årene fremover, særlig mellom nikkel og kobolt som per i dag er meget sentrale for batteriproduksjon.

4 Tidligere litteratur

Det er gjennomført mange ulike studier på prognoser, men ikke fullt så mange rettet mot metallpriser. Dette kapittelet skal kartlegge tidligere litteratur med spesielt fokus rettet mot prognostisering av metallpriser. Først skal vi se på litt grunnleggende teori, før vi ser på andre modeller. Avslutningsvis skal vi se på tidligere brukte variabler med tanke på mer komplekse modeller.

Watkins og McAleer (2004) har gjennomført en metastudie på økonometriske modeller for «ikke-jernholdige» metaller. De har gjennomgått 45 ulike artikler utgitt mellom 1980 og 2002. Studien har hatt fokus på økonometriske analyser av priser og avkastningsmodeller for spot og futuresmarkedet til metallene aluminium, kobber, nikkel, bly, tin og sink. Studien viser at flere viktige empiriske problemer som strukturelle endringer, målefeil, overlappende data, manglende korrekt bruk av indirekte variabler, samt problemer knyttet til ikke-stasjonaritet av spot og futurespriser har blitt ignorert. Av den grunn bemerker de at selv om det i tidsperioden er gjennomført empiriske analyser på ikke-jernholdige metaller, så bør de empiriske konklusjonene i de ulike analysene vurderes med forbehold.

Fama og French (1987) ser på to kjente hypoteser tilknyttet futurespriser, «theory og storage hypothesis (eller *Cost of Carry*)» og «the risk premium hypothesis». Når det gjelder «*Theory of storage*» hypotesen tar den utgangspunkt i at variasjonen i basis kan forklares av rentekostnad, kostnaden for lagring av fysisk vare og verdien av å sitte på en fysisk vare (convenience yield). Convenience yield vil si verdi som kan oppstå ved at en aktør sitter på en fysisk vare, i den tro at prisen vil øke i spotmarkedet grunnet eksempelvis endringer i tilbud/etterspørsel. Lagerstatus vil også spille inn her, ettersom et fullt lager kan ha en negativ effekt på convenience yield. I perioder med et høyt lagernivå kan marginal lagerkostnad også være høy, noe som igjen påvirker pris (Fama & French, 1987; French, 1986)

Fama og French (1987) har undersøkt 1, 3, 6 og 12 måneders futureskontrakter i perioden mellom januar 1967 til mai 1984 for metallene gull, platina, sølv og kobber. Hvor de finner at lav basis varians for edle metaller kan være en bra prognose i *Theory of storage* modellen. Modellen baserer seg på et såkalt arbitrasjeargument ved at futuresprisen består av spotprisen

og kostnaden ved å holde råvaren (carrying cost). I så måte må futuresprisen veie opp for kostnadene frem mot forfall av kontrakten.

The Risk Premium Hypothesis en annen tilnærming som nevnes av Fama og French (1987), hvilket innebærer en mer tradisjonell fremstilling av risiko og avkastning som vi kjenner til i andre deler av finans og økonomifaget. Det vil si at differansen mellom futures pris og tidligere spotpris kan uttrykkes som en sum av en forventet risikopremie og en forventet endring av spotpris. Dette kan man bruke som utgangspunkt for prognostisering (Chow et al., 2000; Fama & French, 1987; Reeve & Vigfusson, 2010). I så måte kan den fungere i tilfeller hvor en asset ikke er en fysisk råvare som kan lagres.

Fama og French (1987) finner at en lav basis gir dårligere prognoser for risk premium hypotesen for metallene. Reeve og Vigfusson (2010) finner at det å bruke risikopremie som utgangspunkt for prognose, ikke gir bra resultat for prognose.

Futurespris

Et relevant spørsmål er om det nærliggende å anta at futurespris er tilnærmet lik den ellers uobserverbare sanne forventingen av fremtidens spotpris, og ikke minst om dette kan brukes for prognostisering. Hvis man går ut fra at markedet er i balanse, det vil si at det eksisterer likevekt i etterspørselen mellom long og short hedge, så vil futures reflektere forventet spotpris (Gjølberg, 2017).

Reeve og Vigfusson (2010) har målt prognoseevnen til futures for spotprisen og sammenlignet med en random walk og en random walk med drift. De konkluderer med at futuresprisen har vært marginalt bedre enn en random walk til å predikere spotprisen, samtidig avhenger resultatet av hvor mye futuresprisen viker fra spotpris, dette har også Fama og French (1987) diskutert. Random walk med drift prestere dårligere enn både futuresmodellen og random walk. I tilfeller hvor det er høy basis så er futuresprisen en bedre prognose enn i tilfeller med lavere basis.

I studien til Dooley & Lenihan (2005) går det frem at futures ikke kan forventes å gi en helt nøyaktig prognose, men at denne modellen presterer bra spesielt på 3 måneders tidshorison.

I studiene til Gjølberg (2017) undersøkes futuresmarkedet for olje i perioden 2000-2015.

Studien konkluderer med at futurespris gjennomsnittlig presterer bedre som prognose enn hva tidligere periodes spotpris gjør. Stasjonaritet er en utfordring her, men Gjølberg (2017) påpeker likevel at denne modellen presterer bra, men at det må forventes at standardfeilene til parameterne vil være feilaktige. Studien finner at basis (på endringsnivå) derimot gir dårligere resultat. Ustabile parameter og ulik validitet i forskjellige tidsperioder av samplet er en utfordring her. I perioder med mye usikkerhet og høy svingninger i spotpris, kan altså gi utslag på basis. Ettersom risikopremien kan variere med tiden, kan det være en mulighet å ta hensyn til contango eller backwardation inn i futuresmodeller. En annen mulighet er å prognostisere prisretningen, altså forsøke å lag en bedre prognose en tilfeldig 50/50 myntkast.

Andre modeller

Det finnes flere andre modeller for prognostisering, en av dem er ARIMA (autoregressive integrated moving average). Dooley og Lenihan (2005) har benyttet perioden 1988-1999 for å undersøke hvorvidt prisen på metallene sink og bly kan prognostiseres. De har benyttet to ulike tidsserie prognostiseringsmodeller, herav «lagede» forward priser og ARIMA. De konkluderer med at prisprognostisering er svært vanskelig i metallindustrien og at det er vanskelig å skille hvilken av de to modellene som er mest eksakte, men ut av 16 målinger har ARIMA prognostiseringen vært mest nøyaktig i ni tilfeller.

Issler et al. (2014) bruker både VAR (vector autoregression) og VECM (vector error correction model). De finner at VECM modellene presterer bra på aluminium, bly, kobber nikkell og tinn. Mo og Jeon (2018) benytter også VECM for å undersøke dynamikken mellom prisen på råvarer tilknyttet lithium-ion batterier (LIB), herunder lithium, kobolt, nikkell og mangan, med etterspørselen etter elektriske kjøretøy (EK). De har benyttet månedlige data fra 2008 til 2016. Resultatet fra deres forskning viser at etterspørselen etter EK har en påvirkning på lithium og kobolt prisen. Kobolt er mest påvirket, hvor effekten av et «sjokk» i EK etterspørselen varer i to

år. Et tilsvarende sjokk har relativt liten langsiktig betydning for lithium, nikkel og mangan. Det gjennomføres mye forskning på batteriteknologi og dersom det lykkes i å endre sammensetningen i oppladbare batterier vil det potensielt ha en innvirkning på prisdynamikken.

Buncic og Moretto (2015) benytter «*dynamic model averaging and selection (DMA/DMS)*» for å lage en månedlig prognose for LME kobber avkastning ved å benytte 18 ulike prediktor variabler. I tillegg bruker de en OLS regresjon.

Den dynamiske modellen (DMA/DMS) gir mulighet for at modellens parametere og prediktorer kan endres over tid, det vil si tar hensyn til ustabilitet i parameterne. Det argumenteres at dette er en god modell å benytte for kobber, da kobber har hatt en stor utvikling gjennom årene, fra å kun være et metall som blir benyttet i et sluttprodukt til å også være sentralt for tradere og spekulasjon.

Problemet med ustabile parameter er noe også Gjølberg (2017) finner problematisk. Ettersom etterspørselen etter hedging over tid vil variere, kan det være en fare for at parameterne også endrer seg avhengig av tidsperioden. En annen løsning kan være å dele opp i ulike perioder bestemt av typiske trekk eller trender i ulike periode. På den måten kan man få ulike prognoser for ulike perioders volatilitet.

Tilbake til den dynamiske modellen konkluderer Buncic og Moretto (2015) med at i en «out of sample» periode fra mai 2002 til juni 2014, så er DMA/DMS signifikant bedre enn en random walk til å predikere prisen. Det kan derfor tenkes at sjokk og brudd som finanskriser osv kan dra fordel av denne modellen.

Det er ikke kun fleksibiliteten til DMA/DMS som gir det gode resultatet, men de nøye utvalgte prediktor variablene med relevans for kobber har vært sentralt. Antallet forklarende variabler kan bli mange, som igjen kan føre til mange parameter i en endelig modell. Et verktøy som DMA kan lettere hjelpe til med å beregne et stort antall modellkombinasjoner uten at det er nødvendig å bruke simuleringer (Buncic & Moretto, 2015; Chen et al., 2010; Nonejad, 2021).

Maskinlæring

Liu C, Hu, Li og Liu S (2017) benytter en maskinlæringsalgoritme med valgtre (decision tree) for å predikere fremtidig kobber pris. De har benyttet daglige data fra januar 2008 til desember 2015 for syv ulike råvarer, deriblant gull, sølv og kobber. De konkluderer med at deres modell er kapabel til å predikere kobberprisen både på kort og lang sikt med en MAPE (Mean Absolute Percentage Error) på under 4%.

Zhang et al. (2021) benytter ulike maskinlæringsalgoritmer for å utvikle nye prediksjonsmodeller som kan benyttes til å predikere kobberprisen. De benytter månedlige data for perioden januar 1990 til desember 2019. De konkluderer med at “multi-layer perceptron” (MLP) neuralt nettverk som den beste modellen og at valutakursene til landene med høyest kobber produksjon, bør benyttes i prognosen. MLP er et “kunstig intelligens nettverk” og består av flere identiske enheter som er organisert i flere ulike lags. Output på lags regnes som input på det neste lags.

Rubaszek et al. (2020) analyserer prisdynamikken gjennom AR og VAR modeller for fire metaller, blant annet aluminium, kobber og nikkel. Estimatene baseres på månedlige data fra perioden 1980 til 2019. De konkluderer med at prisene beveger seg mot gjennomsnittlig pris og at modeller som tar for seg dette presterer langt bedre enn den naive random walk modellen.

Kriechbaumer et al. (2014) viser til at metallpriser ifølge tidligere forskning har klare sykliske trekk. For å trekke ut disse sykliske bevegelsene benytter de en «wavelet» analyse. En slik analyse deler tidsserien inn ulike perioder. På den måten får de identifisert sykliske mønstre som ikke nødvendigvis er synlige i den originale tidsserien. Denne analysen kombinerer de med en ARIMA modell, og konkluderer med at prognoseevnen til ARIMA modellen blir sterkt forbedret ved å kombinere den med en wavelet analyse. De har benyttet månedlige data i perioden januar 1960 til april 2012 og undersøkt metallene aluminium, kobber, bly og sink.

Valg av variabler

Valg av variabler kan være vesentlig for utfallet når mer komplekse modeller som VAR eller VECM blir benyttet. Bakshi et al. (2011) finner at vekstraten til Baltic Dry indeksen (BDI) kan være en prediktor for blant annet råvareindekser. Datasettet består av månedlige observasjoner fra mai 1985 til september 2010. BDI viser inntjeningsnivået for frakt av tørrlast som blant annet jernmalm til sjøs. Det konkluderes gjennom både statistiske og økonomiske signifikanstester med at vekstraten til BDI kan ha prediktive egenskaper for det globale råvaremarkedet. Det er verdt å merke seg at indeksene som benyttes kun tar for seg kobber av de metallene vi undersøker.

Issler et al. (2014) finner sterke sammenhenger mellom global industri produksjon og metallpriser, men noe svakere sammenheng for industriproduksjon i USA. Buncic og Moretto (2015) har også industriell produksjon i sine analyser. I tillegg benytter også de verdens kobber produksjon sammen med LME lagervolum for metallene som mål på tilbud og etterspørsel. Videre bruker de også convenience yield.

Chen et al., (2010) lanserer en ide om at det kan være nyttig å se på utvalgte lands obligasjon og aksjemarkedenes eventuelle tilknytning til råvarepriser. Å finne et mål på økonomisk aktivitet og forventinger kan være utfordrende, ettersom man må ta noen valg. Buncic og Moretto (2015) benytter S&P 500 (Standard and Poor's 500), WTI (West Texas Intermediate) Råoljeprisen, spotpris for gull, TED spread (differanse mellom U.S. 10-year Treasury Bond og the 3 month Treasury Bill rate) og VIX (Chicago Board Options Exchange Market Volatility Index).

Det er også diskusjoner om hvor vidt utvalgte valutakurser (såkalte råvarevalutaer) kan ha sammenheng med råvarepriser. Chen et al., (2010) finner at valutakurser kan være et godt utgangspunkt for prognoser for råvarer. Valutaer tilknyttet, Australia, Canada, og New Zealand er undersøkt i deres studie. Også Buncic og Moretto (2015) benytter seg av den Australske valutakursen. Tanken er å se på valutakurser for land med utpreget høy råvareeksport. Riktig nok bør disse landenes økonomier være av en vesentlig større og av betydning sett i sammenheng med verdensøkonomien og råvarehandel.

Pincheira Brown og Hardy (2019) viser at chilenske pesos har mulighet til å predikere avkastningen på LMEX (London Metal Exchange index), og på blant annet, aluminium, nikkel og kobber. Det økonomiske forholdet baseres på nåverditeori om valutakurser og at kobber står for omtrent halvparten av den chilenske eksporten og 45% av utenlandske investeringer. Deres funn indikerer at den chilenske pesos kan ha en relasjon til kobberprisen. De finner bevis for prognoseevnen både in sample og out of sample, og sammenligner sine modeller med random walk med og uten drift, samt enkel AR(1) modell. Det avdekkes «Granger kausalitet» fra den chilenske pesoen på samtlige seks metaller på kvartalsvis data, men noe mindre utslag på månedlige data. Datasettet består av månedlige data i perioden oktober 1999 til juni 2017, og kvartalsvis data for perioden Q4 1999 til Q2 2017, og det er benyttet chilensk valutakurs relativ til US Dollar.

Sykluser og sesongvariasjoner blir undersøkt av flere. Kort forklart vil forskjellen på disse to begrepene innebære at sesong er mønster i løpet av året, mens sykluser kan skje over lengre tid enn sesong. Variasjoner i produksjon eller etterspørsel kan ifølge «the theory of storage hypothesis» generere sesongvariasjoner som påvirker basis og convenience yield. French (1986) påpeker derimot at sesong ikke trenger å ha en påvirkning på metaller, etter som metaller produseres relativt gjevt over hele året. Issler et al. (2014) ser på prognostisering ved å bruke sykluser, de finner sammenhenger mellom metallprisvariasjonen og industriproduksjon både globalt, men også i noe mindre grad for USAs industriproduksjon.

5 Metode og datamateriale

I dette kapittelet skal vi presentere studiens utvalgte modeller, samt redegjøre for økonomiske hensyn som er lagt til grunn. Vi har, som nevnt innledningsvis, valgt å undersøke modellene AR/OLS, futures som prognose gjennom regresjon av spot på futuresprisen, basismodellen, samt VECM. Vi kommer nærmere inn på disse i detalj, men først skal vi se på datamaterialet, økonomiske hensyn, samt hvordan vi måler prognosene. Analysene, presentasjoner og prognoser er hovedsakelig gjennomført i R-studio og ved bruk av Excel. Datamaterialet er hentet fra Thomson Reuters.

5.1 Redegjørelse for datamateriale

I våre analyser benytter vi perioden fra juni 2010 til desember 2022 for våre variabler. Ettersom oppgaven skal teste om metallpriser kan prognostiseres én måned frem i tid benytter vi månedlige prisdata. Dette gir oss totalt 151 observasjoner. For å få lik lengde på datasettet i prognosedelen av oppgaven, setter vi startdatoen til juni 2010. Dette med tanke på at kobolt ble lansert på LME dette året. Vi benytter LME da det er den største markedsplassen for disse metallene og betraktes som en god indikator for prisene i verdensmarkedets (Kriechbaumer et al., 2014; Watkins & McAleer, 2004). Alle priser er oppgitt i US dollar per tonn. Vi benytter naturlig logaritmer i våre analyser.

