




# KAN KUNSTIG INTELLIGENS INDIKERE ØKONOMISK BEDRAGERI

En studie for å finne ut om man kan lære opp kunstig intelligens til å gjenkjenne økonomisk bedrageri, basert på finansregnskapet til bedrageri-dømte norske aksjeselskap.

JAHN ÅSVALD EINARSMO  
ROLF ENVER LAMPE BJØRNSTAD  
CHRISTOFFER FONAHN

VEILEDER  
Terje Heskestad

**Universitetet i Agder, 2018**  
Fakultet for Handelshøyskolen ved UiA  
Institutt for strategi og ledelse



## Forord

Denne masteroppgaven er et selvstendig arbeid bygd rundt fagemnet «Finansregnskap», på Handelshøyskolen ved Universitetet i Agder. Verktøyet - Kunstig Intelligens - som har blitt brukt er blitt utarbeidet i samarbeid mellom forskerne og personer knyttet til fagmiljøet rundt CAIR (Center for Artificial Intelligence Research).

Arbeidet med avhandlingen har gitt oss dypere innsikt i fagfelt og teknologi som engasjerer. Det at vi har fått ny kjennskap knyttet til teknologi – som mest sannsynlig vil forme den nærmeste fremtiden – gjør oss privilegerte. Vi har vært heldige og truffet på et spesifikt område som det ser ut til å ikke ha blitt forsket på tidligere i Norge. Dette har økt vår motivasjon til å gjøre et forskningsarbeid vi kan være stolte av. Det har vært spennende å dykke ned i tidligere dommer og lære hvordan bedrageri har blitt gjennomført. Likeså har det vært interessant å lære hvordan kunstig intelligens utvikles og brukes av «alle» i dagens samfunn, slik som Netflix, Facebook, Siri og auto-genererte nyhetsartikler. I vårt tilfelle har den blitt utviklet til å oppdage røde flagg i regnskap. Arbeidet har gitt oss mye ny kunnskap som har tatt oss med i mange dype diskusjoner. Man kan nesten si at den har endret vårt syn, både med tanke på det teknologiske aspektet, og på hvordan bedriftsøkonomien fungerer og reguleres. Samarbeidet har gjort at vennskapet i gruppen har blitt sterkere og åpnet for god «takhøyde» som har medført at forslag har blitt snudd og vendt på for enten å bli tatt med eller forkastet. Arbeidet tilknyttet datainnsamlingen samt utvikling og forståelse av kunstig intelligens har vært vesentlig og har lært oss viktigheten av strukturert arbeid og hvordan det kan være med å øke motivasjonen ytterligere.

Vi ønsker å rette en stor takk til våre kontaktpersoner, Benoit Watremetz ved Saint-Gobain Ceramic Materials AS for hjelp til utvikling av datarammen og Jahn Thomas Fidje ved CAIR, i forbindelse med utviklingen av den kunstige intelligensen. Videre ønsker vi å rette en stor takk til vår veileder – Terje Heskestad – for å ha gitt oss en interesse for fagområdet gjennom kurset «Finansregnskap og Røde Flagg». Vi takker for konstruktive vinklinger og bidrag under vår søken etter løsninger. Ditt engasjement har overgått våre forventninger. Du har vært et meget positivt bidrag til vår utdanning ved UIA.

Vi ønsker deg en god lesning.

Kristiansand, 14.06.2018

Christoffer Frithjof Fonahn

Rolf Enver Lampe Bjørnstad

Jahn Åsvald Einarsmo

## Sammendrag

Denne masteroppgaven går ut på prediksjon av bedrageri basert på kunstig intelligens og finansregnskap. Dette er viktig fordi bedrageri skaper urettmessige fordeler for de som utfører det, samt at det medfører risiko for tap for interessentene til de bedriftene det gjelder.

Kunstig intelligens er tidligere brukt til samme formål med suksess, men dette er ikke observert utført på norske bedrifter. Oppgaven er kun ment å vise at prediksjon av bedrageri basert på kunstig intelligens og finansregnskap er mulig.

Forskningsspørsmålet i denne oppgaven er:

**«Er det mulig å identifisere økonomisk bedrageri basert på numeriske data i finansregnskapet til norske aksjeselskaper ved hjelp av kunstig intelligens.»**

Dataene som blir brukt er finansregnskap som er innhentet fra Proff Forvalt (forvalt.no) og dommer som er innhentet fra Lovdata (lovdata.no). Dataene er importert inn i en dataramme ved bruk av dataprogrammet Python og behandlet ved hjelp av Python modulen Tensorflow. Datasettet deles opp i et treningssett og et valideringssett. I treningssettet vektet den kunstige intelligensen variablene i finansregnskapene basert på om bedriftene er bedragerske eller ikke, for så å teste disse vektene ut på valideringssettet hvor den kunstige intelligensen ikke vet om bedriftene er bedragerske eller ikke. Valideringssettet brukes for å se om funksjonen som den kunstige intelligensen kommer frem til er generaliserbar og kan brukes til data utenfor treningssettet.

Resultatene viser at det er mulig å påvise om en bedrift er bedragerisk eller ikke med stor grad av sikkerhet, selv med et begrenset og ubalansert datasett.

Implikasjonene av resultatet i denne oppgaven er at arbeid som brukes for å detektere bedrifter som utfører bedrageri kan reduseres signifikant. Videre kan det også hjelpe til med å detektere bedragerske bedrifter før de blir insolvente og dermed redusere risiko for tap for interessentene.

# Innholdsfortegnelse

Forord.....	i
Sammendrag.....	ii
Innholdsfortegnelse .....	iii
Figurliste.....	v
1 Innledning .....	1
2 Resultat kvalitet og røde flagg .....	3
2.1 Analyse av regnskap.....	3
2.2 Aksjeselskap og regnskapsregulering i Norge .....	3
2.3 God regnskapsskikk.....	5
2.4 God regnskapsskikk for små foretak .....	8
2.5 Røde flagg .....	9
2.5.1 Psykologisk aspekt .....	10
2.5.2 Manipulering av inntekter .....	11
2.5.3 Manipulering av kostnader .....	14
2.6 Avslutning .....	16
3 Kunstig intelligens .....	17
3.1 Læringsproblemet.....	17
3.2 Trening og validering.....	24
3.3 Undertilpassing versus overtilpassing.....	25
3.4 Trening versus validering .....	27
3.5 Læringsparadigmer .....	28
3.6 Avslutning .....	30
4 Data.....	31
4.1 Beskrivelse av data.....	31
4.1.1 Finansregnskap (input data) .....	31
4.1.2 Dommer (output data).....	32
4.1.3 Dataramme (input + output).....	32
4.2 Datarensing.....	33
4.2.1 Finansregnskap (input data) .....	33
4.2.2 Dataramme (input + output).....	34
4.2.3 Kunstig intelligens (pre-prosessering).....	35
4.3 Avslutning .....	35
5 Metode.....	36
5.1 Studiens bakgrunn .....	36

5.2	Forskningsmetode.....	36
5.3	Forskningsdesign.....	36
5.4	Innsamlingsmetode.....	37
5.4.1	Utvelgelse av syke bedrifter.....	37
5.4.2	Utvelgelse av friske bedrifter.....	38
5.5	Dataanalyse.....	38
5.5.1	Programmering av datarammen.....	38
5.5.2	Programmering av kunstig intelligens.....	39
5.6	Evaluering av metode.....	40
5.6.1	Validitet.....	40
5.6.2	Reliabilitet.....	41
5.7	Etikk.....	43
5.8	Avslutning.....	43
6	Resultater.....	44
6.1	Oppsummering av teori for trening og validering.....	44
6.2	Resultat av trening og validering.....	45
6.3	Analyse av resultat.....	47
6.3.1	Usikker prediksjon.....	47
6.3.2	Feil prediksjon.....	49
6.4	Avslutning.....	50
7	Konklusjon.....	52
7.1	Implikasjoner.....	53
7.2	Begrensninger.....	53
7.3	Videre forskning.....	54
7.3.1	Anbefaling for videre forskning.....	54
8	Referanser.....	55
9	Vedlegg.....	vi
9.1	Dom-forside.....	vi
9.2	Dom-tiltale.....	vii
9.3	Dom-domsslutning.....	viii

## Figurliste

Figur 1: Tabell med oversikt over mulige regnskapsspråk for de forskjellige selskapsformene .....	4
Figur 2: Fraud Triangle - earnings management - The numbers game - Scientific Figure on ResearchGate .....	11
Figur 3: Metedata fra et bilde .....	17
Figur 4: Metadata fra en film .....	18
Figur 5: Metadata fra en bruker.....	18
Figur 6: Kobling av metadata fra film og bruker .....	19
Figur 7: Oversikt over problemoppsettet .....	21
Figur 8: Datasett med syke (x) og friske (o) bedrifter .....	23
Figur 9: Datasett med ukorrekt klassifisert data (a) og korrekt klassifisert data (b) .....	23
Figur 10: Klassifisering av data ved endring av vektor [w] og bruk av epoker.....	24
Figur 11: Trening og validering av kunstig intelligens.....	25
Figur 12: Visuell representasjon av overtilpassing.....	26
Figur 13: Visuell representasjon av undertilpassing .....	27
Figur 14: MNIST datasettet ("MnistExamples," 2017) .....	28
Figur 15: Fordeling av umerkede mynter etter vekt og størrelse (a). Gruppering av umerkede mynter basert på ikke-veiledende læring (b) .....	29
Figur 16: Oversikt over Atari spill som Deepmind's Alphago ble trent opp på.....	30
Figur 17: Finansregnskap eksportert til Excel fra Proff Forvalt.....	31
Figur 18: Dataramme som inneholder samtlige bedrifters finansregnskap .....	33
Figur 19: Trening og validering av kunstig intelligens.....	44
Figur 20: Sammenligning av trening- og valideringssettets nøyaktighetsfunksjon for vurdering av undertilpassing.....	45
Figur 21: Sammenligning av trening- og valideringssettets tapsfunksjon for vurdering av overtilpassing .....	46
Figur 22: Sannsynlighet for bedrageri.....	47
Figur 23:Fordeling av friske og syke bedrifter .....	48
Figur 24: Oversikt over bedrifter med sannsynlighet for bedrageri <30 , 60>% .....	48
Figur 25: Oversikt over bedrifter som læringsalgoritmen predikerte feil.....	49
Figur 26: Oversikt over konsernrelasjon for bedrift 643, med tilhørende sannsynlighet for bedrageri .....	50

## 1 Innledning

Denne avhandlingen er en kombinasjon av fagfeltene kunstig intelligens og økonomi. Oppgaven tar i bruk kunstig intelligens for å kunne predikere regnskapsmanipulasjon basert på finansregnskap.

Kunstig intelligens og teoriene som bygger opp rundt emnet er eldre enn man kanskje først skulle anta. Gill Press skriver i artikkelen «A very short history of Artificial Intelligence (AI)», at publiseringen Ramon Llull gjorde allerede i 1308 kan knyttes mot kunstig intelligens (Gil Press, 2018). Men det er først rundt 1950 da Alan Turing publiserer "Computing Machinery and Intelligence" – og foreslår «imitation game», som senere blir kjent som «Turing Test» – man kan kjenne igjen teknologien man ser i dag (Turing, 1950).

Det å oppdage regnskapsbedrageri er viktig fordi det skaper urettmessige fordeler for de som utfører det, samt at det medfører risiko for tap for interessentene til de bedriftene det gjelder. Jo lenger regnskapsbedrageriet pågår, desto større er sannsynligheten for at det ikke er likvider igjen i firmaet til å gjøre opp kravene kreditorene har til konkursboet.

Det er hovedsakelig to grunner til at man analyserer regnskap. Det ene er prestasjonsmåling og det andre er verdsetting (Tellefsen & Langli, 2005). Røde flagg vil ligge under begge disse kategoriene da det kan være flere årsaker til at bedriften driver med regnskapsmanipulasjon. Røde flagg i et bedriftsregnskap kan være et tegn på at en bedrift går dårlig og dermed prøver å pynte på regnskapstallene. Å finne slike røde flagg er både tid- og ressurskrevende.

Frem til tidlig 2000 tallet var tilgang på data- og prosesseringskraft to av de viktigste årsakene til at kunstig intelligens ikke ble tatt i bruk. I dagens teknologialder lagres det meste av data elektronisk og prosesseringskraften som er til rådighet i hjemme pc'er er nå allerede god nok til å kjøre komplekse nevralt nettverk. Dette åpner for muligheten til å ta i bruk kunstig intelligens for å finne bedrageriske bedrifter og på denne måten redusere både tid og ressurser som brukes på dette.

Bruk av kunstig intelligens for å finne bedrageriske bedrifter basert på finansregnskapet er gjort i tidligere forskning med høy grad av suksess. (Ravisankar, Ravi, Raghava Rao, & Bose, 2011) har ved bruk av et probabilistisk nevralt nettverk (PNN) oppnådd en treffsikkerhet på 98%, basert på et balansert datasett av 202 kinesiske bedrifter. (Kirkos, Spathis, & Manolopoulos, 2007) har ved bruk av en «Bayesian Belief Network» (BBN) oppnådd en treffsikkerhet på 90,3% basert på et balansert datasett av 76 greske bedrifter. (Lin, Chiu, Huang, & Yen, 2015) har ved bruk av et nevralt nettverk (Back-propagating ANN) oppnådd en treffsikkerhet på 92,8% basert på et ubalansert datasett på 129 bedrageriske og 447 ikke-bedrageriske kinesiske bedrifter. Et balansert datasett vil si at man har like mange bedrageriske som ikke bedrageriske bedrifter.

Mesteparten av artikler innen koblingen av kunstig intelligens og regnskapsbedrageri er såkalte «grey artikles» og det er få slike artikler innen databaser som ISI og EBSCO. Etter grundige undersøkelser er det ikke funnet at det er gjort forskning på dette emnet i bedrifter som rapporterer etter norsk regnskapslovgivning eller undersøkelser utført i Norge. Det gjør at forskningsspørsmålet som må besvares er:

**«Er det mulig å identifisere økonomisk bedrageri basert på numeriske data i finansregnskapet til norske aksjeselskaper ved hjelp av kunstig intelligens.»**

I oppgaven gjøres det ikke rede for norsk eller internasjonal regnskapsregulering. Det brukes kun selskaper som rapporterer etter norsk regnskapslovgivning og god regnskapsskikk og det fokuseres derfor ikke på internasjonale regnskapsbestemmelser. Videre er det satt en avgrensning ved at det

kun sees på numerisk informasjon i finansregnskapene. Styrets årsberetning og finansregnskapets noter er dermed ikke med. Den kunstige intelligensen er trent opp med datasett bestående av friske regnskap og regnskapene til bedrifter dømt for økonomisk bedrageri. Således vil røde flagg som den kunstige intelligensen finner i datasettet referere til indikatorer som tyder på regnskapsbedrageri.

I denne avhandlingen brukes finansregnskap (input) og dommer innen økonomisk bedrageri (output) som datagrunnlag for en kunstig intelligens. Innsamling av input data og output data har vært meget tidkrevende og står for en betydelig del av arbeidet i oppgaven. Dette omfatter innhenting av data fra 20 000 bedrifter for å danne grunnlaget for input data, samt en gjennomgang av 12 158 dommer for å danne grunnlaget for output data. Dette har resultert i et datagrunnlag på 14 111 finansregnskap, hvor hvert finansregnskap inneholder 156 regnskapslinjer, med totalt 668 557 unike datapunkter.

Avhandlingen bruker data som i all hovedsak er numerisk hvilket fordrer en kvantitativ metode. Det er valgt et eksplorativt design grunnet lite forskning innen koblingen av kunstig intelligens og finansregnskap. Input data og output data er koblet sammen i en dataramme som er programmert i Python med modulen Pandas. En dataramme er en matrise som brukes for å importere større datasett og forenkle håndtering og behandling av data (Pydata.org, 2018). Denne datarammen inneholder all informasjon av finansregnskap og tilhørende dommer, som håndteres av den kunstige intelligensen. Den kunstige intelligensen er av typen veiledende læringsalgoritme, og er programmert i Python modulen Tensorflow. Denne algoritmen importerer dataen fra datarammen og deler den opp i et treningssett – hvor output er kjent – og et valideringssett – hvor output ikke er kjent. Basert på dette trenes den kunstige intelligensen på kjente data i treningssettet og tester trainingen basert på den ukjente dataen i valideringssettet. Både input data, output data, dataramme og læringsalgoritmen er rensset for å minimere risiko for feil og bias.

Den trente læringsalgoritmen er sjekket for overtilpassing, undertilpassing og bias mot konkurs. Overtilpassing er når læringsalgoritmen overvurderer variablene i treningssettet – på bekostning av variablene i valideringssettet – og gjør den beregnede funksjonen mindre generaliserbar. Undertilpassing er når læringsalgoritmen ikke lykkes med å tilpasse datapunktene, hverken treningssettet eller valideringssettet. Bias kan forklares ved at læringsalgoritmen skaper en korrelasjon i datasettet som ikke finnes i virkeligheten. Det ble ikke observert undertilpassing eller bias mot konkurs, men det ble observert en svak tendens til overtilpassing fra epoke 21 og utover. Læringen ble stoppet ved epoke 20 og de gjeldende resultatene ble brukt videre i avhandlingen. Epoke er en term som brukes ved trening og validering av læringsalgoritmen. Under læringen går læringsalgoritmen igjennom datasettet flere ganger, den trener på treningssettet for så å verifisere hva den har lært på valideringssettet. En slik gjennomgang kalles for epoke. Resultatene viser at læringsalgoritmen presterer å klassifisere 98% av datasettet riktig.

Arbeidet som er utført i denne oppgaven viser at det er mulig å bruke kunstig intelligens til å predikere bedrageri, selv med et begrenset og ubalansert datasett. Dette betyr at den numeriske informasjonen som foreligger i finansregnskapene med stor presisjon kan brukes til å predikere bedrageri. Dette er et verktøy som kan være til stor nytte for interessenter av bedrifter, slik som skattemyndigheter, kreditorer, investorer, banker, styre og aksjonærer. Bruk av kunstig intelligens for prediksjon av bedrageri kan bidra til redusert tids- og ressurs-bruk på analyse av bedriftsregnskap, samt bistå til å kanalisere ressursbruken i retning av de bedriftene hvor sannsynlighet for bedrageri er stor. Denne kanaliseringen av ressurser vil igjen kunne bidra til redusert risiko for tap for de overnevnte interessentene.



## 2 Resultatkvalitet og røde flagg

I dette kapitlet gjennomgås teori knyttet til resultatkvalitet og røde flagg samt de vanligste regnskapsstandardene og hvordan disse er fordelt. Det skiller i denne sammenhengen mellom selskapsstruktur og hvilke selskapsdefinisjoner de havner under.

I kapittel 2.1 presenteres analyse av regnskap, hvilke forskjellige tilnærminger som finnes og hvorfor det blir gjort. Kapittel 2.2 beskriver hvilke selskaps kategorier som forskningen i denne avhandlingen ser på og hvilke regnskaps-reguleringer som finnes og hvordan disse er fordelt mellom selskaps-kategoriene. Kapittel 2.3 presenterer god regnskapsskikk og hva den inneholder. Kapitlet avsluttes med å presentere de 10 regnskapsprinsippene som finnes. Kapittel 2.4 gjennomgår god regnskaps-skikk for små foretak og beskriver definisjonen av små foretak. Kapitlet avsluttes med hva som legges i regnskapskvalitet. Kapittel 2.5 gjennomgår til slutt de vanligste kjente tegnene man bør se etter om man er på leting etter røde flagg.

### 2.1 Analyse av regnskap

Det er mange grunner til at vi analyserer regnskapene i selskaper. Det kan være for å sjekke om ledelsen har kontroll med driftskostnadene, om kapitalen i selskapet blir effektivt utnyttet, om man er fornøyd med ledelsens innsats og resultatet. Man kan også finne tegn på at bedriften går mot vanskelige tider og at nye prioriteringer må iverksettes (Tellefsen & Langli, 2005). Men det kan også være direkte feil registreringer eller andre menneskelige påvirkninger som ikke har illegale hensikter, som er årsaken til at en analyse iverksettes. Det er lovfestet et overordnet krav om at årsregnskapet skal gi et "rettvisende bilde" av den regnskapspliktiges eller konsernets eiendeler og gjeld (Kvifte & Johnsen, 2008). Bestemmelsen gir regnskapspliktige rett og plikt til å i noen tilfeller overstyre regnskapslovens krav for å sikre at regnskapet gir et rettvisende bilde. Dessverre er det sånn at bedrifter kan være fristet til å bedrive en kreativ regnskapsføring og utnytte blant annet denne bestemmelsen til egen vinning. I slike tilfeller vil en analyse være på søken etter mer alvorlige forhold som kan innebære manipulering av regnskapstall. Dette kan være gjennomført for å gi ledelsen økonomiske nettofordeler gjennom for eksempel en bonusavtale eller eiere som vil manipulere aksjeprisen ved salg, ledelse som ønsker å villedde investorer eller banker i forbindelse med kapitalforhøyelse, lån eller fusjon.

Går man bort fra de tallmessige størrelsene så innehar også en analyse å vurdere blant annet muligheten for valg av prinsipper, altså graden av valgfrihet virksomheten har. Dette er et område som kan bli kreativt utnyttet til økonomisk vinning. Informasjonskvaliteten knyttet til regnskapet kommer også frem i notene og her kan viktige og avgjørende vurderinger være beskrevet. Disse kan være med å kanskje rettferdiggjøre tallstørrelser som i utgangspunktet virket feilaktige, eller motsatt, forsterke en mistanke som kommer frem i analysen (Heskestad, 2014a; Tellefsen & Langli, 2005).

### 2.2 Aksjeselskap og regnskapsregulering i Norge

I dette kapitlet nevnes teori knyttet til aksjeselskap og hvilke reguleringer som benyttes i Norge. Det finnes mange selskapsformer i Norge men i 2015 står aksjeselskap for 89% av den totale omsetningen og 77% av den totale sysselsettingen i Norge (Sentralbyrå, 2018). Det gjør at i denne selskapsformen er det et potensial for svindel og manipulering av regnskap som er skadevirkende for samfunnet.

Aksjeselskaper kan bruke ulike regnskapsstandarder som blir delt inn forskjellige typer «språk». I tabellen under blir det presentert fire forskjellige regnskapsspråk der GRS (god regnskapsskikk) er den mest utbredte og blir presentert i kapittel 2.3. Det finnes en forenklet versjon av GRS som kalles GRS for små foretak. Denne regnskapsstandarden er til for å forenkle rapporteringen for små foretak og blir gjennomgått i kapittel 2.4. IFRS (International Financial Reporting Standard) er en standard

EU-parlamentet krevde at alle selskaper oppført i EU måtte rapportere i henhold til. Denne standarden ble iverksatt regnskapsåret som begynte etter 1. januar 2005 (Soderstrom & Sun, 2007). Børsnoterte selskaper har siden den tid måtte rapportere i henhold til denne standarden. Andre selskaper og små foretak har kunnet fritt velge om de vil rapportere i henhold til denne standarden. Den største forskjellen mellom GRS og IFRS er tilnærmingen til regnskapet. GRS er i all hovedsak resultatorientert mens IFRS er balanseorientert og tar utgangspunkt i definisjoner av forpliktelser og eiendeler (Fardal, 2007a). Forenklet IFRS er en «hybrid» som åpner for forenkling i noteopplysningskravene mens reglene for innregning og måling i hovedsak følger full IFRS (Bernhoft & Mjanger, 2015).

Utviklingen av regnskapsspråkene skjer gjennom standardsetting og praksis der formen på anvendelsen blir styrt av dette (Kvifte, Bernhoft, & Tofteland, 2011). Figur 1 viser tre kategorier selskapsformene blir delt inn i. Børsnoterte selskaper inneholder alle de selskapene som er notert på børsen. For å komme på børs må selskapet blant annet ha en markedsverdi på 300 millioner NOK og ha en spredning av aksjekapitalen blant allmennheten på 25% (Oslo Børs ASA, 2018). Små foretak er de selskapene som havner innenfor definisjonen beskrevet i kapittel 2.4. «Andre» er de selskapene som havner mellom børsnoterte selskaper og de selskapene som havner innenfor definisjonen av små foretak.

I Figur 1 er det også nevnt selskapsregnskap og konsernregnskap. I Norge plikter selskaper som har juridisk kontroll eller faktisk kontroll over et selskap å utarbeide konsernregnskap. Juridisk kontroll vil si at man eier 50% eller mer, mens faktisk kontroll kan foreligge når man ikke har juridisk kontroll, men allikevel har den faktiske kontrollen over selskapet. Et slikt regnskap skal rapporteres i henhold til lover og regler for konsernregnskap og selskapet får innskrenkede muligheter i forbindelse med valg av regnskapsspråk. Det samme kan gjelde datterselskaper om de er i posisjoner som kan kvalifisere til det (Andersen, 2000). Med selskapsregnskapet som nevnes så menes finansregnskapet for enkel juridisk enhet. Figur 1 viser hvilke alternativer til regnskapsstandard de forskjellige selskapskategoriene og regnskapsformene har.