5.1.1 Utelatte observasjoner og differensiering

I de tilfellene hvor vi differensierer datasettet tar vi prisen i dag minus prisen i går.

$$\Delta S_t = S_t - S_{t-1} \quad (1)$$


Ved arbeid på våre data har det naturligvis blitt noen utelatte observasjoner når vi har benyttet differensierte priser, samt ved testing med ulike lags. I slike tilfeller forsvinner den/de første verdiene i datasettet.

Ved differensiering forsvinner første observasjon og ved ulike lags forsvinner antallet observasjoner etter hvor mange lags som benyttes. Eksempelvis i en modell med 5 lags blir de 5 første observasjonene utelatt.

5.1.2 Grunnlag for in sample data

For å utvikle en prognose trenger man å ha et sample-design, og dermed trenger vi å ta noen valg angående behandlingen av in sample og out of sample. En prognose utvikles gjennom trening og testing av data. Kort fortalt går metoden ut på å dele en tidsserie opp i ulike deler, hvorav første del (in-sample) brukes for å utvikle parametere for prognosen. Out of sample utgjør siste del av tidsserien, hvor man tester sine in-sample parameter (Brooks, 2019). Vi starter på en In sample periode fra 1.6.10 til 1.5.19, mens out of sample tilsvarer 1.6.19 til 1.12.22. Det gir oss totalt 151 observasjoner per metall. Vi har gjennomført en prognose på 1 måned, med 70% in sample og 30% out of sample. Ifølge Hyndman og Athanasopoulos (2018), bør in-sample være på rundt 80%, men at det avhenger av lengden på datasettet og prognosehorisonten. Med vårt datasett vil 80% kun gi oss 30 observasjoner i out-of-sample. Vi har derfor valgt en mellomløsning ved å benytte 70% in sample, noe som gir oss 44 observasjoner i out of sample og 107 i in sample, noe vi anser som et bedre valg.

Vi velger å benytte oss av en rullerende prognose hvor antallet observasjoner in sample er fast på 107 observasjoner. Dette gjøres ved at vi flytter in sample perioden frem en verdi av gangen og lager prognose for neste måned. Den faktiske verdien blir en del av in sample i neste runde, mens den første verdien in sample utgår. Figur 5-1 på neste side illustrer denne metoden.




Figur 5-1 illustrert rullerende treningssett. I gult predikert verdi fra siste steg

Fordelen med å benytte denne varianten er at samtlige prognoser har like mange observasjoner in sample, samt at vi fjerner eldre data og erstatter det med nye oppdaterte verdier for hvert steg, noe som gjør modellen mer dynamisk. Slik sett vil modellen tilpasse seg og større svingninger lenger tilbake i tid vil etter hvert miste sin betydning. En annen fordel med dette er at man kan sammenlikne to ulike prestasjoner i to ulike perioder out of sample, ettersom antall observasjoner er fast (Tashman, 2000). Et naturlig alternativ til denne metoden hadde vært å la startdatoen for in sample være fast, slik at in sample ble lengre for hver prediksjon.

5.2 Prognosefeil og bias-variance trade-off

Når man behandler prognoser, er det viktig å ha fokus på hvor godt en modell er tilpasset dataene. Det vil si om modellen passer datasettet godt, eventuelt om den er overtilpasset (overfitted) eller motsatt undertilpasset (underfitted). Man kan dele prediksjonsfeil inn i en ikke-reduserbar feil, varians, og bias. Begrepet varians her vil si variansen av gjennomsnittet og gir oss informasjon om spredningen til predikert verdi for in sample, mens bias er en kvadrert differanse mellom gjennomsnittlig virkelig verdi og prognoseverdi. Det er viktig å understreke

at størrelsen på residualene for in sample ikke trenger å være et godt estimat for prognosefeilene for out of sample, ettersom den ikke tar høyde for kompleksiteten. Målet er å ha en bra balanse slik at prediksjonsfeilene blir lavest mulig uten at variansen eller bias er for høy. I praksis ønsker vi en modell som i størst mulig grad er midt mellom en under- og overfitted modell, for å gi minst mulig prediksjonsfeil i out of sample (Hastie, Tibshirani & Friedman (2009)).



Figur 5-2 in og out sample som en funksjon av modellkompleksitet

Figur 5-2 over illustrer «the Bias–Variance Tradeoff» inspirert av modellen til (Hastie et al., 2009). Når en modells kompleksitet øker (mange variabler), øker i tillegg variansen også, mens bias har en tendens til å være lav. Bias in sample er altså lav, og det innebærer at modellen treffer bedre, men har høy varians. Dersom modellen treffer for godt (overfitted) vil modellen adoptere seg selv for tett på in sample, og dermed vil bias bli større i out of sample. Motsatt i tilfeller hvor modellen har for få parametere (for enkel modell), da vil variansen være lav mens

bias vil være høy. Modellen vil da bli for enkel og treffer dårlig, og det er dette vi kaller en underfitted modell. Utfordringen her er å finne en balanse mellom variansen og bias, altså det såkalte Bias–Variance Tradeoff (Hastie et al., 2009).

5.3 Statistiske måltall for sammenligning av prognosemodeller

For å avgjøre hvilke modeller som presterer bedre enn andre modeller, trenger vi en metode for rangering. Dette avgjøres ved å se på differanseverdien mellom predikert verdi og virkelig verdi, dette utgjør den ikke-predikerte delen. Med utgangspunkt i dette kan vi kalkulere måltall som gir oss informasjon om hvor stor del av prognoseverdien som er en ikke-predikerte verdi. Altså hvor godt modellen presterer på in og out sample. Ulike måltall kan brukes til dette formålet, hvorav Root mean squared error (RMSE) og Mean absolute error (MAE) er vanlig å bruke. Lav verdi av MAE, vil si at prognosen søker mot median, mens lav verdi av RMSE innebærer at prognosen søker mot et gjennomsnittet. En hovedforskjell mellom RMSE og MAE, er at feilene blir kvadrert i RMSE og dermed blir store feil «straffet» i større grad enn ved bruk av MAE (Hyndman & Athanasopoulos, 2018). I denne studien vil vi kalkulere både RMSE og MAE, men ettersom en lavere RMSE vil ha høyere grad av nøyaktighet, velger vi å la RMSE avgjøre rangeringen av våre modeller.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2)$$

Likning 2 over viser utregningen av RMSE, hvor \hat{y}_i = estimert pris i periode «i» og y_i = faktisk pris i periode «i». Antall observasjoner er representert ved n. I praksis representerer RMSE å ta kvadratroten av de kvadrerte gjennomsnittlige prognosefeilene. Ved å kvadrere feilene blir også samtlige verdier positive og derfor unngås problemet ved at feilene «nuller ut» hverandre.

MAE er et annet kjent måltall for å sammenligne treffsikkerheten. I motsetning til RMSE, straffes store feil i MAE proporsjonalt i like stor grad som små feil, ettersom feilene ikke blir kvadrert. Slik navnet tilsier benytter MAE absolutte prognosefeil, og dette hindrer at feilene

«nuller ut» hverandre. Generelt tilsier en lavere MAE en mer treffsikker prognose (se likning 3 under)

$$MAE = \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{n} \quad (3)$$

Hvor y_i = faktisk pris i periode «i» og \hat{y}_i = estimert pris i periode «i».

Vår prognose ønsker å minimere de store feilene og vektlegger derfor RMSE i størst grad i denne oppgaven. Generelt tilsier et lavere måltall en mer treffsikker prognose, men det er viktig å påpeke at et lavere måltall ikke alltid betyr det beste resultatet. I enkelte tilfeller kan en modell med høyere måltall være en bedre prognose enn en modell med lave måltall.

Videre viser vi til justert r-kvadrat som forteller hvor mye av variasjonen til den avhengige variabelen som kan beskrives av den uavhengige variabelen. Det er et måltall for hvor godt modellen passer til datasettet, men det er sentralt å se r-kvadrat i sammenheng med flere faktorer, da et høyt r-kvadrat kan skyldes eksempelvis «overfitting». Likningen for r-kvadrat er som følger:

$$R^2 = 1 - \sum_{i=1}^n \frac{(y_i - \hat{y}_i)^2}{(y_i - \bar{y})^2} \quad (4)$$

Hvor y_i = faktisk pris i periode «i», \hat{y}_i = estimert pris i periode «i» og \bar{y} = gjennomsnittlig faktisk pris. For å oppnå den justerte r-kvadraten vi benytter må r-kvadraten fra likningen over benyttes i følgende likning:

$$R_j^2 = 1 - \left(\frac{n-1}{n-k-1} \right) * (1 - R^2) \quad (5)$$

Hvor n = antall observasjoner, k = antall uavhengige variabler og R^2 = r-kvadrat.

5.4 Stasjonaritet

En test for stasjonaritet er nødvendig ettersom en klassisk OLS regresjon går ut fra at alle variabler er stasjonære (Dooley & Lenihan, 2005). En stasjonær tidsserie innebærer at observerte data vil være uavhengig av hvor på tidsaksen vi befinner oss, hvilket betyr at observerte data ikke er påvirket av trend eller sesongsvingninger. En tidsserie med white noise er derfor en stasjonær tidsserie (Hyndman & Athanasopoulos, 2018).

Brooks (2019) beskriver stasjonære tidsserier som en serie med «*konstant gjennomsnitt, konstant varians og konstant autokovarians for hvert lag*». Konstant autokovariasjon vil si graden av kovariasjon mellom opprinnelig verdi og hver enkelt lags. Brooks (2019) viser til tre hovedårsaker til hvorfor det er essensielt å undersøke hvorvidt tidsserier er stasjonære. For det første vil et «sjokk» i en ikke stasjonær tidsserie ha en konstant betydning, mens i en stasjonær tidsserie vil betydningen bli mindre over tid. For det andre så kan tidsserier som er ikke-stasjonære gi «falske regresjoner». Dersom to uavhengige variabler «a og b», har lik trend, vil en regresjon med eksempelvis b på a kunne gi en høy forklart varians i R^2 , samt signifikante koeffisienter og derfor tilsynelatende se bra ut, men i realiteten er den ubrukelig. For det tredje vil ikke «t-verdier» følge en t-fordelingen og «f-verdier» vil ikke følge f-fordelingen.

Normalt sett er ikke finansielle tidsserier stasjonære, grunnet økonomisk vekst. For å gjøre ikke-stasjonære tidsserier om til stasjonære tidsserier differensieres dataene, det vil si å sette tidsserien på endringsform. Differensieringen har en stabiliserende effekt på gjennomsnittet, hvilket innebærer at variansen reduseres, noe som igjen fører til at eventuell trend og sesong blir redusert. For å undersøke hvorvidt datasettet er stasjonært, benytter vi en enhetsrot test og en stasjonaritet test, henholdsvis augmented dickey-fuller (ADF) test, og en Kwiatkowski-Phillips-Schmidt-Shin (KPSS) test.

5.4.1 Augmented Dickey-fuller - (ADF)

ADF-testen er en enhetsrot-test. Den avhengige variabel vil enten være pris på nivåform eller differensiert/endringsform. Det er ikke uvanlig at tidseriestudier av økonomisk art kan ha en

tendens til å inneholde trend grunnet økonomisk vekst (Hyndman & Athanasopoulos, 2018; Wang & Tomek, 2007). Vi inkluderer derfor en trendvariabel og konstant i vår ADF-test.

Videre må det bestemmes antallet lags i modellen. Det er et poeng å ikke inkludere for få lags, da det kan være fare for at ikke all autokorrelasjonen forsvinner. For mange lags kan derimot føre til en økning i koeffisientens standard error (Brooks, 2019). Ettersom våre data er i månedlig frekvenser, er det ifølge Brooks (2019) en grei regel å starte med 12 lags for den avhengige variabelen. Et alternativ er også å bruke informasjonskriteria som utgangspunkt, eksempelvis AIC. Vi velger å starte med 12 lags, før vi fjerner ett og ett lags frem til vi eventuelt oppnår signifikante t-verdier.

$$\Delta y = \alpha + \beta t + \lambda y_{t-1} + \sum_{i=1}^p \theta_i \Delta y_{t-i} + \varepsilon_t \quad (6)$$

Likning 6 over illustrerer ADF-test med trend og konstant. Y er avhengig variabel, α er konstant, β er trend, λ er parameter for enhetsrot, θ er koeffisient for Δy_{t-i} , og ε_t er feilledet. Ved test med konstant så er $\alpha \neq 0$ og $\beta = 0$. Testen med konstant og trend innebærer er $\alpha \neq 0$ og $\beta \neq 0$.

Tilstedeværelse av enhetsrot betyr at $\lambda = 0$, og dermed må vi beholde H_0 som uttrykker at enhetsrot er til stede og derav ikke-stasjonær. Alternativhypotesen (H_1) er at $\lambda \neq 0$, altså at tidsserien er stasjonær. For å teste hvorvidt det er en enhetsrot benytter vi Tau verdien fra ADF-testen og sammenligner med den kritiske Tau verdien på 5% nivå.

Ifølge Wang og Tomek (2007) kan ADF ha lav statistisk kraft for å utelukke ikke-stasjonære data, og en studie av Nelson og Plosser (1982) viser at ADF fungerer dårlig for tidsserier som er nær en enhetsrot. Ifølge Brooks (2019) vil ADF-testen prestere dårlig dersom det er ett eller flere strukturelle brudd i datasettet. Vi velger derfor og også inkludere en Kwiatkowski-Phillips-Schmidt-Shin test (KPSS).

5.4.2 Kwiatkowski-Phillips-Schmidt-Shin – (KPSS)

KPSS-testen er en stasjonaritetstest i motsetning til ADF som er en enhetsrotstest (Brooks, 2019). Ved KPSS-test uttrykker H_0 at det ikke finnes en enhetsrot, derav at tidsserien er stasjonær. Testen gjennomføres med en OLS regresjon se likning 7 under:

$$x_t = r_t + \beta_t + \varepsilon_t \quad (7)$$

Hvor r_t er en «random walk», β_t er deterministisk trend og ε_t er stasjonaritetsfeilen. For at vi skal avkrefte H_0 må feilledet være signifikant ulikt null. For å beregne korrekt antall lags benytter modellen følgende uttrykk ved likning 8:

$$4 * \left(\frac{T}{100}\right)^{0,25} \quad (8)$$

Hvor T er antallet observasjoner i tidsserien (Kwiatkowski et al., 1992).

5.5 Kointegrasjon og Granger kausalitet

Kointegrasjon beskriver om det finnes en langsiktig likevekt eller en stasjonær sammenheng mellom variablene i en tidsserie. Selv om variablene hver for seg ikke er stasjonære $I(0)$, kan det være at kombinasjonen mellom to variabler beveger seg sammen og er kointegrerte. Dette innebærer at variablene kan ha ulik integrasjon, men at de kan benyttes for tolkning i prognoseanalyse, eksempel hvor variabel x er $I(0)$, mens variabel Y er $I(1)$ (Brooks, 2019; Dooley & Lenihan, 2005).

Engle Granger

Vi sjekker kointegrasjon ved Engle Granger metoden ved å ta regresjon mellom variablene og deretter gjennomføre en ADF-test på residualene. Dersom ADF-testen viser at residualene er stasjonære så regner vi variablene som kointegrerte. Ettersom ADF-testen gjennomføres på

residualene fra en regresjon, er ikke de kritiske verdiene fra ADF-testen gyldig, og vi blir derfor nødt til å sammenligne t-verdien opp mot kointegrasjonstabellen til MacKinnon (MacKinnon, 2010). Se ADF likning 6 i kapittel 5.4.1 s. 43.

Johansen kointegrasjon

Johansen kointegrasjonstest tester for kointegrasjon i et system av ulike variabler. Resultatet fra johansen testen gir antallet kointegrerte relasjoner i systemet. Det er to muligheter å tolke johansen testen på, herav max eigenvalue og trace statistikk. Hypotesen tester for $r = 0$, dersom eigenvalue/trace statistikken er høyere enn kritisk verdi på 5% kan H_0 -hypotesen om 0 kointegrerte relasjoner forkastes, og vi har minimum 1 kointegrert relasjon. Neste steg er da $r \leq 1$, hvis dette nivået også forkastes har vi minimum 2 kointegrerte relasjoner. Slik fortsetter det. Dersom $r \leq K$, hvor K er antallet endogene variabler, forkastes, så betyr det at datasettet er stasjonært. Vi benytter de kritiske verdiene til Osterwald-Lenum (1992). Johansen testens input er variabler som antas å være kointegrerte.