	<b>Børsnoterte</b>	<b>Andre</b>	<b>Små foretak</b>
<b>Selskapsregnskapet</b>	IFRS Forenklet IFRS GRS	IFRS Forenklet IFRS GRS	IFRS Forenklet IFRS GRS GRS Små foretak
<b>Konsernregnskapet</b>	IFRS	IFRS Forenklet IFRS GRS	IFRS Forenklet IFRS GRS GRS Små foretak

Figur 1: Tabell med oversikt over mulige regnskapsspråk for de forskjellige selskapsformene

## 2.3 God regnskapsskikk

De fleste norske aksjeselskaper legger til grunn den norske regnskapsloven og god regnskapsskikk (GRS). Den bygger på en transaksjonsbasert modell og er resultatorientert der etablert regnskapspraksis er grunnlaget for modellen med en deskriptiv innfallsvinkel (Kvifte & Johnsen, 2008). Den etablerte regnskapspraksisen endrer seg i takt med utviklingen av samfunnet. Derfor omtales god regnskapsskikk ofte som et «dynamisk begrep» (Kvifte et al., 2011). «I GRS er det størst fokus på resultatregnskapet, og den overordnede målsetningen er å gi en mest mulig fornuftig måling av periodens resultat. Balanseoppstillingen får da en noe mer underordnet rolle»(Fardal, 2007b). Grunnmuren i ordinær regnskapsføring er bygd opp av de grunnleggende regnskapsprinsippene der innholdsrik resultatmåling er det viktigste, og derfor er prinsippene resultatorienterte (Kvifte & Johnsen, 2008).

De grunnleggende regnskapsprinsipper årsregnskapet skal utarbeides etter er lovfestet i RL § 4-1. Disse defineres som følger:

### § 4-1 Sammenstillings-prinsippet

Grunntanken til sammenstillingsprinsippet er at kostnadene som har vært med å skape periodens inntekter, skal sammenstilles med hverandre i samme periode. Det gjør at føringen av inntektene blir styrende for føringen av kostnadene (Kvifte et al., 2011). Prinsippet legger til grunn at kostnader skaper fremtidig inntekt men i de tilfellene der dette ikke kan sannsynliggjøres så skal kostnadene utgiftsføres umiddelbart (Revisjon.no, 2018).

### § 4-1 Opptjenings-prinsippet

For at inntektsføringen reflekterer virksomhetens aktiviteter, så skal den resultatføres i takt med inntjeningen. I varehandel kan man si at dette skjer på transaksjonstidspunktet, men i noen tilfeller er dette tidspunktet vanskelig å tidfeste. Juridisk kan man si at det skjer ved risiko- og kontroll-overgang. Typiske situasjoner er ved anleggskontrakter der denne overførselen av risiko og kontroll er glidende (Kvifte et al., 2011). Andre eksempler på urealisert inntekt (verdibasert transaksjon) kan være urealiserte valutagevinster på kortsiktige pengeposter i utenlandsk valuta. Argumentasjonen som legges til grunn er at valutagevinsten kan umiddelbart realiseres ved en stadfestet transaksjon og dermed gjøre den urealiserte gevinsten realisert. Dette er regulert gjennom regnskapsloven §§ 5-8 og 5-9 (Revisjon.no, 2018).

### § 4-1 Transaksjons-prinsippet

Transaksjoner skal regnskapsføres til verdien av vederlaget på transaksjonstidspunktet. Transaksjonstidspunktet er når det har skjedd en overføring av risiko og kontroll fra den ene part til den andre. Det trenger ikke være utført betaling for at det er blitt gjort en transaksjon, men at taps- og gevinstpotensialet samt beslutningsmyndighet og råderett er overført fra en part til en annen. Prinsippet tar også hensyn til at regnskapsføring og verdimåling av vederlag og overdratt eiendel skal gjøres på transaksjonstidspunktet (Kvifte et al., 2011). Videre så stilles det ytterligere to krav til innregning av transaksjoner. Det ene er at transaksjonene har et reelt økonomisk innhold og det andre er at transaksjonene gjennomføres av informerte, uavhengige og villige parter (Godtland Consulting, 2018).

#### § 4-1 Forsiktighets-prinsippet

En forståelse av forsiktighetsprinsippet er laveste verdis prinsipp. Det betyr at eiendeler skal vurderes til laveste verdi av anskaffelseskost og virkelig verdi, det er nedskrivningsplikt for anleggsmidler og gjeld skal vurderes til høyeste verdi. Ifølge anvendelsen av prinsippet så skal også urealiserte tap skal bli tatt hensyn til og resultatføres. Man skal merke seg at prinsippet ikke tillater å legge til en sikkerhetsmargin i forbindelse med f.eks. virkelig verdi vurdering. Verdiene skal baseres på hva som forventes (Godtland Consulting, 2018; Kvifte et al., 2011). Den mest relevante målingen kan man si er virkelig verdi men den er samtidig mer krevende og vanskeligere å beregne. En feil angivelse i utgangsnivået vil påvirke estimatene og derfor ha konsekvenser. Det viser seg at ledelsen ofte er positiv i sin vurdering og at dermed kan eiendeler bli overvurderte. Man antar derfor at det ofte forekommer feil i et regnskap der virkelig verdi er beregnet av selskapet selv (Kinserdal, 2017).

#### § 4-1 Sikring «Sikringsprinsippet»

Som en motvekt til forsiktighetsprinsippet, kommer det mange velger å kalle sikringsprinsippet. Det sier at gevinst resultatføres når den er realisert, mens urealisert tap skal resultatføres umiddelbart (Kvifte et al., 2011). «Sikringsprinsippet ble tilført for å skape symmetri i regnskapet (Finans.no, 2018) "». Om et foretak har sikret seg mot et urealisert tap så vil prinsippet hindre foretaket å resultatføre dette.

#### § 4-5 Fortsatt drift

Under forutsetning om fortsatt drift og at det ikke er sannsynlighetsovervekt for at virksomheten vil bli avvirket, så skal årsregnskapet utarbeides (rk/v, 1998). Dette betyr at de to alternativene utelukker hverandre og derfor er årsregnskapene basert på ett av to alternativ (Revisjon\_AS, 2018). Det er styret og Ledelsen i virksomheten som må vurdere om virksomheten er i stand til å fortsette, da det ikke er tallfestet hvor stor prosentmessig sannsynlighetsovervekt det må være for å evne videre drift (Berner & Aastveit, 2009). Forståelsen av bestemmelsen kan i ytterste konsekvens strekkes så langt at man kan si at kravet for avvikling først kommer når det ikke finnes andre alternativ (Tofteland & Fladstad, 2014). En slik forståelse åpner opp for muligheter for å tilpasse regnskapet til sin fordel og dermed forlenge «livet» til en allerede «død» virksomhet.

#### § 4-2 Beste estimat

Det skal brukes beste estimat om det er usikkerhet i forbindelse med årsregnskapsavleggelsen. Estimaten skal bygges på den informasjonen som er tilgjengelig på balansedagen, men i NRS 3 *Hendelser etter balansedagen* er for eksempel endringer i varelagerets salgsverdi et forhold som i utgangspunktet gjelder på balansedagen. Dette selv om endringen kom etter balansedagen (Kvifte et al., 2011). Ved usikkerhet må det anvendes en viss varsomhet slik at ikke overvurdering av eiendeler eller undervurdering av gjeld forekommer. Varsomheten knyttet til slike vurderinger har tradisjonelt blitt oppfattet som en del av «forsiktighetsprinsippet». Forsiktighetsprinsippet kommer til uttrykk i NRS 13 Usikre forpliktelser og betingede eiendeler (jf. punkt 4.3.1):

*«Ved utøvelse av skjønn må det utvises aktsomhet slik at inntekter og eiendeler ikke blir overvurdert og kostnader og forpliktelser ikke blir undervurdert.»*

#### § 4-3 Kongruens-prinsippet

Prinsippet medfører at alle egenkapitals endringer som ikke omhandler transaksjoner mellom eierne og regnskapspliktige skal resultatføres. Det betyr at alle kostnader og inntekter skal resultatføres. Det finnes to lovbestemte unntak som åpner opp for at endringene føres mot egenkapitalen: regnskapsføring av prinsippendringer og korrigeringer av feil. En endring av prinsipp kan ikke relateres til periodens resultat og dermed ville en resultatføring gi et feilaktig bilde av resultatet i perioden, noe som også gjelder for feilkorrigeringer (Kvifte et al., 2011). Den effekten

prinsippendringen og feilkorrigeringen gir mot egenkapitalen skal i henhold til regnskapsloven § 7-25 da vises eksplisitt i egen note.

For små foretak gjelder ikke de obligatoriske unntakene fra kongruensprinsippet. Selskapene kan selv velge å ikke gjøre unntak og dermed føre vesentlige endringer og feil over resultatregnskapet. (Kvifte et al., 2011; Revisjon.no, 2018).

#### **§ 4-4 Prinsipp-anvendelse**

Årsregnskapet skal baseres på ensartede prinsipper og være konsistent anvendt over tid. Det betyr at både prinsippanvendelsen for den enheten som rapporterer og selve prinsippanvendelsen skal være uforandret fra ett år til neste. Dette er til for å sikre sammenlignbarheten i årsregnskapene (Kvifte et al., 2011). Det ble i 2005 bestemt at børsnoterte selskaper skal avlegge årsregnskapet etter IFRS mens andre kunne velge å avlegge årsregnskapet etter IFRS (Fardal, 2007b; Kvifte et al., 2011). Denne lovendringen har i praksis åpnet opp for full prinsippfleksibilitet (Kvifte et al., 2011). Det kommer også tydelig frem i regnskapsloven § 4-4.2 at bruk av ulike prinsipper kan benyttes i regnskap for konsern og selskap men at avleggelsen må være sammenfallende noe som også blir forsterket i regnskapsloven § 3-6.

Bestemmelsen fordrer at, for konsolideringsformål, skal selskapsregnskap som ikke anvender samme prinsipper som morselskapet omarbeides slik at de er i samsvar med morselskapets prinsippanvendelse. Denne bestemmelsen er blant annet til for å legge til rette for konsern som bruker IFRS i regnskapsavleggelsen, men har datterselskap som ikke gjør det. En slik prinsippfrihet som det nå er lagt opp til gjør at det alltid vil være aktuelt med prinsippendring, en slik endring er i all hovedsak begrenset til en forbedret «periodisering». Om en slik endring blir gjennomført må dette bli beskrevet i noter hva endringen innebærer, og hvilken regnskapseffekt endringen har. Det åpnes i Norge opp for at vesentlige effekter av endringer for små foretak kan i resultatregnskapet vises som en ekstraordinær post.

#### **§ 4-5 Fortsatt drift**

Regnskapsprinsippet er til for å regulere at årsregnskapet utarbeides under forutsetning om fortsatt drift og at dette gjelder så lenge det ikke er sannsynlighet for at selskapet vil bli avviklet. Bestemmelsen dekker både de situasjonene der regnskapet utarbeides med utgangspunkt i fortsatt drift, og de tilfellene der det er sannsynlighet for at selskapet blir avviklet. Betingelsene for fortsatt drift og avvikling kansellerer hverandre ved at det ene alternativet utelukker det andre. Om selskapet ikke finner sannsynlighet for fortsatt drift har dette betydelige konsekvenser. Regnskapet i selskapet eller virksomheten skal dermed avlegges under forutsetning om avvikling og et avviklingsregnskap skal fremmes.

Kriteriene for hva som ligger i begrepet sannsynlighet er ikke helt klart. Problemstillingen knyttet til mangelen på begrepsdefinisjon har vært oppe til høring og endret ved flere anledninger. Terskelen knyttet til sannsynligheten for avvikling er blitt løftet fra 50% til en ikke-tall-gitt størrelse, men heller til en ordlyd som ikke opplevdes like strengt. Tidshorisonten ble nå tatt med i betraktning, da det ble lagt til grunn at sannsynlighet ikke kunne være en spesifikk angivelse av et sannsynlighetsnivå (Revisjon.no, 2018). Ifølge Kvifte et al. (2011) så er begrepsbruken i IFRS noe mer operasjonell å forholde seg til enn det norske alternativet. Dette kommer av at IASB viser mer til spesielle situasjoner, der fortsatt drift ikke kan forutsettes. Foruten dette må bestemmelsen sees i sammenheng med de krav aksjelovgivningen gir til forsvarlig egenkapital og bestemmelser i regnskapsloven § 3-3 angående opplysningsplikten for fortsatt drift (Revisjon.no, 2018).

## § 4-6 God regnskapsskikk

Det heter i regnskapsloven § 4-6 at årsregnskap skal formes etter god regnskapsskikk. Det betyr at utformingen skal skje i samsvar med regnskapslovens øvrige bestemmelser, grunnleggende regnskapsprinsipper og regnskapspraksis som er allment akseptert (Revisjon.no, 2018).

Bestemmelsens hovedformål er at årsregnskapet skulle gi et «true and fair view» som EU's regnskapsdirektiv krevde da det ble innført. Det har vært omdiskutert om god regnskapsskikk ga en riktig representasjon av EU's direktivkrav. Denne diskusjonen ble avsluttet da lovendringen i 2005 implementerte en egen bestemmelse som sa at regnskapet skal gi et rettviseende bilde. God regnskapsskikk blir omtalt som et «dynamisk begrep», at god regnskapsskikk slik den er i dag, ikke trenger å være det i morgen. Det kommer av at det er en fortløpende endring av det økonomiske bildet, at praksis og den teoretiske utviklingen er stadig i endring. Samfunnet generelt er også stadig i endring, nye transaksjonstyper blir presentert og dermed må god regnskapsskikk utvikles på lik linje (Kvifte et al., 2011). Til tross for dette hevder Kvifte et al. (2011) at bestemmelsen strengt tatt er overflødig. Det kommer av at hele lovens innhold og struktur er bygd på at bestemmelsene utdypes gjennom god regnskapsskikk, samt at det i loven for øvrig er henvist i forskjellige bestemmelser til god regnskapsskikk.

### 2.4 God regnskapsskikk for små foretak

Det skilles mellom små foretak, store foretak og andre foretak i regnskapsloven. Små foretak er gitt en del krav og regler som skal forenkle regnskapsrapporteringen. Noen av unntakene fremkommer i lovteksten, mens andre forenklinger er utviklet gjennom god regnskapsskikk og fremgår av NRS 8 God regnskapsskikk (Kvifte et al., 2011). «Formålet med NRS 8 God regnskapsskikk for små foretak er å supplere og fortolke de grunnleggende regnskapsprinsippene og regnskapslovens bestemmelser for øvrig for små foretak.» (Norsk regnskapsstiftelse, 2018, p. 4). For å havne i gruppen små foretak, må man etter regnskapsloven §1-6 havne inn under 2 av de 3 punktene nevnt under. Det er verdiene rapportert 31.12 som vanligvis legges til grunn og man må ha vært innenfor disse rammene 2 år på rad for å endre definisjonen på selskapet. Dette er størrelser som kan bli endret, og man må derfor være bevisst hvilke grenseverdier som gjelder for perioden om man ønsker å endre definisjon av selskapet.

- 70 millioner kroner eller mindre i salgsinntekt i regnskapsåret
- 35 millioner kroner eller mindre i balansesum på balansedagen
- 50 eller færre årsverk i regnskapsåret

Virksomheter kan heller ikke være registrert som et allmennaksjeselskap og samtidig rapportere i henhold til God regnskapsskikk for små foretak.

Et eksempel på en forenkling er at bedrifter som havner i kategorien små foretak, kan la være å ta med faste kostnader når anskaffelseskost beregnes. Små foretak kan således legge variabel tilvirkningskost til grunn ved beregning for denne typen varer (Tofteland & Fladstad, 2014). Dette fører til at de faste kostnadene overføres til neste periode og på den måten oppnår selskapet et høyere resultat. Det er viktig å merke seg at å endre prinsipp fra periode til periode ikke er tillat og at slike endringer av prinsipp skal føres i notene (Terje Heskestad, 2015). Et annet eksempel er at virksomheten kan ved anleggskontrakter fravike opptjeningsprinsippet. Det vil si at virksomheten kan velge å inntektsføre når kontrakten er fullført. Dette representerer ikke inntektsføring i takt med fremdriften i prosjektet, men skal virke forenklende for små foretak.

## Regnskapskvalitet

Når den underliggende økonomiske realiteten blir presentert og beskrevet på en realistisk og god måte i regnskapet kaller vi det ofte for god regnskapskvalitet (Tofteland & Fladstad, 2014). Men det kan også forklares på flere måter. Det ene er at regnskapet må være fritt for «forurensning», altså at det ikke skal være uriktigheter eller feilkilder i regnskapet. Det andre er at regnskapet skal være en informasjonskilde for en effektiv beslutningsprosess, altså at det skal være beslutningsnyttig. Derimot kan brukerne være mange og ulike brukere har ulike informasjonsbehov. Det gjør at vi må vite hvem brukeren er for at regnskapet skal være relevant for brukerne (Baksaas & Stenheim, 2017).

Picker (2016) definerer regnskapskvalitet på en litt annerledes måte; at de økonomiske virkelighetene blir representert med et rettviseende bilde for brukeren. At det er komplett, feilfritt og nøytralt. Der nøytralt vil si at regnskapet ikke har blitt ført med holdninger som kan ha påvirket utformingen. At et regnskap skal være komplett vil si at det inneholder all informasjon, slik som transaksjoner som har blitt gjennomført i regnskapsåret.

Reglene for føring av regnskapet gir valgmuligheter og dermed åpner muligheten for at regnskapslinjene føres ulikt (Kvifte et al., 2011). Man kan også legge til skjønnsmessige estimater og selskapets valg av prinsipper som tilleggsfaktorer for feil i regnskapet (Gjesdal, 2003).

Men det kan være mange forhold som påvirker avgjørelser i forbindelse med føring av regnskap. Noen er beviste mens andre ikke er det. Noen eksempler på opplagte insentiver for å gjøre beviste regnskapsfeil kan være at ledelsen ønsker å «pynte» regnskapet for potensielle interessenter, eller at det finnes bonusordninger for de ansatte som er styrt av forskjellige regnskapslinjer (Mulford & Comiskey, 2002). Det finnes også opplagte forklaringer på ubeviste feil som kan være så enkelt som feil føring på grunn av høyt arbeidspress, eller inkompetanse blant regnskapsførere for å nevne noen.

## 2.5 Røde flagg

I dette kapitlet presenteres de psykologiske aspektene som viser seg å være tilstede når misligheter begås samt metoder for regnskapsmanipulasjon. Med mindre annet er oppgitt vil kapitlene 2.5.2 og 2.5.3 være basert på Terje Heskestads artikler om «Manipulering av inntekter og røde flagg» (Heskestad, 2014a) og «Manipulering av kostnader og røde flagg» (Heskestad, 2014b).

Viktigheten av å øke bevisstheten rundt røde flagg og generelt om bedrifters kulturer og ukulturer blir godt belyst basert på de funn gjort i en studie gjennomført av Dichev, Graham, Harvey, and Rajgopal (2016). I studien kommer det frem at av 400 økonomisjefer som ble intervjuet så mente 20% av dem at bedriften de jobbet for manipulerte inntjeningen, selv om de fulgte de lover og regler som gjaldt for regnskapsføring i landet. Dette gir enorme utslag i den totale økonomiske hverdagen til et samfunn og viser hvorfor det er et viktig fokusområde.

Vi har her valgt å fokusere mest på de «røde flaggene» som kan analyseres ut fra regnskapet, men det finnes flere. Man kan blant annet se i noen skandaler at revisor er med «på laget». Er man en interessent til foretaket er dette absolutt et rødt flagg å ta hensyn til. Revisor skal tjene alle interesser heter det i revisorloven revisorloven § 1-2 første ledd. Revisor må derfor ta hensyn og påse at han eller hun er uavhengig av interessenter rundt foretaket og det reviderte foretaket i seg selv (Gulden, 2015). Noen andre eksempler som kan nevnes kort er å se på styrets sammensetning og kompetanse, brudd på lånebetingelser og hvor komplisert selskapsstruktur konsernet har (Terje Heskestad, 2018).

### 2.5.1 Psykologisk aspekt

Fokuserer man på mennesket og de vanligste psykologiske aspektene ved handlinger som ofte går igjen i skandaler finnes det tegn og typiske mønster. De blir ofte inndelt slik at dersom mulighet, insentiver/press og holdninger/rasjonalisering er tilstede, så øker risikoen for at misligheter finner sted. Dette kan brukes til å forutse og forebygge svindel i bedriften (Petter Gottschalk, 2012). I fagteorien blir dette omtalt som «Fraud Triangle» eller mislighetstrianglet på Norsk. En teori ble lansert allerede på 50 tallet av Donald Cressey, der han presenterte en hypotese:

*«Trusted persons become trust violators when they conceive of themselves as having a financial problem which is non-shareable, are aware this problem can be secretly resolved by violation of the position of financial trust, and are able to apply to their own conduct in that situation verbalizations which enable them to adjust their conceptions of themselves as trusted persons with their conceptions of themselves as users of the entrusted funds or property» (Cressey, 1950, p. 742).*

De tre aspektene som øker risikoen for misligheter blir beskrevet her:

- **Mulighet.** Finnes det muligheter for å begå misligheter så er kanskje dette det mest kritiske aspektet (Tvedt & Thaysen, 2015). Muligheten i denne sammenhengen er tilgangen til eiendeler, informasjon og it-systemer og andre elementer som bidrar ikke bare til å gjennomføre misligholdet, men også til å skjule det. (Coenen, 2008).
- **Insentiver/press** er når selskaper eller enkeltpersoner er under press - det kan være fra kilder utenfor eller innad organisasjonen - så øker sannsynligheten for at misligheter kan oppstå (International Auditing and Assurance Standards Board, 2009). Dette kan for eksempel være at det er bonusordninger knyttet til driftsresultatet (Tvedt & Thaysen, 2015).
- **holdninger/rasjonalisering** er når arbeidstakere blir fast bestemt på eller rettferdiggjør for seg selv at handlingen er akseptabel. Eller at individene vet at det er ulovlig, men resonerer og rettferdiggjør ovenfor seg selv at handlingen er akseptabelt (Coenen, 2008; Murphy & Dacin, 2011).

I Figur 2 systematiseres de tre nevnte aspektene mulighet, insentiver/press og holdninger/rasjonalisering og forsøker å vise hvordan alle disse tre elementene henger sammen når misligheter inntreffer.





Figur 2: Fraud Triangle - earnings management - The numbers game - Scientific Figure on ResearchGate  
 Hentet fra: [https://www.researchgate.net/Figur-5-The-Fraud-Triangle-Bolton-2015-Stuart-2011\\_fig4\\_319872767](https://www.researchgate.net/Figur-5-The-Fraud-Triangle-Bolton-2015-Stuart-2011_fig4_319872767)

### 2.5.2 Manipulering av inntekter

I dette kapittelet vil røde flagg knyttet til hovedsak inntekter bli gjennomgått. En eksakt definisjon av begrepet regnskapsmanipulering er komplisert da det anvendes og forstås på forskjellige måter. Blant synonymene til begrepet som oftest blir brukt er: regnskapssvindel, regnskapsjuks, resultatstyring og kreativregnskapsføringer. Det at begrepene brukes om hverandre i faglitteraturen sier noe om at regnskapsmanipulering har et allsidig innhold (Stenheim & Blakstad, 2012). Tellefsen and Langli (2005) har fritt oversatt Healy and Wahlen (1999) sin definisjon av regnskapsmanipulasjon:

*«Regnskapsmanipulasjon foreligger når ledelsen bruker regelverkets fleksibilitet eller strukturerer transaksjoner på en slik måte at regnskapsrapportene enten feilinformerer noen interessenter om den underliggende utviklingen av selskapet eller påvirker utfallet på kontrakter knyttet til regnskapstall i en for motparten ugunstig retning» (Tellefsen & Langli, 2005, s. 757).*

#### Forskjell i inntekt

Når man skal se etter røde flagg på inntekter for en bedrift er det viktig å sammenligne disse inntektene med sammenlignbare bedrifter i samme bransje. For å kunne sammenligne forskjellige bedrifter er det viktig å trekke ut inntekter som ikke er knyttet til bedriftens hovedaktivitet, slik som «Andre inntekter».

Eksempler på regnskapslinjer under «Andre inntekter» kan være salg av anleggsmaskiner og bygningsmateriale. Hvis det er store forskjeller mellom lønnsomhet for de sammenlignende bedriftene etter at regnskapslinjer som ikke angår hovedaktivitet er trukket fra, så kan dette være et rødt flagg, og årsaken til dette bør vurderes nærmere. I slike tilfeller kan notene ha viktig informasjon som forklarer den opplevde differansen.

## **Salgsinntekter**

Salgsinntekten i et foretak anses i noen sammenhenger som et mål for bedriftens potensial og kan virke inn på utbytte kapasiteten i selskapet. Det blir lagt storvekt på salgsinntekten i forbindelse med verdsetting av selskapet og for bonusordninger i selskapet (Kvifte et al., 2011). Hvilken periode inntekten skal resultatføres i er ikke alltid like enkelt å vite. Som tidligere nevnt skal - i henhold til transaksjonsprinsippet - salg av varer føres når en transaksjon har blitt gjennomført og det er derfor normalt sett ikke et problemområde. Det er først ved salg av tjenester at tidspunkt for resultatføring at det kan være noe diffust.

I flere av regnskapsskandalene i Norge er manipulering av inntekter og tidligere nevnt problematikk en av flere fremgangsmåter som blir benyttet. Ledelsen i selskapet kan ha som hensikt å inntektsføre for tidlig, for sent eller generere fiktive inntekter. Sistnevnte er selvfølgelig det mest alvorlige, men også for tidlig og for sen inntektsføring kan ha betydelige negative konsekvenser for interessenter. Konsekvenser og avsløring av disse handlingene blir forklart senere i dette kapitlet.

## **Kundefordringer versus omsetning**

Forskjellen i inntekter knyttet til sammenlignbare bedrifters hovedaktivitet kan være grunnet for tidlig/sen bokføring eller fiktive inntekter. For tidlig bokføring av inntekter er når man regnskapsfører inntekter i en periode som er tidligere enn hva som er avtalt/skrevet ned i kontrakt. Inntektsføres det for tidlig, resulterer det i at kundefordringene vokser unormalt mye og virksomheten opplever en betydelig lavere omløpshastighet på kundefordringene. Da den er et resultat av forholdet mellom salgsinntekt og kundefordringer og sier noe om hastigheten kapital genereres i virksomheten. Det gjør at omløpshastigheten kan brukes som et sammenligningsgrunnlag mellom bedrifter i samme bransje og på den måten avdekke et rødt flagg. Det er viktig å bemerke seg at en endring i omløpshastigheten kan også komme av manglende tapsavsetning eller i økt kredittid. Dette kan igjen være indikasjoner på mindre attraktivt produkt eller lukrative rabattordninger, og på en annen side også kan være tegn på røde flagg (Penman, 2013).