Granger kausalitet

For å avdekke hvorvidt variabel X påvirker variabel Y benytter vi grangers kausalitetstest. Hensikten er å avdekke årsakssammenhenger. I finans kan dette forholdet ha noen unntak fra den tradisjonelle tanken om kausalitet, ettersom eksempelvis futures kan sees på som en forventet pris for fremtiden.

Utfallet kan være at x påvirker y , at y påvirker x , begge påvirker begge, eller ingen av delene. Vi gjennomfører derfor grangers kausalitetstest for å avdekke om noen variabler sammenfaller i en tidsserie.

5.6 Test for sesongvariasjon

For å undersøke hvorvidt vi har signifikante sesongvariasjoner i datasettet gjennomfører vi en regresjonsanalyse med dummyvariabler for januar til november. Dersom testen viser at en eller flere måneder har en p-verdi på minimum 5% nivå så har vi en signifikant sesongvariasjon i datasettet og vi blir nødt til å hensynta det i de videre prognosene.

$$S_t = \alpha + \sum_{i=1}^p \beta_i S_{t-i} + \lambda_{jan} + \dots + \lambda_{nov} + \varepsilon_t \quad (9)$$

Her er α = konstantledd (desember), β = stigningstall S_{t-i} = spotpris for periode i, $\lambda_{jan} + \dots + \lambda_{nov}$ = dummy variabler for månedene januar til og med november, ε_t =feilledd ved tidspunkt t.

5.7 Prognosemodeller benyttet i studien

I dette delkapittelet presenterer vi de ulike prognosemodellene vi benytter i våre analyser. For å presentere mer lesbare funksjonsuttrykk presiserer vi her at samtlige tall er på logaritmisk form. Det blir presentert i følgende rekkefølge: Naive modeller, futures som prognose, basismodellen, OLS/AR(P) og VECM.

For å ta høyde for problemet med mulig hetroskedastisitet og autokorrelasjon har vi brukt robuste standardfeil, herav Heteroskedastiske og Autokorrelasjons Konsistente Standard Feil (HACSE). Vi benytter også logaritmer på alle variabler og i alle modeller, dette for å forsøke å unngå hetroskedastisitet (Brooks, 2019).

5.7.1 Den naive modellen som benchmark

I litteraturen er det ikke uvanlig å bruke den naive modellen, også kjent som random walk modellen, som benchmark for videre modellering. Modellene sammenlignes da mot benchmark for å undersøke om modellen kan si noe mer enn en random walk. Dette gir grunnlag for å

kunne rangere og si noe om mer avanserte modeller er bedre enn en enkel naiv modell. Dette vil også denne studien ta utgangspunkt i.

Den naive modellen går ut fra at prisen eller prisendringen forrige periode er den beste prognosen for prisen i neste periode. Modellen fungerer vanligvis godt for finansielle tidsseriedata, og er optimal dersom prisen følger en random walk. Av den grunn kalles modellen også for en «random walk modell». Det er mulig å bruke den naive modellen både med og uten drift, og først skal vi se nærmere på den naive modellen uten drift på prisnivå og endringsform.

$$\hat{S}_{t+1} = S_t \quad (10)$$

Likning 10 over viser naive modell uten drift på prisnivå, hvor \hat{S}_{t+1} er prognosen 1 periode frem i tid og S_t er prisen på tidspunkt t.

$$\Delta\hat{S}_{t+1} = \Delta S_t \quad (11)$$

Likning 11 over viser naive modell uten drift på prisendring, hvor $\Delta\hat{S}_{t+1}$ er prognosen 1 periode frem i tid og ΔS_t er prisendringen på tidspunkt t.

En utvidet variant av den naive modellen, er den naive modellen med drift. Driften er gjennomsnittlig prisendring frem til tidspunkt t. Det vil si at prisen i dag pluss drift, er beste prognose for prisen i morgen. I praksis innebærer dette at man litt enkelt forklart kan dra en linje for tiden mellom første og siste observasjon, hvor man fortsetter linjen inn i fremtiden (Hyndman & Athanasopoulos, 2018). Likning 12 under viser uttrykket.

$$\hat{S}_{t+1} = \alpha + S_t \quad (12)$$

Hvor \hat{S}_{t+1} er estimert pris neste måned, S_t er pris på tidspunkt t, og α = drift, driften er gjennomsnittlig prisendring fra periodestart.

Naiv modell med drift prisendring

$$\Delta\hat{S}_{t+1} = \alpha + \Delta S_t \quad (13)$$

Likning 13 over viser naiv modell med drift på prisendring, hvor $\Delta\hat{S}_{t+1}$ er prognosen 1 periode frem i tid og ΔS_t er pris på tidspunkt t, og α = drift, driften er gjennomsnittlig prisendring fra periodestart.

5.7.2 Kan futuresprisen prognostisere spotpris?

For å undersøke om futures kan brukes i prognoser, er det viktig å undersøke om det er kointegrasjon mellom spot og futures. For en råvare forventes det at det er kointegrasjon mellom spotprisen og futuresprisen, ettersom det er samme råvare som prises, men til ulike tider. Hvis det ikke er tilfelle kan det være en indikator på at futuresprisen ikke er bra prognose for spotprisen (Watkins & McAleer, 2004).

Før vi setter opp modellene, sjekker vi alle respektive variabler for stasjonaritet og kointegrasjon. Kointegrasjon sjekker vi gjennom ADF-test for residualene og vi undersøker i tillegg Granger cause. Mer detaljer rundt denne testingen er redegjort for i kapittel 5.4.1 s. 43 og kapittel 5.5 s. 45.

Etter denne testingen setter vi opp to ulike modeller. Den første er en regresjon av spotprisen på forrige observerte futurespris og den andre kaller vi for basismodellen. Vi benytter 1 måneders horisont på futureskontrakter. Tidshorisonter over 1 måned kan føre til overlappende observasjonsproblemer, autokorrelasjon og ofte hetroskedastisitet (Gjølberg, 2017).

Regresjon av spot på futures

En vanlig metode for å teste futuresprisens prognoseevne for spotpris er å gjennomføre en regresjon av spotpris på den forrige observerte futuresprisen. Se likning 14 på neste side.

$$\hat{S}_{t+1} = \alpha + \beta(F_t) \quad (14)$$

Likning 14 over viser at prisen neste måned en lineær funksjon av futuresprisen.

\hat{S}_{t+1} = estimert pris neste periode, F_t = futuresprisen på 1 måneders kontrakt. Konstantleddet α representerer her en mulig risikopremie ved en signifikant α ulik 0. β forventes å ikke være signifikant ulik 1, hvilket indikerer en unbiased prognose. Feilleddet forventes å ha 0 i gjennomsnitt og med konstant varians.

En utfordring med en slik modell er at den er på nivåform og at spotprisen og futuresprisen er ikke-stasjonære. Gjølborg (2017) påpeker at selv om vi vet at parameterenes standardfeil kan være kunstig lave, kan det være av interesse å prognostisere om futures er en bra prognose på pris likevel.

Basismodellen

I tillegg til en standard regresjon av spotpris på futuresprisen tester vi hvorvidt basis (forskjellen mellom futurespris og spotpris) kan være en prognose for prisendringen, i vårt tilfelle, 1 måned frem i tid.

$$\Delta\hat{S}_{t+1} = \alpha + \beta(F_t - S_t) \quad (15)$$

Likning 15 over illustrerer at $\Delta\hat{S}_{t+1}$ = estimert prisendring neste periode, F_t = futuresprisen på 1 måneders kontrakt. I likhet med Likning 14 så er konstantleddet α en mulig risikopremie ved en signifikant α ulik 0. β forventes å ikke være signifikant ulik 1, hvilket indikerer en unbiased prognose. En positiv β innebærer at basis i tidspunkt t kan inneholde forklaringskraft for prisendringen i tidspunkt t+1. Feilleddet forventes å ha 0 i gjennomsnitt og med konstant varians. I denne modellen er spot og futures stasjonære på endringsform, hvilket gjør at unngår problemet med at parameterne kan ha kunstig lave standard error.

5.7.3 Prognose med OLS og Auto regressive modell - AR(p)

I en AR(p) modell avhenger dagens verdi kun av historiske verdier (for den aktuelle prisen) pluss et feilledd. En AR(p) modell predikerer verdien basert på de «p» antall foregående verdiene. Det er normalt å benytte stasjonære data i en AR-modell. Vi lager en OLS-modell og en Ar(p) modell, hvor av førstnevnte bruker ikke-stasjonære data (derav omtalt som en OLS). Som beskrevet i kapittel 5.4 byr dette på en del problematikk. Vi er klar over disse problemene, men ifølge Hyndman og Athanasopoulos (2018) kan ikke-stasjonære data gi en god prognose på kort sikt, til tross for at treffsikkerheten vil avta på lengre horisont. Ettersom vi benytter månedlige data og kun prognostiserer én måned frem i tid anser vi det som en kort horisont og velger å teste OLS med lags. Det kan også argumenteres for at det viktigste for en prognose er hvor treffsikker vi kan få den til å være i out of sample, i motsetning til økonometriske hensyn som stasjonaritet.

$$S_t = \alpha + \sum_{i=1}^p \beta_i S_{t-i} + \varepsilon_t \quad (16)$$

I likning 16 over er S_t pris på tidspunkt t, α = konstantledd, β_i = stigningstall S_{t-i} = prisen «i» måneder før tidspunkt t, og ε_t = feilledd.

5.7.4 Vector error correction model (VECM)

Dersom det er kointegrasjon mellom variablene kan en VECM benyttes (Johansen & Juselius, 1992). Denne modellen benytter en feilkorrigeringsmekanisme som tillater at man kan bruke ulike ikke-stasjonære data. Hvilket betyr at det eksisterer en lineær kombinasjon av (kointegrerte) variabler som er stasjonære, derav en langsiktig likevekt. For at en VECM-modell skal kunne benyttes må variablene være integrert i lik orden, eksempelvis I(1), altså at dataene blir stasjonære etter én differensiering. For å teste I(1) gjennomfører vi en augmented dickey

fuller (ADF) test og KPSS test, og vi benytter Engle Granger for å teste for kointegrasjon. En VECM kan estimeres slik:

$$\Delta y_t = \alpha \beta' y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta y_{t-i} + \sum_{i=0}^q \phi_i x_{t-i} + \varepsilon_t \quad (17)$$

Hvor $\beta' = \begin{pmatrix} \beta_{1,1} \dots \beta_{1,n} \\ \beta_{p,1} \dots \beta_{p,n} \end{pmatrix}$ og $\alpha = \begin{pmatrix} \alpha_{1,1} \dots \alpha_{1,n} \\ \alpha_{p,1} \dots \alpha_{p,n} \end{pmatrix}$

I Likning 17 over viser Δy_t til den førstedifferensierte av y_t . β' og α er en $p \times n$ vektor der p er antallet endogene variabler og n er antallet kointegrerte relasjoner som bestemmes av Johansen testen. Hver kolonne i β er en kointegrert vektor, og α er justeringshastigheten. α er mellom 0 og 1, jo nærmere 1 jo raskere beveges det mot likevekt. Videre er $\alpha \beta' y_{t-1}$ feilkorrigeringsmekanismen (ECT) og Γ_i er en matrise for de endogene koeffisientene, mens y_t er en vektor med de endogene variablene. ϕ_i er en vektor for de eksogene koeffisientene og x_t er en vektor med de eksogene variablene. ε_t er feilledet.

Kvaliteten i en VECM-modell kan økes ved å ta ut enkelte variabler ut av modellen. Hvis det ikke har noen effekt når vi kjører modellen på nytt, kan vi si at utelatt variabel ikke grangerforklarer i vår modell.

Valg av antall lags for VECM

Vi benytter VARselect() funksjonen i R for å definere antallet lags til VECM. Funksjonen tar imot treningssettet og returnerer anbefalt lags basert på Aikake informasjonskriterie (AIC), Hannan-Quinn Information (HQ), Schwarz Information criterion (SC), og Final prediction error (FPE). Dette gir potensielt fire ulike forslag til lags, for å avgjøre antallet lags vi benytter vi gjennomsnittet av AIC, HQ, SC og FPE.

Valg av variabler i VECM

For vår VECM har vi forsøkt å sette sammen en blanding av mål på økonomisk aktivitet og et mål på risikobildet i markedet, det er også inkludert to typiske råvarevalutaer.

Det er benyttet tidligere litteratur i jakt på variabler til VECM. Dette har ledet oss til BalticDry, VIX, US industriell produksjon, chilenske pesos mot USD og australske dollar mot USD. Disse variablene testes mot hvert metall gjennom Engle Granger kointegrasjonstest og Granger kausalitetstest. Videre sjekker vi de endogene variablene for å avdekke antall kointegrerte relasjoner gjennom Johansen kointegrasjonstest. Antallet kointegrerte relasjoner benyttes inn i VECM modellen. De ulike variablene i modellen er beskrevet som følgende:

Volatilitets indeksen (VIX) er videre kjent som en «fryktindeks» da den måler forventet 30 dagers volatilitet i det amerikanske aksjemarkedet ved å benytte prisen for kjøps- og salgsoptjoner. VIX indeksen er et globalt anerkjent mål for forventet volatilitet (CboeExchange, 2023).

Baltic Dry Index er en tørrlastindeks og er kjent for å være en god estimator for tilbud og etterspørsel for gods og råvarer. Baltic Dry Index blir ofte benyttet som en indikator for økonomisk vekst da den indikerer varestrømmen for både råvarer og ferdig produserte varer (Buncic & Moretto, 2015).

US industriell produksjonsindeks er en kjent indikator for å måle økonomisk aktivitet for USA. Dette kan være en bra indikator for økonomisk aktivitet, men samtidig er også et mål for hva som allerede er produsert. Sistnevnte er noe som kan også ødelegge noe for prognoseevnen (Buncic & Moretto, 2015).

Chilenske peso. Chile er verdens største eksportør av kobber. Chen et al., (2010) og Pincheira, Brown og Hardy(2019) kommer frem til at den chilenske pesoen kan ha en påvirkende evne for kobber-, aluminium- og nikkelpriisen.

Australsk dollar står for eksport av mange råvarer deriblant bauxit, og var i 2008 den 3. største eksportøren av kobber (Buncic & Moretto, 2015). Det er i dag flere land som eksporterer mer kobber enn Australia, men de regnes å ha 10% av kobberreservene i verden, kun Chile med 20% regnes å ha høyere reserver (Center, 2023)

Vi har etter VECM analysen in sample sett på signifikansen til de forskjellige variablene, fjernet ikke-signifikante verdier og deretter forsøkt den samme testen på nytt med et oppdatert datasett. Dette har vi gjort for å forsøke å luke ut irrelevant informasjon fra modellen.

Dette er en vanskelig øvelse da signifikansen til de ulike variablene også avhenger av hvilke variabler som er med i datasettet. Måten vi løser dette på er å benytte noe skjønn ved utplukking av ikke-signifikante variabler. Etter beste evne forsøker vi å se det i en totalsammenheng med hvordan signifikansen endrer seg mellom de ulike datasettene, samt RMSE. Vi er klar over at dette ikke er en 100% optimal metode, men det vil kreve store mengder datakraft for å håndtere alle ulike kombinasjoner med endogene og eksogene variabler. Av den grunn blir vi nødt til å sette begrensninger.

6 Presentasjon av in sample resultater

I dette kapitlet presenterer vi resultatene fra in-sample analysen. Vi redegjør også for testresultatene for stasjonaritet, kointegrasjon og granger cause. Hensikten er å avdekke hvilke variabler og modeller som skal benyttes videre i out of sample prognosen. In sample perioden er som nevnt fra 01.06.2010 til 01.05.2019. Kapitlet tester først stasjonaritet, deretter avkrefter vi sesongvariasjon for metallene, før vi avslutningsvis ser på prognoseresultatene.

6.1 Stasjonaritetstest med ADF og KPSS

Av praktiske hensyn velger vi å presentere kun de variablene som er tilknyttet alle modellene som blir presentert i denne studien. I vår utarbeidelse av VECM ble det utviklet flere modeller som presterte dårligere enn de som blir presentert i denne studien.

Tabell 6-1 på neste side viser resultatene fra ADF og KPSS testen. ADF er testet med konstant, samt med konstant og trend. ADF og KPSS testene viser noe ulike resultater. Her ser vi antallet lags i parentes ved siden av de respektive t-verdiene, «*» indikerer signifikans på 5% nivå.

Vi velger å kun behandle variabler som stasjonære på $I(0)$ dersom både ADF og KPSS viser at variabelen er stasjonær. Det vil si at vi behandler BalticDry, VIX og Australske dollar som ikke-stasjonære på tross av at ADF testen viser stasjonaritet, da KPSS viser det motsatte. Når vi differensierer er variablene stasjonære både ifølge ADF og KPSS, derav $I(1)$. Videre undersøkelse av figuren viser at kobolt på endringsform kun har tre signifikante lags med konstant og trend. Av den grunn tester vi ikke flere lags enn opp til en AR(3) modell på kobolt for å unngå problemet med ikke-stasjonaritet.

Tabell 6-1: ADF og KPSS testresultater

ADF og KPSS						
Variabel	ADF med konstant $\alpha \neq 0, \beta=0$		ADF med konstant og trend $\alpha \neq 0, \beta \neq 0$		KPSS	
	Prisnivå	Endringsnivå	Prisnivå	Endringsnivå	Prisnivå	Endringsnivå
Kobber cash	(0) -1,62	(9) -3,24 *	(0) -2,37	(9) -3,43 *	(4) 1,29	(4) 0,1*
Aluminium cash	(0) -2,08	(8) -3,38 *	(0) -2,32	(8) -3,5 *	(4) 0,65	(4) 0,07*
Nikkel cash	(0) -1,61	(12) -2,93 *	(0) -2,13	(11) -3,67 *	(4) 1,56	(4) 0,08*
Kobolt cash	(0) -1,28	(5) -2,98 *	(0) -1,51	(3) -3,88 *	(4) 0,73	(4) 0,12*
Kobber futures 1m	(0) -1,61	(9) -3,23 *	(0) -2,35	(8) -3,94 *	(4) 1,29	(4) 0,11*
Aluminium futures 1m	(0) -2,07	(8) -3,37 *	(0) -2,33	(8) -3,48 *	(4) 0,66	(4) 0,07*
Nikkel futures 1m	(0) -1,61	(12) -2,93 *	(0) -2,13	(11) -3,67 *	(4) 1,56	(4) 0,08*
Baltic Dry	(5) -3,14 *	(11) -2,99 *	(0) -3,87 *	(10) -3,95 *	(4) 0,56	(4) 0,14*
US Industrial Production Index	(0) -2,36	(4) -3,27 *	(0) -1,7	(4) -3,48 *	(4) 1,44	(4) 0,32*
Volatility Index (VIX)	(4) -2,98 *	(12) -4,12 **	(4) -3,47 *	(12) -4,12 **	(4) 1,09	(4) 0,08*
Australian Dollar to US \$	(0) -0,74	(12) -3,44 *	(1) -3,66 *	(6) -3,96 *	(4) 1,86	(4) 0,25*
Chilean Peso to US \$	(0) -0,91	(11) -2,95 *	(0) -2,68	(6) -3,87 *	(4) 1,88	(4) 0,14*

* = signifikansnivå på 5 %, i parentes antall signifikante lags

6.2 Test for sesongvariasjon

Vi har testet for hvorvidt det er signifikante sesongvariasjoner i metallprisendringene gjennom en OLS regresjon. Vi observerte i kapittel 3.6 at det potensielt kan være sesongvariasjon i april for kobber. For å teste denne antagelsen, samt teste de andre metallene for sesonggjennomfører vi regresjonsanalyse med dummyvariabler for månedene januar – november.

Regresjonens resultater kan ses i tabell 6-2 på neste side, og viser at ingen metaller har en signifikant sesongvariasjon på 5% nivå. Testen er gjennomført med robuste t-verdier (HACSE). Dette samsvarer med funnene til French (1986), som ikke fant noen bevis for sesongvariasjoner for metaller. Vi vurderer at disse resultatene gir oss grunn til å ikke ta videre hensyn for sesongvariasjoner i våre prognoser.

Tabell 6-2: Parameterestimat for sesongvariasjon 1.6.2010-1.12.2022.

Sesongtest				
	Kobber	Aluminium	Nikkel	Kobolt
Alpha	0,018 (-0,852)	0,014 (0,95)	-0,020 (-0,652)	-0,001 (-0,039)
Jan	-0,005 (-0,197)	-0,022 (-0,926)	0,029 (0,785)	0,040 (1,407)
Feb	-0,023 (-0,756)	0,001 (0,041)	0,075 (1,975)	0,003 (0,047)
Mar	0,007 (0,261)	0,010 (0,441)	0,022 (0,613)	0,047 (1,162)
Apr	-0,046 (-1,717)	-0,043 (-1,873)	-0,010 (-0,23)	-0,003 (-0,105)
May	-0,014 (-0,51)	0,001 (0,04)	0,041 (1,052)	0,012 (0,415)
Jun	-0,031 (-1,053)	-0,034 (-1,443)	-0,008 (-0,214)	-0,014 (-0,542)
Jul	-0,031 (-1,048)	-0,033 (-1,524)	0,000 (-0,003)	-0,007 (-0,221)
Aug	-0,007 (-0,239)	-0,002 (-0,067)	0,057 (1,432)	-0,038 (-1,037)
Sep	-0,026 (-1,066)	-0,006 (-0,288)	0,018 (0,407)	0,027 (0,813)
Oct	-0,033 (-1,005)	-0,016 (-0,667)	-0,001 (-0,024)	-0,008 (-0,307)
Nov	0,009 (0,345)	-0,012 (-0,515)	0,038 (0,97)	-0,022 (-0,802)

6.3 Presentasjon av in sample prognoseresultater

I dette delkapittelet presenteres resultatene fra de ulike prognosemodellene. Vi presenterer først en oppsummerende tabell for hele in sample perioden, deretter settes en benchmark for den naive modellen, før resultatene fra hver enkelt modell presenteres i følgende rekkefølge; spot som regresjon av futuresprisen, basismodellen, OLS/AR og avslutningsvis VECM. Vi minner om diskusjonen i kapittel 5.3 hvor vi valgte å forholde oss til RMSE for å rangere resultater for ulike modeller. For modellene på prisnivå vil det på grunn av ikke-stasjonaritet som nevnt i kapittel 5.4 potensielt resultere i «falske regresjoner», hvor signifikante koeffisienter ikke er gyldige, i tillegg til at forklart varians i justert R^2 kan vise kunstig høye verdier. Ifølge Hyndman & Athanasopoulos (2018) kan det som nevnt fungere som en god prognose på kort sikt. Vi har derfor valgt å teste OLS(3) modell in og out sample på tross av ikke stasjonære data, det samme

gjelder for futures som prognose for spot. Det å sette et bestemt antall lags i OLS og ikke teste mer utover det er ifølge Brooks (2019) en vanlig prosedyre.

Oppsummerende in sample resultater er presentert i tabell 6-3, rangert etter laveste RMSE verdi. På endringsform ser vi at for aluminium og kobolt er det AR modellen som presterer best. For kobber er det tilsynelatende basismodellen som gir den beste prognosen. For nikkell har vi ingen signifikante parametere verken med AR eller basismodellen. Vi skal se nærmere på detaljene rundt parameterne for de ulike modellene. Det blir en nærmere diskusjon rundt prognosen sin treffsikkerhet i kapittel 6.3.4. RMSE resultatene er gode, men lave parameterverdier gir en relativt ubetydelig prognose. På prisnivå gir VECM best resultat for aluminium, kobber og nikkell, mens OLS(3) presterte best på kobolt. Det er verdt å notere seg at nest beste RMSE-rangering er OLS (3) for alle metallene. OLS (3) er mindre kompleks modell en VECM og kan derfor være å foretrekke i tvilstilfeller.

Tabell 6-3: In sample, oppsummerende tabell

Nivå	Metall	Modell	In sample		
			RMSE	MAE	R-Kvadrat Justert
Endringsnivå	Aluminium	AR (1)	0,0544	0,0443	0,0600
		Basismodell	0,0546	0,0444	0,0541
		Naive modell uten drift	0,0750	0,0599	-0,9233
	Kobber	Basismodell	0,0602	0,0441	0,0086
		Naive modell uten drift	0,0804	0,0623	-0,8903
		AR (1-6)	Ingen signifikante parameter		
	Kobolt	AR (2)	0,0836	0,0563	0,0600
		Naive modell uten drift	0,1066	0,0768	-0,5034
		Basismodell	Ikke gjennomført		
	Nikkel	Naive modell uten drift	0,1110	0,0890	-0,7670
		Basismodell	Ikke signifikante parameter		
		AR (1-6)	Ingen signifikante parameter		
Nivåform	Aluminium	VECM	0,0467	0,0372	0,8878
		OLS (3)	0,0521	0,0429	0,8600
		Futures som prognose	0,0551	0,0442	0,8422
		Naive modell uten drift	0,0561	0,0448	0,8358
	Kobber	VECM	0,0444	0,0334	0,9461
		OLS (3)	0,0574	0,0424	0,9100
		Futures som prognose	0,0597	0,0443	0,9017
		Naive modell uten drift	0,0608	0,0452	0,8976
	Kobolt	OLS (3)	0,0822	0,0558	0,9500
		Naive modell uten drift	0,0862	0,0584	0,9394
		Futures som prognose	Ingen signifikante parameter		
		VECM	Ingen kontegrerte relasjoner		
	Nikkel	VECM	0,0761	0,0610	0,9389
		OLS (3)	0,0812	0,0683	0,9300
		Futures som prognose	0,0839	0,0701	0,9239
Naive modell uten drift		0,0847	0,0710	0,9220	

In sample (01.06.2010 - 01.05.2019)

Tabell 6-3 er rangert etter laveste RMSE-verdi for hvert metall in sample.

6.3.1 Naiv modell – Valg av Benchmark

Vi fortsetter prognosekapittelet med å sette en benchmark for prognosene. Tabell 6-4 under presenterer resultatene for den naive modellen med og uten drift. På prisnivå for aluminium, nikkel og kobolt gir den naive modellen uten drift best resultat. For kobber har den naive modellen med drift marginalt best prestasjon på in sample (differanse på 0,004), men vi skal senere i kapittel 7.1 s.73 se at for out of sample så er den naive modellen uten drift bedre en med drift. Vi velger derfor å gjøre en skjønnsmessig vurdering og benytter den minst komplekse

modellen som er den naive modellen uten drift som benchmark også for kobber. At den naive modellen presterer best uten drift er også i samsvar med funnene til Reeve og Vigfusson (2010).

Vi ser at justert R-kvadrat ligger mellom 0,83 og 0,94 for alle metallene på prisnivå. Hvilket gir en indikasjon på at den naive modellen gir en god forklaring på spotprisens varians. På endringsnivå er fremdeles den naive modellen uten drift den beste for alle metallene. Det er verdt å notere at justert R-kvadrat er negativt for samtlige metaller. Dette betyr at modellen passer datasettet svært dårlig.

Tabell 6-4 In sample, naive modell, pris og endringsnivå

Prisnivå	Naive modell uten drift			Naive modell med drift		
	RMSE	MAE	R-Kvadrat Justert	RMSE	MAE	R-Kvadrat Justert
Kobber	0,0608	0,0452	0,8976	0,0604	0,0447	0,9006
Aluminium	0,0561	0,0448	0,8358	0,0566	0,0454	0,8344
Nikkel	0,0847	0,0710	0,9220	0,0856	0,0711	0,9198
Kobolt	0,0862	0,0584	0,9394	0,0878	0,0601	0,9381

Endringsnivå						
Kobber	0,0804	0,0623	-0,8903	0,0884	0,0662	-1,2895
Aluminium	0,0750	0,0599	-0,9233	0,0798	0,0629	-1,1788
Nikkel	0,1110	0,0890	-0,7670	0,1160	0,0928	-0,9298
Kobolt	0,1066	0,0768	-0,5034	0,1089	0,0790	-0,5690

In sample (01.06.2010 - 01.05.2019)

I tabell 6-4 er beste RMSE mellom drift og uten drift uthevet i fet skrift.

6.3.2 Futures som utgangspunkt for prognoser

Vi gjennomfører futures prognosene kun på kobber, aluminium og nikkel da vi ikke har lyktes i å innhente 1 måneds futureskontrakt på kobolt. Fra stasjonaritetstesting presentert i tabell 6-1 i kapittel 6.1 s.55 ser vi at ingen av spot eller 1 måneders futuresprisene er stasjonære. Vi tester videre for kointegrasjon mellom spot og futures for å undersøke om vi kan benytte prisnivå i prognosen.

Kointegrasjon mellom spot og futures

Dersom det er kointegrasjon mellom spotprisen og laget futurespris er det mulig å bruke absolutte verdier som utgangspunkt for prognosene (Dooley & Lenihan, 2005). Dette innebærer

at vi ved kointegrasjon mellom spot og futures, har en mulighet til å prognostisere på prisnivå, men vi tar høyde for ikke-stasjonære data. H0-hypotesen er at det ikke er kointegrasjon mellom spot og futures 1 måned, mens H1-hypotesen sier at det er kointegrasjon mellom spot og futures. Det er grunn til å forvente at spot og futureskontrakten for samme råvare er kointegrerte, da futureskontrakten priser den samme råvaren, men 1 måned frem i tid. Kointegrasjon har blitt sjekket ved å gjennomføre en Engle Granger kointegrasjonstest. Tabell 6-5 under viser signifikans på 5 % nivå for samtlige par og derav er spotprisene kointegrerte med sine respektive 1 månedsfutureskontrakter. Videre har vi valgt å gjennomføre Grangers kausalitetstest, for å undersøke årsakssammenhengen i en F-test. Vi har signifikant granger kausalitet for futureskontrakten til nikkel og kobber, men ikke aluminium.

Tabell 6-5 Resultat kointegrasjon og Granger Cause, spot og 1 måned futures (f1)

Avhengig variabel	Uavhengig variabel	Kointegrasjon, DF tverdi	GrangerCause, GC pverdi
Kobber	Kobber- 1m futures	-9,759 *	0,031 *
Aluminium	Aluminium- 1m futures	-11,827 *	0,822
Nikkel	Nikkel- 1m futures	-8,609 *	0,026 *

* signifikant 5 %

Estimerte parametere, futures som prognose for spot

Tabell 6-6 under presenterer estimerte parametere for futures som prognose for spot. Aluminium er den eneste som har en signifikant $\alpha \neq 0$, noe som kan indikere at det eksisterer en risikopremie i futuresprisen til aluminium. β er for de tre metallene signifikant og relativt nært 1. Justert r-kvadrat er relativt høyt, men ettersom dette er ikke-stasjonære tidsserier så er det å forvente at disse resultatene kan vise kunstig høye justert R-kvadratverdier og kunstig lave standard feil.

Tabell 6-6: Parametere for futures som prognose for spot.

Metall	α	β	Justert R-kvadrat
Kobber	4,31E-01 (-1,434)	0,951 (27,78) **	0,902
Aluminium	0,601 (2,417) *	0,92 (27,941) **	0,842
Nikkel	0,401 (-1,691)	0,958 (38,649) **	0,924

Tabell 6-6 viser robuste t-verdier HACSE, i parentes. Signifikans: * = 5% og ** = 1%.

Estimerte parameter, basismodellen

Tabell 6-7 viser parametere for basismodellen. Basismodellen har signifikant β kun på kobber og aluminium, men det er lave betaverdier noe som vil gi en relativt flat og ubetydelig prognose. Dette kan indikere at basis har en tendens til å undervurdere prisendringen. Verdien for α er negativ for samtlige metaller, men altså ikke signifikant forskjellig fra 0. Justert r-kvadrat er svært lavt for alle metallene, hvilket indikerer at forklart varians i denne modellen er liten for prisendringen. Nikkel har ingen signifikante parametere, av den grunn blir ikke basismodellen benyttet til å teste prognoser for nikkel.