Fiktive inntekter er inntekter som bokføres hvor det ikke er sannsynlig at motparten er likvid nok til å betale, eller at det ikke finnes noen motpart. Dette er kanskje den mest alvorlige overtredelsen i og med at handlingen ofte er mer bevisst og ikke bygget på tilfeldige feilføringer. Dette vil også medføre en lavere omløpshastighet enn normalt i bransjen og kan avsløres på samme måte som for tidlig førte inntekter. En annen effekt av for tidlig bokføring eller fiktive inntekter er at den netto operasjonelle kontantstrømmen for bedriften ikke stemmer overens med driftsresultatet. Da netto operasjonell kontantstrøm kan defineres som hvor store inn- og utbetalinger knyttet til de ulike driftsaktivitetene faktisk har vært. Man vil også se at de registrerte inn- og utbetalingene ikke stemmer overens med virkeligheten (Tellefsen & Langli, 2005).

Sen inntektsføring forekommer også, da kan motivet være å oppnå en resultatutjevning. En annen konsekvens av sen inntektsføring er reduserte skatter og avgifter inneværende periode, noe som kan tenkes å være motivert av å øke driftsresultatet og de positive virkningene det har (Schilit, 2002). Det er likevel viktig å poengtere at disse røde flaggene ikke gir et definitivt svar på manipulering av regnskap, kun en indikasjon.

### **Uopptjent inntekt versus omsetning**

Ved salg av en tjeneste der den fremtidige forpliktelsen ikke er levert kalles uopptjent inntekt. Slike transaksjoner forekommer ofte, eksempelvis i flybransjen der en billett blir solgt og betalingen finner sted før selve flyturen er gjennomført. Man kan manipulere regnskap med slike transaksjoner ved å undervurdere uopptjente inntekter (Schilit, 2002). Dette medfører at opptjent inntekt overvurderes og fører til et feilaktig bedre resultat. Dette vil man se ved at den prosentvise uopptjente inntekten i forhold til omsetning reduseres sammenlignet med tidligere år. En måte å avdekke slike føringer er å se på den prosentvise andelen av uopptjent inntekt i forhold til omsetningen og sammenligne den med tidligere år og med normen i bransjen.

### **Avsetning versus garanti- og serviceforpliktelser**

Avsetninger tilknytter garanti- og serviceforpliktelser er ofte erfaringsbaserte og kan lett manipuleres. Ved å undervurdere avsetningene kan man oppnå et høyere resultat enn hva som er reelt. Dette kan resultere i ubehagelige overraskelser i fremtiden da kostnaden forskyves til fremtidige perioder. Redusert avsetning kan også skyldes forbedringer av bedriftens produkter og trenger derfor ikke være et rødt flagg.

Ved å sammenligne bedriftens avsetning til garanti- og service forpliktelser med bedrifter i samme bransje vil man kunne få indikasjoner på om undervurdering av avsetninger forekommer (Tellefsen & Langli, 2005).

### **Overdreven bruk av avsetninger**

Overdreven bruk av avsetninger utføres ofte for å skaffe seg skjulte reserver. Man skaffer seg skjulte reserver i «gode år» med intensjon om å ta ut denne reserven i «dårlige år». Problemet med dette er at regnskapet ikke gir et riktig bilde av bedriftens situasjon, og den vil fremstå som mer lønnsom enn det som er reelt i «dårlige år». Man kan avsløre dette ved å se på den prosentvise avsetningen i forhold til produksjonskostnadene og sammenligne dette med tidligere år, eller bedrifter i samme bransje. Underliggende insentiver kan være å skape lavere forventning fra interessenter i «gode år» og dermed leve opp til forventninger i «dårlige år». Eller at det senere forbedrede resultatet setter ledelsen i et «godt lys» i «dårlige år» og er tilknyttet bonusavtaler som ledelsen senere vil nyte godt av eller andre goder tilknyttet driftsresultatet (Hope & Wang, 2018).

### **Fordringer overfor selskap i samme konsern**

Fordringer overfor selskap i samme konsern kan oppstå på grunn av transaksjoner som lån, konsernbidrag eller salg av varer og tjenester. Det er ikke uvanlig at det foregår transaksjoner mellom selskapene i samme konsern. Slike interne transaksjoner er regulert etter blant annet aksjeloven §3-9, som Bråthen (2004) mener har til hensikt å bekjempe illojale transaksjoner i konsernforhold. Transaksjonene skal foregå etter vanlige forretningsmessige vilkår og prinsipper og informeres om i notene i finansregnskapet. I tillegg til dette har man kun lov til å inntektsføre slike fordringer dersom det er sannsynlig at parten kan betale forpliktelsen. Har et av selskapene likviditetsproblemer bør man derfor være spesielt oppmerksom på slike konserninterne fordringer. Vokser interne fordringer unormalt mye, kan det være at det dreier seg om fiktive transaksjoner og man bør se etter røde flagg, da på samme måte som ved fiktive transaksjoner mot utenforstående selskaper. Et annet eksempel kan være kortsiktig gjeld som gjøres om til langsiktig gjeld, uten tilhørende note i regnskapet. Generelt kan man si at uklare eller ustrukturerte noter i denne sammenhengen er et rødt flagg.

### 2.5.3 Manipulering av kostnader

I dette kapittelet gjennomgås røde flagg i forbindelse med føring av kostnader. Definisjonen av begrepet manipulasjon er gjort rede for i kapittel 2.5.2 og vil derfor ikke blir gjennomgått på nytt.

#### **Varelager versus varekostnad**

Varer skal vurderes etter laveste verdis prinsipp, hvor verdien til varene settes til det laveste av anskaffelseskost og virkelig verdi. For både beregning av anskaffelseskost og vurdering av virkelig verdi må det utføres skjønn som kan medføre overvurdering av varelageret. En effekt av at varelageret blir overvurdert er at varekostnaden undervurderes og driftsresultatet bli for høyt. Dette kan igjen føre til at deler av de faste kostnadene fra varelageret blir overført til senere perioder og at varelagerets omløpstid reduseres. Ved å sammenligne resultat og omløpshastighet over tid og med virksomheter i samme bransje kan man se om den gjeldende bedriften skiller seg markant ut, hvilket kan være en indikasjon på at varelageret er overvurdert (Tellefsen & Langli, 2005).

#### **Forskning og utvikling**

Regnskapsloven § 5-6 gir anledning for bedrifter å kostnadsføre utgifter for egen forskning og utvikling. I henhold til IFRS 38 skal egenutviklet forskning kostnadsføres og egenutviklet utvikling balanseføres og avskrives – så lenge det kan dokumenteres at eiendelen blir ferdigutviklet og vil være lønnsom. Selv med klare regler slik som dette er det ikke opplagt hva som kan defineres som forskning og utvikling eller om prosjekter vil være lønnsomme i fremtiden, hvilket medfører bruk av skjønn. Store og likvide bedrifter tenderer til å kostnadsføre forskning og utvikling, mens mindre bedrifter med liten grad av likviditet, tenderer til å balanseføre forskning og utvikling. Hvis bedriften balansefører og har svak lønnsomhet og egenkapital, må man være oppmerksom på om det har vært vesentlige økninger på denne posten. Det samme gjelder hvis forskning og utvikling utgjør en stor andel av bedriftens egenkapital.

Har et selskap lav likviditet og egenkapital, og samtidig balansefører vesentlige regnskapslinjer innen forskning og utvikling, så er det et rødt flagg. Videre så bør man se på tidligere regnskap for å se om denne regnskapslinjen har økt drastisk de siste årene eller om den har vært stabil. Hvis den har økt betydelig så kan det tyde på at bedriften prøver å «pynte på tallene». Viser det seg at stor andel av egenkapitalen er balanseførte immaterielle eiendeler så er det et rødt flagg.

#### **Avskrivningspolitikk**

I henhold til International Accounting Standards 16-6 så defineres avskrivning som: «En systematisk allokering av kostprisen for en gjenstand over dens levetid.» Videre skal det tas hensyn til gjenstandens utrangeringsverdi, hvilket settes som nåverdi prisen til en gjenstand av tilsvarende art. Både avskrivninger og utrangeringsverdi åpner for bruk av skjønn, som igjen kan være med på å skape et bilde av at bedriften er bedre økonomisk stilt enn hva som er reelt (Kinserdal, 2014). Ved å sammenligne bedriften med andre sammenlignbare konkurrenter kan man se om det blir brukt andre avskrivnings metoder eller avskrivnings tider, og om dette stiller bedriften i et bedre økonomisk perspektiv.

## **Nedskrivning**

I henhold til regnskapsloven § 5-3 skal anleggsmidler nedskrives til virkelig verdi hvis det er forekommet et varig verdifall. I samme paragraf står det at hvis dette verdifallet frafaller skal nedskrivningen reverseres. Det samme gjelder for immaterielle eiendeler. Et rødt flagg kan her være at en bedrift ikke gjennomfører nedskrivning, mens andre sammenlignbare bedrifter nedskriver. Her kan det være at bedriften ikke nedskriver for å fremstå mer økonomisk likvid enn hva som er reelt. Videre så er det ikke uvanlig at nye ledere ønsker å «rydde opp» når de tar over en ny bedrift. Dette kan de blant annet gjøre ved å nedskrive anleggsmidler eller immaterielle eiendeler. Hvis man ser at det har forekommet et lederskifte bør man være oppmerksom på vesentlige nedskrivninger sammenlignet med tidligere år. Her kan det være at den nye lederen ønsker å slanke resultatet slik at det blir lettere for den nye lederen å oppnå fremtidige mål.

## **Avsetning**

Eksempler på avsetninger som bedrifter er pliktet til å balanseføre er tap på fordringer, ukurans i varelager, miljø, garantier, reparasjon og garanti på driftsmidler, avgifter, skatt og søksmål. Videre så må det kunne dokumenteres at det er mer enn 50% sannsynlighet for at kostnaden finner sted, samt at dette skal føres i noter i finansregnskapet. Slike avsetninger er ofte veldig usikre og er forbundet med stor grad av skjønn, hvilket medfører risiko for manipulering av regnskapet.

Hvis en bedrift avsetter for lite i regnskapet vil dette medføre at kostnader blir undervurdert og at resultatet blir for høyt. Dette kan observeres ved at bedriften internt vil ha en avtagende prosentandel av avsetninger i forhold til inntekter og eksternt ved at bedriften har en bedre lønnsomhet sammenlignet med andre konkurrenter i bransjen.

Videre kan bedriften også avsette mer enn forventet, i den hensikt å skaffe seg skjulte reserver som på et senere tidspunkt reverseres uten noen klar beskrivelse i finansregnskapets noter. En forklaring på hvorfor dette utføres kan være at lederen av bedriften har finansielle insentiver knyttet til resultatet eller ønsker å oppnå et mål som ikke ville ha blitt nådd uten bruk av denne skjulte reserven.

## **Pensjonsforpliktelser og pensjonskostnader**

Det finnes to hovedgrupper pensjonsordninger, den eldre ytelsesbaserte og den nyere innskuddsbaserte ordningen (Tofteland & Fladstad, 2014). Det er kun ved den eldre ytelsesbaserte ordningen at bedriftene har en fremtidig pensjonsforpliktelse. Denne pensjonsforpliktelsen blir beregnet basert på pensjonens forventede verdi ved pensjonsavgang og utbetales løpende som en pensjonskostnad samtidig med lønn. Eventuell opparbeidet avkastning på de avsatte pensjonsmidlene trekkes fra bedriftens løpende pensjonskostnader, slik at forventet verdi på pensjonen blir korrekt. Videre vil forskjellen mellom bedriftens antatte diskonteringsrente og lønnsutvikling påvirke størrelsesordenen av den fremtidige pensjonsforpliktelsen. Både fremtidig pensjonsforpliktelser og løpende pensjonskostnad er forbundet med stor grad av skjønn, hvilket igjen åpner for muligheten til å manipulere regnskapet.

Det er Norsk Regnskapsstiftelse som legger føringer for forutsetninger som skal brukes for beregning av fremtidig pensjonsforpliktelser. Hvis bedrifter bruker andre forutsetninger enn det som er anbefalt av Norsk Regnskapsstiftelse bør man være på vakt. Dette gjelder spesielt hvis det brukes forutsetninger som resulterer i en lavere pensjonskostnad eller pensjonsforpliktelse for bedriften. Et eksempel kan være å overvurdere diskonteringsrenten i forhold til lønnsutviklingen, hvilket medfører en undervurdering av bedriftens fremtidige pensjonsforpliktelse. Et annet eksempel kan være å overvurdere avkastningen på pensjonsmidlene som resulterer i en undervurdering av de løpende pensjonskostnadene. Ved å undervurdere pensjonsforpliktelser eller pensjonskostnader vil bedriften fremstå som mer lønnsom og ha for høy egenkapital.

## Utsatt skattefordel

Utsatt skatteforpliktelse og utsatt skattefordel oppstår på bakgrunn av forskjellige skattemessige regler for finansregnskap og beregning av skatt. Dette kan medføre forskjell mellom skattemessig resultat og regnskapsmessig resultat. Hvis skattemessig resultat overstiger regnskapsmessig resultat oppstår det en utsatt skattefordel på eiendelssiden i balansen. Hvis derimot regnskapsmessig resultat overstiger skattemessig resultat oppstår det en utsatt skatteforpliktelse på gjeldssiden i balansen (Tofteland & Fladstad, 2014).

Etter som de regnskapsmessige verdiene er utsatt for skjønn kan dette medføre en overvurdering av eiendelssiden og undervurdering av gjeldssiden. Hvis en bedrift har svak lønnsomhet og lav egenkapital i kombinasjon med en vesentlig andel av balanseført utsatt skattefordel - kan dette indikere manipulering av regnskapet - i den hensikt å blåse opp balansen og dermed fremstå som mer økonomisk solid enn hva som er reelt. Det samme gjelder for bedrifter hvor egenkapitalen inneholder en vesentlig andel av utsatt skattefordel.

## 2.6 Avslutning

Reguleringen i Norge gjør at selskapsstruktur og størrelse er styrende for hvilke muligheter selskapene har i forbindelse med valg av regnskapsstandard. Selskaper som havner innenfor definisjonen for små foretak har større valgfrihet og kan velge mellom 4 forskjellige «språk», børsnoterteselskap kan kun velge IFRS (International Financial Reporting Standards). GRS (god regnskapsskikk) er ansett å være den mest utbredte og er i hovedsak benyttet av selskaper som verken er børsnoterte eller havner inn under definisjonen små foretak.

Det finnes forenklinger av GRS og denne er til for å gjøre rapporteringen enklere og mindre ressurskrevende for små foretak. Det gjør at denne regnskapsstandarden ikke kan benyttes av selskaper i de andre kategoriene. For at årsregnskapene skal bli utarbeidet på best mulig måte, er det i regnskapsloven 10 regnskapsprinsipper som skal være med å regulere dette så godt som mulig. Regnskapsprinsippene lager til sammen en grunnmur som brukes til å regulere eksempelvis når inntekter og kostnader skal føres og til hvilken periode. Prinsippene er samtidig med og skaper gråsoner slik som utøvelse av skjønn i forbindelse med fastsettelse av blant annet virkelig verdi. Dette gir en tilgang for selskaper til å utnytte prinsippene til sin fordel. Dette blir gjort på mange måter og det er da viktig å se til vanlig regnskapspraksis eller om det finnes bestemmelser som regulerer handlingen.

I mange tilfeller blir informasjonsstørrelsen og tidsaspektet for interessenter så overveldende at det ikke er lett å avdekke slike handlinger. Det er i denne forbindelse bygget opp en del erfaringsbaserte og teoretiske verktøy som hjelper for å finne unormale forhold. På fagspråket blir ofte slike unormale forhold kalt «røde flagg» og kan bestå av mange forskjellige interne og eksterne forhold. Disse er knyttet til både mennesker og dets natur og handlingsmønster til markedsmessige og upåvirkelige utenforliggende forhold. «Røde flagg» kan bevege seg fra alvorlige misligheter med kriminelle handlinger som er motivert av egen eller selskapets vinning som utgangspunkt, til mindre feilregistreringer og utenforliggende forhold som et sviktende marked.

Avslutningsvis gjennomgår avhandlingen de vanligste teoriene og verktøyene knyttet til «røde flagg» og hva som forårsaker de unormale forholdene og noen eksempler blir presentert for å klargjøre problemstillingene.

### 3 Kunstig intelligens

Formålet med dette kapittelet er å gi en generell innsikt i teorien bak kunstig intelligens, samt en kort beskrivelse av hvordan denne fungerer. Kapittel 3.1 starter med å beskrive hvordan et problem løses empirisk ved hjelp av kunstig intelligens. Deretter fortsettes det med å beskrive generell teori om hvordan kunstig intelligens virker. Kapittelet avsluttes med en teoretisk beskrivelse av hvordan den kunstige intelligensen klassifiserer datasett. Kapittel 3.2 beskriver hvordan kunstig intelligens læres opp ved hjelp av trening og validering, mens kapittel 3.3 forklarer forskjellige scenarier hvor den kunstige intelligensen ikke klarer å danne en generalisert funksjon. Kapittel 3.4 gir innsikt i hvordan en kunstig intelligens kan skape en generalisert funksjon, basert på et begrenset datasett. Kapittel 3.5 avslutter med en oversikt over de hovedtypene som finnes av kunstig intelligens.

I dette studiet kan man dele inn bedriftene i to kategorier. Såkalt «syke» bedrifter og «friske» bedrifter. Med syke menes bedrifter dømt for økonomisk bedrageri mens de friske er bedrifter som ikke er dømt for økonomisk bedrag. En læringsalgoritme er et annet ord for kunstig intelligens, og disse vil videre bli brukt om hverandre i denne avhandlingen. Teorien i dette kapittelet er basert på boken Learning From Data, av Yaser Said Abu-Mostafa fra 2012 (Abu-Mostafa, 2012), hvilket har vært en av Amazons best selgende bøker innen data teknologi. Denne boken beskriver kunstig intelligens på en kortfattet og forståelig måte.

#### 3.1 Læringsproblemet

##### Problemoppsett

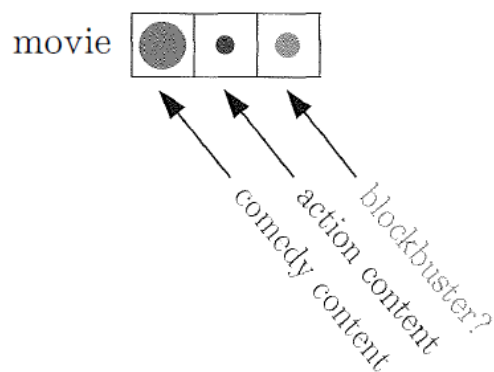
Det finnes forskjellige metoder å løse problemer på. En metode er analytisk, hvor man bruker eksakte data i numerisk form og kommer frem til en eksakt løsning på problemet, slik som en matematisk funksjon. En annen metode er empirisk, hvor man ofte bruker observasjon og eksperimentering. I kontrast med analytisk metode så gir ikke en empirisk metode et eksakt svar, men heller en approksimasjon.

Kunstig intelligens lærer ved hjelp av data. Dataen blir brukt for å komme frem til en empirisk løsning på et problem. Et eksempel på dette er anbefalings systemet til Netflix (Gomez-Uribe & Hunt, 2016). Filmer kan klassifiseres ut fra en rekke variabler, på samme måte som det gjøres med bilder i metadata (portrett/landskap, lukkertid, blender åpning, sort-hvit/farge, eksponering).

EXIF Metadata	
Make	NIKON CORPORATION
Model	NIKON D7000
Software	Ver. 1.03
Date/Time	2015-04-03 15:10:23
Exposure Time	1/1502 sec
Exposure Program	Aperture priority
Exposure Bias	-1 EV
F Number	F 4
Max Aperture	F 2.83
ISO Speed ratings	ISO 200
Flash	Flash did not fire [off]
Focal Length	38 mm
35mm Equivalent	
Metering Mode	Multi-segment
GPS	

Figur 3: Metedata fra et bilde

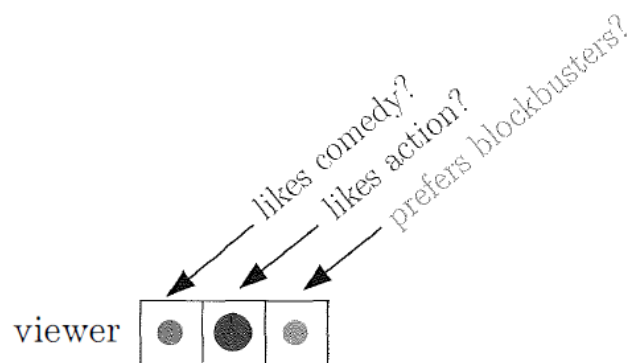
Eksempler på metadata som kan tillegges filmer kan være: sjanger, skuespiller, lengde på film, utgivelsesår.



Figur 4: Metadata fra en film

Ved å tillegge filmer en rekke slike metadata kan man koble disse med filmhistorikken til brukerne, for å lettere kunne forstå hva slags type filmer brukeren foretrekker.

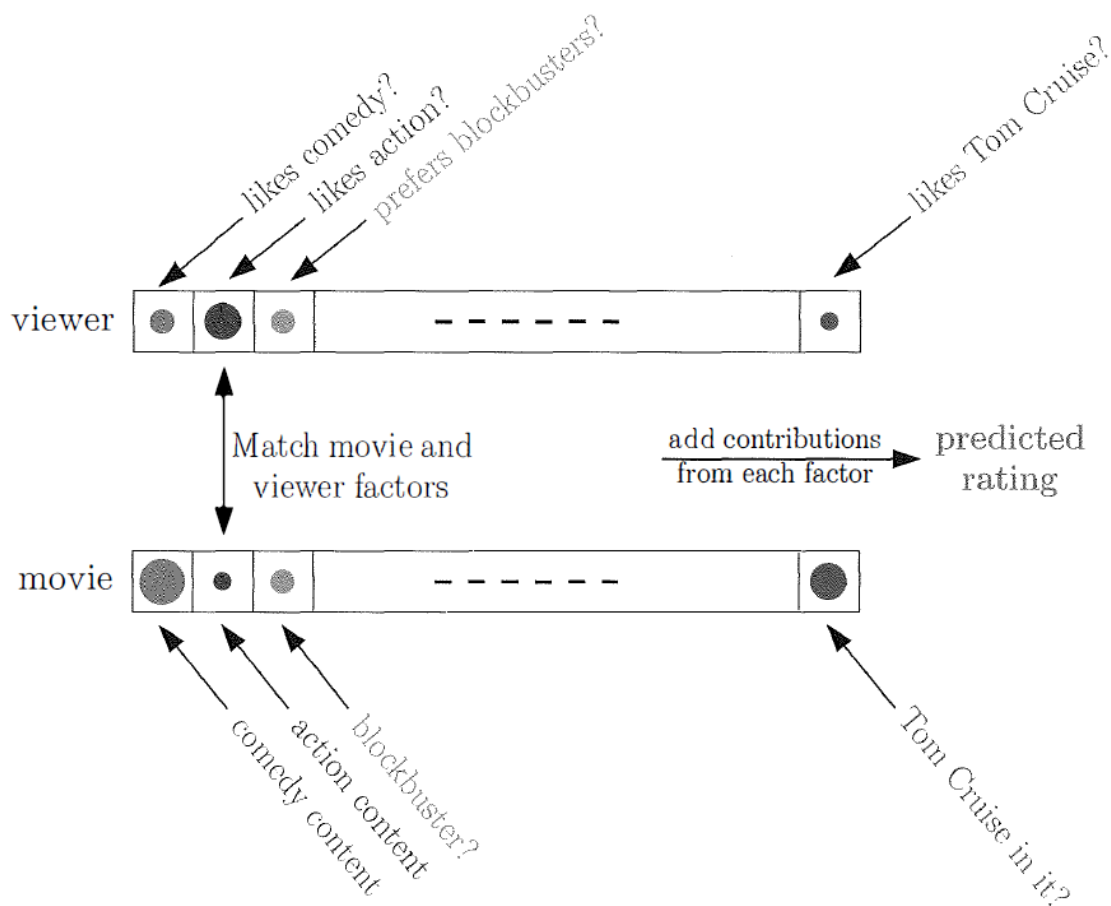
Et eksempel kan være at brukeren ser masse amerikanske filmer av sjangeren action, spesielt med Tom Cruise i hovedrollen. Basert på dette kobles følgende metadata til brukeren: [Produsert i: Amerika], [Sjanger: Action], [Skuespiller: Tom Cruise]



Figur 5: Metadata fra en bruker

Dette kan gjøres ved å implementere et enkelt ratingsystem, hvor brukeren får to valg, god eller dårlig. Input fra brukeren kobles så med metadataen til filmen. Etter at det er blitt samlet opp nok data kan den kunstige intelligensen tillegge brukeren metadata som videre kan brukes for å estimere om brukeren vil like en gitt film eller ikke.





Figur 6: Kobling av metadata fra film og bruker

Ved bruk av denne metoden kan den kunstige intelligensen allerede før brukeren har sett filmen forutse om brukeren synes det er en god film eller ikke. Ved å sammenligne metadataen til brukeren opp mot kartoteket til Netflix kan den kunstige intelligensen finne de filmene som har størst sannsynlighet for at brukeren skal like den og dermed øke omsetningen til Netflix.

### Hvordan kunstig intelligens virker

For å kunne gi et overblikk for hvordan en enkel kunstig intelligens virker gjennomgås et eksempel. Kripos ønsker å redusere arbeidsmengden som kreves og øke nøyaktigheten på å finne bedrifter som utfører bedrageri. Det finnes ingen enkel analytisk metode for å finne bedrifter som er bedrageriske, men det finnes historiske data på dette området, hvilket åpner for muligheten for å bruke en empirisk metode.

Basert på dette har Kripos bestemt seg for å bruke kunstig intelligens. For å få til dette trenger de data som de kan lære opp den kunstige intelligensen på. Alle bedrifter er pliktige til å levere årsregnskap. I årsregnskapet finnes det en rekke variabler  $[x]$  slik som fordringer, salgsinntekt, driftskostnader og varekostnad. Samtidig er det mulig å innhente data på bedrifter som er dømt for bedrageri.

Kripos legger frem følgende hypotese:

«Basert på variablene i en bedrifts finansregnskap  $[x]$ , er det mulig å sette opp en funksjon  $[f]$  som forutsier om denne bedriften er bedragerisk eller ikke  $[y]$ .»

Dette kan settes opp som funksjonen:

$$f: x \rightarrow y$$

Formel 1

Hvor  $[f]$  er den *ideelle* – og ukjente – funksjonen for oppdagelse av bedrageri,  $[x]$  er input-variablene fra finansregnskapet og  $[y]$  er svaret (output) på om bedriften er bedragerisk eller ikke, i form av ja/nei.

---

*Enklere forklart er denne funksjonen virkeligheten, altså en funksjon det er umulig å finne, men som også i mange andre fagfelt, så forsøker vi å komme så nærme som mulig matematisk. Inputen til virkeligheten/funksjonen vil i kripot sitt tilfelle være finansregnskapenes forskjellige regnskapslinjer. Og outputen vil være svaret på om det er et finansregnskap som likner på bedrageriske finansregnskap eller ikke. Den kunstige intelligensens hovedoppgave er å komme så nærme som mulig denne funksjonen ved hjelp av de variablene som blir presentert i finansregnskapet.*

---

Videre kan det settes opp et datasett  $[D]$  som består av historiske data av finansregnskapets variabler  $[x]$  og eventuelle tilhørende dommer  $[y]$ :

$$D = (x_1, y_1), \dots, (x_n, y_n)$$

Formel 2

---

*I dette tilfellet vil datasettet  $[D]$  bestå av et utvalg bedrifter, finansregnskap for samtlige av bedriftenes driftsår og samtlige regnskapslinjer i finansregnskapet.*

---

Dette datasettet  $[D]$  kan så kobles opp mot den *ideelle* og ukjente funksjonen  $[y_n]$  som er en funksjon av inputvariablene  $f(x_n)$  hvor  $n = 1, \dots, N$  tilsvarer de forskjellige bedriftene i datasettet  $[D]$ :

$$y_n = f(x_n) \quad n = 1, \dots, N$$

Formel 3

---

*I vårt tilfelle er treningsdatasettet både «syke» og «friske» finansregnskap som vi kunne koble mot en ideell funksjon, hadde det vært mulig. Man ville da ha brukt alle variablene på funksjonen, summert opp til et resultat som ville gitt oss svar på om bedriftens finansregnskap hadde tegn på bedrageri eller ikke.*

---

Basert på datasettet  $[D]$  beregner den kunstige intelligensen – ved hjelp av en læringsalgoritme  $[A]$  – en funksjon  $[g]$  som best tilnærmer den ideelle og ukjente funksjonen  $f: x \rightarrow y$ :

$$g: x \rightarrow y$$

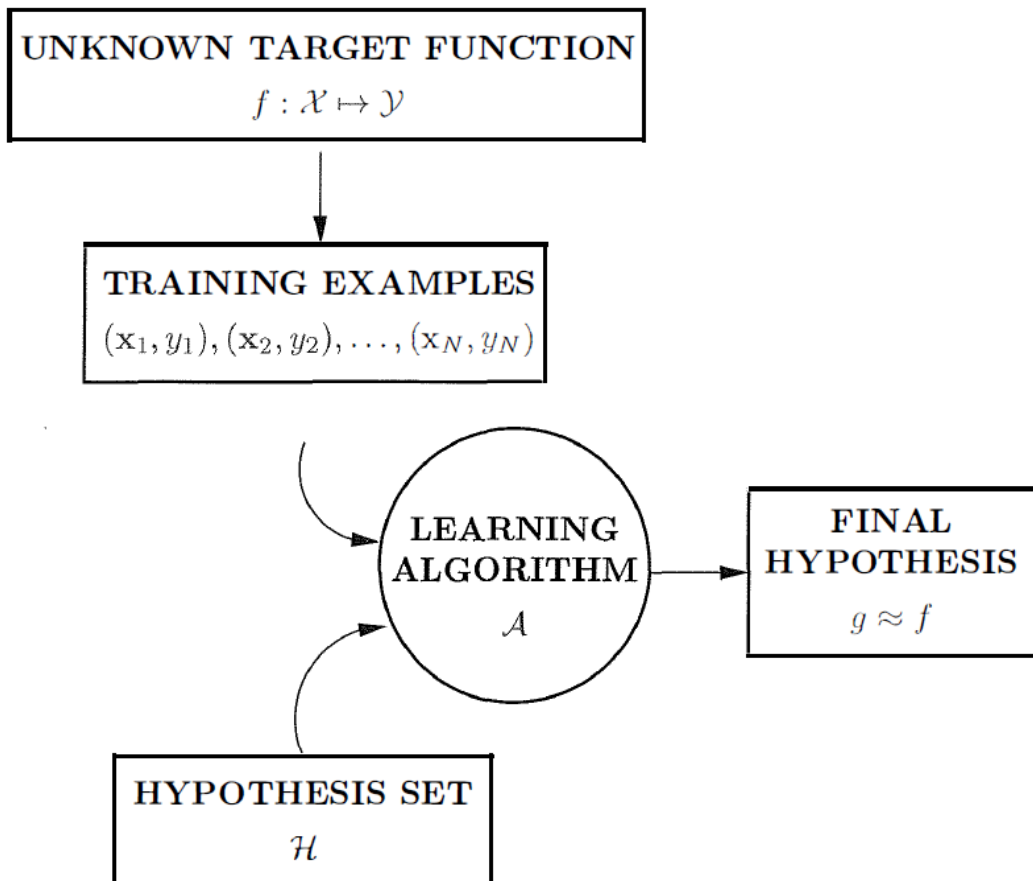
Formel 4

---

*Den kunstige intelligensen bruker her datasettene den får presentert til å lage en funksjon  $[g]$  som prøver å nærme seg den ideelle funksjonen  $[f]$ . Dette gjør den ved prøving og feiling til differansen er så liten som mulig. For å gjøre dette mulig har både brukeren og den kunstige intelligensen en «verktøykasse» som kalles hypotese sett  $[H]$  som muliggjør manipulasjon på forskjellige måter av funksjonen  $[g]$ .*

---

Den kunstige intelligensen  $[A]$  velger  $[g]$  ut fra et sett av forhåndsbestemte formler  $[H]$  som kalles for hypotese sett. En oversikt over problemoppsettet kan sees i Figur 7.



Figur 7: Oversikt over problemoppsettet

I et gitt problemoppsett vil alltid den *ideelle* funksjonen  $[f]$  og datasettet  $[D]$  være satt av problemet man ønsker å løse. Læringsalgoritmen  $[A]$  og Hypotesesettet  $[H]$  er ikke definert av problemet, og er noe som brukeren og den kunstige intelligensen velger ut fra et sett av verktøy og blir ofte kalt for læringsmodellen.

---

*Hypotese settet  $[H]$  er en verktøykasse med forskjellige muligheter for å manipulere funksjonen  $[g]$  der målet er å komme så nærme funksjonen  $[f]$  som mulig.*

---

Det settes opp et input rom:

$$X = \mathbb{R}^d$$

Formel 5

Hvor  $\mathbb{R}^d$  er det Euklidiske d-dimensjonale rommet. Videre settes det opp et output rom:

$$y = \{+1, -1\}$$

Formel 6

Hvor output gir et enkelt ja/nei svar.  $[+1]$  defineres som at bedriften er ikke-bedragerisk og  $[-1]$  at den er bedragerisk.

---

Det Euklidiske  $d$ -dimensjonale input rommet vil i dette tilfellet være alle variablene som finnes i finansregnskapet. Som en sammenligning så vill koordinatene i et Euklidisk 3-dimensjonalt rom inneholdt 3 variabler. Resultatet eller outputen i dette tilfellet er svaret på om den kunstige intelligensen mener finansregnskapet likner på et bedragerisk finansregnskap eller ikke.

---

Videre kan det settes opp en input vektor:

$$x \in \mathbb{R}^d$$

Formel 7

Som korresponderer med variablene som finnes i finansregnskapene til de forskjellige bedriftene. Hypotesesettet  $[H]$  velges basert på en funksjon som alle hypotesene  $[h]$  deler:

$$h \in H$$

Formel 8

Denne funksjonen  $h(x)$  vektet de forskjellige koordinatene av  $x$ , hvor vektene  $[w]$  forteller hvor stor påvirkningsgrad variablene  $[x]$  har på utfallet  $[y]$ . Disse vektene legges sammen og sammenlignes med en forhåndsdefinert grense:

Bedriften ansees som:

$$\text{Bedragerisk hvis } \sum_{i=1}^d w_i x_i > \text{grense}$$

Formel 9

$$\text{Ikke-bedragerisk hvis } \sum_{i=1}^d w_i x_i < \text{grense}$$

Formel 10

Denne funksjonen kan videre bli forkortet slik:

$$h(x) = \text{sign} \left( \left( \sum_{i=1}^d w_i x_i \right) + b \right)$$

Formel 11

Hvor: Komponentene av  $X$  er variablene  $x_1, \dots, x_d$ , vektene er  $w_1, \dots, w_d$  og  $b$  er grensen for når en bedrift er bedragerisk eller ikke. Dette vil gi  $h(x)$ , som er svaret for når en bedrift er bedragerisk eller ikke.

---


*Kort oppsummert settes det her opp en funksjon som beskriver hvordan vektingen av de forskjellige variablene utføres og grensen for når en bedrift ansees for å være enten bedragerisk eller ikke bedragerisk.*

---

### Klassifisering av datasett


Læringsalgoritmen  $[A]$  leter gjennom et sett av hypotesesett  $[H]$  og bruker det hypotesesettet og den grensen  $[b]$  som best passer datasettet  $[D]$ . Positive vektorer  $[w]$  på koordinatene tyder på variabler som henviser til ikke-bedrageri, mens negative vektorer  $[w]$  tyder på variabler som henviser til bedrageri.

En enkel illustrasjon av hvordan dette virker kan vises med et datasett  $[D]$  i et to-dimensjonalt rom ( $d=2$ ). Dette datasettet består av variabler fra finansregnskapet til bedrifter som både er bedrageriske ( $x$ ) og ikke-bedrageriske ( $o$ ).



Figur 8: Datasett med syke (x) og friske (o) bedrifter

Dette todimensjonale rommet deles i to av en linje, hvor den ene regionen tilsvarende bedragerisk og den andre ikke-bedragerisk. Denne linjen bestemmes av funksjonen  $w_1x_1 + w_2x_2 + b = 0$ , hvor  $[x]$  er variablene fra finansregnskapet,  $[w]$  er vektene som tillegges variablene og  $[b]$  er grensen. Denne forenklete funksjonen vil klassifisere dataene riktig dersom de er *lineært separerbare*. Nedenfor kan det sees eksempler for korrekt klassifiserte og ukorrekt klassifiserte data.



Figur 9: Datasett med ukorrekt klassifisert data (a) og korrekt klassifisert data (b)

Ved å endre på  $w_1$ ,  $w_2$  og  $b$ , endres også linjen som separerer rommet i en bedragerisk region og en ikke bedragerisk region. Funksjonen kan videre forenkles ved å definere grensen  $[b]$  som en vekt  $[w_0]$  og implementere den i de andre vektene til en vektor  $W = [w_0, w_1, \dots, w_d]^T$ . Hvor  $^T$  viser til «transpose of a vector», og  $[W]$  er dermed en kolonne vektor. På samme måte kan variabelen  $[x]$  settes opp som kolonne vektor og blir dermed  $X = [x_0, x_1, \dots, x_d]^T$ , hvor  $[x_0]$  settes som  $x_0=1$ . Basert på disse forenklingene blir input rommet:

$$X = \{1\} \times \mathbb{R}^d = \{[x_0, x_1, \dots, x_d]^T \mid x_0 = 1, x_1 \in \mathbb{R}, \dots, x_d \in \mathbb{R}\}$$

Formel 12

I vektor form kan funksjonen for  $h(x)$  forenkles til:

$$h(x) = \text{Sign}(W^T X)$$


Formel 13

Måten læringsalgoritmen klarer å skille dataene på er gjennom epoker (iterering). For hver epoke  $[t]$ , hvor  $t=0,1,2,3\dots n$  gir dette en verdi til vekt-vektoren  $W(t)$ . Læringsalgoritmen velger ut en vilkårlig feilklassifisert variabel  $(x(t), y(t))$  av det historiske datasettet  $[D]$ , hvor  $D = (x_1, y_1), \dots, (x_n, y_n)$ . Denne feilklassifiserte variabelen brukes så for å oppdatere vekt vektoren  $W(t)$ . Dette gjøres basert på funksjonen:

$$W(t + 1) = W(t) + x(t), y(t)$$

Formel 14

Denne itereringen av epoker gjennomføres helt til  $(x(t), y(t))$  er riktig klassifisert. Dette får vektoren  $[W]$  til å flytte seg i retning av å klassifisere  $(x(t), y(t))$  riktig.



Figur 10: Klassifisering av data ved endring av vektor  $[w]$  og bruk av epoker

Når denne variabelen er riktig klassifisert velger den en ny feilklassifisert variabel og fortsetter helt til det ikke finnes flere feilklassifiserte variabler. Når det ikke finnes flere feilklassifiserte variabler vil hypotesen  $h(x)$  være lik den ideelle funksjonen  $y(x)$ :

$$y(x) = h(x) = \text{Sign}(W^T X)$$

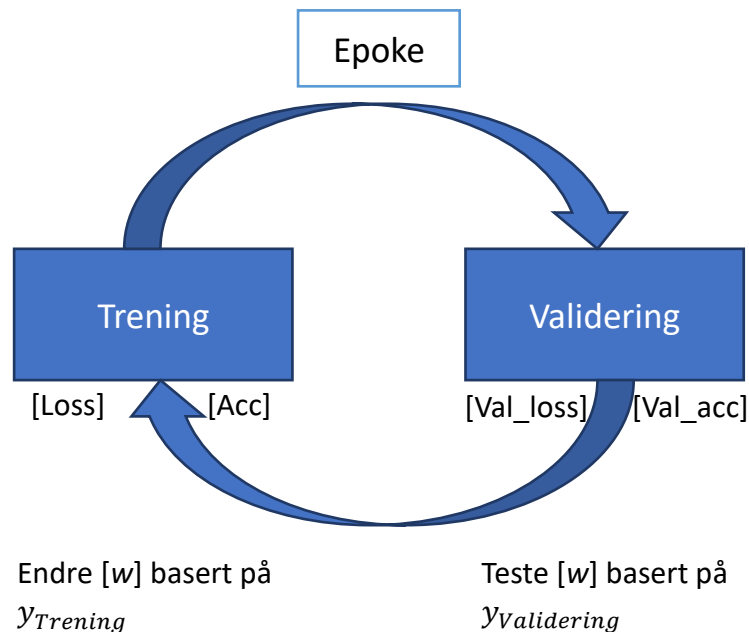
Formel 15

### 3.2 Trening og validering

Treningen av den kunstige intelligensen gjøres ved å legge til vektor  $[w]$  til variablene  $[x]$  i regnskapene. Vektene forteller hvor stor påvirkningskraft disse variablene har på resultatet  $[y]$ . Den kunstige intelligensen starter læringen ved å dele datasettet i et treningssett og et valideringssett. Både treningssettet og valideringssettet inneholder begge kategorier av bedrifter, syke og friske. For hvert av disse datasettene kan det beregnes en tapsfunksjon og nøyaktighet. Disse funksjonene brukes for å vurdere hvor godt læringsmodellen passer den gitte problemstillingen og vil bli beskrevet nærmere i kapittel 3.3.

Ved starten av læringen randomiseres vektene  $[w]$  til variablene  $[x]$  i treningssettet. Dette gjøres for å forhindre bias under læringen. I treningssettet vet den kunstige intelligensen resultatet  $[y]$ , og endrer vektene  $[w]$  til variablene  $[x]$  for å prøve å oppnå det oppgitte resultatet  $[y]$ . Vektene  $[w]$  som læringsalgoritmen kom frem til i treningssettet brukes så på valideringssettet, hvor resultatet  $[y]$  ikke er kjent. Basert på om nøyaktigheten i valideringssettet  $[Val\_acc]$  øker eller minker, endres vektene

på nytt – i treningssettet – i et forsøk på å maksimere  $[Val\_acc]$ . Dette utføres frem til vektene  $[w]$  er optimaliserte hvilket gir en optimal prediksjon av resultatet  $[y]$ . Dette vises konseptuelt i figuren under.




Figur 11: Trening og validering av kunstig intelligens

### 3.3 Undertilpassing versus overtilpassing

Som beskrevet i kapittel 3.2 beregnes det to forskjellige typer funksjoner under trening og validering. Dette er  $[Loss]$  og  $[Acc]$  for treningssettet og  $[Val\_loss]$  og  $[Val\_acc]$  for valideringssettet.  $[Loss]$  og  $[Val\_loss]$  er tapsfunksjoner og står for «categorical crossentropy» (Keras, 2018).  $[Acc]$  og  $[Val\_acc]$  er nøyaktigheten i prosent. Disse funksjonene brukes for å vurdere hvor godt læringsmodellen passer problemoppsettet, og vil bli beskrevet i dette avsnittet. Hvis læringsmodellen ikke passer problemoppsettet vil den overtilpasse eller undertilpasse datasettet.

#### Overtilpassing

Overtilpassing er når læringsalgoritmen overvurderer variablene i treningssettet – på bekostning av variablene i valideringssettet – og gjør den beregnede funksjonen  $[g]$  mindre generaliserbar. Dette kan eksemplifiseres i et to-dimensjonalt diagram med fem datapunkter. Den ukjente og ideelle funksjonen  $[f]$  (target) disse datapunktene følger er en annen grads funksjon.



Figur 12: Visuell representasjon av overtilpassing

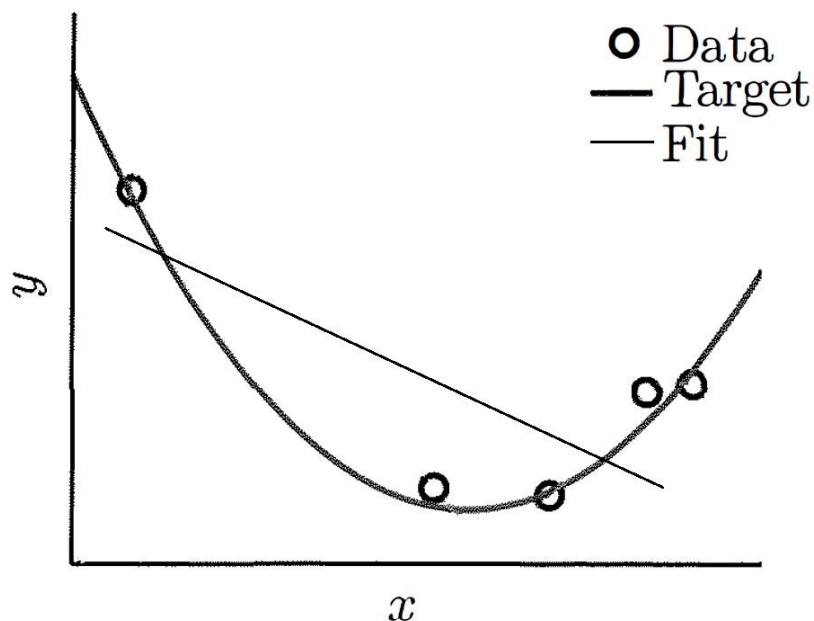
Jo flere epoker læringsalgoritmen gjennomfører desto mer vil læringsalgoritmen søke etter å maksimere passformen etter datapunktene. Dette kan føre til at læringsalgoritmen skaper en mer kompleks funksjon  $[g]$  (fit) som ikke stemmer med den ideelle og ukjente funksjonen  $[f]$  (target). I dette eksempelet vises dette med en fjerde grads funksjon (fit) – som passer datapunktene perfekt men – som ikke vil passe for datapunkter utenfor treningssettet, som følger den ideelle og ukjente funksjonen  $[f]$  (fit).

Ved bruk av tapsfunksjonene –  $[Loss]$  for treningssettet og  $[Val\_loss]$  for valideringssettet – kan man vurdere om læringsmodellen overtilpasser datasettet. Ved overtilpassing vil  $[Loss]$  over tid synke, samtidig som  $[Val\_loss]$  stiger. Dette betyr at den kunstige intelligensen overvurderer variablene i treningssettet – på bekostning av variablene i valideringssettet – og gjør den beregnede funksjonen  $[g]$  (fit) mindre generaliserbar. For å redusere risiko for overtilpassing stoppes læringen når indikasjon for dette forekommer.

### Undertilpassing

Undertilpassing er når læringsmodellen forsøker å tilpasse datapunktene i treningssettet hvilket den – av forskjellige mulige årsaker – ikke klarer. Likt som eksempelet for overtilpassing kan dette eksemplifiseres med et to-dimensjonalt diagram med fem datapunkter, med den samme ukjente og ideelle annen-gradsfunksjonen  $[f]$  (target).





Figur 13: Visuell representasjon av undertilpassing

I dette eksempelet vises dette ved at hypotesesettet  $[H]$  som læringsalgoritmen bruker er basert på en første-grads funksjon  $[g]$  (Fit), som ikke klarer å treffe datapunktene i datasettet.

Ved bruk av nøyaktighetsfunksjonene –  $[Acc]$  for treingssettet og  $[Val\_acc]$  for valideringssettet – kan man vurdere om læringsmodellen undertilpasser datasettet. Ved undertilpassing vil den kunstige intelligensen – selv over utallige epoker – ikke oppnå høy nøyaktighet for  $[Acc]$  eller  $[Val\_acc]$ . Dette betyr at læringsalgoritmen ikke klarer å beregne en funksjon  $[g]$  (fit) som passer for datapunktene i datasettet.

### 3.4 Trening versus validering

Når man trener en læringsalgoritme basert på et datasett, er det viktig å forsikre seg at funksjonen  $[g]$  – som læringsalgoritmen har approksimert til å passe den *ukjente og ideelle* funksjonen  $[f]$  – ikke kun fungerer på datasettet  $[D]$ , men også for andre og fremtidige data. Altså at funksjonen  $[g]$  er *generaliserbar*. Dette gjøres ved å holde en del av datasettet  $[D]$  tilbake slik at det er ukjent for læringsalgoritmen, og på et senere tidspunkt – når læringsalgoritmen er trent opp – teste om funksjonen  $[g]$  også passer for datasettet som er ukjent.

En analogi som kan brukes er hvordan man øver til en eksamen. Når man øver til en eksamen får man ofte gamle eksamens sett (trenings sett) å øve på. Disse gamle eksamens settene (input) kommer ofte også med fasit (output), slik at man kan prøve seg frem med forskjellige fremgangsmåter for å komme til riktig svar (vektning og epoker). Hensikten med denne treningen er ikke å bli god på akkurat disse eksamens settene, men å skaffe seg en fundamental forståelse for hvordan slike oppgaver skal løses  $[g]$ , slik at man senere kan bruke den samme forståelsen på oppgaver av samme type. Når man har trent ferdig på de gamle eksamens settene er man klar til å ta eksamen (validerings sett) og se hvor godt den fundamentale forståelsen  $[g]$  man har opparbeidet seg passer med oppgavene man nå får (generalisering).

For den trente læringsalgoritmen kan unøyaktigheten  $[E]$  beregnes. Denne kan deles opp i i-datasett-unøyaktighet  $E_{train}$ , utenfor-datasett-unøyaktighet  $E_{out}$  og validerings-unøyaktighet  $E_{val}$ .  $E_{train}$  forteller hvor god unøyaktigheten er for selve trenings datasettet.  $E_{out}$  derimot sier hvor høy unøyaktigheten er for hele input rommet  $[X]$ . Input rommet er alle mulige datapunkter som passer

den *ideelle og ukjente* funksjonen ( $f$ ).  $E_{val}$  gir hvor høy unøyaktighet som er målt på valideringssettet. Når læringsalgoritmen gis et valideringssett for å teste hvor godt den presterer på dette ukjente settet, så er det et forsøk på å se hvor godt læringsalgoritmen klarer å generalisere den funksjonen den har kommet frem til, til å gjelde hele input rommet  $[X]$ . Det kan vises at ved et stort nok antall datapunkter i valideringssettet så vil  $E_{val} \approx E_{out}$ . Med 1 000 datapunkter i valideringssettet så vil  $E_{val} \pm 5\% E_{out}$  med en sannsynlighet  $\geq 98\%$ .

### 3.5 Læringsparadigmer

Etter som læring fra data omhandler å bruke observasjon for å finne en underliggende prosess har det oppstått en rekke forskjellige paradigmer som forsøker å håndtere forskjellige situasjoner og antagelser. Den viktigste forskjellen mellom disse typene av paradigmer omhandler hvordan dataene blir håndtert. De tre viktigste læringsparadigmene gjennomgås i dette kapittelet og er:

- Veiledende læring
- Ikke veiledende læring
- Forsterkende læring

#### Veiledende læring

Dette er metoden som blir brukt i denne oppgaven. Under paradigmet veiledende læring så vil det for hver input  $[x]$  være tilgjengelig en korresponderende output  $[y]$ . Eksempelet som er gjennomgått i kapittel 3.1 er et eksempel på veiledende læring. Et annet kjent eksempel er MNIST datasettet, hvor det er satt opp en rekke eksempler på håndskrevne tall  $[0,1,2,3,4,5,6,7,8,9]$  (input), med korresponderende digitale verdier (output). Dette datasettet presenteres for læringsalgoritmen i form av ['bilde', 'tall verdi'], og kan defineres som  $(x_n, y_n)$  slik som tidligere beskrevet.