Tabell 6-7: Parametere for basismodell

Metall	α	β	Justert R-kvadrat
Kobber	-2,00E-04 (-0,0327)	0,1345 (2,0749) *	0,0086
Aluminium	-0,0011 (-0,2022)	0,2517 (2,9131) **	0,0541
Nikkel	-0,0052 (-0,6175)	0,1962 (1,8462)	0,0293

Tabell 6-7 viser robuste t-verdier HACSE, i parentes. Signifikans: * = 5% og ** = 1%

Resultater for futures som prognose for spot og basismodellen in sample

Tabell 6-8 neste side viser resultatene for in sample perioden (1.6.2010-1.5.2019). Futures som prognose for spot har relativt høy justert R-kvadrat, men som tidligere nevnt er verken futures eller spot stasjonære tidsseriedata, så justert R-kvadrat kan derfor være kunstig høy. Futures som prognose for spot har likevel med relativt liten margin klart å slå den naive modellen på alle tre metallene, målt etter RMSE.

Tabell 6-8 In sample resultater «basismodellen» og «futures som prognose»

Nivå	Metall	Modellnavn	RMSE	MAE	R-Kvadrat Justert
Endringsnivå	Aluminium	Basismodell	0,0546	0,0444	0,054
		Naive modell uten drift	0,0750	0,0599	-0,923
	Kobber	Basismodell	0,0602	0,0441	0,009
		Naive modell uten drift	0,0804	0,0623	-0,890
Nivåform	Aluminium	Futures som prognose	0,0551	0,0442	0,842
		Naive modell uten drift	0,0561	0,0448	0,836
	Kobber	Futures som prognose	0,0597	0,0443	0,902
		Naive modell uten drift	0,0608	0,0452	0,898
	Nikkel	Futures som prognose	0,0839	0,0701	0,924
		Naive modell uten drift	0,0847	0,0710	0,922

In sample (01.06.2010 - 01.05.2019)

Basismodellen har veldig lav justert R-kvadrat. Dette er en klar indikasjon på at prisendringen blir lite forklart av denne modellen. Målt i RMSE presterer begge modellene tilsynelatende bedre enn den naive modellen, men de lave β verdiene kan ødelegge for denne modellen.

Til tross for overnevnte problemstillinger velger vi å ta med begge disse modellene videre for å teste out of sample prognoseresultater.

6.3.3 OLS - Prisenivå

Her presenterer vi in sample resultatene for OLS-prognose på prisnivå med 3 lags. Tabell 6-9 viser parameterne til modellen. Vi noterer oss betaverdiene, men ettersom vi ikke kan stole på t-verdiene fra en regresjon på ikke-stasjonære data ser vi ikke nærmere på signifikansen i denne OLS modellen.

Tabell 6-9: Prisenivå OLS (3), parametere

	α	β_1	β_2	β_3	Justert R-Kvadrat
Kobber	0,41 (1,28)	0,88 (8,85) **	0,17 (1,51)	-0,10 (-1,21)	0,91
Aluminium	0,48 (1,79)	0,73 (7,76) **	0,25 (2,09) *	-0,05 (-0,45)	0,86
Nikkel	0,40 (1,49)	0,82 (8,09) **	0,26 (2,05) *	-0,13 (-1,27)	0,93
Kobolt	0,45 (1,73)	1,06 (12,73) **	0,18 (1,9)	-0,28 (-3,34) **	0,95

Tabell 6-9 viser robuste t-verdier HACSE, i parentes. Signifikans: * = 5% og ** = 1%.

Tabell 6-10 under presenterer resultatene for OLS-modellen på prisnivå. Vi noterer at RMSE og MAE er lavere på denne modellen enn benchmark.

Tabell 6-10: In-sample måltall, OLS(3) prisnivå.

Metall	Modellnavn	RMSE	MAE	R-Kvadrat Justert
Aluminium	OLS (3)	0,0521	0,0429	0,8600
	Naive modell uten drift	0,0561	0,0448	0,8358
Kobber	OLS (3)	0,0574	0,0424	0,9100
	Naive modell uten drift	0,0608	0,0452	0,8976
Kobolt	OLS (3)	0,0822	0,0558	0,9500
	Naive modell uten drift	0,0862	0,0584	0,9394
Nikkel	OLS (3)	0,0812	0,0683	0,9300
	Naive modell uten drift	0,0847	0,0710	0,9220

In sample (01.06.2010 - 01.05.2019)

6.3.4 AR(p) - Endringsnivå

Vi tester opptil 6 ulike lags på endringsnivå for å komme frem til den AR-modellen med flest signifikante lags og tar den med videre til out of sample analysen. Kobolt har ifølge KPSS testen kun 3 lags som er stasjonære, ved 4 lags er ikke koboltprisen lenger stasjonær og vi tester derfor kun opptil AR(3) på kobolt. Fra tabell 6-11 på neste side ser vi at AR(1) for aluminium og AR(2) for kobolt har signifikante parametere, mens kobber og nikkel er ikke signifikante. Det er verdt å bemerke seg at de signifikante betaverdiene er relativt lave, hvilket vil redusere betydningen for de lagde verdiene i prognosen. I tillegg har justert R kvadrat og α svært lave verdier. Dette er klare indikasjoner på at modellens prognoser blir relativt ubetydelige. Den negative betaen til aluminium indikerer at dersom prisendringen på dag 1 er positiv, vil prognosen for dag 2 være negativ. Det motsatte er tilfelle for kobolt hvor betaen er positiv.

Tabell 6-11: Endringsnivå, AR(2) parametere

	α	β_1	β_2	Justert R-Kvadrat
Kobber	0 (-0,29)	-0,1 (-1,32)	0,08 -1,02	0,00
Aluminium	0 (-0,37)	-0,25 (-2,89) * *	0,02 -0,19	0,05
Nikkel	-0,01 (-0,68)	-0,16 (-1,61)	0,11 -1,14	0,03
Kobolt	0 (-0,07)	0,08 -0,96	0,26 (3,19) * *	0,06

Tabell 6-11 viser robuste t-verdier HACSE, i parantes. Signifikans: * = 5% og ** = 1%

I tabell 6-12 under presenteres RMSE, MAE og justert r-kvadrat for den signifikante AR modellen. Vi ser at AR modellene her slår den naive modellen med ganske god margin, men som nevnt noterer vi oss problemene med lave parameter verdier.

Tabell 6-12: In sample måltall, Ar(p) på endringsnivå

	Modell	RMSE	MAE	R-Kvadrat Justert
Aluminium	AR (1) * *	0,0544	0,0443	0,0600
	Naive modell uten drift	0,0750	0,0599	-0,9233
Kobolt	AR (2) * *	0,0836	0,0563	0,0600
	Naive modell uten drift	0,1066	0,0768	-0,5034

In sample (01.06.2010 - 01.05.2019)

I tabell 6-12 er **= signifikant beta 1 %. Fet skrift = laveste RMSE

6.3.5 VECM

Ettersom våre data er ikke stasjonære på nivåform kan ikke VAR modell benyttes og vi bruker derfor en VECM. Det er svært mange ulike kombinasjoner i en VECM modell og av den grunn velger vi å kun presentere det som presterer best in sample, selv om vi har gjort vesentlig flere analyser. Vi har utforsket VECM med flere ulike variabler. Først har vi undersøkt ved å teste et stort antall variabler med granger kointegrasjon og granger kausalitet for å finne potensielle endogene og eksogene kandidater. Deretter har vi ved hjelp av skjønn og signifikante/ikke signifikante parametere kuttet ut variabler i 5 ulike omganger for å forsøke å oppnå en optimal

VECM modell. Denne metoden har ikke gitt nevneverdig gode resultater og vi har derfor i større grad vektlagt tidligere litteratur i utvelgelsen av variabler.

Det er flere fallgruver som vi var inne på i kapittel 5.7.4 s.51, men vi har valgt å velge basert på signifikans, kointegrasjon, granger cause og noe skjønn. Vi er klar over at det er mange ulike kombinasjoner og forskjellige variabler vi kan teste, men vi har etter beste evne forsøkt å komme frem til den beste modellen.

Valg av variabler, Kointegrasjon og Granger kausalitetstest

Vi har altså valgt å ta utgangspunkt i variabler tilknyttet tidligere litteratur. Vi har valgt å bruke Baltic Dry indeks som endogen variabel, og som eksogene variabler har vi: US industriell produksjon, VIX, valutaene Chilenske Pesos og Australske dollar til US dollar. Dette har vært vår utgangsposisjon, hvorpå vi tar ut enkelte variabler for å forsøksvis øke kvaliteten på prognosen. Vi redegjør for den prosessen i detalj i dette kapitlet, før vi til slutt ser nærmere på in sample måltallene.

Utgangspunktet for VECM-analysen vår er å benytte en Engle Granger kointegrasjonstest for å teste de ulike metallene parvis opp mot variablene. H0 hypotesen sier at variablene ikke er kointegrerte. Tabell 6-13 under illustrerer resultatene som viser at Baltic dry er kointegrert med kobber og aluminium. Nikkel og Kobolt er ikke kointegrert med Baltic dry eller noen andre av våre andre utvalgte variabler ifølge Engle Granger testen. Av den grunn benytter vi BalticDry som endogen variabel og det viser seg i Johansen testen for nikkel at vi har 1 kointegrert relasjon slik at VECM modellen kan kjøres. Da det kun er Baltic Dry som virker å være kointegrert blir de resterende variablene plassert som eksogene variabler i modellen.

US industriell produksjon og VIX har signifikant granger kausalitet mot kobber. Aluminium har signifikant granger kausalitet med Baltic Dry, men ingen andre. Nikkel er også granger kausal med Baltic Dry og VIX. Det er altså ikke entydig at våre utvalgte variabler kan gi en god VECM prognose, men vi må likevel gjøre noen valg. Kobolt mangler signifikante variabler både fra Engle Granger kointegrasjonstest og Granger kausalitetstest, i tillegg viser johansen

kointegrasjonstesten at det ikke er noen kointegrerte relasjoner, derfor droppes kobolt fra VECM modellen.

Ved første test av VECM benyttes de respektive metallprisene lagget 1 periode og BalticDry som endogen variabel. Når det gjelder valg av eksogene variabler, velger vi å gjennomføre med alle utvalgte variabler som planlagt i første omgang. Vi noterer oss at ikke alle er signifikante i Granger kausalitetstesten, men vi ønsker likevel å sjekke prognoseevnen før vi eliminerer eventuelle ikke-signifikante variabler. Kritisk t-verdi for kointegrasjon på 5% signifikans er 3,3377 (MacKinnon, 2010).

Tabell 6-13: Resultater Engle Granger kointegrasjon og Granger kausalitetstest

Avhengig variabel	Uavhengig variabel	Kointegrasjon, DF tverdi	GrangerCause, GC pverdi
Kobber	Baltic Dry	-3,807 *	0,107
	Austalsk dollar til US \$	-1,416	0,786
	Chile Pesos til US \$	-1,54	0,603
	US Industriell produksjon	-1,861	0,003 *
	VIX	-2,45	0,03 *
Aluminium	Baltic Dry	-3,942 *	0,046 *
	Austalsk dollar til US \$	-1,695	0,698
	Chile Pesos til US \$	-1,85	0,471
	US Industriell produksjon	-1,852	0,108
	VIX	-2,241	0,501
Nikkel	Baltic Dry	-2,983	0,022 *
	Austalsk dollar til US \$	-0,983	0,328
	Chile Pesos til US \$	-1,145	0,234
	US Industriell produksjon	-1,459	0,393
	VIX	-2,854	0,028 *
Kobolt	Baltic Dry	-2,631	0,251
	Austalsk dollar til US \$	-1,681	0,653
	Chile Pesos til US \$	-1,75	0,495
	US Industriell produksjon	-1,83	0,579
	VIX	-1,448	0,075

* signifikant 5 %

Johansen kointegrasjonstest

Neste skritt for å utvikle en VECM er å gjennomføre en Johansen kointegrasjonstest for å finne antallet kointegrerte relasjoner. Resultatene presenteres i tabell 6-14 under.

Trace statistikken og max eigen viser 1 kointegrerte relasjon for hvert metall med unntak av nevnte kobolt. Vi husker at Nikkel ikke var kointegrert med Baltic Dry ifølge Engle Granger, men Johansen testen viser at det er minimum 1 kointegrert relasjon så VECM modellen kan benyttes. Antallet kointegrerte relasjoner benyttes som en variabel inn i VECM modellen.

Tabell 6-14: Johansen kointegrasjonstest, resultat

		λ Trace	10pct	5pct	1pct
Kobber	$r \leq 1$	2,10	7,52	9,24	12,97
	$r = 0$	24,59 *	17,85	19,96	24,60
Aluminium	$r \leq 1$	2,24	7,52	9,24	12,97
	$r = 0$	23,32*	17,85	19,96	24,60
Nikkel	$r \leq 1$	3,19	7,52	9,24	12,97
	$r = 0$	22,14	17,85	19,96	24,60
Kobolt	$r \leq 1$	2,04	7,52	9,24	12,97
	$r = 0$	15,36	17,85	19,96	24,60

		λ max Eigen	10pct	5pct	1pct
Kobber	$r \leq 1$	2,10	7,52	9,24	12,97
	$r = 0$	22,49 *	13,75	15,67	20,20
Aluminium	$r \leq 1$	2,24	7,52	9,24	12,97
	$r = 0$	21,08 *	13,75	15,67	20,20
Nikkel	$r \leq 1$	3,19	7,52	9,24	12,97
	$r = 0$	18,95*	13,75	15,67	20,20
Kobolt	$r \leq 1$	2,04	7,52	9,24	12,97
	$r = 0$	13,31	13,75	15,67	20,20

Valg av antall lags

Det neste steget i VECM modellen er å definere antallet lags. Her benytter vi VARselect() i R og putter inn de endogene variablene. Vi velger antall lags som beskrevet under «valg av lags» i kapittel 5.7.4. Resultatet viser at 1 lag er det optimale for våre data.

Parametere

Undersøkelse av parameterne skjer i flere trinn. Først undersøker vi parameterne for samme utvalg variabler på alle metallene. Det vil si metallet selv og Baltic Dry som endogen, og som eksogen har vi US industriell produksjon, Chilensk pesos til US \$, Australsk dollar til US \$, og VIX. Tabell 6-15 under presenterer parameterne. Av praktiske hensyn har vi laget en presentasjon av

alle parameterne til de 3 ulike metallene. Understreker at hver bolk i tabellen er en unik VECM for hvert metall. Det samme gjelder tabellen for cointegration equation som vises under.

Tabell 6-15: Parametere for VECM for metallene Kobber, Aluminium og Nikkel

Kobber VECM	ECT	Intercept	Kobber -1	BalticDry -1
	-0,2667***	6,4633***	-0,124	-0,0906***
	US industriell Produksjon	Chilensk Pesos	Australia dollar	VIX
	-0,4264*	-0,3736**	0,1083	-0,0967***
Aluminium VECM	ECT	Intercept	Aluminium -1	BalticDry -1
	-0,0887**	2,8414*	-0,3196***	-0,0674***
	US industriell Produksjon	Chilensk Pesos	Australia dollar	VIX
	-0,6341**	0,1134	-0,1021	-0,0880***
Nikkel VECM	ECT	Intercept	Nikkel -1	BalticDry -1
	-0,1506***	3,5036	-0,2299*	-0,1103***
	US industriell Produksjon	Chilensk Pesos	Australia dollar	VIX
	-0,3628	-0,1113	-0,0992	-0,0940**

Tabell 6-16: VECM kointegrasjonslikninger 1

VECM metal	Baltic Dry
Kobber	-0,25471
Aluminium	-0,45944
Nikkel	-0,55706

Cointegration Equation

Resultatet viser at alle tre metallene har signifikante ECT (error correction term), noe som indikerer at det er en langsiktig (negativ) likevekt mellom Baltic Dry og de respektive 3 metallene. Som vi ser av Cointegration equation i tabell 6-16 har også her Baltic Dry her en negativ effekt på og de respektive 3 metallene.

Vi ser at kobberprisen lagget en periode ikke er signifikant, men aluminium og nikkel lagget en periode er signifikant for henholdsvis aluminium og nikkel. Baltic dry er signifikant for alle tre metaller.

Av de eksogene variablene, ser vi at australsk dollar til US \$ ikke er signifikante for noen av modellene. Chilensk Pesos er signifikant for kobber, men US industriell produksjon ikke er signifikant for nikkel. For å forsøke å optimalisere modellen reduserer vi antallet variabler.

Fjerner ikke-signifikante variabler - grunnlag for endelig modell

Ettersom vi ser at en del variabler er ikke-signifikante, velger vi som nevnt å ta ut disse variablene i et forsøk på å øke kvaliteten på vår prognose. Resultatet blir diskutert videre under, og det er denne modellen vi benytter videre i out of sample prognosen.