Figur 14: MNIST datasettet ("MnistExamples," 2017)

Videre så kan læringsalgoritmene klassifiseres basert på måten de henter datasettet på. Eksempler på dette kan være *aktiv læring* og *online læring*.

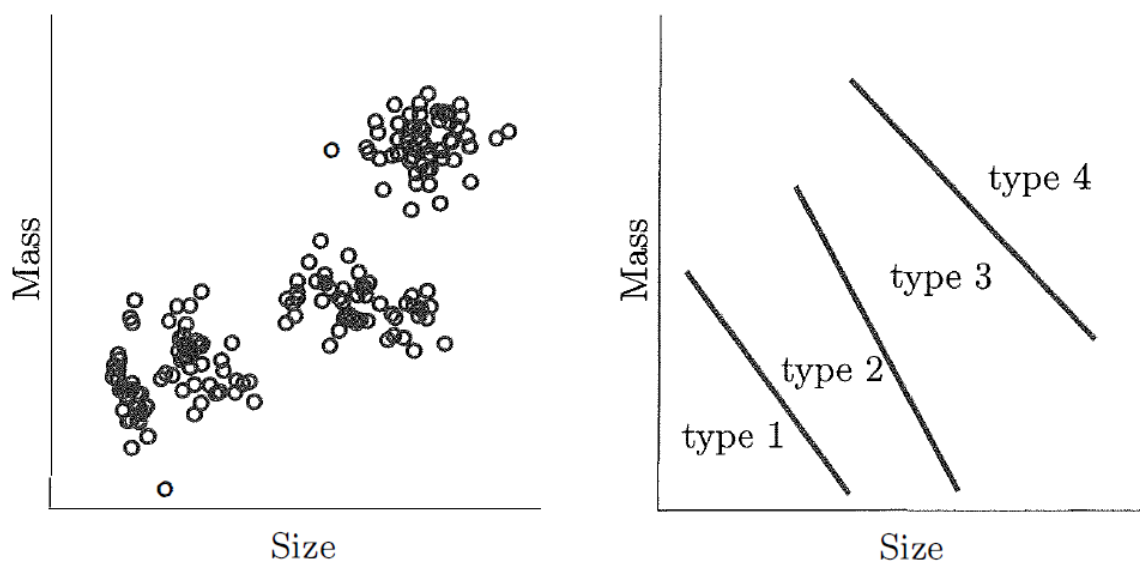
Ved aktiv læring hentes datasettet basert på en spørring som veilederen utfører. Dette medfører at veilederen selv velger et punkt i input rommet som kan optimere informasjonsverdien i datasettet.

Online læring er en måte å kontinuerlig hente ut data på, et datasett av gangen. Dette medfører at læringsalgoritmen kan prosessere dataen etter hvert som det kommer mer data. Anbefalings systemet til Netflix som er beskrevet tidligere er et eksempel på dette. Kontinuerlig innhenting av data er nyttig i situasjoner hvor prosesseringskraft og lagringsplass er begrenset.

### Ikke veiledende læring

Ikke veiledende læring er konseptuelt ganske likt veiledende læring, men med en markant forskjell. I ikke veiledende læring gis læringsalgoritmen data med bare input verdier. Det er dermed opp til læringsalgoritmen å klassifisere datasettet kun basert på input dataen. Ikke veiledende læring kan brukes for å se etter mønster og strukturer i input dataen og dermed skape en bedre representasjon av dataen. Ikke veiledende læring kan ofte være en forløper til veiledende læring.

Et eksempel på dette kan være å klassifisere mynter. Myntene veies og måles og det settes opp et datasett basert på dette ['vekt', 'diameter']. Læringsalgoritmen får kun denne informasjonen og må prøve å klassifisere dataene basert på dette. Forskjellige mynter har ofte forskjellige vekter og størrelser. Videre vil det også være en viss variasjon i hver mynt grunnet presisjonen til utstyret som lager myntene. Det vil dermed oppstå en naturlig gruppering av mynter som læringsalgoritmen vil kunne utnytte til å klassifisere. Etter som vekt og diameter er den eneste informasjonen læringsalgoritmen får så vil klassene ikke få unike navn, kun en numerisk navngivning.



Figur 15: Fordeling av umerkede mynter etter vekt og størrelse (a). Gruppering av umerkede mynter basert på ikke-veiledende læring (b)

### Forsterkende læring

Informasjonen om forsterkende læring er basert på en artikkel gitt ut av Deepmind Technologies, «Playing Atari with Deep Reinforcement Learning» av (Mnih et al., 2013).

Ved forsterkende læring gis både input og output, slik som i veiledende læring. I forsterkende læring derimot kan en gitt input ha en rekke forskjellige output. For at læringsalgoritmen skal kunne operere med et slikt datasett legges det til en ekstra variabel, hvilket er gradering av output. Når en input ikke har kun én mulig output, men flere forskjellige muligheter må det finnes en måte å vurdere om input gir det ønskede resultatet av output. Dette gjøres ved å legge til en ekstra variabel, gradering av output ['input', 'mulig output', 'gradering av output'].

Et godt eksempel på bruk av dette er i dataspill. Input i et dataspill vil for kunstig intelligens ofte være den samme inputen som mennesker bruker, og det er de input som brukes for å operere spillet, f.eks. [↑, ↓, ←, →, 'løp', 'hopp']. For at en spiller skal vite hvilke input som skal brukes trenger den output. I slike spill vil spillet ofte være over i form av at man dør. Dette kan være læringsalgoritmens output [levende/død]. Hvis hensikten med spillet er noe annet enn kun å holde seg i live vil ikke denne outputen hjelpe læringsalgoritmen å bli bedre, den trenger noe mer (Abu-Mostafa,

2012). Det er ikke uvanlig i spill at man blir gradert, altså at man får en score for hvor godt man presterer. Dette er et godt eksempel på en gradering av output. Ved bruk av disse tre variablene ['input', 'mulig output', 'gradering av output'] kan læringsalgoritmen trenes opp (Abu-Mostafa, 2012). Læringsalgoritmen slippes løs i et virtuelt miljø og prøver seg frem med tilfeldige input. Disse input [ $\uparrow$ ,  $\downarrow$ ,  $\leftarrow$ ,  $\rightarrow$ , 'løp', 'hopp'] fører til en av flere mulige output [levende/død], som igjen graderes ved hjelp av en score. Basert på output og gradering, vekter læringsalgoritmen de input som ble gjort. Basert på de oppdaterte vektene på input prøver læringsalgoritmen på nytt og forsøker å optimere output og gradering.



Figur 16: Oversikt over Atari spill som Deepmind's Alphago ble trent opp på

Et godt eksempel på dette er Deepmind Technologies' Alphago som i 2013 ble lært opp til å mestre en rekke forskjellige atarispill basert på en avansert form for forsterkende læring (Mnih et al., 2013).

### 3.6 Avslutning

Kunstig intelligens bruker en empirisk metode for å løse et problem. Dette gjør den ved å beregne en funksjon – som approksimerer den ideelle og ukjente funksjonen for problemet – basert på historiske input og output data. I sin enkleste form kan kunstig intelligens beskrives som et to-dimensjonalt rom, hvor linjen  $Y = aX + b$  er funksjonen som den kunstige intelligensen bruker for å klassifisere data med. Den kunstige intelligensen trenes opp ved å splitte et datasett opp i to deler. Et treningssett hvor output er kjent og et valideringssett hvor output ikke er kjent. Både treningssettet og valideringssettet inneholder begge kategorier av bedrifter, syke og friske. Basert på output data i treningssettet forsøker den kunstige intelligensen å justere linjen som klassifiserer datasettet i to deler. Den samme linjen brukes på valideringssettet for å verifisere at klassifiseringen også kan brukes når output er ukjent.

Overtilpassing er når læringsalgoritmen favoriserer datapunktene i treningssettet. Dette medfører at læringsalgoritmen kommer frem til en funksjon  $[g]$  – som passer datapunktene i treningssettet, men – som ikke passer med den ideelle og ukjente funksjonen  $[f]$  (mindre generaliserbar). Undertilpassing er når læringsalgoritmen ikke klarer å lage en funksjon  $[g]$  som passer hverken datapunktene i treningssettet eller den ideelle og ukjente funksjonen  $[f]$ .

Jo større valideringssettet er desto større er sannsynligheten for at funksjonen den kunstige intelligensen kommer frem til er generalisert. Dette betyr at funksjonen også kan brukes på data som er utenfor datasettet, så lenge det omhandler samme type problem.

Det finnes tre hovedtyper av læring: veiledende læring, ikke-veiledende læring og forsterkende læring. Det er veiledende læring som blir brukt i denne avhandlingen.

## 4 Data

Formålet med dette kapittelet er å presentere dataene som er brukt i denne avhandlingen, samt å beskrive hvordan disse dataene er renset. Kapittel 4.1 starter med å presentere data for finansregnskap, for så å presentere data for dommer, og avslutter med datarammen som er en kobling av finansregnskap og dommer. Kapittel 4.2 deles opp på samme måte og beskriver hvordan disse dataene er renset. I tillegg er det lagt til et avsnitt som beskriver hvordan den kunstige intelligensen renser dataene før prosessering.

Innsamling av input data og output data har vært meget tidkrevende og står for en betydelig del av arbeidet i oppgaven. Dette omfatter innhenting av data fra 20 000 bedrifter for å danne grunnlaget for input data, samt en gjennomgang av 12 158 dommer for å danne grunnlaget for output data. Dette har resultert i et datagrunnlag på 14 111 finansregnskap, hvor hvert finansregnskap inneholder 156 regnskapslinjer, med totalt 668 557 unike datapunkter. Hvor datapunkter er hver unike celle i datarammen, eller enklere forklart som kun unike og relevante celler/punkter med informasjon som slekter fra årsregnskapene i Excel- arkene.

### 4.1 Beskrivelse av data

I dette kapittelet beskrives dataene som er brukt i denne avhandlingen. Dataene kan klassifiseres i to kategorier: finansregnskap som er input data [x] og dommer som er output data [y]. Disse dataene – input og output – kobles sammen i en dataramme.

#### 4.1.1 Finansregnskap (input data)

Finansregnskapene er hentet fra Proff Forvalt (forvalt.no). Dataene i finansregnskapet er kun numeriske i natur og samtlige datasett har identiske maler, hvilket forenkler sammenligning av dataene. Nedenfor kan det sees et eksempel på hvordan et finansregnskap hentet ut fra Proff Forvalt ser ut.

RESULTATREGNSKAP	1998	1999	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010
Konsernregnskap	Nei	Nei	Nei	Nei	Nei	Nei	Nei	Nei	Nei	Nei	Nei	Ja	Ja
Startdato													
Avslutningsdato	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####	#####
Valutakode	NOK	NOK	NOK	NOK	NOK	NOK	NOK	NOK	NOK	NOK	NOK	NOK	NOK
Sum salgsinntekter	89,247	94,443	102,759	126,603	131,957	130,005	140,738	149,362	186,417	213,349	231,683	248,955	260,987
Leieinntekter													
Annen driftsinntekt	0	0	0	0	0	2,504	0	0	0	0	0	2,144	1,852
Sum driftsinntekter	89,247	94,443	102,759	126,603	131,957	132,509	140,738	149,362	186,417	213,349	231,683	251,099	262,839
Varekostnad	48,058	43,471	44,982	45,757	44,547	44,618	53,948	52,085	74,147	83,442	89,626	92,869	88,142
Endr. behold. varer under tilvirk./ferdige						108	-3,941	96	-5,445	-622	-4,686	-596	-714
Beholdningsendringer	-3,042	1,289	6,439	563	726	108	-3,941	96	-5,445	-622	-4,686	-596	-714
Endr. behold. varer under tilvirk.													
Endr. behold. ferdig tilvirk. varer													
Endr. behold. egentilvirk. anleggsmidl.													
Lønnskostnader	27,334	31,671	35,373	60,461	64,290	64,922	68,814	70,432	82,959	86,021	97,914	106,267	117,578
Herav kun lønn		23,750	26,817	51,117	52,652	54,508	57,383	58,539	67,503	78,447	87,276	94,332	106,752
Pensjonskostnader								2,501	4,646		8,070		7,418
Obligatorisk tjenestepensjon													
Avskrivning varige driftsmidler/im. eiend.	5,605	5,155	5,011	4,822	5,277	6,261	6,524	6,282	6,511	9,152	10,699	12,084	13,381
Nedskrivning av driftsmidler/im. eiend.													
Tap på fordringer													-18
Andre driftskostnader	10,573	10,855	19,930	13,949	15,048	14,828	15,648	14,632	18,359	23,654	27,208	31,291	49,281
Husleiekostnader													
Sum driftskostnader	88,528	92,441	111,735	125,552	129,888	130,522	140,993	143,527	176,531	201,646	220,762	241,915	267,650
Driftsresultat	719	2,002	-8,976	1,051	2,069	1,987	-255	5,835	9,887	11,702	10,922	9,184	-4,811
Mottatt utbytte													
Inntekt på investering i datterselskap						0	0	0	0	0	0	0	0
Inntekt på invest. annet foretak i sm konsern						0	0	0	0	0	0	0	0
Inntekt på invest. i tilknyttet selskap						0	0	0	0	0	0	0	0
Renteinnt. fra foretak samme konsern													
Sum annen renteinntekt		1,803	1,039	1,363	1,909	0	0	0	0	0	0	0	0
Verdiøk. markedsbas. fin.omløpsmidl.													
Verdiøk. andre fin.instr. vurd. virkelig verdi								720	-584	732		2,600	3,358
Sum annen finansinntekt		0	0	0	0	935	825	425	794	1,316	1,827	5,146	4,286
Sum finansinntekter	1,215	1,803	1,039	1,363	1,909	935	825	1,146	211	1,317	1,827	5,147	4,286

Figur 17: Finansregnskap eksportert til Excel fra Proff Forvalt

Finansregnskapene som hentes for de forskjellige bedriftene er to-delte. Den ene inneholder regnskapslinjer for balanse og resultatregnskap, mens den andre inneholder nøkkeltall og kontantstrøm. For hver av disse filene inngår samtlige innrapporterte år for den gjeldende bedriften.

Det er foretatt et uttrekk fra Proff Forvalt, fordelt på 10 000 bedrifter som fortsatt er i drift og 10 000 bedrifter som er lagt ned. Antallet bedrifter ble valgt basert på det maksimale uttrekket som er mulig å hente ut fra Proff Forvalt.

#### 4.1.2 Dommer (output data)

For å identifisere bedrifter med stor sannsynlighet for bedrageri er det brukt dommer fra Lovdata (lovdata.no). Disse dommene går på person og ikke bedrift, hvilket vil si at personene i dommene må knyttes til bedriftene, samtidig som at de må ha stor nok påvirkningskraft til at de skal kunne påvirke regnskapet til bedriften. Kriteriene som er blitt brukt er at personen skal ha en høyere topplederstilling, slik som daglig leder, produksjons sjef, økonomisjef eller sitte i styret til bedriften, eller på en annen måte ha stor nok innflytelse i bedriften for å kunne manipulere regnskapet. Et annet kriterier som er brukt er at personen må være dømt for forbrytelsen. Dommene som hentes fra Lovdata er sensurerte, uavhengig om de faktiske dommene er unndratt offentligheten eller ikke. Dette medfører at man må kontakte de gjeldende lagmannsrettene og tingrettene og forespørre om å få innsyn i de gjeldende dommene for å finne bedriftene.

På lik måte som ved Proff Forvalt er det foretatt et uttrekk fra databasen til Lovdata. Dette er gjort ved bruk av Lovdata Pro's avanserte registersøk, hvilket er et abonnement som må betales for. De gjeldende kategoriene som er tatt med i uttrekkene er:

- Grov korrupsjon
- Grov økonomisk utroskap
- Grov regnskapsovertredelse
- Grov villedende og uriktig selskapsinformasjon
- Grovt bedrageri
- Grovt skattesvik
- Grov hvitvasking
- Grovt underslag
- Grovt forsikringsbedrageri
- Dokumentfalsk

Dommene består av data i tekst basert form, med innslag av numeriske data. Det er kun den tekstbaserte dataen som er av interesse i dommene. Dette medfører at ekstraksjon av informasjon fra dommene må gjøres manuelt. Som beskrevet i starten av kapittelet er det hentet ut 12 158 dommer. Årsaken til det store uttrekket er reduserte muligheter for filtrering på sidene til Lovdata – blant annet mulighet for å filtrere på ønsket tidsperiode. Etter manuell gjennomgang av alle dommene fra de overnevnte kategoriene fra Lovdata gjenstod kun 87 bedrifter som fylte kriteriene. Det er disse som brukes som output data. I vedlegg A, B og C kan det sees et eksempel på en dom hvor forside, tiltale og domsslutning er trukket frem. Dommen er på totalt 145 sider og er sensurert av personverns hensyn.

#### 4.1.3 Dataramme (input + output)

Dataene fra finansregnskapene og dommene er blitt slått sammen i en dataramme ved bruk av Python modulene Pandas, hvor videre behandling er foretatt. Hensikten med en dataramme er å organisere finansielle data (input) og rettslige data (output) fra de forskjellige bedriftene slik at den kunstige intelligensen skal kunne analysere og sammenligne dataene.



forskjellen i begrensning av antall år med finansregnskap er at syke bedrifter ofte blir slått konkurs etter at dom har funnet sted, og at det dermed finnes få slike bedrifter med mange års drift.

### **Sammenslåing av regnskapstall og regnskapsanalyse**

På Proff Forvalt kan man eksportere regnskapsinformasjon i Excel format. Denne regnskapsinformasjonen er splittet i to deler: regnskapstall og regnskapsanalyse. Disse er blitt slått sammen manuelt til et dokument per bedrift.

#### 4.2.2 Dataramme (input + output)

### **Fjerning av variabler som kun er summering av tidligere variabler**

I denne konteksten vil variabler henvise til de forskjellige regnskapslinjene i finansregnskapet. I finansregnskapet er det en rekke regnskapslinjer som kun er satt opp for å gjøre det lettere for leseren å lese finansregnskapet. Eksempler på dette er «samleposter», hvor tidligere regnskapslinjer i samme kategori blir summert opp:

- Sum driftsinntekter
- Sum driftskostnader
- Driftsresultat
- Sum anleggsmidler
- Sum omløpsmidler
- Sum eiendeler
- Sum langsiktig gjeld
- Sum egenkapital og gjeld

Etter som disse «samlepostene» i seg selv ikke innehar noen ny informasjon – men kun er en summering av andre unike rådata – vil det heller ikke gi den kunstige intelligensen noen ny informasjon. Disse regnskapslinjene vil kun være med på å øke prosesseringskraften og fjernes dermed fra datarammen.

### **Fjerning av rader uten informasjon**

Datarammen var i starten programmert på en slik måte at det for hver bedrift ble hardkodet samtlige år fra 1998-2017 på y-aksen. Hvis en bedrift derimot hadde mindre år med finansregnskap enn hva som er hardkodet ville det for samtlige variabler i disse årene uten finansregnskap settes «NaN», hvilket står for «Not a Number». Når den kunstige intelligensen bruker dataene i datarammen vil disse «NaN» hindre den kunstige intelligensen i å finne mønstre, og dermed redusere treffsikkerheten. Av denne grunn er datarammen programmert om til å ha en variabel y-akse, hvor det for hver bedrift kun settes opp det antall år hvor det finnes finansregnskap.

### **Endring av blanke celler (NaN) til verdien -1**

Det er ikke vanlig at alle regnskapslinjer i finansregnskapet blir brukt. Regnskapslinjene som står blanke i finansregnskapet vil bli importert som «NaN» i datarammen og resultere i de samme problemene som beskrevet tidligere. Av denne grunn er slike blanke regnskapslinjer kodet til -1 i datarammen. Å kode «NaN» regnskapslinjene til -1 gjør at de vil bli tolket som 0 og dermed ikke påvirke den kunstige intelligensen.

### **Fjerning av variabler som har lite eller ingen data**

For at den kunstige intelligensen skal bli trent opp på en god måte må den ha tilstrekkelig med data. Etter som det er forskjellig fra bedrift til bedrift hvilke regnskapslinjer som det er relevant å føre opp informasjon i, så vil det dermed også være varierende mengde med data for hver variabel (regnskapslinje). Av denne grunn er det satt en nedre grense på minimum 2 000 datapunkter for at



en variabel skal tas med eller ikke. Etter fjerning av variabler med mindre enn 2 000 datapunkter gjenstod 69 variabler.

#### 4.2.3 Kunstig intelligens (pre-prosessering)

##### **Standardisering (Feature standardization)**

Ettersom trening av den kunstige intelligensen innebærer en rekke matematiske operasjoner hvor vektorer og variabler multipliseres og korrigeres er det viktig å redusere prosesseringskraften uten å endre den unike informasjonen til datasettet. Dette gjøres ved å standardisere datasettet.

Standardisering innen pre-prosessering av data ved maskin læring går ut på å skalere dataene i et datasett til å ha et gjennomsnitt på verdi på 0 og et standardavvik på 1. Ved å skalere datasettet på denne måten unngår man å måtte bruke unødvendig mye prosesseringskraft på å beregne store tall, og hindrer at tall går mot uendelig. Standardisering utføres i modulen Tensorflow for Python og er et innebygget pre-prosesseringsverktøy.

##### **Tilfeldig utvalg av bedrifter til treningssett og valideringssett**

For å sikre at utvalg av bedrifter til treningssett og valideringssett ikke er påvirket av menneskelig interaksjon og forutinntatthet så velges disse ut tilfeldig. Tilfeldig utvalg av treningssett og valideringssett utføres i modulen Tensorflow for Python og er et innebygget pre-prosesseringsverktøy, på lik linje som med standardisering. Både treningssettet og valideringssettet inneholder begge kategorier av bedrifter, syke og friske.

Resultatet av dette vil være at den kunstige intelligensen vil få ulikt treningssett og tilhørende valideringssett for hver gang algoritmen kjøres, hvilket igjen resulterer i forskjellig nøyaktighet på å predikere bedrageri. Hvis datasettet innehar bedrifter som er feilklassifisert som enten syke eller friske bedrifter så vil differansen i treffsikkerhet være stor, hvis det er få feilklassifiserte bedrifter vil den være liten. Dette på grunn av at den kunstige intelligensen får et treningssett hvor det finnes feilklassifiserte data så trenes den opp til å tro at mønstre i finansregnskapet som faktisk indikerer bedrageri ikke er det, og motsatt. Dette vil gjøre det vanskelig for algoritmen å generalisere formelen og vil resultere i en lav treffsikkerhet. På lik linje som i eksempelet over så vil bedrifter som har unormale finansregnskap kunne resultere i samme problem.

#### 4.3 Avslutning

Finansregnskapene er importert fra Proff Forvalt og inneholder balanse og resultatregnskap – med tilhørende underposter – og kontantstrøm samt nøkkeltall. Samtlige innrapporterte år foreligger i en og samme fil. Disse regnskapslinjene importeres inn i datarammen og brukes som input data [x] for den kunstige intelligensen. Dommer er importert fra Lovdata og foreligger i tekst basert form, hvilket fordrer manuell gjennomgang. Informasjonen fra disse dommene brukes for å knytte personer dømt for bedrageri opp mot gjeldende bedrifter. Regnskapslinjene i finansregnskapet til disse bedriftene importeres som input data [x] og kobles med tilhørende output data [y] som henviser til bedrageri i datarammen. I datarammen blir input data og output data for både friske og syke bedrifter importert. Datarammen brukes for å forenkle behandlingen av data for den kunstige intelligensen og samler alle data i en fil. Dataene for finansregnskap (input), dommer (output), dataramme (input + output) og den kunstige intelligensen (pre-prosessering) er renset for å minimere risk for feil og bias.

## 5 Metode

Formålet med dette kapittelet er å redegjøre for de metodiske valg som er tatt, samt å gi en beskrivelse for hvordan det er gått frem i oppgaven. Kapittel 5.1 starter med å presentere bakgrunn for studien. kapittel 5.2 redegjør for hvilke metoder som er brukt og kapittel 5.3 redegjør for hvilke designmessige valg som er tatt. Videre presenteres det i kapittel 5.4 metoden for innsamling av data og kapittel 5.5 beskriver hvordan disse er blitt behandlet. I kapittel 5.6 vurderes dataens validitet og reliabilitet og avslutningsvis i kapittel 5.7 blir etikken knyttet til håndtering av sensitive data gjennomgått.

### 5.1 Studiens bakgrunn

Kunstig intelligens blir mer og mer dagligdags. Dette brukes til blant annet automatisert nyhetsgenerering, persontilpasset reklame, online kundesupport, anbefaling av musikk og film, smart-hus og i styringssystemer til biler, båter og fly. Tilgangen til data stiger for hver dag som går, og dette fører til at det kommer stadig flere områder hvor kunstig intelligens kan brukes for å løse et gitt problem.

Det er gjort liknende studier i andre land, men etter hva forskerne og veileder har klart å finne er det ikke gjort lignende studier i Norge. Studien kan være verdifull for skattemyndigheter, banker, investorer og andre interessenter. Det er også et håp om at studien kan bidra til økt forståelse for kunstig intelligens – for interessenter – og være med på å redusere barrierene i koblingen mellom fagfeltene kunstig intelligens og økonomi.