Tabell 6-17: VECM endelige parameter

Kobber VECM	ECT	Intercept	Kobber -1	BalticDry -1
	-0,2763***	5,8486***	-0,1131	-0,0911***
	US industriell Produksjon	Chilensk Pesos	Australia dollar	VIX
	-0,4057	-0,2778***	Tatt ut av modell	-0,0955***
Aluminium VECM	ECT	Intercept	Aluminium -1	BalticDry -1
	-0,0951**	3,4958***	-0,3111***	-0,0666***
	US industriell Produksjon	Chilensk Pesos	Australia dollar	VIX
	-0,6113***	Tatt ut av modell	Tatt ut av modell	-0,0881***
Nikkel VECM	ECT	Intercept	Nikkel -1	BalticDry -1
	-0,0555**	0,2647**	-0,2507**	-0,1021**
	US industriell Produksjon	Chilensk Pesos	Australia dollar	VIX
	Tatt ut av modell	Tatt ut av modell	Tatt ut av modell	-0,0758**

Tabell 6-18: VECM kointegrasjonslikninger 2 (endelige parameter)

VECM metal	Baltic Dry
Kobber	-0.2505024
Aluminium	-0.4210548
Nikkel	-1.219125

Cointegration Equation

Tabell 6-17 over tyder på at det fremdeles er signifikant ECT, altså en langsiktig (negativ) likevekt mellom de respektive 3 metallene og Baltic Dry. Vi ser også i VECM-analysens cointegrations equation (tabell 6-18), at det er tydelige negative sammenhenger også her. Vi har derfor grunn til å tro at det eksisterer en langsiktig relasjon.

Når det gjelder de kortsiktige sammenhengene ser vi at kobber lagget en periode ser ut til å ikke være signifikant, noe de andre metallenes lags er. Baltic Dry derimot er også signifikant på en periodes lags. Når det gjelder kobber ser vi at i motsetning til de andre metallenes VECM, så er ikke US industriell produksjon signifikant her. Vi testet en ny VECM uten denne variabelen,

men det førte til et svakere resultat så vi har valgt å ha med US industriell produksjon for kobber.

Ut fra parameterne kan det tyde på at kobber har en (negativ) kortsiktig likevekt med Baltic dry, chilensk Pesos til US \$, VIX og muligens også US industriell produksjon (ikke signifikant på 5% nivå). Aluminium har en kortsiktig likevekt med seg selv lagget en periode, Baltic Dry, US industriell produksjon og VIX. Nikkel har også en signifikant kortsiktig likevekt med seg selv, Baltic Dry og VIX. Når det gjelder den australske dollaren til US \$, ser det ikke ut til at den har noen kortsiktig likevekt med noen av våre metaller.

Måltall in sample VECM

Etter nøye utvelgelse av variabler har vi en komplett VECM modell. De beste resultatene fra in sample testen vises i tabell 6-19 under og sammenliknes med den naive modellen uten drift. Resultatene viser at VECM later til å prestere bra, og slår den naive modellen for samtlige metaller både på RMSE og MAE. Justert R-kvadrat er relativt høy for alle metallene.

Tabell 6-19: Måltall VECM in sample

Metall	Modellnavn	RMSE	MAE	Justert R-Kvadrat
Aluminium	Naive modell uten drift	0,0561	0,0448	0,8358
	VECM	0,0467	0,0372	0,8878
Kobber	Naive modell uten drift	0,0608	0,0452	0,8976
	VECM	0,0444	0,0334	0,9461
Nikkel	Naive modell uten drift	0,0847	0,0710	0,9220
	VECM	0,0761	0,0610	0,9389

In sample (01.06.2010 - 01.05.2019)

r

7 Presentasjon av out of sample resultater

I dette kapitlet presenteres prognoseresultatene fra out of sample. For at vi skal kunne svare nærmere på vår problemstilling «**Kan metallpriser prognostiseres?**» er målet som nevnt at en eller flere av modellene skal prestere bedre enn den beste naive modellen.

Vi presenterer først en oppsummering av resultatene i tabell 7-1 på neste side, før vi går mer i detalj på out of sample resultatene for naiv modell, futures som prognose for spotpris, basismodellen, OLS og AR(p) modell og avslutningsvis VECM. Vi vil i kapittel 8 gjennomføre dypere analyse og drøfte resultatene opp mot tidligere forskning. Vi minner om kapittel 5.3 hvor vi beskrev valget om å forholde oss til RMSE for å rangere resultatene.

Tabell 7-1 på neste side illustrerer denne studiens beste resultater fra out of sample. På endringsnivå ser vi at AR (1) har best resultat for aluminium, mens AR (2) har best resultat for kobolt. For kobber er det basismodellen som presterer best på endringsnivå. For nikkel hadde ikke parameterne signifikante verdier for basismodellen eller AR-modellen og ble derfor droppet. VECM kommer dårligst ut i samtlige forsøk. Dette står i kontrast til resultatene fra in sample. Den naive modellen presterer best på nivåform for samtlige metaller.

Tabell 7-1: Out of sample måltall, oppsummerende tabell

Nivå	Metall	Modell	In sample			Out of sample	
			RMSE	MAE	R-Kvadrat Justert	RMSE	MAE
Endringsnivå	Aluminium	AR (1)	0,0544	0,0443	0,0600	0,0654	0,0499
		Basismodell	0,0546	0,0444	0,0541	0,0663	0,0530
		Naive modell uten drift	0,0750	0,0599	-0,9233	0,0891	0,0721
	Kobber	Basismodell	0,0602	0,0441	0,0086	0,0703	0,0545
		Naive modell uten drift	0,0804	0,0623	-0,8903	0,0893	0,0687
		AR (1-6)	Ingen signifikante parameter				
	Kobolt	AR (2)	0,0836	0,0563	0,0600	0,1126	0,0840
		Naive modell uten drift	0,1066	0,0768	-0,5034	0,1612	0,1266
		Basismodell	Ikke gjennomført				
	Nikkel	Naive modell uten drift	0,1110	0,0890	-0,7670	0,1408	0,1140
		Basismodell	Ikke signifikante parameter				
		AR (1-6)	Ingen signifikante parameter				
Nivåform	Aluminium	Naive modell uten drift	0,0561	0,0448	0,8358	0,0630	0,0498
		Futures som prognose	0,0551	0,0442	0,8422	0,0667	0,0530
		OLS (3)	0,0521	0,0429	0,8600	0,0687	0,0552
		VECM	0,0467	0,0372	0,8878	0,0707	0,0555
	Kobber	Naive modell uten drift	0,0608	0,0452	0,8976	0,0690	0,0536
		OLS (3)	0,0574	0,0424	0,9100	0,0706	0,0528
		Futures som prognose	0,0597	0,0443	0,9017	0,0706	0,0536
		VECM	0,0444	0,0334	0,9461	0,0812	0,0621
	Kobolt	Naive modell uten drift	0,0862	0,0584	0,9394	0,1031	0,0729
		OLS (3)	0,0822	0,0558	0,9500	0,1065	0,0796
		Futures som prognose	Ikke gjennomført				
		VECM	Ingen kontegrerte relasjoner				
	Nikkel	Naive modell uten drift	0,0847	0,0710	0,9220	0,1063	0,0843
		Futures som prognose	0,0839	0,0701	0,9239	0,1102	0,0901
		OLS (3)	0,0812	0,0683	0,9300	0,1120	0,0927
		VECM	0,0761	0,0610	0,9389	0,1183	0,0934

In sample (01.06.2010 - 01.05.2019)

Out of sample (01.06.2019 - 01.12.2022)

Tabell 7-1 presenterer beste out of sample resultat for hver prognosemodell rangert etter RMSE

7.1 Naiv modell

For å sette benchmark til out of sample resultatene tester vi igjen den naive modellen med og uten drift. Tabell 7-2 på neste side presenterer måltallene for både pris- og endringsnivå. Den naive modellen uten drift presterer best for samtlige metaller på både RMSE og MAE. Dette står i kontrast til våre resultater for in sample for kobber på prisnivå, hvor den naive modellen med drift presterte marginalt bedre (se tabell 6-4 s. 60). Den naive modellen uten drift er derfor benchmarken videre i denne studien både på pris- og endringsnivå.

Tabell 7-2: Out of sample måltall, naive modell (pris og endringsnivå)

Prisnivå	Naive modell uten drift		Naive modell med drift	
	RMSE	MAE	RMSE	MAE
Kobber	0,0690	0,0536	0,0705	0,0551
Aluminium	0,0630	0,0498	0,0648	0,0516
Nikkel	0,1063	0,0843	0,1092	0,0878
Kobolt	0,1031	0,0729	0,1038	0,0723
Endringsnivå				
Kobber	0,0893	0,0687	0,0897	0,0691
Aluminium	0,0891	0,0721	0,0895	0,0724
Nikkel	0,1408	0,1140	0,1414	0,1144
Kobolt	0,1612	0,1266	0,1620	0,1272

Out of sample (01.06.2019 - 01.12.2022).

Grunnet den naive modellens natur ved at prognostisert pris er lik prisen forrige periode viser vi ikke prognosen i en graf.

7.2 Futuresmodeller

For futures som prognose for spot, har vi tatt med kobber, aluminium og nikkel. For basismodellen har vi kun beregnet out of sample for kobber og aluminium ettersom vi ikke har signifikant β parameter for nikkel, som vist i kapittel 6.3.2 s. 60.


Futures som prognose for spot, viser seg å være noe svakere enn den naive modellen for samtlige metaller. For basismodellen derimot, presterer modellen bedre enn den naive modellen. Vi må likevel huske på at justert R-kvadrat på in sample var negativ, hvilket må tas i betraktning. Fra kapittel 6.3.2 s. 60 husker vi også at β koeffisienten var relativt lav, hvilket også kan indikere at basismodellen gir svake prognoser.

Tabell 7-3: Out of sample måltall, futures som prognose og basismodellen

Nivå	Metall	Modellnavn	RMSE	MAE
Endringsnivå	Aluminium	Basismodell	0,0663	0,0530
		Naive modell uten drift	0,0891	0,0721
	Kobber	Basismodell	0,0703	0,0545
		Naive modell uten drift	0,0893	0,0687
Nivåform	Aluminium	Naive modell uten drift	0,0630	0,0498
		Futures som prognose	0,0667	0,0530
	Kobber	Naive modell uten drift	0,0690	0,0536
		Futures som prognose	0,0706	0,0536
	Nikkel	Naive modell uten drift	0,1063	0,0843
		Futures som prognose	0,1102	0,0901

Out of sample (01.06.2019 - 01.12.2022)

Figur 7-1 s. 76, viser grafisk hvordan futures som prognose for spot virker mer treffsikker frem mot våren 2021 enn den resterende perioden. Det kan naturligvis være mange årsaker til det resultatet, vi anser nedtrapping av COVID-19 restriksjoner som en mulig årsak, samt krigens utbrudd i Ukraina. Dette er hendelser som har ført til store svingninger i metallprisene noe modellen ikke har fanget opp. Vi observerer at det endres fra generell underprognostisering til overprognostisering rundt sommeren 2022. Det kan skyldes den kraftige prisoppgangen mot 2022 etterfulgt av en rask prisedgang.




Figur 7-1: Futures som prognose for spot, grafet prognose 1.6.19 til 1.12.22

Basismodellen

Basismodellen gir ifølge måltallene (tabell 7-3 s. 75) en markant bedre prognose av prisendringer enn benchmark for samtlige metaller. Ved å observere prognosen nærmere ser vi at basismodellen tenderer til å ha meget lave prognoser, noe som skyldes lave beta verdier

presentert i kapittel 6.3.2. Dette gjør prognoseevnen til basismodellen relativt ubetydelig for samtlige metaller. Prognosen er illustrert i figur 7-2 under.



Figur 7-2: Basismodellen, grafet prognose 1.6.19 til 1.12.22

7.3 OLS og Autoregressive modell

I in sample delen testet vi en OLS modell med 3 lags for prisnivå, og konkluderte med signifikante parametere på endringsnivå med AR(1) for aluminium og AR(2) for kobolt. Først ser vi nærmere på resultatene fra out of sample for prisnivå, deretter på endringsnivå.


Tabell 7-4 under illustrerer out of sample prestasjonene for OLS med 3 lags på prisnivå. Som vi ser presterer den naive modellen uten drift bedre enn OLS modellen for samtlige metaller målt i RMSE. Ser vi på MAE så kan det argumenteres for at OLS med 3 lags på kobber presterer marginalt bedre enn benchmarken. Dette står i kontrast til resultatene fra in sample hvor OLS(3) presterte bedre enn den naive modellen for samtlige metaller. Det kan være en indikasjon på at 3 lags er for mye noe som har gjort modellen overfitted, derav de lave måltallene i in sample.

Tabell 7-4: Out of sample måltall, OLS(3) - prisnivå

Metall	Modellnavn	RMSE	MAE
Aluminium	Naive modell uten drift	0,0630	0,0498
	OLS (3)	0,0687	0,0552
Kobber	Naive modell uten drift	0,0690	0,0536
	OLS (3)	0,0706	0,0528
Kobolt	Naive modell uten drift	0,1031	0,0729
	OLS (3)	0,1065	0,0796
Nikkel	Naive modell uten drift	0,1063	0,0843
	OLS (3)	0,1120	0,0927

Out of sample (01.06.2019 - 01.12.2022)

Fra figur 7-3 på neste side observerer vi at OLS modellene tenderer å underprognostisere prisen på samtlige metaller frem mot april/mai 2022, deretter er det noen måneder hvor det overprognostiseres. Det kan antas at overprognostiseringen rundt sommeren 2022 skyldes det raske skiftet fra bratt prisoppgang ved oppstarten av krigen i Ukraina til bratt prisnedgang.



Figur 7-3: OLS prognosepresentasjon for samtlige metaller


Tabell 7-5 på neste side presenterer resultatene for out of sample for AR(p) på endringsnivå. Hvis vi ser isolert på RMSE så vil både aluminium AR(1) og kobolt AR(2) være i stand til å slå den naive modellen. Vi minner likevel om diskusjonen i forhold til de lave parameterne som presentert i kapittel 6.3.4 s.64.

Tabell 7-5: Out of sample måltall, AR(p)

	Modell	RMSE	MAE
Aluminium	Naive modell	0,0891	0,0721
	AR (1)	0,0654	0,0499
Kobolt	Naive modell	0,1612	0,1266
	AR (2)	0,1126	0,0840

Out of sample (01.06.2019 - 01.12.2022)

De lave parameterne gjør at prognosene også blir lave, det fører videre til at differansen mellom faktisk og predikert verdi blir redusert noe som gir lavere RMSE. Med andre ord trenger ikke en lavere RMSE nødvendigvis bety en bedre prognose. Det kan være interessant å se hvorvidt modellen prognostiserer riktig prisretning, men dette ser vi ikke nærmere på i denne studien. Vi observerer av figur 7-4 under at AR modellen gir temmelig ulike prognoser for prisendringer sammenlignet med de faktiske prisendringene, noe som skyldes de lave beta verdiene. Den generelt lave prognosen viser at modellen ikke klarer å prognostisere de store utslagene.



Figur 7-4 Ar (p) modeller på endringsnivå, prestasjoner

7.4 VECM

Etter noen justeringer av inkluderte variabler i in sample oppnådde vi gode resultater for VECM. Ved å benytte de samme endogene og eksogene variablene, se tabell 6-17 s.70 i out of sample har vi ikke like gode resultater. Modellen viser høyere RMSE og MAE enn den naive modellen for samtlige metaller. Det er tenkelig at vi kan ha noen problemer med at vår modell er overfitted, ettersom modellen ser ut til å passe relativt bra in sample og ikke out of sample.


Tabell 7-6: Out of sample måltall, VECM

Metall	Modellnavn	RMSE	MAE
Aluminium	Naive modell uten drift	0,0630	0,0498
	VECM	0,0707	0,0555
Kobber	Naive modell uten drift	0,0690	0,0536
	VECM	0,0812	0,0621
Nikkel	Naive modell uten drift	0,1063	0,0843
	VECM	0,1183	0,0934

Out of sample (01.06.2019 - 01.12.2022)

Figur 7-5 under illustrer virkelig og prognostisert verdi for metallene. Vi observerer av figuren at modellen tenderer å underprognostisere ved prisoppgang og overprognostisere ved prisnedgang. Modellen virker å være mindre treffsikker ved store prisutslag og mer treffsikker der prisutviklingen er relativt flat. Dette er særlig tydelig for aluminium fra 1.6.19-1.12.19, der ser vi at prognosen virker å treffe godt på virkelig verdi. RMSE straffer store feil i større grad ettersom at feilene blir kvadrert, noe som kan skyldes de høyere RMSE verdiene. Hvis det er tilfelle kan det tenkes at modellen er god ved mindre prisendringer. Denne antagelsen blir vanskelig å støtte videre da MAE som ikke kvadrerer feilene presterer svakere for VECM kontra den naive modellen.

Det er ingen garanti for at de eksogene variablene gjør modellen bedre. I forsøk på å forbedre prognosen har vi fjernet de eksogene variablene. Resultatet viste at prognosen ikke ble nevneverdig forbedret.



Figur 7-5: VECM prognosepresentasjon for kobber, aluminium og nikkel

8 Diskusjon og tolkning av resultatene

Gjennom kapittel 7 har vi sett hvor krevende det er finne en modell som presterer bedre enn den naive modellen i out of sample. Vi vil i dette kapitlet drøfte våre resultater fra de ulike modellene opp mot den naive modellen og se det i sammenheng med tidligere litteratur.

Resultatene for alle modellene er illustrert på tabell 8-1 s.87.

Først og fremst er den naive modellen uten drift benchmarken for alle våre modeller, noe som samsvarer med resultatene til blant annet Reeve og Vigfusson (2010). For Kobber på prisnivå presterte modellen med drift marginalt bedre, men vi valgte å gjøre en skjønnsmessig vurdering og benytte uten drift som benchmark ettersom differansen var marginal (se kapittel 6.3.1 s.59). Når det gjelder sesongvariasjoner har vi i likhet med French (1986) ikke klart å finne signifikante verdier som kan indikere at prisene varierer basert på sesong.

Så kan det forventes at 1 måneds futureskontrakt kan brukes som prognose for spotpris?

Vi hadde på forhånd noen forventninger til futures som en prognosemodell for spotprisen. Årsaken til det ligger i futureskontraktens natur, ettersom futuresprisen ofte benyttes som en indikasjon på fremtidig spotpris. Våre undersøkelser viser kointegrasjon mellom spot og futures for metallene, men bare Granger cause for nikkel og kobber. Alle metallene har signifikante β -parameter, og aluminium har signifikant α , hvilket kan indikere at det eksisterer en risikopremie. Vår studie viser at med våre data så gir ikke futures som prognose for spot en bedre prognose enn den naive modellen.

Basismodellen har kun signifikant beta på kobber og aluminium, men betaverdien er til gjengjeld lav noe som gir en relativt flat prognose. Ser vi isolert på måltallene virker prognosen å være bra. Basismodellen slår den naive modell for kobber, men ved grafisk fremstilling ser vi hvor lite den faktisk prognostiserer, hvilket skyldes de lave beta verdiene. Justert R kvadrat er også svært lav. Konklusjonen er derav at basismodellen i praksis ikke presterer bedre enn den naive modellen.

Dooley & Lenihan (2005) hevder at det kan forventes at futures kan gi en bedre prognose enn den naive modellen spesielt på 3. måneder. Også Reeve og Vigfusson (2010) finner at futures

som prognose (gjennomsnittlig) overgår den naive modellen i perioder med stor forskjell mellom futures og spot. For oss var modellene ikke i stand til å slå den naive modellen uten drift. Basismodellen vår presterer dårlig, noe som samsvarer med funnene til Gjølberg (2017).

Det er en diskusjon hvor vidt det eksisterer bra prognosemodeller i futuresmarkedet, og konsensus i forskningen nok et stykke unna (Gjølberg, 2017; Reeve & Vigfusson, 2010). En mulig forklaring til at vi ikke har klart å slå den naive modellen, kan være knyttet til størrelsesforholdet på basis og standardavvik. Funnene til Fama og French (1987) indikerer at lav basis fører til bedre prognoseresultat. Gjølberg (2017) påpeker at høyt standardavvik kan føre til prognosene blir noe dårligere, ettersom markedet ikke forutser store prisendring like enkelt.

Et annet poeng Gjølberg (2017) diskuterer er svingningene i etterspørselen etter hedging. Hvis man går ut fra at futures representerer forventet fremtidig spotpris (og et balansert marked for hedging), så vil etterspørselen etter hedging variere over tid. Hvilket kan påvirke parameterne, noe som kan gi grunnlag for å dele opp samplet i ulike perioder etter grad av volatilitet i ulike tidsperioder. Av hensyn til begrensninger i oppgaven har vi ikke undersøkt dette nærmere, men dette kan være noe å undersøke nærmere i videre studier.

OLS/AR modellen er en velkjent modell benyttet på tidsseriedata. Da vi også har benyttet ikke stasjonære data ved å lage en prognose på prisnivå omtaler vi det som en OLS regresjon. Denne modellen er gjennomført med tre lags. Modellen på prisnivå blir tatt med da vi anser en potensielt god prognose som interessant å undersøke til tross for at det går på bekostning av ikke-stasjonaritet. Av resultatet i out of sample ser vi at OLS(3) ikke presterer bedre enn den naive modellen, til tross for relativt bra resultater in sample. På en side kan det bety at modellen er overfitted med tre lags og at det ville vært bedre med kun ett lag, men på en annen side det også blant annet skyldes at det er to ulike tidsperioder. Ser vi nærmere på MAE resultatene så presterer OLS(3) for kobber marginalt bedre enn den naive modellen. Dette kan skyldes at MAE ikke kvadrerer feilene, hvilket kan tenkes å gi utslag i spesielt volatile perioder.

På endringsform presterer AR modellen bedre, men på tross av lavere RMSE har vi noen problemer med denne modellen. Når vi ser nærmere på parameterne fra in sample analysen i

kapittel 6.3.4 s.64 så har vi i likhet med basismodellen svært lave betaverdier. Dette fører til en relativt ubetydelig prognose, og vi finner et problem med å blindt vektlegge RMSE. De lave betaverdiene fører til at den laggede prisendringen tillegges lite vekt i prisprognosen og prognosen blir derfor relativt ubetydelig og det blir nesten slik at kun «feilledet» gjenstår.

VECM

VECM var en krevende prosess da vi forsøkte oss på mange ulike kombinasjoner før vi landet den variabelsammensetningen som er presentert i denne studien. Utgangspunktet var å teste tørrlastindeksen Baltic Dry indeksen (BDI) og metallet som endogen variabel. Med VIX, chilensk pesos til US \$, australsk dollar til US \$, og US industriell produksjon som eksogene variabler. Det ble brukt 1 lags på endogen variabel og ingen på de eksogene variablene. Ikke alle variablene var Granger kausal i vår Granger kausalitetstest, men vi valgte å teste ut prognoseevnen likevel med bakgrunn i tidligere litteratur. Kobolt ble ikke testet, da vi ikke fant kointegrasjon mellom kobolt og tørrlastindeksen Baltic Dry.

For de andre metallene var det en klar kointegrert sammenheng mellom metallet og Baltic Dry. Bakshi et al. (2011) finner at vekstraten til Baltic Dry indeksen (BDI) kan være en prediktor for blant annet råvareindekser. Deres undersøkelse ble gjort på kobber, og vi finner at den fremdeles er relevant for kobber i tillegg til aluminium og nikkel. Våre funn tyder på en side at Baltic Dry i så måte kan ha en prediktiv verdi for å utvikle prognoser for en større del av metallmarkedet, ettersom resultatene fra Johansen kointegrasjonstest tyder på at Baltic dry er kointegrert med våre respektive metaller. På en annen side noterer vi oss at nikkel og baltic dry ikke er kointegrerte ifølge Engel Granger kointegrasjonstest. I resultatene fra Granger kausalitetstest ser vi at det bare er nikkel og aluminium som er granger kausal med baltic dry. Sammenhengen er derfor ikke helt entydig, men det er likevel noen identifikasjoner som kan peke i en retning av at det er sammenhenger.

US industriproduksjon har signifikante VECM-parametere for aluminium, hvilket de andre metallene ikke har. Kobber har til tross for ikke signifikante parameter, Granger kausalitet for US industriproduksjon, som det eneste metallet vårt. Nikkel har ingen kortsiktig likevekt med US industriproduksjon ifølge våre funn. Industrielle produksjonsindekser blir benyttet av blant

annet Buncic og Moretto (2015) og Issler et al. (2014) som finner at global industriproduksjons indeks kan være noe bedre enn for bare for US, som vi har benyttet. Muligens burde vi benyttet globale indekser, men det ser ut til at det kan være en noe prediksjonsevne ifølge våre funn.

Vi har også benyttet VIX, i likhet med Buncic og Moretto (2015). I vår Granger kausalitetstest, får vi signifikante verdier for VIX på Kobber og nikkel. Vi har signifikante parametere for VIX i VECM tilhørende kobber, aluminium og nikkel. Vi er generelt forsiktige med å erklære at det er en kausal årsakssammenheng, men det kan se ut til at VIX kan ha en prediksjonsevne for nevnte 3 metaller.

Chen et al., (2010) hevder at valutakurser kan være et godt utgangspunkt for å prognostisere råvarer. Når det gjelder australsk dollar til US \$ som også Buncic og Moretto (2015) benytter seg av, har vi grunn til å mistenke at det har liten predikasjonsverdi for våre metaller i denne perioden. Ingen av parameterne er signifikante i VECM modellen, ei heller ser vi noen Granger kausalitet i våre tester.

Chilensk pesos som bl.a Pincheira Brown og Hardy (2019) benytter, kan se ut til å ha en prognoseverdi for kobber. Ettersom Chiles eksport av kobber er nesten halvparten av landets samlede eksport, kan det gi mening at prognosen for kobber er relevant for valutaen. På en annen side bemerker vi oss at ingen av metallene er Granger kause for chilensk pesos, ei heller kobber.

Når det gjelder prognoserresultene presterte VECM best på in sample for kobber, aluminium og nikkel. Out of sample klarte den ikke å slå den naive modellen for noen av metallene målt etter RMSE. Hva dette skyldes er ikke et entydig svar. Det kan tenkes at det er et innslag av overfitting som vi har omtalt i metodekapittelet. Tendensen til å prestere veldig bra in sample, men ikke out of sample kan indikere dette. Noe som igjen kan være et tegn på at vår modell har vært for kompleks. En annen teori er at perioden vi har undersøkt har ulik volatilitet in sample vs out of sample, eller at den er svært ulik i forhold til tidligere studiers prognosehorisont. Vi er forsiktige med å fastslå at dette skyldes overnevnte forhold, men det kan tenkes at slike forhold er gjeldende. Det er også en mulighet at en annen variabelsammensetning hadde vært bedre for

prognosen. Vi har testet mange andre variabler som ikke er presentert i studien i en mer eksplorerende fase, uten å lykkes i å få en bedre prognose.

Fra vår side vil vi understreke at det er vanskelig å endelig konkludere med at våre utvalgte variabler har bestemte årsakssammenhenger eller prediksjonsevner. Diskusjonen over illustrerer at dette kan være vanskelig å konkludere med. Vi har indikasjoner på prediksjonsevne for flere av variablene, men allikevel viser ikke RMSE resultatene at VECM presterer bedre enn den naive modellen. Det vi kan si er at det kan være interessant også for andre å undersøke våre funn videre.

Tabell 8-1:Komplett tabell med in sample og out of sample prognoseresultater

Nivå	Metall	Modell	In sample			Out of sample	
			RMSE	MAE	R-Kvadrat Justert	RMSE	MAE
Endringsnivå	Aluminium	AR (1)	0,0544	0,0443	0,0600	0,0654	0,0499
		Basismodell	0,0546	0,0444	0,0541	0,0663	0,0530
		Naive modell uten drift	0,0750	0,0599	-0,9233	0,0891	0,0721
	Kobber	Basismodell	0,0602	0,0441	0,0086	0,0703	0,0545
		Naive modell uten drift	0,0804	0,0623	-0,8903	0,0893	0,0687
		AR (1-6)	Ingen signifikante parameter				
	Kobolt	AR (2)	0,0836	0,0563	0,0600	0,1126	0,0840
		Naive modell uten drift	0,1066	0,0768	-0,5034	0,1612	0,1266
		Basismodell	Ikke gjennomført				
	Nikkel	Naive modell uten drift	0,1110	0,0890	-0,7670	0,1408	0,1140
		Basismodell	Ikke signifikante parameter				
		AR (1-6)	Ingen signifikante parameter				
Nivåform	Aluminium	Naive modell uten drift	0,0561	0,0448	0,8358	0,0630	0,0498
		Futures som prognose	0,0551	0,0442	0,8422	0,0667	0,0530
		OLS (3)	0,0521	0,0429	0,8600	0,0687	0,0552
		VECM	0,0467	0,0372	0,8878	0,0707	0,0555
	Kobber	Naive modell uten drift	0,0608	0,0452	0,8976	0,0690	0,0536
		OLS (3)	0,0574	0,0424	0,9100	0,0706	0,0528
		Futures som prognose	0,0597	0,0443	0,9017	0,0706	0,0536
		VECM	0,0444	0,0334	0,9461	0,0812	0,0621
	Kobolt	Naive modell uten drift	0,0862	0,0584	0,9394	0,1031	0,0729
		OLS (3)	0,0822	0,0558	0,9500	0,1065	0,0796
		Futures som prognose	Ikke gjennomført				
		VECM	Ingen kontegrerte relasjoner				
	Nikkel	Naive modell uten drift	0,0847	0,0710	0,9220	0,1063	0,0843
		Futures som prognose	0,0839	0,0701	0,9239	0,1102	0,0901
		OLS (3)	0,0812	0,0683	0,9300	0,1120	0,0927
		VECM	0,0761	0,0610	0,9389	0,1183	0,0934

In sample (01.06.2010 - 01.05.2019)

Out of sample (01.06.2019 - 01.12.2022)

Tabell 8-1 over er identisk med tabell 7-1 på side 73, og er satt inn av praktiske årsaker for leser i diskusjonskapittelet.

9 Konklusjon

Denne oppgaven har hatt som mål å besvare problemstillingen «**Kan metallpriser prognostiseres?**». Studien har testet prognoser på pris- og endringsnivå med modellene: futures som prognose for spotprisen, basismodell, OLS/AR modell og VECM. Av dette utvalget har vi altså noen enklere tidsseriemodeller og en mer kompleks VECM. Det ble benyttet månedlige data fra LME i perioden 2010-2022, hvor hensikten var å utvikle en kortsiktig prognose 1 måned frem i tid som presterer bedre enn den naive modellen.

Studiens resultater indikerer at å prognostisere metallpriser og prisendringer med OLS/AR, futures som prognose, basismodellen eller VECM en måned frem i tid er vanskelig. Samtlige modeller presterer bedre enn den naive modellen in sample, men de gode resultatene uteble for out of sample testingen.

Den naive modellen presterer best i out of sample for alle modeller basert på RMSE, med to unntak. Basismodellen for kobber, og AR modellen for aluminium og kobolt presterer ifølge RMSE bedre enn den naive modellen, men byr på andre problemer. Basismodellen og AR modellen har lave betaverdier og gir derfor relativt ubetydelige prognoser. Dette blir spesielt tydelig når man grafer forskjellen på virkelig verdi og prognosen. Studien har derfor konkludert med at disse modellene ikke presterer bedre enn den naive modellen i praksis. Vi har et mulig funn for OLS(3) hvor MAE er marginalt bedre enn den naive modellen for kobber i out of sample. Dette kan være tilfeldig, men det kan også være noe det er verdt å undersøke videre.

Oppsummert indikerer våre resultater at studien ikke klarer å finne en modell som presterer bedre enn den naive modellen for pris- eller endringsnivå i perioden 2010-2022. Dette basert på vår avgjørelse om å rangere prestasjoner basert på RMSE.

10 Kritikk av vår studie

En svakhet ved studien var at vi ikke har fått gjennomført samtlige prognosemodeller for samtlige metaller, da vi ikke lyktes med å finne datamaterie for kobolt 1 måned futureskontrakt (LME). Nikkel på endringsnivå har ikke vært mulig å undersøke grunnet ikke-signifikante parameter for både AR og basismodellen. Kanskje hadde det vært naturlig å forsøke flere modeller på nikkel.

Naiv modell på endringsnivå hadde negativ justert R-kvadrat, hvilket vi kunne undersøkt nærmere, men vi lyktes ikke å avdekke årsaken til dette.