### 5.2 Forskningsmetode

I det daglige er det fort gjort å hoppe til konklusjoner raskt, mens man innen forskning har strengere krav til bevisføring før man trekker konklusjoner. Metodelæren kan hjelpe oss i å strukturere forskningsarbeidet slik vi lettere kan undersøke om våre antagelser er i overensstemmelse med virkeligheten eller ikke. Man deler vitenskapelig forskning inn samfunnsvitenskap og naturvitenskap. Videre deler man samfunnsvitenskapen i to, kvalitativ og kvantitativ metode (Johannessen, Christoffersen, & Tufte, 2010). Denne avhandlingen er av samfunnsvitenskapelig art, hvilket medfører at valget står mellom kvalitativ og kvantitativ metode. Kvalitativ metode omhandler innsamling av data i form av lyd, tekster og bilde. Kvantitativ metode omhandler innsamling og registrering av data i form av tall (Johannessen, Christoffersen, & Tufte, 2011).

Denne avhandlingen ønsker - basert på numeriske data i bedrifters finansregnskap – å finne ut om kunstig intelligens kan benyttes til å detektere bedrageri i norsk registrerte virksomheter. Det gjør at denne studien vil falle under kvantitativ metode. De innsamlede dataene skal analyseres og vises frem ved hjelp av grafer og tabeller, og således bidra til å undersøke og beskrive trender og sammenhenger i datamaterialet. Kvantitative data gir ellers lite mening om man kun så på de innsamlede dataene alene (Saunders, Lewis, & Thornhill, 2012). Kvantitativ metode legger begrensninger for bruk av tekst basert informasjon slik som finansregnskapets noter og styrets årsberetning. Dette er dog et nødvendig valg for å avgrense oppgavens omfang.

### 5.3 Forskningsdesign

Når man innsamler data kan man si at den overordnede strategien for innsamlingen – og den fremgangsmåten man tar utgangspunkt i for å forstå fenomenet – kan kalles forskningsdesign (Johannessen et al., 2010). Å velge riktig metodisk teknikk er viktig i forhold til å øke sjansen for å få en effektiv og planmessig godt gjennomført oppgave. Man deler ofte forskningsdesign inn i tre hovedtyper: kausalt design, eksplorativt design og deskriptivt design. Disse designene beskrives i dette avsnittet.

Kausalt design brukes når man ønsker å finne en årsak/virknings-sammenheng. Dette designet brukes ofte i naturvitenskapelige emner (Grenness, 2001). Eksplorativt design brukes når fenomenet man ønsker å utforske er nytt eller har en uklar problemstilling. Emnet er ofte forsket lite på og brukes når man ønsker å oppnå en mer grunnleggende forståelse om emnet (Grenness, 2001). Deskriptivt design brukes når man ønsker å beskrive bestemte områder og situasjoner. Emnet er ofte forsket mye på og forskerne innehar en grunnleggende forståelse for problemet (Grenness, 2001).

Etter som det finnes lite forskning innen koblingen av kunstig intelligens og finansregnskap – samt at forskerne ikke innehar en grunnleggende forståelse for emnet – faller valget på eksplorativt design. Dette hjelper på avgrensingen av oppgaven og stiller ikke like strenge krav til datasettet.

## 5.4 Innsamlingsmetode

Dataene som benyttes er samlet inn og digitalisert av Brønnøysund registrene (brreg.no) og Lovdata (lovdata.no). Finansregnskapene blir så gjort digitalt tilgjengelig hos tjenester som Proff Forvalt (forvalt.no), som er leverandøren det er benyttet i denne oppgaven. Samlet sett gjør dette at det finnes tilgjengelig sekundærdata. Disse dataene er samlet inn av andre og med et annet formål enn det forskerne skal benytte dem til. Ved bruk av slik type data er det viktig å ta stilling til reliabilitet og validitet (Gripsrud et al., 2010). Dette presenteres i kapittel 5.6.1 og 5.6.2.

Datakvalitet er en av to kritiske faktorer innen kunstig intelligens. Ghahramani (2015) hevder at data ikke kan brukes uten at det først er rensket og kategorisert slik at det blir riktig forstått av den kunstige intelligensen. Den andre kritiske faktoren er datatilgjengelighet, hvor Domingos (2012) hevder at mer data slår en smart algoritme. Basert på dette vil tilgjengeligheten av data være en faktor man bør trakte etter før man begynner å forbedre algoritmen.

I dette studiet kan man dele inn bedriftene i to kategorier. Såkalt «syke» bedrifter og «friske» bedrifter. Med syke menes bedrifter dømt for økonomisk bedrageri mens de friske er bedrifter som ikke er dømt for økonomisk bedrag. I denne avhandlingen er det begrenset tilgang til syke bedrifter. Dette kommer av at Norge er et relativt lite land og har derfor på lik linje få bedrifter dømt for bedrageri sammenlignet med større land. Tilgjengeligheten av data for friske bedrifter er vesentlig større og omhandler alle Norsk registrerte aksjeselskap som har innrapportert finansregnskap men ikke er dømt for bedrageri.

### 5.4.1 Utvelgelse av syke bedrifter

Dataene som blir brukt i denne avhandlingen er hentet fra Lovdata og Proff Forvalt. Alle straffesaker i Norge er samlet og søkbare på Lovdata, men de er anonymiserte med hensyn til personvernet (Lovdata, 2018).

For å finne de aktuelle sakene settes det opp et søk med filter for økonomisk kriminalitet i Lovdata sin søkefunksjon. Deretter gjennomgås alle sakene og de selekteres etter hvor relevante de er. De gjeldende domstolene blir presentert saksnummeret med de sakene som gjelder deres region og bes oversende de etterspurte sakene. I disse dokumentene er det nevnt både bedrifter og personer som er involvert i saken. Navnene blir knyttet til de aktuelle bedriftene som igjen benyttes til å søke frem de aktuelle finansregnskapene ved Proff Forvalt sin database. Proff Forvalt henter finansregnskapene fra Brønnøysund Registrene og gjør det mulig å eksportere i Microsoft Excel format (Forvalt, 2018). Excel filene blir så samlet i en mappe og importert inn i en dataramme ved hjelp av Python-modulen Pandas. Det gjør at den menneskelige interaksjonen og påvirkningen til dataene i denne avhandlingen kun skjer i to punkter.

Det første punktet er når forskerne finner de aktuelle sakene og igangsetter kommunikasjon med domstolene. Det andre punktet er når domstolene finner frem de aktuelle sakene og sender disse til forskerne. For å kvalitetssikre at de dataene som blir presentert for den kunstige intelligensen er de dataen som er ment skal være der, så sjekkes saksnummeret alltid opp mot det saksnummeret på de dokumentene som sendes fra domstolene. Deretter så kontrolleres også at de bedriftene som nevnes med dom, er de bedriftene finansregnskapene som er hentet fra Proff Forvalt tilhører. Det resterende er utført ved hjelp av Python og har mindre mulighet for menneskelige feilkilder og forurensning av dataene.

#### 5.4.2 Utvelgelse av friske bedrifter

Utvelgelsen av virksomheter som kan representere en normal populasjon av bedrifter i Norge er viktig for å ikke gjøre den kunstige intelligensen forutinntatt. Det vises her til (Domingos) som beskriver, «*Bias is a learner's tendency to consistently learn the same wrong thing*» (Domingos, 2012, p. 3). Altså at forutinntatthet er elevens tendens til å konstant lære de gale tingene. I boken Forskningsmetode for økonomisk-administrative fag skriver Johannessen: «*sannsynlighetsutvelgelse garanterer ikke representative utvalg, men gir stor sannsynlighet for at utvalget er representativt, og gjør det mulig å benytte statistisk teori for å gjøre statistiske generaliseringer*» (Johannessen et al., 2011, p. 259). Avhandlingen har fulgt denne fremgangsmetoden og tatt utgangspunkt i et sannsynlighetsutvalg der det er gjort et randomisert uttrekk fra aksjeselskapene registrert i Proff Forvalt sin database.

Det er tilgang til relativt store mengder finansregnskap av friske bedrifter som kan implementeres. Man kan da si at desto større disse mengdene blir desto nærmere kommer man en miniatyrverden av populasjonen man skal undersøke (Johannessen et al., 2011). Dette øker sannsynligheten for at populasjonsuniverset representeres på en god måte.

Finansregnskapene er hentet fra Proff Forvalt. Det er foretatt to individuelle uttrekk, en for bedrifter som er i drift og den andre for bedrifter som er lagt ned. Hver av disse uttrekkene er på 10 000 bedrifter. Dette er gjort for å sikre at den kunstige intelligensen ikke skal få en forutinntatthet mot enten bedrifter som er i drift eller bedrifter som er lagt ned. Årsaken til at det er valgt 10 000 bedrifter er at dette er det maksimale uttrekket som kan utføres på Proff Forvalt.

Det er videre satt en begrensning på minimum 10 års drift for begge uttrekkene. Dette er for å sikre at den kunstige intelligensen skal få et stort nok datagrunnlag for trening.

### 5.5 Dataanalyse

Dataanalysen er foretatt ved bruk av programmeringsspråket Python. Ved hjelp av dette programmet er det laget en dataramme som avhandlingens input og output data er samlet i. Denne datarammen er videre brukt som datasett for en kunstig intelligens som er basert på Python modulen Tensorflow.

#### 5.5.1 Programmering av datarammen

En dataramme er en matrise som brukes for å importere større datasett og forenkle håndtering og behandling av data. Matrisen er todimensjonal og statisk, hvilket vil si at man på forhånd må programmere hvor mange rader og kolonner den skal ha. Samtlige rader og kolonner kan klassifiseres med navn (Pydata.org, 2018).

Datarammen er programmert med modulen Pandas i programmeringsspråket Python og satt opp basert på parameterne som finnes i finansregnskapene. Den er satt opp til å lese Excel .xlsx filer, etter som dette er det gjeldende formatet til finansregnskapene. Videre er den blitt programmert til å sette opp bedriftsnavn og rapporteringsår på y-aksen og regnskapslinjene på x-aksen. Oppsettet og

regnskapslinjene i de norske finansregnskapene har for perioden 1998 – 2017 ikke endret seg. Dette forenkler importeringen av finansregnskapene inn i datarammen etter som man ikke må forholde seg til varierende posisjon og formatering av parameterne.

Finansregnskapene er blitt kategorisert og satt opp i følgende mappestruktur:

1. Friske bedrifter
  - a. Friske bedrifter fortsatt i drift
  - b. Friske bedrifter som er lagt ned
2. Syke bedrifter
  - a. Syke bedrifter fortsatt i drift
  - b. Syke bedrifter som er lagt ned

Basert på den gjeldende mappestrukturen er datarammen programmert til å importere samtlige finansregnskap i mappene og legge til tilleggsinformasjonen:

1. Bedrageri: [1, 0]
2. Drift: [1, 0]

Dette er parametere som er programmert inn i datarammen og settes for hver bedrift og rapporteringsår, basert på hvilken mappe datarammen importerer bedrifter fra. Disse parameterne er resultatet [y], som den kunstige intelligensen skal prøve å oppnå ved å endre vektene [w] for hver variabel [x] i datarammen. Det er også verdt å nevne at denne modellen med enkelhet kan endres fra å predikere bedrageri til å predikere konkurs nettopp fordi informasjon om drift allerede er lagt til i datarammen.

### 5.5.2 Programmering av kunstig intelligens

Den kunstige intelligensen som er brukt i denne avhandlingen er basert på en Python modul som heter Tensorflow. Tensorflow er et åpent kildekode bibliotek produsert av Google Brain Team som brukes innen kunstig intelligens og nevrale nettverk (Google AI, 2018).

Den kunstige intelligensen som brukes i denne avhandlingen er en veiledende lærings algoritme og beskrives nærmere under teori kapittelet. Den kunstige intelligensen importerer informasjonen fra datarammen, hvor både variablene [x] (regnskapslinjene) og resultatet [y] (bedrageri: [1, 0]) foreligger. Den kunstige intelligensen er programmert til å dele datarammen inn i to grupper, hvor utvalget av bedrifter er tilfeldig:

#### 1. Treningssett

- I treningssettet er resultatet [y] (bedrageri: [1, 0]) kjent for den kunstige intelligensen. Her vektet variablene [x] på en slik måte at den kunstige intelligensen klarer å skille mellom syke og friske bedrifter i treningssettet
- Resultatet av treningen betegnes som [Loss] og [Acc] og forteller hvor godt vektene [w] klarer å skille mellom syke og friske bedrifter i treningssettet

#### 2. Valideringssett

- De vektene [w] som den kunstige intelligensen kom frem til i treningssettet brukes så på valideringssettet. Her er resultatet [y] (bedrageri: [1, 0]) ikke kjent for den kunstige intelligensen og den bruker vektene [w] – den kom frem til i treningssettet – for å klassifisere om bedriftene i valideringssettet er bedrageriske eller ikke
- Resultatet av valideringen betegnes som [Val\_loss] og [Val\_acc] og forteller hvor godt vektene [w] fra treningssettet klarer å skille mellom syke og friske bedrifter i valideringssettet

Operasjonen hvor den kunstige intelligensen trenes og valideres kalles for Epoke. For hver gang den kunstige intelligensen gjennomfører en Epoke korrigeres vektene  $[w]$  i et forsøk på å maksimere  $[Acc]$  og  $[Val\_acc]$  og minimere  $[Loss]$  og  $[Val\_loss]$ . Den kunstige intelligensen er programmert til å gjennomføre dette 50 ganger, for så å velge den epoken med de vektene  $[w]$  som gir best resultat. Hvor mange epoker som trengs for trening av den kunstige intelligensen er avhengig av hvor stort datasettet er og hvor god korrelasjon det er mellom variablene  $[x]$  og resultatet  $[y]$ . Et stort datasett, med god korrelasjon mellom variablene  $[x]$  og resultatet  $[y]$  behøver færre epoker for å komme frem til et godt skille, og motsatt.

For hver epoke presenteres  $[Loss]$ ,  $[Acc]$ ,  $[Val\_loss]$  og  $[Val\_acc]$ , for å kunne observere utviklingen av den kunstige intelligensen. Basert på treningen er den kunstige intelligensen programmert til å vise hvilke bedrifter den predikerte riktig og galt – både for friske og syke bedrifter – totalt fire kategorier. Til slutt er den programmert til å lagre sannsynlighet for bedrageri for samtlige av bedriftene i valideringssettet.

## 5.6 Evaluering av metode

Man finner styrker og svakheter i alle metoder og denne avhandlingen er ikke et unntak. Det er derfor nødvendig med en gjennomgang av studiens reliabilitet og validitet for å belyse dette på en riktig måte. Dette avsnittet belyser utfordringene knyttet til dette og hvordan de er hensyntatt i denne avhandlingen.

### 5.6.1 Validitet

Data er en representasjon av virkeligheten, det gjør at dataenes validitet kan uttrykkes som hvor godt den representerer det fenomenet den skal representere (Johannessen et al., 2011). Et godt eksempel som blir presentert er beskrivelsen av et museum med høyt besøkstall. Det kan antas at det høye besøkstallet kommer av stor interesse for historie. Etter en stund faller besøkstallet samtidig som nabobygget åpner. Dette viser seg å ha sammenheng med at nabobygget også har offentlig toalett, og at man dermed ikke behøver å gå til museet for å gå på toalett (Grenness, 2001).

Eksempel over viser hvor feil gjenspeilet virkeligheten kan være om validiteten er lav. I oppgavens tilfelle er de faktiske dataene som behandles innrapporterte data. Det er dataene som skal tolkes for å se om de er manipulerte eller ikke. Det gjør at sammenligner man oppgaven med det nevnte eksemplet og setter de innsamlede dataene opp som besøkstallene så er det egentlig informasjonen bak dataene avhandlingen analyserer. Hadde museet i eksemplet målt seg opp mot andre museum – kanskje til og med et stort antall av museum – så ville det presenterte besøkstallet lettere blitt funnet unormalt høyt og dermed kunne man sett litt dypere på de forskjellige grunnene til det. Det er korrelasjoner slik som disse læringsalgoritmen analyserer i denne oppgaven.

Som tidligere beskrevet består dataen i denne avhandlingen av finansregnskap (input) og dommer (output). Når det gjelder input data så er det foretatt et uttrekk på 20 000 bedrifter, hvor det er foretatt et tilfeldig utvalg på 822 bedrifter. Det kan stilles spørsmål til om både uttrekket og det tilfeldige utvalget er stort nok til å ansees som representativt. Det er sannsynlig at en økning av input data vil resultere i mer representativt utvalg. Dette vil dog danne et mer ubalansert datasett – grunnet den reduserte tilgangen av bedrageriske bedrifter – som vil redusere treffsikkerheten til den kunstige intelligensen. Når det gjelder output datasettet så er dette begrenset til 87 bedrageriske bedrifter. En økning av output datasettet vil bidra til å skape et mer representativt utvalg, samt å gjøre datasettet mindre ubalansert.

Men det er to aspekter ved oppgaven som bygger på skjønn og en kollektiv forståelse som kan ha feilvurderinger i seg. Det første aspektet er utvalget av syke bedrifter, hvor finansregnskapene blir valgt på grunn av at de har vært gjennom en domstol og blitt dømt. Det kan være at noen av bedriftene i det syke utvalget er dømt på feil grunnlag. I så fall ville dette lære opp den kunstige intelligensen feil og redusere prediksjonsnøyaktigheten. For å redusere sannsynligheten for dette er samtlige dommer sjekket for anke i de andre rettsinstansene. Det andre aspektet er utvalget av friske bedrifter. Etter som det friske utvalget er basert på et tilfeldig utvalg av bedrifter på Proff Forvalt kan det være at noen av disse bedriftene driver med økonomisk bedrag. Avhengig av mengden feilkategorisering vil dette resultere i liten eller stor variasjon i læringsalgoritmens treffsikkerhet. Ved bruk av store utvalg – slik som i det friske datasettet – vil feilkategoriserte bedrifter ansees som støy av læringsalgoritmen, og vil ikke vektes like høyt som resten av datasettet.

### 5.6.2 Reliabilitet

Påliteligheten til dataen som brukes i forskningen betegnes ofte i forskning som reliabilitet (Johannessen et al., 2011). Et eksempel på en undersøkelse kunne være å måle hvor ofte bilister kjører for fort. Dette kan f.eks. gjøres ved at man sender ut en spørreundersøkelse om vanene i forbindelse med kjøringen. Her kan det være mange feilkilder. Saunders et al. (2012) mener at det finnes trusler som kan redusere reliabiliteten og at forskere må være bevisst disse. De mener det finnes fire slike trusler:

#### 1. Respondentfeil

Respondentfeil er når omgivelsene slik som tidspunkt, humør og energinivå osv. påvirker respondenten. Har man en kvalitativ undersøkelse bør man vurdere å gjennomføre intervjuer på samme tidspunkt av dagen i så nøytrale rom og med samme energinivå fra intervjuer som mulig

#### 2. Respondentskjevhet

Finnes det klare forventninger eller andre faktorer som kan styre hvordan respondenten svarer kan man fort få en respondentskjevhet. I dette tilfelle kan en løsning være å anonymisere intervjuobjektet og samtidig legge vekt på at det ikke finnes riktige svar

#### 3. Forskerfeil

Som forskere er det viktig at man vurderer resultatene og selve undersøkelsen godt. Forskerfeil kan forekomme og det er viktig at man har fokus på dette. Tar man ikke hensyn til at andre kan ha lånt bilen i eksempelet over, så bør man ikke legge frem resultater som prøver å vise et bilde av kjørevanene til forskjellige aldersgrupper.

#### 4. Forskerskjevhet

Mennesker har en tendens til å finne det de leter etter. Det er derfor viktig å ha tenkt gjennom dette i sin forskning og ta hensyn til at man allerede kan ha forutinntatte forventninger som kan farge resultatene.

I og med at avhandlingen er kvantitativ faller trusler som omhandler det menneskelige vesenets tilstand i spørreskjema, intervju og liknende situasjoner bort. Det gjenstår da forskerfeil og forskerskjevhet.

## **Forskerfeil**

Et eksempel kan være at den kunstige intelligensen blir trent opp til å ha en forutinntatt tilnærming til analysen. Dette kan skje hvis en overvekt av de normale bedriftene fortsatt er i drift, samtidig som en overvekt av de bedrageriske er lagt ned. Den kunstige intelligensen vil da bli feilaktig trent opp til å anta at bedrifter som er lagt ned er bedrageriske. I stedet for en kunstig intelligens som finner bedrageriske vil man da ende opp med en som finner bedrifter som er lagt ned. Innen fagfeltet maskin læring kalles dette for bias.

For å redusere sannsynligheten for dette er uttrekket av de friske bedriftene delt opp i 50% bedrifter som fortsatt er i drift og 50% som er lagt ned. Hvis den kunstige intelligensen på tross av dette trenes opp til å finne bedrifter som er lagt ned vil denne 50/50 fordelingen av friske bedrifter resultere i en meget lav presisjon. Dette fordi den da feilaktig vil klassifisere 50% av det friske datasettet som bedragerisk.

Et annet eksempel kan være at man ikke fjerner blanke celler i finansregnskapene. Det kan tenkes at en overvekt av de bedrageriske bedriftene er små – og dermed lite komplekse – bedrifter, og at de dermed bruker relativt få regnskapslinjer i finansregnskapene sine. Hvis det samtidig er en overvekt av store – og dermed også komplekse – normale bedrifter som bruker vesentlig flere regnskapslinjer, så kan dette medføre at den kunstige intelligensen trenes til å anta at bedrifter med få regnskapslinjer i finansregnskapet er bedrageriske. Dette er også et eksempel på bias, slik som beskrevet i eksempelet over.

I denne avhandlingen er blanke celler endret til verdien -1. Dette medfører at en bedrift med få regnskapslinjer i finansregnskapet vil bli behandlet på samme måte som en bedrift med mange regnskapslinjer i finansregnskapet. Samtidig vil verdien -1 for disse blanke regnskapslinjene tilsvare den laveste verdien som finnes i datasettet (se Feature Standardisation, kap 4.2.4) og dermed gi minimal påvirkning for den kunstige intelligensen.

## **Forskerskjevhet**

Er datagrunnlaget farget av forskerne så vil dette gi et utslag i skjev analyse av dataene. Selv et stort og representativt utvalg av input og output data kan gjøres skjevt av forskerne. Dette kan skje under rensing av dataene, slik som overdreven bruk av datarensing. I god tro kan forskerne fjerne regnskapslinjer med lite eller ingen data. Dette vil kunne forbedre treffsikkerheten til den kunstige intelligensen, ettersom den opererer med en større andel av variabler (regnskapslinjer) som innehar mange datapunkter. Fjernes for mange slike variabler kan man ende opp med et datasett med for lite informasjon. Dette kan medføre at den kunstige intelligensen ikke vil finne noen korrelasjon mellom informasjonen i finansregnskapet og om en bedrift er bedragerisk eller ikke. Basert på et slik resultat kan det være at forskerne konkluderer med at det ikke er mulig å bruke kunstig intelligens for å finne bedrageriske bedrifter basert på finansregnskap.

I denne avhandlingen er variabler (regnskapslinjer) med lite eller ingen informasjon fjernet. Dette er gjort i et forsøk på å gi den kunstige intelligensen mer relevant data, og dermed øke treffsikkerheten. Likevel kan det resultere i det motsatte, grunnet at for mye informasjon er fjernet fra datasettet. Måten dette er utført på er å programmere inn en åpen parameter i datarammen. Denne åpne parameteren styrer kriteriet for hvor mange datapunkter som kreves for at en gitt variabel (regnskapslinje) skal tas med i datarammen eller ikke. Hvis den kunstige intelligensen får en lav treffsikkerhet kan man redusere antall datapunkter som kreves for at en variabel (regnskapslinje) skal tas med, og dermed gi den et datasett med mer informasjon.



## 5.7 Etikk

En viktig del av avhandlingen omhandler innsamling av informasjon knyttet til tidligere dommer. Det gjør at personvernet er et viktig fokus i gjennomføringen. Mange personer har sonet sine dommer og har kommet videre i livet. Det er da viktig at studien ikke er i veien eller skaper andre hinder som skader de personer som har vært involvert.

Etikk omhandler i hovedsak retningslinjer, regler og prinsipper for å finne ut om handlinger er riktige eller gale (Johannessen et al., 2011). Innsamlede data er derfor behandlet konfidensielt. All persondata og annen informasjon som kan bidra til å gjenkjenne personer er slettet for å bevare anonymiteten fra denne studien. Bedriftsinformasjon er også anonymisert for å forhindre mulig negativ publisitet for de gjeldende bedriftene.

## 5.8 Avslutning

Bakgrunnen for studiet er et ønske om å bidra til økt kunnskap innen koblingen av fagfeltene kunstig intelligens og økonomi. Avhandlingen bruker data som i all hovedsak er numerisk hvilket fordrer en kvantitativ metode. Det er valgt et eksplorativt design grunnet lite forskning innen koblingen av kunstig intelligens og finansregnskap.

Bedriftene som brukes i denne avhandlingen kan deles inn i to kategorier, syke bedrifter og friske bedrifter. Med syke menes bedrifter dømt for økonomisk bedrageri og med friske menes bedrifter som ikke er dømt for økonomisk bedrageri. De friske bedriftene er valgt basert på to tilfeldige utvalg fra Proff Forvalt. Et tilfeldig utvalg for friske bedrifter som er i drift, og et tilfeldig uttrekk for friske bedrifter som er lagt ned. Dette er gjort for å sikre at den kunstige intelligensen ikke skal få bias mot en av disse. De syke bedriftene er funnet ved å gå igjennom dommer for økonomisk kriminalitet på Lovdata. De dømte personene i dommene er koblet opp til gjeldende bedrifter, for så å innhente finansregnskap fra Proff Forvalt. Det er programmert en dataramme som importerer all input og output data til en fil. Videre er det programmert en kunstig intelligens som er av typen veiledende læringsalgoritme. Denne algoritmen importerer dataen fra datarammen og deler den opp i et treningssett – hvor output er kjent – og et valideringssett – hvor output ikke er kjent. Basert på dette trenes den kunstige intelligensen på kjente data i treningssettet og tester treningen basert på den ukjente dataen i valideringssettet.

Når det gjelder dataens validitet så er output datasettet begrenset. Dette kan medføre at utvalget for de bedrageriske bedriftene ikke er representativt. Det er foretatt en rekke tiltak for å ivareta dataens reliabilitet, hvilket kan sees i kapittelet for datarensing. Det er ikke – så vidt forskerne er kjent – noen svakheter i dataens validitet. Både person- og bedriftsinformasjon er anonymisert for å bevare personvernet, samt hindre mulig negativ publisitet.

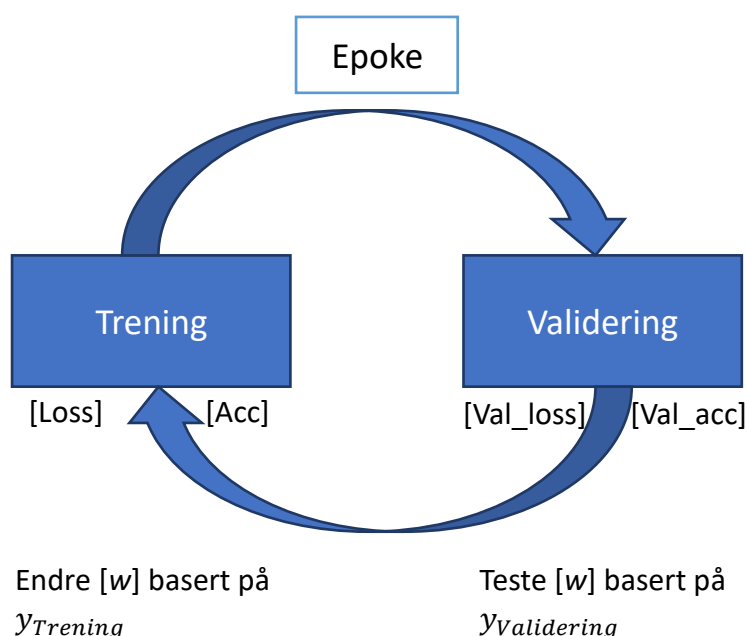
## 6 Resultater

Dette kapitlet starter med å gi en oppsummering av hvordan en kunstig intelligens lærer opp. Deretter presenteres resultatet for treningen. I all hovedsak besvarer resultatet av treningen – kapittel 6.2 – det fremlagte forskningsspørsmålet og oppgaven kunne avslutte med dette. Likevel ønsket forskerne å dykke dypere i resultatene for å prøve å trekke noen konklusjoner som går utover selve forskningsspørsmålet. Dette presenteres i kapittel 6.3.

### 6.1 Oppsummering av teori for trening og validering

Treningen av den kunstige intelligensen gjøres ved å legge til vektorer  $[w]$  til variablene  $[x]$  i regnskapene. Vektene forteller hvor stor påvirkningskraft disse variablene har på resultatet  $[y]$ . Den kunstige intelligensen starter læringen ved å dele datasettet i et treningssett og et valideringssett. Både treningssettet og valideringssettet inneholder begge kategorier av bedrifter, syke og friske. For hvert av disse datasettene kan det beregnes en tapsfunksjon og nøyaktighet. Dette er  $[Loss]$  og  $[Acc]$  for treningssettet og  $[Val\_loss]$  og  $[Val\_acc]$  for valideringssettet.  $[Loss]$  og  $[Val\_loss]$  er tapsfunksjoner som kalkuleres i modulen Tensorflow og står for «categorical crossentropy» (Keras, 2018).  $[Acc]$  og  $[Val\_acc]$  er nøyaktigheten i prosent.

Ved starten av læringen randomiseres vektene  $[w]$  til variablene  $[x]$  i treningssettet. Dette gjøres for å forhindre bias under læringen. I treningssettet vet den kunstige intelligensen resultatet  $[y]$ , og endrer vektene  $[w]$  til variablene  $[x]$  for å prøve å oppnå det oppgitte resultatet  $[y]$ . Vektene  $[w]$  som læringsalgoritmen kom frem til i treningssettet brukes så på valideringssettet, hvor resultatet  $[y]$  ikke er kjent. Basert på om nøyaktigheten i valideringssettet  $[Val\_acc]$  øker eller minker, endres vektene på nytt – i treningssettet – i et forsøk på å maksimere  $[Val\_acc]$ . Dette kalles for «Epoke» og utføres frem til vektene  $[w]$  er optimaliserte hvilket gir en optimal prediksjon av resultatet  $[y]$ . Dette vises konseptuelt i figuren under.



Figur 19: Trening og validering av kunstig intelligens


For å vurdere prestasjonen til læringsalgoritmen kan resultatene analyseres for undertilpassing, overtilpassing og bias. Overtilpassing er når læringsalgoritmen favoriserer datapunktene i treningssettet. Dette medfører at funksjonen læringsalgoritmen kommer frem til en funksjon  $[g]$  – som passer datapunktene i treningssettet, men – som ikke passer med den ideelle og ukjente funksjonen  $[f]$  (mindre generaliserbar). Undertilpassing er når læringsalgoritmen ikke klarer å lage en funksjon  $[g]$  som passer hverken datapunktene i treningssettet eller den ideelle og ukjente funksjonen  $[f]$ . Bias kan forklares ved at læringsalgoritmen skaper en korrelasjon i datasettet som ikke finnes i virkeligheten.

## 6.2 Resultat av trening og validering

Datasettet ble delt opp i et treningssett på 609 bedrifter og et valideringssett på 300 bedrifter. For valideringssettet var 90,33% av bedriftene friske og 9,67% syke. Med syke menes bedrifter dømt for økonomisk bedrageri mens friske er bedrifter som ikke har vist seg å være dømt for økonomisk bedrageri. For trening av den kunstige intelligensen ble det satt opp 50 epoker som utgangspunkt. For å vurdere prestasjonen til læringsalgoritmen analyseres resultatene for undertilpassing og overtilpassing, hvilket presenteres i Figur 20 og Figur 21, samt at det sjekkes for bias mot konkurrs.

### Undertilpassing

Først analyseres det etter tegn på undertilpassing. Dette gjøres ved å vurdere nøyaktigheten for treningssettet  $[Acc]$  og valideringssettet  $[Val\_acc]$ . Ved undertilpassing vil den kunstige intelligensen – selv over utallige epoker – ikke oppnå høy nøyaktighet for  $[Acc]$  eller  $[Val\_acc]$ . Det kan være flere årsaker til dette. En årsak kan være er at det ikke er noen korrelasjon mellom input eller output. En annen kan være at den gjeldende læringsmodellen ikke passer til problemet og en tredje årsak kan være at den gjeldende læringsalgoritmen ikke er optimalisert for problemet.



Figur 20: Sammenligning av trening- og valideringssettets nøyaktighetsfunksjon for vurdering av undertilpassing

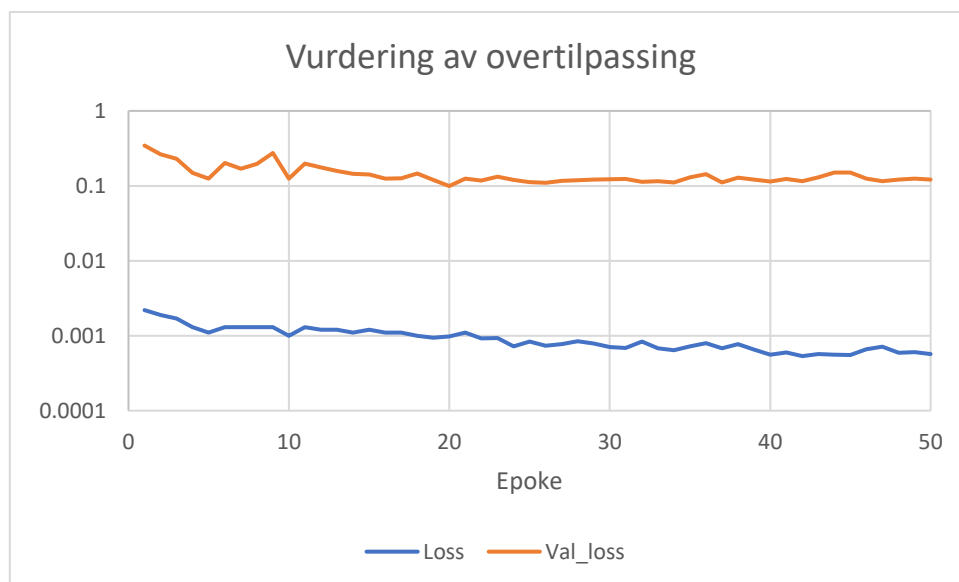
Som nevnt under teori-oppsummeringen i dette kapitlet randomiseres vektene  $[w]$  til variablene  $[x]$  i treningssettet. Dette gjøres for å hindre bias under læringen men resulterer også i redusert  $[Acc]$  og  $[Val\_acc]$  for de første epokene. Dette fordi at vektene ved start av læring er tilfeldige og at det dermed er liten korrelasjon mellom input og output. Det er verdt å nevne at nøyaktigheten som vises for  $[Acc]$  og  $[Val\_acc]$  for hver epoke er *etter* at vektene er justert.

Nøyaktigheten for valideringssettet [ $Val\_Acc$ ] er etter epoke 1 på 95,67%. Dette betyr at ved kun å endre vektene [ $w$ ] til variablene [ $x$ ] i treningssettet – som ved start av læring er randomiserte – en gang så klassifiserer læringsalgoritmen 287 bedrifter riktig ut av et datasett 300 bedrifter. Dette tyder på en sterk korrelasjon mellom input og output.

Basert på resultatene for [ $Acc$ ] og [ $Val\_acc$ ] er det ikke tegn til undertilpassing. Det observeres dog at [ $Acc$ ] er lav for de første epokene hvilket kan forklares av en funksjon som er implementert i læringsalgoritmen som kalles for «drop-out». For hver epoke velger drop-out funksjonen en tilfeldig variabel som fjernes fra treningssettet. Denne funksjonen brukes for å hindre overtilpassing, men resulterer i en feilaktig lav [ $Acc$ ].

### Overtilpassing

Videre analyseres det etter tegn på overtilpassing. Dette gjøres ved å sammenligne tapsfunksjonene for treningssettet [ $Loss$ ] og valideringssettet [ $Val\_loss$ ]. Ved overtilpassing vil [ $Loss$ ] over tid synke, samtidig som [ $Val\_loss$ ] stiger. Dette betyr at den kunstige intelligensen overvurderer variablene i treningssettet – på bekostning av variablene i valideringssettet – og gjør den beregnede funksjonen [ $g$ ] mindre generaliserbar.



Figur 21: Sammenligning av trening- og valideringssettets tapsfunksjon for vurdering av overtilpassing

Det er en svak tendens til overtilpassing fra epoke 21 og utover. Ved å lagre vektene og resultatene fra Epoke 20 minimeres sannsynligheten for overtilpassing. Det er disse vektene som er brukt videre i avhandlingen.

### Bias mot konkurs

For å hindre at læringsalgoritmen fikk bias mot å predikere konkurs ble det friske datasettet delt i to, med en 50/50 fordeling av bedrifter som var lagt ned og bedrifter som fortsatt var i drift. Dette er beskrevet i kapittel 4.2.1. Grunnet det begrensede utvalget av bedrageriske bedrifter var det ikke mulig å få en 50/50 fordeling av disse. Av de bedrageriske bedriftene var 15% fortsatt i drift.

En læringsalgoritme som feilaktig trenes opp til å ha bias mot konkursrammede bedrifter vil – for en overvekt av bedriftene som er lagt ned – predikere høy sannsynlighet for bedrageri. Basert på det friske datasettet – hvor bedrifter er lagt ned – er det kun 2 bedrifter ut av 411 som predikeres som bedrageri. Basert på dette vurderes det at læringsalgoritmen ikke har bias mot konkursprediksjon.

## Konklusjon

Basert på de presenterte resultatene kan det konkluderes med at læringsmodellen som brukes i denne avhandlingen hverken undertilpasser eller overtilpasser. Det er i kapittel 5.6.1 og 4.2.2 beskrevet at datasettet er begrenset og ubalansert, samt at det er redusert fra 156 variabler til 69 variabler. Basert på vektene fra epoke 20 endte nøyaktigheten for valideringssettet [*Val\_acc*] på 98%, hvilket vil si at ut av 300 bedrifter klassifiserte læringsalgoritmen 294 bedrifter riktig. Selv med de begrensninger som her er beskrevet, virker det ikke som dette påvirker nøyaktigheten til læringsalgoritmen.


### 6.3 Analyse av resultat

I dette avsnittet forsøker forskerne å dykke dypere i resultatene for å prøve å trekke noen konklusjoner som går utover selve forskningsspørsmålet. Dataene som analyseres er valideringssettet – med resultater for sannsynlighet for bedrageri – basert på de lagrede vektene fra epoke 20.

Resultatene som presenteres i tabell er i form av sannsynlighet, hvor 1 representerer 100% sannsynlighet for bedrageri og 0 representerer 0% sannsynlighet for bedrageri. Kakediagrammene presenterer fordelingen mellom syke og friske bedrifter.

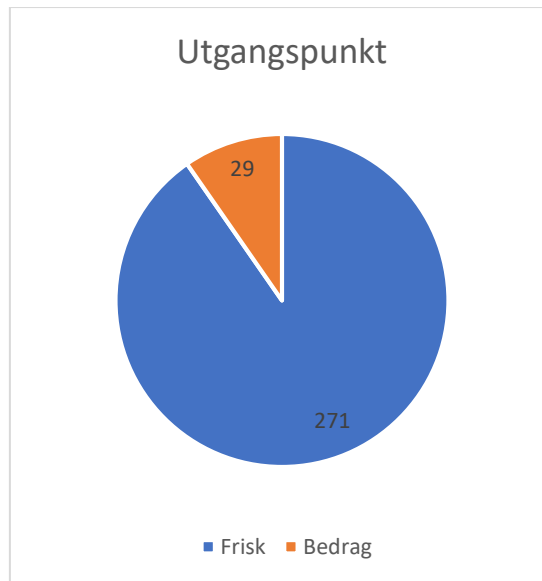
#### 6.3.1 Usikker prediksjon

Det presenteres en oversikt over spredningen av sannsynlighet for bedrageri for de 300 bedriftene i valideringssettet.



Figur 22: Sannsynlighet for bedrageri

Figur 22 viser sannsynlighet for bedrageri som læringsalgoritmen har kommet frem til for valideringssettet. Det kan sees at 232 bedrifter klassifiseres som friskt med 5% sannsynlighet for bedrageri eller mindre. Videre klassifiseres 26 bedrifter som sykt med 95% sannsynlighet for bedrageri eller mer. Til slutt kan det sees at 42 bedrifter ligger i området <5 , 95>%.



Figur 23: Fordeling av friske og syke bedrifter

I Figur 23 presenteres utgangspunktet for samme datasett, hvor 271 bedrifter er definert som friske bedrifter og 29 er definert som syke. Ved å sammenligne figurene kan det sees at mesteparten av bedriftene med en sannsynlighet <5 , 95>% i Figur 22 kommer fra det friske datasettet i Figur 23.

Det kan være av interesse å analysere de bedriftene hvor den kunstige intelligensen er usikker, hvilket presenteres i Figur 24.

ID	TRUE	Pred	Fraud	Guess
22	1	0	0,496087	Fail
53	1	0	0,48428	Fail
119	0	0	0,326895	Correct
160	0	0	0,39845	Correct
183	0	0	0,430144	Correct
188	0	0	0,484571	Correct
271	0	0	0,428015	Correct
306	0	0	0,429393	Correct
331	0	0	0,42762	Correct
378	0	0	0,48461	Correct
387	0	0	0,491681	Correct
395	0	0	0,484931	Correct
404	0	0	0,428768	Correct
408	0	0	0,484244	Correct
450	0	0	0,491964	Correct
453	0	0	0,472303	Correct
513	0	0	0,449365	Correct
529	0	0	0,434908	Correct
562	0	0	0,361297	Correct
673	0	0	0,468335	Correct
689	0	0	0,359036	Correct
799	0	0	0,363908	Correct
806	0	0	0,328624	Correct
881	0	0	0,314117	Correct

Figur 24: Oversikt over bedrifter med sannsynlighet for bedrageri <30 , 60>%

Dette er et uttrekk av bedriftene hvor den kunstige intelligensen er usikker, totalt 34 av 300. Med usikker menes sannsynlighet for bedrageri  $<30, 60>$  %. Flesteparten av disse bedriftene er i datarammen definert som friske, foruten to som vil bli beskrevet i neste avsnitt. En mulig forklaring for hvorfor den kunstige intelligensen er usikker – på bedrifter som er definert friske – kan være at den er trent opp på å finne bedrifter som utfører bedrageri i en så stor skala at de dømmes for dette. Sannsynligheten for at læringsalgoritmen indikerer konkurs vil i dette tilfellet være liten, etter som det er allerede vurdert for bias mot konkurs. Det er derfor ikke usannsynlig at dette kan være bedrifter som utfører regnskapsmanipulasjon av mindre grad, hvilket gjør at læringsalgoritmen scorer med en lavere sannsynlighet for bedrageri.

### 6.3.2 Feil prediksjon

Videre kan det være av interesse å analysere de bedriftene hvor den kunstige intelligensen predikerte feil, hvilket presenteres i Figur 25.

ID	TRUE	Pred	Fraud	Guess
22	1	0	0,496087	Fail
53	1	0	0,48428	Fail
263	0	1	0,701313	Fail
496	0	1	0,998302	Fail
643	0	1	0,997216	Fail
894	0	1	0,935714	Fail

Figur 25: Oversikt over bedrifter som læringsalgoritmen predikerte feil

Feilklassifiseringen kan deles opp i to grupper:

Den første gruppen er bedrifter som i datarammen er definert som syke, men som den kunstige intelligensen klassifiserer som friske. Dette er bedrift 22 og 53. Her kan det sees at prediksjonsraten ligger tett opp mot grensen  $[b]$  på 0,5, hvilket indikerer at den kunstige intelligensen mener at det er en tilnærmet 50/50 sjanse for at de gjeldende bedriftene er syke. En årsak for dette kan være at det er en type økonomisk bedrag som den kunstige intelligensen mangler data på i treningssettet, og når den skal predikere dette i valideringssettet blir den usikker. Den ser mønster som stemmer over ens med det den har blitt lært opp til i treningssettet, men samtidig ser den også mønster som ikke passer med treningssettet.

Den andre gruppen er bedrifter som i datarammen er definert som friske, men som den kunstige intelligensen klassifiserer som syke. Dette er det mest interessante resultatet, og omfatter bedrift 263, 496, 643 og 894. Metoden som er brukt for å finne friske bedrifter er å ta et tilfeldig uttrekk fra Proff Forvalt. Av denne grunn kan det ikke utelukkes at noen av disse bedriftene faktisk er bedragerske. De angitte bedriftene er sjekket opp mot dommer i Lovdata for å se om de er dømt for økonomisk bedrageri hvilket de ikke er. Det er også foretatt søk på nettet for å se om det finnes informasjon som kan indikere økonomisk bedrageri, hvilket heller ikke ble funnet. Det kan være mulig at dette faktisk er bedrifter som er bedragerske, men som ennå ikke er oppdaget og dømt for dette. En annen mulig forklaring kan være at dette er friske bedrifter med et uvanlig oppsett av regnskapslinjer – og dermed ikke finnes i treningssettet – som læringsalgoritmen ikke er trent opp på.

## Gjennomgang av bedrift 643

De bedriftene som læringsalgoritmen indikerte høy sannsynlighet for bedrageri ble gjennomgått. Av disse bedriftene var bedrift 643 av interesse. Det ble gjort søk både på nettet, Lovdata og finansregnskap ble gjennomgått, i analysen ble det ikke gjort noen funn. Det ble videre gjort et søk på daglig leder i bedriften og det kom frem at denne personen hadde flere bedrifter i samme konsern, som ikke var med i det tidligere datasettet. Finansregnskapene til de resterende bedriftene ble lagt til datasettet og den kunstige intelligensen analyserte datasettet på nytt. Resultatet kan sees i Figur 26.

Konsernrelasjoner					
ID	Navn	Pred	Certainty	Eierandel	
903	██████████ HOLDING AS	1	99,997 %		
901	↳ ██████████	0	0,708 %		100.00
902	↳ ██████████ HOLDING AS	1	99,993 %		100.00
643	↳ ██████████	1	99,722 %		100.00

Figur 26: Oversikt over konsernrelasjon for bedrift 643, med tilhørende sannsynlighet for bedrageri

Basert på prediksjon fra den kunstige intelligensen ansees tre av de fire bedriftene for å være syke, med en sannsynlighet over 99%. På nytt ble nettet, Lovdata og finansregnskap for de gjeldende bedriftene gjennomgått, uten noen avgjørende funn.

Etter som det ikke var mulig å verifisere resultatene til den kunstige intelligensen kan ikke forskerne med sikkerhet si at disse bedriftene er bedrageriske. Likevel mener forskerne at dette er en sterk indikasjon, tatt i betraktning den kunstige intelligensens totale treffsikkerhet [*Val\_acc*] på 98% i valideringssettet.

## 6.4 Avslutning

En læringsalgoritme læres opp ved bruk av data. Et datasett deles opp i treningssett og valideringssett. Både treningssettet og valideringssettet inneholder begge kategorier av bedrifter, syke og friske. Læringsalgoritmen trenes opp basert på treningssettet og verifiserer hva den har lært på valideringssettet, dette kalles for epoke. For hvert av disse datasettene beregnes det to forskjellige score, dette er [*Loss*] og [*Acc*] for treningssettet og [*Val\_loss*] og [*Val\_acc*] for valideringssettet. [*Loss*] og [*Val\_loss*] er tapsfunksjoner som kalkuleres i modulen Tensorflow og [*Acc*] og [*Val\_acc*] er nøyaktigheten i prosent.

Undertilpassing er når læringsalgoritmen ikke klarer å lære noe av datasettet (lav [*Acc*] og [*Val\_acc*]). Overtilpassing er når læringsalgoritmen overvurderer variablene i treningssettet – på bekostning av variablene i valideringssettet – og gjør den beregnede funksjonen [*g*] mindre generaliserbar ([*Loss*] synker og [*Val\_loss*] stiger). Det er mulig å stoppe en læringsalgoritme under trening for så å velge den epoken som gir best resultater. Læringsalgoritmen i denne avhandlingen undertilpasser ikke, men det ble observert en svak tendens til overtilpassing fra epoke 21 og utover. Vektene og resultatene for epoke 20 ble lagret. Det ble oppnådd en nøyaktighet på 98% for valideringssettet, hvilket vil si at læringsalgoritmen klassifiserer riktig på 294 ut av 300 bedrifter. Læringsalgoritmen ble også sjekket for bias mot konkursprediksjon, hvilket det ble vurdert at den ikke hadde.

Ved gjennomgang av resultatene fra valideringssettet var det 34 bedrifter som hadde en sannsynlighet for bedrageri på <30, 60>%. En mulig årsak kan være at dette er bedrifter som utfører regnskapsmanipulasjon, men ikke i et så stort omfang at de blir dømt for det.



Læringsalgoritmen feilklassifiserte seks bedrifter. Fire av disse var definert som friske i datarammen, hvilket læringsalgoritmen klassifiserte som syke. Disse ble gjennomgått, men det ble ikke gjort noen funn. Ved en nøyere gjennomgang kom det frem at daglig leder for bedrift 643 hadde tre bedrifter som ikke var med i datasettet. Disse bedriftene ble lagt inn i datasettet og læringsalgoritmen klassifiserte to av disse tre bedriftene som syke, med en sannsynlighet over 99%.

## 7 Konklusjon

I denne avhandlingen er det forsøkt å finne en sammenheng mellom bedrageriske bedrifter og deres finansregnskap. Dette er gjort ved bruk av kunstig intelligens, hvilket medfører at denne oppgaven er en kobling mellom fagfeltene økonomi og maskinlæring. Bakgrunnen for at kunstig intelligens er valgt for å løse denne problemstillingen er fordi dette er en teknologi med et stort potensialt og mange bruksområder. Det var et ønske for forskerne å få en forståelse for dette fagfeltet, og hvordan det kan brukes for å løse definerte problem. Kapittel 7.1 presenterer implikasjonene som avhandlingen gir. Kapittel 7.2 gjennomgår hvilke begrensninger som finnes i avhandlingen og avslutningsvis vil det i kapittel 7.3 bli beskrevet hva som anbefales for videre forskning.

I denne oppgaven er det hentet ut finansregnskaper for totalt 909 bedrifter fra Proff Forvalt, samt at det er gjennomgått 12 158 dommer fra Lovdata innen økonomisk bedrageri. Til sammen utgjør dette totalt 14 143 år med input og outputdata. Informasjonen fra finansregnskapene og dommene er satt inn i en dataramme ved hjelp av dataprogrammet Python. En dataramme er et verktøy som brukes for å samle store datamengder på en plass, og forenkle håndtering av data. Informasjonen i denne datarammen er brukt som læringsmateriale for en kunstig intelligens som er trent opp til å finne bedrifter som utfører bedrageri. Læringsalgoritmen splitter informasjonen fra datarammen i et treningssett og et valideringssett. Både treningssettet og valideringssettet inneholder begge kategorier av bedrifter, syke og friske. Først trener den på treningssettet, for så å verifisere hva den har lært på valideringssettet. Dette kalles for epoke.