Denne studien har ikke gjort mer dyptgående tester på parameterne fra de ulike modellene. Testing for strukturelle brudd og stabilitet kunne vært en fordel. Identifisering av strukturelle brudd kunne gitt grunnlag for å utvikle regresjoner basert på ulike parametere. Spesielt basismodellen og AR på endringsnivå har hatt en del utfordringer knyttet til lave betaverdier. I så tilfelle kunne løsningen vært å dele opp dataene i ulike tidsperioder basert på volatilitet, noe som vil gi ulike parameter.

Når det gjelder VECM var det en utfordrerne prosess å finne en passende modell. Studien burde testet residualene i VECM for autokorrelasjon og heteroskedastisitet, i tillegg til ulike lags på de eksogene variablene. Ved å benytte ulike lags og teste for de nevnte problemstillingene kan prognosemodellen i bestefall forbedres. Det kunne også vært av interesse å undersøke impulsresponsfunksjoner og varians-dekomponering.

11 Videre forskning

Studien har et potensielt funn for kobber ved OLS(3) som har en marginalt bedre MAE enn den naive modellen. Det kan være interessant for videre forskning å gjennomføre OLS modeller med ulike lags over andre tidsperioder for å se om resultatene blir forbedret.

Det er mange varianter av prognosemodeller som kunne vært interessante å undersøke. Vi vurderer det som veldig interessant for videre forskning å undersøke hvorvidt prognosemodellene i studien kan prognostisere riktig prisretning.

Det lyktes ikke oss å bevise sesongtrender i våre analyser, men det kan være spennende å se på sykluser.

For futuresmodeller kan det være av interesse å inkludere contango og backwardation som dummyvariabel. En annen mulighet er å se om prisen for futures sist periode alene er en bra prediksjon for spot. Denne modellen har vi forsøkt på våre metaller, men vi klarte ikke å få denne modellen heller til å slå den naive. ARIMA og ECM har vi også forsøkt oss på, men av hensyn til oppgavens omfang har vi ikke gått videre med dette. Det kan være interessant å teste disse modellene ytterligere.

Når det gjelder VECM forsøkte vi å inkludere mange ulike variabler i vårt arbeid. Selv om det ikke lyktes oss, kan det være av interesse for andre å undersøke relevante aksjer for selskaper innen gruver og smelteverk. En annen ide er å inkludere lagertall, import, renter eller gjenvinning som variabler.

12 Referanseliste

- Bakshi, G., Panayotov, G. & Skoulakis, G. (2011). The Baltic Dry Index as a Predictor of Global Stock Returns, Commodity Returns, and Global Economic Activity.
https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1747345#references-widget
- Blas, J. (2011, 5. Oktober). Tumbling base metals open door for supply cuts. *Financial Times*.
<https://www.ft.com/content/83bc9112-ef27-11e0-918b-00144feab49a>
- Board, T. E. (2021, 10. mai). A very different kind of supercycle. *Financial Times*.
<https://www.ft.com/content/81779b56-3823-4205-9ed2-65e967898519>
- Brooks, C. (2019). *Introductory Econometrics for Finance* (4., Red.). Cambridge University Press.
- Buncic, D. & Moretto, C. (2015). Forecasting copper prices with dynamic averaging and selection models. *The North American journal of economics and finance*, 33, 1-38.
<https://doi.org/10.1016/j.najef.2015.03.002>
- Canada, N. R. (2023a). *Aluminum facts*. Hentet 15.03.2023 fra <https://natural-resources.canada.ca/our-natural-resources/minerals-mining/minerals-metals-facts/aluminum-facts/20510>
- Canada, N. R. (2023b). *Cobalt facts*. Hentet 15.03.2023 fra <https://natural-resources.canada.ca/our-natural-resources/minerals-mining/minerals-metals-facts/cobalt-facts/24981>
- Canada, N. R. (2023c). *Copper facts*. Hentet 15.03.23 fra <https://natural-resources.canada.ca/our-natural-resources/minerals-mining/minerals-metals-facts/copper-facts/20506>
- Canada, N. R. (2023d). *Nickel facts*. Hentet 15.03.2023 fra <https://natural-resources.canada.ca/our-natural-resources/minerals-mining/minerals-metals-facts/nickel-facts/20519>
- CboeExchange. (2023). *VIX Index*. Hentet 15.6.23 fra https://www.cboe.com/tradable_products/vix/
- Center, N. M. I. (2023). *Historical Global Statistics for Mineral and Material Commodities*. Hentet 15.3.23 fra <https://www.usgs.gov/centers/national-minerals-information-center/historical-global-statistics-mineral-and-material>
- Chen, Y.-C., Rogoff, K. S. & Rossi, B. (2010). Can Exchange Rates Forecast Commodity Prices? *The Quarterly Journal of Economics*, 125(3), 1145-1194.
<https://doi.org/10.1162/qjec.2010.125.3.1145>
- Chow, Y. F., McAleer, M. & Sequeira, J. (2000). Pricing of forward and futures contracts. *Journal of Economic Surveys*, 14(2), 215-253.
- Dooley, G. & Lenihan, H. (2005). An assessment of time series methods in metal price forecasting. *Resources policy*, 30(3), 208-217.
<https://doi.org/https://doi.org/10.1016/j.resourpol.2005.08.007>

- Fama, E. F. & French, K. R. (1987). Commodity Futures Prices: Some Evidence on Forecast Power, Premiums, and the Theory of Storage. *The Journal of business (Chicago, Ill.)*, 60(1), 55-73. <https://doi.org/10.1086/296385>
- Flood, C. (2007, 7 juni). LME intervenes in nickel market. *Financial Times*. <https://www.ft.com/content/f645ff44-1528-11dc-b48a-000b5df10621>
- Flood, C. (2009, 19 januar). Aluminium at lowest for five years. *Financial Times*. <https://www.ft.com/content/7ae78d2c-e619-11dd-8e4f-0000779fd2ac>
- French, K. R. (1986). Detecting Spot Price Forecasts In Futures Prices. *The Journal of business (Chicago, Ill.)*, 59(2), S39-S54. <https://doi.org/10.1086/296338>
- Gjølborg, O. (2017). Oil Futures Revisited. I *Finance in Society. An Anthology in Honour of Thore Johnsen* (s. 378-388). Cappelen Damm akademisk.
- Hastie, T., Tibshirani, R., Friedman, J. H. & Friedman, J. H. (2009). *The elements of statistical learning: data mining, inference, and prediction* (Bd. 2). Springer.
- Hume, N. (2022, 20 juli). Copper price bounces higher as miners cut production forecasts. *Financial Times*. <https://www.ft.com/content/8c95f946-58bc-4649-92b2-637d1e4037f9>
- Hume, N. & Sanderson, H. (2018, 4. desember). Car batteries and trade war truce energise copper price. *Financial Times*. <https://www.ft.com/content/dc1421ea-f6ea-11e8-af46-2022a0b02a6c>
- Hyndman, R. J. & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
- Issler, J. V., Rodrigues, C. & Burjack, R. (2014). Using common features to understand the behavior of metal-commodity prices and forecast them at different horizons. *Journal of international money and finance*, 42, 310-335. <https://doi.org/https://doi.org/10.1016/j.jimonfin.2013.08.017>
- Johansen, S. & Juselius, K. (1992). Testing structural hypotheses in a multivariate cointegration analysis of the PPP and the UIP for UK. *Journal of Econometrics*, 53(1-3), 211-244. <https://EconPapers.repec.org/RePEc:eee:econom:v:53:y:1992:i:1-3:p:211-244>
- Kofstad, P. K. (2023). Nikkel. I *Store norske leksikon*. <https://snl.no/nikkel>
- Kriechbaumer, T., Angus, A., Parsons, D. & Rivas Casado, M. (2014). An improved wavelet-ARIMA approach for forecasting metal prices. *Resources policy*, 39, 32-41. <https://doi.org/https://doi.org/10.1016/j.resourpol.2013.10.005>
- Kuo, C.-Y. (2016). Does the vector error correction model perform better than others in forecasting stock price? An application of residual income valuation theory. *Economic Modelling*, 52, 772-789. <https://doi.org/https://doi.org/10.1016/j.econmod.2015.10.016>
- Kwiatkowski, D., Phillips, P., Schmidt, P. & Shin, Y. (1992). Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *Journal of Econometrics*, 54(1-3), 159-178. <https://EconPapers.repec.org/RePEc:eee:econom:v:54:y:1992:i:1-3:p:159-178>

- Liu, C., Hu, Z., Li, Y. & Liu, S. (2017). Forecasting copper prices by decision tree learning. *Resources policy*, 52, 427-434. <https://doi.org/https://doi.org/10.1016/j.resourpol.2017.05.007>
- MacKinnon, J. G. (2010). *Critical values for cointegration tests*. Queen's Economics Department Working Paper.
- Mo, J. Y. & Jeon, W. (2018). The Impact of Electric Vehicle Demand and Battery Recycling on Price Dynamics of Lithium-Ion Battery Cathode Materials: A Vector Error Correction Model (VECM) Analysis. *Sustainability*, 10(8), 2870. <https://www.mdpi.com/2071-1050/10/8/2870>
- Morrison, K. (2005). Supply concerns push copper to new peak. Hentet 22.02.2023 fra <https://www.ft.com/content/22f1179c-610a-11da-9b07-0000779e2340>
- Nelson, C. R. & Plosser, C. R. (1982). Trends and random walks in macroeconomic time series: Some evidence and implications. *Journal of Monetary Economics*, 10(2), 139-162. [https://doi.org/https://doi.org/10.1016/0304-3932\(82\)90012-5](https://doi.org/https://doi.org/10.1016/0304-3932(82)90012-5)
- NERC. (2023). *Production of copper, refined*. Hentet 15.03 fra <https://www2.bgs.ac.uk/mineralsUK/statistics/wms.cfc?method=listResults&dataType=Production&commodity=42&dateFrom=2019&dateTo=2020&country=&agreeToTsAndCs=agreed>
- Nonejad, N. (2021). AN OVERVIEW OF DYNAMIC MODEL AVERAGING TECHNIQUES IN TIME - SERIES ECONOMETRICS. *Journal of Economic Surveys*, 35(2), 566-614. <https://doi.org/10.1111/joes.12410>
- Osterwald-Lenum, M. (1992). A Note with Quantiles of the Asymptotic Distribution of the Maximum Likelihood Cointegration Rank Test Statistics1. *Oxford Bulletin of Economics and Statistics*, 54(3), 461-472. <https://doi.org/https://doi.org/10.1111/j.1468-0084.1992.tb00013.x>
- Pedersen, B. (2022). Kobolt. I *Store norske leksikon*. <https://snl.no/kobolt>
- Pedersen, B. (2023a). Aluminium. I *Store norske leksikon*. <https://snl.no/aluminium>
- Pedersen, B. (2023b). Kobber. I *Store norske leksikon*. <https://snl.no/kobber>
- Pincheira Brown, P. & Hardy, N. (2019). Forecasting base metal prices with the Chilean exchange rate. *Resources policy*, 62, 256-281. <https://doi.org/https://doi.org/10.1016/j.resourpol.2019.02.019>
- Reeve, T. & Vigfusson, R. (2010). Evaluating the Forecasting Performance of Commodity Futures Prices. *International Finance Discussion Paper*, 2010, 1-19. <https://doi.org/10.17016/IFDP.2010.1025>
- Rubaszek, M., Karolak, Z. & Kwas, M. (2020). Mean-reversion, non-linearities and the dynamics of industrial metal prices. A forecasting perspective. *Resources policy*, 65, 101538. <https://doi.org/https://doi.org/10.1016/j.resourpol.2019.101538>
- Sanderson, H. (2018a, 6. november). Cobalt mine sales halt to push up price of key electric car metal. *Financial Times*. <https://www.ft.com/content/07af8226-e1d9-11e8-8e70-5e22a430c1ad>

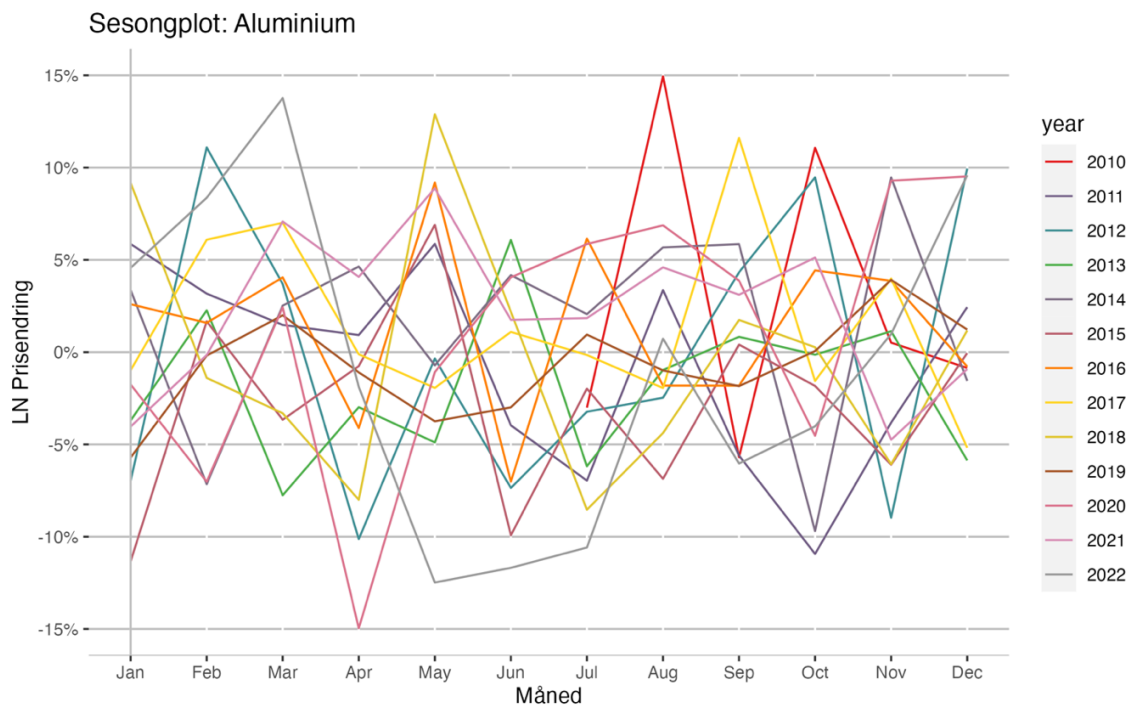

- Sanderson, H. (2018b, 9. mars). Cobalt price hits highest level since 2008 on electric car demand. *Financial Times*. <https://www.ft.com/content/1e6303f6-2386-11e8-add1-0e8958b189ea>
- Sanderson, H. & Hume, N. (2021, 15. oktober). Energy crunch drives up global metals prices. *Financial Times*. <https://www.ft.com/content/406155a9-e92f-439c-8ead-73cf87bd6a57>
- Tashman, L. J. (2000). Out-of-sample tests of forecasting accuracy: an analysis and review. *International journal of forecasting*, 16(4), 437-450.
- Wang, D. & Tomek, W. G. (2007). Commodity Prices and Unit Root Tests. *American Journal of Agricultural Economics*, 89(4), 873-889. <https://doi.org/10.1111/j.1467-8276.2007.01031.x>
- Watkins, C. & McAleer, M. (2004). Econometric modelling of non-ferrous metal prices. *Journal of Economic Surveys*, 18(5), 651-701. <https://doi.org/https://doi.org/10.1111/j.1467-6419.2004.00233.x>
- Webber, J. & Farchy, J. (2010, 9. november). Chile miners' strike turns cost of copper red hot. *Financial Times*. <https://www.ft.com/content/ccf75f58-ec33-11df-9e11-00144feab49a>
- Zhang, H., Nguyen, H., Vu, D.-A., Bui, X.-N. & Pradhan, B. (2021). Forecasting monthly copper price: A comparative study of various machine learning-based methods. *Resources policy*, 73, 102189. <https://doi.org/https://doi.org/10.1016/j.resourpol.2021.102189>

13 Vedlegg


V1 – Graf for sesongvariasjoner

Av praktiske hensyn for lesbarhet har vi plassert sesonggraf for samtlige metaller som vedlegg.


Grafen viser pris svingningene måned for måned



Sesongplot: Kobolt



Sesongplot: Nikkel





Norges miljø- og biovitenskapelige universitet
Noregs miljø- og biovitenskapelige universitet
Norwegian University of Life Sciences

Postboks 5003
NO-1432 Ås
Norway