For å sikre at læringsalgoritmen ikke er lært opp feil er det sjekket for over- og undertilpassing, samt bias mot konkurs. Overtilpassing er når læringsalgoritmen overvurderer variablene i treningssettet – på bekostning av variablene i valideringssettet – og gjør den beregnede funksjonen  $[g]$  mindre generaliserbar. Undertilpassing er når læringsalgoritmen ikke lykkes med å tilpasse datapunktene, hverken for treningssettet eller valideringssettet. Bias kan forklares ved at læringsalgoritmen skaper en korrelasjon i datasettet som ikke finnes i virkeligheten. Hvis samtlige av de syke bedriftene i datasettet er lagt ned, mens de friske bedriftene i datasettet i hovedsak fortsatt er i drift kan en slik bias dannes. Læringsalgoritmen kan da feilaktig læres til å tro at samtlige bedrifter som legges ned er bedrageriske.

Det ble ikke observert indikasjoner for undertilpassing eller bias mot konkurs, men det ble observert en svak tendens til overtilpassing fra epoke 21 og utover. På bakgrunn av dette ble læringen stoppet på epoke 20, og resultatet fra denne epoken ble brukt videre i oppgaven. Basert på resultatene fra epoke 20 kan det vises at læringsalgoritmen oppnår en treffsikkerhet på 98%, hvilket vil si at den klassifiserer 294 av 300 bedrifter riktig.

I innledningen av denne oppgaven ble det presentert et forskningsspørsmål:

***«Er det mulig å identifisere økonomisk bedrageri basert på numeriske data i finansregnskapet til norske aksjeselskaper ved hjelp av kunstig intelligens.»***

Basert på resultatene kan det konkluderes at forskningsspørsmålet kan besvares positivt:

***«Det er mulig å identifisere økonomisk bedrageri basert på numeriske data i finansregnskapet til norske aksjeselskaper ved hjelp av kunstig intelligens.»***

## 7.1 Implikasjoner

Arbeidet som er utført i denne oppgaven viser at det er mulig å bruke kunstig intelligens til å predikere bedrageri, selv med et begrenset og ubalansert datasett. Dette betyr at den numeriske informasjonen som foreligger i finansregnskapene med stor presisjon kan brukes til å predikere bedrageri. Dette er et verktøy som kan være til stor nytte for interessenter av bedrifter, slik som skattemyndigheter, kreditorer, investorer, banker, styre og aksjonærer. Bruk av kunstig intelligens for prediksjon av bedrageri kan bidra til redusert tids- og ressurs-bruk på analyse av bedriftsregnskap, samt bistå til å kanalisere ressursbruken i retning av de bedriftene hvor sannsynlighet for bedrageri er stor. Dette vil potensielt bidra til redusert risiko for tap for de overnevnte interessentene.

## 7.2 Begrensninger

### **Begrenset datasett**

Det er verdt å nevne at treningen og valideringen av den kunstige intelligensen er utført på et begrenset datasett, og da spesielt datasettet for syke bedrifter. Datasettet er basert på en gjennomgang av 12 158 dommer innenfor økonomisk kriminalitet. Dette datasettet ble videre redusert til kun 87 bedrifter. Det er stor sannsynlighet for at dette datasettet ikke dekker alle mulige måter en bedrift kan utføre økonomisk bedrageri på, hvilket kan resultere i at bedrifter som er bedrageriske anses som friske av den kunstige intelligensen.

### **Ubalansert datasett**

Videre så er datasettet ubalansert, med en overvekt av friske bedrifter. Ubalanserte datasett vil ikke gi like gode resultater som balanserte datasett. Årsaken til dette er at læringsalgoritmen vil få begrenset informasjon av den datatypen som det er minst av, hvilket i denne avhandlingen er bedrageriske bedrifter. I verste fall vil ikke læringsalgoritmen finne en korrelasjon mellom input og output data. Basert på resultatene i denne oppgaven har datasettet vist seg å være stort nok til å kunne si med 98% sannsynlighet om en bedrift er bedragerisk eller ikke.

Tilgangen på data for friske bedrifter er signifikant større enn tilgangen på data for syke bedrifter. For å kompensere for dette kan det vurderes å begrense datasettet med tanke på friske bedrifter, og på denne måten balansere datasettet. Risikoen ved denne fremgangsmåten er at datasettet – totalt sett – blir for lite til at den kunstige intelligensen kan trenes opp til å klassifisere mellom friske og syke bedrifter.

### **Programmert for norske bedrifter**

Datarammen og den kunstige intelligensen som brukes i denne oppgaven er programmert for å ta i bruk norske bedrifters regnskap. Teoretisk sett er det av liten betydning hvilken nasjonalitet bedriftene har. Det som er viktig er at finansregnskapene innehar de samme regnskapslinjene som den kunstige intelligensen bruker som variabler for å predikere bedrag. Hvis man hadde importert finansregnskap med forskjellig nasjonalitet – og dermed også forskjellig finansregnskaps mal og navn på regnskapslinjer – så ville dette med stor sannsynlighet resultere i en kunstig intelligens med lav treffsikkerhet.

### 7.3 Videre forskning

Ettersom denne oppgaven kun har som formål å påvise at det er mulig å bruke kunstig intelligens for å predikere bedrageri basert på finansregnskap, finnes det en rekke muligheter for å utvide omfanget av temaet.

#### **Større datasett**

Det kunne med fordel vært utført forskning innenfor samme område med et større datasett. Som beskrevet tidligere er datasettet begrenset, og det er stor sannsynlighet for at datasettet ikke innehar alle mulige former for bedrageri.

#### **Analyse av bedrifter som predikeres som bedragerske**

Den kunstige intelligensen som er trent opp i denne oppgaven fant en rekke bedrifter hvor det ikke finnes noen informasjon om bedrageri, men hvor den kunstige intelligensen predikerer med stor sannsynlighet at det foregår bedrageri. Videre forskning kunne ha vært å se på disse bedriftene med tanke på røde flagg for å verifisere at den kunstige intelligensen predikerer riktig.

#### **Finne hvilke variabler som indikerer bedrageri**

I denne oppgaven vites det ikke den direkte årsaken til hvorfor den kunstige intelligensen predikerer at noen bedrifter er syke. Ved å modifisere koden til den kunstige intelligensen kan det være mulig å hente ut denne informasjonen og se hvilke variabler i finansregnskapene som med stor sannsynlighet indikerer bedrageri.

#### **Online screening av bedrifter på Proff Forvalt**

Det kan være av interesse å sette opp et Python basert program som automatisk analyserer alle finansregnskap som blir lagt inn på Proff Forvalt for bedrag.

#### **Predikere hvor stor prosentandel av norske bedrifter som driver bedrageri**

Ved å innhente samtlige finansregnskap fra Proff Forvalt skal det være mulig å beregne hvor stor prosentandel av norske bedrifter som er bedragerske. Videre skal det også være mulig å beregne hvor mange bedrifter som utfører regnskapsmanipulasjon, basert på samme fremgangsmetode.

#### **Implementering av noter og styrets årsberetning**

Det kan være av interesse å koble den numeriske informasjonen med den tekstbaserte informasjonen som foreligger sammen med finansregnskapene. Dette omhandler styrets årsberetning og noter. Dette vil øke den tilgjengelige unike informasjonen til læringsalgoritmen, som igjen vil kunne resultere i økt nøyaktighet.

#### **Bruk av finansregnskap og kunstig intelligens for å løse andre problemer**

Det finnes nok mange andre problemer hvor finansregnskap kan brukes som datasett for en kunstig intelligens. Mulige problemer som kan forskes nærmere på kan være konkursprediksjon, tilslag på lån, fremtidig fortjeneste, sannsynlighet for vekst.

#### 7.3.1 Anbefaling for videre forskning

For å sikre god fremgang i de fremtidige oppgavene anbefales det et samarbeid mellom de forskjellige fagfeltene oppgaven omhandler. Tilgang til personell med kunnskap innen programmering og kunstig intelligens er essensielt for å behandle dataene og programmere den kunstige intelligensen. Samtidig trengs en grunnleggende forståelse for emnet man ønsker å undersøke. Det er av forskernes oppfatning at en slik sammensetning best oppnås ved et samarbeid mellom de forskjellige disiplinene.

## 8 Referanser

- Abu-Mostafa, Y. S. (2012). *Learning From Data*: AMLBook.
- Andersen, K. (2000). Oppkjøp og sammenslåing ; regnskapsmessige konsekvenser etter ny regnskapslov. *Magma*, 3(6), 21-33.
- Baksaas, K. M., & Stenheim, T. (2017). Resultat- eller balanseorienterte regnskaper ; hvor stor forskjell er det i praksis? *Magma*, 20(1), 12-13.
- Berner, P. T., & Aastveit, J. (2009). Hva med regnskapet i tider med økonomisk uro? *Magma*, 12(10), 61-69.
- Bernhoft, A.-C., & Mjanger, S. (2015, 01.03.2015). Forenklet IFRS i 2014 – enkelt i praksis? *Regnskap*.
- Bråthen, T. (2004). Konserninterne transaksjoner. *Magma*, 7(1), 7-10.
- Coenen, T. (2008). *Essentials of corporate fraud*. In Essentials Series.
- Cressey, D. R. (1950). The Criminal Violation of Financial Trust. *American Sociological Review*, 15(6), 738-743. doi:10.2307/2086606
- Dichev, I., Graham, J., Harvey, C. R., & Rajgopal, S. (2016). The misrepresentation of earnings.(Author abstract). 72(1), 22. doi:10.2469/faj.v72.n1.4
- Domingos, P. (2012). A few useful things to know about machine learning. *Communications of the Acm*, 55(10), 78-87. doi:10.1145/2347736.2347755
- Fardal, A. (2007a). IFRS og norske regnskapsregler. *Magma*, 10(3).
- Fardal, A. (2007b). IFRS og norske regnskapsregler. *Magma*.
- Finans.no. (2018). Økonomi for mannen i gata. Retrieved from <https://finans.no/regnskapsprinsipper>
- Forvalt, P. (2018). Enkel oversikt fra brønnøysundregistrene. Retrieved 2018/03/22/, from Proff Forvalt <https://www.forvalt.no/regnskap/bronnøysundregistrene>
- Ghahramani, Z. (2015). Probabilistic machine learning and artificial intelligence. *Nature*, 521(7553), 452-459. doi:10.1038/nature14541
- Gil Press. (2018). A Very Short History Of Artificial Intelligence (AI). Retrieved from <https://www.forbes.com/sites/gilpress/2016/12/30/a-very-short-history-of-artificial-intelligence-ai/#7355cda66fba>
- Gjesdal, F. (2003). Resultat kvalitet anno 2003. *Praktisk økonomi & finans*.
- Godtland Consulting. (2018). Grunnleggende regnskapsprinsipper del 1. Retrieved from <http://godtlandconsulting.no/2016/12/22/grunnleggende-regnskapsprinsipper-del-1>
- Gomez-Urbe, C. A., & Hunt, N. (2016). The Netflix Recommender System: Algorithms, Business Value, and Innovation. *ACM Transactions on Management Information Systems (TMIS)*, 6(4), 13. doi:10.1145/2843948
- Google AI. (2018). Retrieved from <https://www.tensorflow.org/>
- Grenness, T. (2001). *Innføring i vitenskapsteori og metode* (2. utg. ed.). Oslo: Universitetsforl.
- Gripsrud, G., Silkoset, R., & Olsson, U. H. (2010). *Metode og dataanalyse : beslutningsstøtte for bedrifter ved bruk av JMP* (2. utg. ed.). Kristiansand: Høyskoleforl.
- Gulden, B. P. (2015). *Den eksterne revisor*. In.
- Healy, P. M., & Wahlen, J. M. (1999). A Review of the Earnings Management Literature and Its Implications for Standard Setting. *Accounting Horizons*, 13(4), 365-383. doi:10.2308/acch.1999.13.4.365
- Heskestad, T. (2014a). Manipulering av inntekter og «røde flagg» | Deloitte Norge. Retrieved from <https://www2.deloitte.com/no/no/pages/legal/articles/manipulering-av-inntekter.html>
- Heskestad, T. (2014b). Manipulering av kostnader og «røde flagg» | Deloitte Norge. Retrieved from <https://www2.deloitte.com/no/no/pages/audit/articles/manipulering-av-kostnader.html>
- Hope, O.-K., & Wang, J. (2018). Management deception, big-bath accounting, and information asymmetry: Evidence from linguistic analysis. *Accounting, Organizations and Society*. doi:10.1016/j.aos.2018.02.004

- International Auditing and Assurance Standards Board. (2009). ISA 240 Revisors oppgaver med og plikter til å vurdere misligheter ved revisjon av regnskaper. In (Vol. ISA 240.A1). New York: Den norske Revisorforening.
- Johannessen, A., Christoffersen, L., & Tufte, P. A. (2010). *Introduksjon til samfunnsvitenskapelig metode* (4. utg. ed.). Oslo: Abstrakt.
- Johannessen, A., Christoffersen, L., & Tufte, P. A. (2011). *Forskningsmetode for økonomisk-administrative fag* (3. utg. ed.). Oslo: Abstrakt forl.
- Keras. (2018). Retrieved from [https://keras.io/backend/#categorical\\_crossentropy](https://keras.io/backend/#categorical_crossentropy)
- Kinserdal, F. (2014). Hvordan manipulere med regnskapet. *Magma*, 17(1), 18-25.
- Kinserdal, F. (2017). Hva er regnskapsmanipulasjon, og hvordan kan den best avdekkes?
- Kirkos, E., Spathis, C., & Manolopoulos, Y. (2007). Data Mining techniques for the detection of fraudulent financial statements. *Expert Systems with Applications*. May2007, 32(4), 995. doi:10.1016/j.eswa.2006.02.016
- Kvifte, S. S., Bernhoft, A.-C., & Tofteland, A. (2011). *Finansregnskap : god regnskapsskikk og IFRS* (2. utg. ed.). Bergen: Fagbokforl.
- Kvifte, S. S., & Johnsen, A. (2008). *Konseptuelle rammeverk for regnskap* (2. utg. ed.). Oslo: Den norske revisorforening.
- Lin, C.-C., Chiu, A.-A., Huang, S. Y., & Yen, D. C. (2015). Detecting the financial statement fraud: The analysis of the differences between data mining techniques and experts' judgments. *Knowledge-Based Systems*, 89, 459-470. doi:<https://doi.org/10.1016/j.knosys.2015.08.011>
- Lov om årsregnskap m.v. (regnskapsloven). (1998). Norge: Finansdepartementet Retrieved from [https://lovdata.no/dokument/NL/lov/1998-07-17-56#KAPITTEL\\_4](https://lovdata.no/dokument/NL/lov/1998-07-17-56#KAPITTEL_4).
- Lovdata. (2018). *Personvern på Lovdata.no*. Lovdata Retrieved from <https://lovdata.no/info/personvern>.
- Mnih, V., Kavukcuoglu, K., Silver, D., Graves, A., Antonoglou, I., Wierstra, D., & Riedmiller, M. (2013). Playing Atari with Deep Reinforcement Learning. *ArXiv e-prints*.
- MnistExamples. (2017). Retrieved from [https://en.wikipedia.org/wiki/MNIST\\_database#/media/File:MnistExamples.png](https://en.wikipedia.org/wiki/MNIST_database#/media/File:MnistExamples.png)
- Mulford, C. W., & Comiskey, E. E. (2002). *The financial numbers game : detecting creative accounting practices*. New York: Wiley.
- Murphy, P., & Dacin, M. (2011). Psychological Pathways to Fraud: Understanding and Preventing Fraud in Organizations. *Journal of Business Ethics*, 101(4), 601-618. doi:10.1007/s10551-011-0741-0
- Norsk regnskapsstiftelse. (2018). God regnskapsskikk for små foretak. In (Vol. NRS 8). Oslo: Norsk Regnskapsstiftelse.
- Oslo Børs ASA. (2018, 13.06.2018). Vilkår for notering. Retrieved from <https://www.oslobors.no/Oslo-Boers/Notering/Aksjer-egenkapitalbevis-og-retter-til-aksjer/Oslo-Boers-og-Oslo-Axess/Vilkaar-for-notering>
- Penman, S. H. (2013). *Financial statement analysis and security valuation* (5th ed., International ed. ed.). New York: McGraw-Hill.
- Petter Gottschalk. (2012). *Kvinner i økonomisk kriminalitet*. Oslo: Akademika.
- Picker, R. (2016). *Applying IFRS standards* (4th ed. ed.). Chichester: Wiley.
- Pydata.org. (2018). Retrieved from <https://pandas.pydata.org/pandas-docs/stable/generated/pandas.DataFrame.html>
- Ravisankar, P., Ravi, V., Raghava Rao, G., & Bose, I. (2011). Detection of financial statement fraud and feature selection using data mining techniques. *Decision Support Systems*, 50(2), 491-500. doi:<https://doi.org/10.1016/j.dss.2010.11.006>
- Revisjon.no. (2018). Våre ti regnskapsprinsipper med kommentarer. Retrieved from [http://www.revisjon.no/spesielle\\_tema\\_regnskap](http://www.revisjon.no/spesielle_tema_regnskap)
- Revisjon\_AS. (2018, 07.03.2018). regnskapsprinsipper. *Revisjon.no*.

- Saunders, M., Lewis, P., & Thornhill, A. (2012). *Research Methods for Business Students* (6th ed. ed.): United Kingdom: Pearson Education M.U.A.
- Schilit, H. (2002). *Financial shenanigans: How to detect accounting Gimmicks & Fraud in financial reports* (2nd ed. ed.). New York: McGraw-Hill.
- Sentralbyrå, S. (2018, 30.05.2018). Framleis flest aksjeselskap og einskildpersonføretak. Retrieved from <https://www.ssb.no/virksomheter-foretak-og-regnskap/artikler-og-publikasjoner/ramleis-flest-aksjeselskap-og-einskildpersonforetak>
- Soderstrom, N. S., & Sun, K. J. (2007). IFRS adoption and accounting quality: A review. *European Accounting Review*, 16(4), 675-702. doi:10.1080/09638180701706732
- Stenheim, T., & Blakstad, L. (2012). Regnskapsmanipulering – definisjon, forutsetninger og incentiver.
- Tellefsen, J. T., & Langli, J. C. (2005). *Årsregnskapet* (8. utg. ed.). Oslo: Gyldendal akademisk.
- Terje Heskestad. (2015). Resultatkvalitetsanalyse, røde flagg og driftsinntekter. *Revisjon og regnskap*(8).
- Terje Heskestad. (2018, 2018/06/13/). Røde flagg knyttet til driftsinntekter og varekostnader. Retrieved from <https://www.regnskapnorge.no/artikler/okonomistyring/rode-flagg-knyttet-til-driftsinntekter-og-varekostnader2>
- Tofteland, A., & Fladstad, H. N. (2014). *Finansregnskap : vurdering og analyse* (4. utg. ed.). Bergen: Fagbokforl.
- Turing, A. M. (1950). Computing Machinery and Intelligence. *Mind*, 59(236), 433-460.
- Tvedt, T., & Thaysen, K. (2015). Misligheter og revisors rolle. *Revisjon og regnskap*, 85(6), 46-49.

## 9 Vedlegg

### 9.1 Dom-forside

RETTET I MEDHOLD AV  
STRAFFEPROSESSLOVEN § 44



#### BORGARTING LAGMANSRETT

##### DOM

**Avsagt:** [redacted] 2012 i Borgarting lagmannsrett,

**Saksnr.:** [redacted]

**Dommere:**

Lagdommer  
Lagdommer  
Tilkalt dommer,  
sønskriver



**Meddommere:**

Seniorrådgiver  
Pensjonist  
Sosionom  
Pensjonist



I Fullstendig anke  
Siktet



Påtalemyndighet

Økokrim

II Fullstendig anke  
Siktet



Påtalemyndighet

Økokrim



Ingen begrensninger i adgangen til offentlig gjengivelse



**1. Tiltalene**

**1.1 Tiltalen mot [REDACTED]**

Oslo statsadvokatembeter har ved tiltalebeslutning av [REDACTED] 2009 satt [REDACTED], født [REDACTED], under tiltale for overtredelse av:

**1 Straffeloven § 275 jf § 276**

for i hensikt å skaffe seg eller andre en uberettiget vinning eller å skade, forsømmer en annens anliggender som han styrer eller har tilsyn med, eller handler mot den annens tarv eller å ha medvirket til dette, i det forholdet anses for grovt særlig på grunn av beløpets størrelse.

Grunnlag er følgende forhold eller medvirkning til disse:

- a) I egenskap av styreleder i [REDACTED] KS besørget han høsten 1997 at selskapet kjøpte skipet [REDACTED] av [REDACTED] [REDACTED] Panama, for USD 2.700.000. [REDACTED] hadde kort tid forut kjøpt skipet for USD 1.800.000 av [REDACTED] Ltd, New Zealand. Av differansen på USD 900.000 disponerte han og/eller [REDACTED] i henhold til avtalte over minst USD 400.000 som gikk til formål som var [REDACTED] KS uvedkommende.
- b) I egenskap av reell leder i [REDACTED] AS besørget han i mars 2000 at selskapet kjøpte skipet [REDACTED] av [REDACTED] Inc, Panama, for USD 5.000.000. [REDACTED] Inc, som var kontrollert av ham og/eller [REDACTED], hadde kjøpt skipet i september/oktober 1999 av [REDACTED] Co Ltd, Japan, for USD 1.750.000. Av kjøpesummen på USD 5.000.000 ble USD 761.162 brukt til oppgradering. Ved å kjøpe skipet via [REDACTED] Inc ble [REDACTED] AS påført en ekstra kostnad på USD 2.488.749 som gikk til formål som var selskapet uvedkommende.
- c) I egenskap av reell leder i [REDACTED] AS besørget han i januar/februar 2003 at selskapet kjøpte skipet [REDACTED] av [REDACTED] [REDACTED] Ltd, British West Indies, for USD 4.500.000. [REDACTED] Ltd, som var kontrollert av ham og/eller [REDACTED], hadde kjøpt skipet i juli 2002 av [REDACTED] Co Ltd, Japan, for USD 2.075.000. Ved å kjøpe skipet via [REDACTED] Ltd ble [REDACTED] AS påført en ekstra kostnad på USD 2.425.000 som gikk til formål som var selskapet uvedkommende.
- d) I egenskap av styreleder i [REDACTED] AS besørget han juni 2001 at selskapet inngikk avtale med [REDACTED] Finans AS (senere [REDACTED] Finans AS) om leasing av [REDACTED] sementpumpe. Banken hadde kjøpt pumpen av [REDACTED] Ltd, British West Indies, for Euro 580.000. [REDACTED] Ltd, som var kontrollert av ham og/eller [REDACTED], hadde kort tid forut kjøpt pumpen av [REDACTED] for Euro 135.000. Ved å selge pumpen til banken via [REDACTED] Ltd påførte han [REDACTED] AS ekstra leasingleie på til sammen NOK 4.694.424.

### 9.3 Dom-domsslutning

#### DOMSSLUTNING

1. [REDACTED], født [REDACTED], dommes for:  
4 – fire - overtredelser av straffeloven § 276, jf. § 275, tiltalen post 1 a, 1 c, 1 d og 8,  
3 – tre - overtredelser av straffeloven § 271, jf. § 270, tiltalen post 2 b, 2 c og 2 d,  
1 – en - overtredelse av straffeloven § 271, jf. § 270, jf. § 49, tiltalen post 3 b,  
2 – to - overtredelser av straffeloven § 278 \*), tiltalen post 4 a og 4 b og  
de forhold som er rettskraftig avgjort ved Oslo tingretts dom av [REDACTED] 2010, alt  
sammenholdt med straffeloven § 62,  
til en straff av fengsel i 5 – fem - år, hvorav 2 – to – år og 6 – seks - måneder gjøres  
betinget med en prøvetid på 2 – to – år, jf. straffeloven §§ 52 – 54. Til fradrag i  
straffen kommer 14 – fjorten – dager for utholdt frihetsberøvelse.
2. [REDACTED] frifinnes for tiltalen postene 1 b, 2 a, 3 a og 6 c.
3. Oslo tingretts dom av [REDACTED] 2010 vedrørende tiltalen post 1 f oppheves og  
hjemvises til ny behandling.
4. [REDACTED] dommes til å betale erstatning til [REDACTED] Bank ASA med  
120 794 – etthundreogtjuetusensjuhundreogtjuefire - USD.
5. I medhold av straffeloven § 34 kan følgende inndras hos [REDACTED]  
ved verdiinndragning:
  - 1 322 577 – enmilliontrehundreogtjuetotusenfemhundreogsyttisju – USD - og
  - 442 250 – firehundreogfortitotusentohundreogfemti – EUR - ogved gjenstandsinndragning:
  - 1 354 090 – enmilliontrehundreogfemtifiretusenogtjue – USD - samt renter på  
dette opptjent på konto i bank [REDACTED].
6. [REDACTED], født [REDACTED], dommes for:  
4 – fire- overtredelser av straffeloven § 276, jf. § 275, tiltalen post 1 a, 1 c, 1 d og 1 f,  
3 – tre - overtredelser av straffeloven § 271, jf. § 270, tiltalen post 2 b, 2 c og 2 d,  
1 – en - overtredelse av straffeloven § 271, jf. § 270, jf. § 49, tiltalen post 3 b og  
1 – en - overtredelse av regnskapsloven (1998) § 8-5, jf. regnskapsloven (1998)  
§ 9-2, jf. regnskapsloven (1977) § 11, jf. forskrift av 6. mai 1999 § 6-3 første  
ledd, jf. regnskapsloven (1998) § 3-3 femte og sjette ledd, jf. regnskapsloven  
(1998) § 5-3, tiltalen post 6 a, alt sammenholdt med straffeloven § 62  
til en straff av fengsel i 4 – fire – år, hvorav 2 – to – år gjøres betinget med en  
prøvetid på 2 – to – år, jf. straffeloven §§ 52 – 54. Til fradrag i straffen kommer 27 –  
tjuesju – dager for utholdt frihetsberøvelse.