

ØKONOMI OG ADMINISTRASJON

MASTEROPPGAVE

**Konkursprediksjon i høy- og  
lavkonjunkturer**

*Martine Bye Lauvsnes og Sander Mørk Selsbak*

*Veileder: Ranik Raaen Wahlstrøm*

Mai 2022

## Forord

Denne masteroppgaven er skrevet som den avsluttende delen av masterstudiet i økonomi og administrasjon ved NTNU Handelshøyskolen våren 2022. Denne avhandlingen utgjør 30 studiepoeng, og er en del av hovedprofilen Business Analytics.

Det var et ønske fra begge forfatterne å benytte oppgaven til å arbeide videre med kvantitative metoder, som hadde vært en viktig del av hele masterstudiet. Konkursprediksjon som tema muliggjorde bruk av kvantitative metoder for å løse et omfattende problem, og åpnet for både statistiske og maskinlæringsbaserte teknikker. Videre åpnet oppgavens tema opp for å undersøke hvilke bedriftsøkonomiske og makroøkonomiske faktorer som spiller inn på et selskaps konkurssannsynlighet. Slik ble også økonomisk teori en viktig del av oppgaven. Det finnes lite forskning på norske selskaper som ser konkursprediksjon i sammenheng med konjunktursvningninger. Denne studien vil forhåpentligvis bidra til et utvidet perspektiv på konkursprediksjon som fagfelt. En stor takk rettes til veileder Ranik Raaen Wahlstrøm, som gjennom hele skriveprosessen har bidratt med strålende veiledning og bistått med datagrunnlaget for oppgaven.

*Innholdet i denne oppgaven står for forfatternes regning*

Trondheim, 24. mai 2022

---

Martine Bye Lauvsnes

---

Sander Mørk Selsbak

## Sammendrag

Denne masteroppgaven omhandler konkursprediksjon under høy- og lavkonjunktur. Hovedmålet med oppgaven er å avdekke om hvorvidt det er hensiktsmessig eller ikke å, basert på konjunktursvingninger, skille datagrunnlaget for prediksjoner. Med hensiktsmessig menes her to ting. For det første, er det ønskelig å undersøke om prediksjonsmodeller kan forbedres ved å adskille perioder med høykonjunktur og perioder med lavkonjunktur. For det andre, ser oppgaven på hvilke egenskaper ved et selskap som har størst innvirkning på konkurssannsynlighet i henholdsvis høy- og lavkonjunktur. Hvilke bedriftsøkonomiske faktorer som er mest relevante med hensyn til konkurssannsynlighet i ulike makroøkonomiske situasjoner, vil være av interesse både for selskapets beslutningstakere og eksterne interessenter. I lys av dette formålet, er det formulert to problemstillinger:

- 1. Hvilke regnskapsmessige forhold gir størst forklaringskraft i konkursprediksjonsmodellene under de ulike konjunkturperiodene?*
- 2. I hvilken grad endres prediksjonsevnen til konkursprediksjonsmodeller for serveringsbransjen ved å tilpasse seg konjunktursvingninger?*

Oppgavens omfang er begrenset til norske selskap innen serveringsbransjen, og datagrunnlaget består av 49 529 årsregnskap i perioden 2006 til 2017. Ved bruk av en konjunkturindikator deles datagrunnlaget inn i høykonjunkturperioder og lavkonjunkturperioder. Deretter brukes to ulike metoder for å predikere konkurs: logistisk regresjon og beslutningstrær med Extreme gradient boosting (XGBoost). Det brukes også to ulike variabelsett: ett basert på Norges Banks SEBRA-modell og et annet utviklet av [Paraschiv et al., 2021]. Oppgaven konkluderer med at en oppdeling i høy- og lavkonjunktur ikke kan sies å føre til at modellene som brukes oppnår mer treffsikre prediksjoner. Videre konkluderes det med at konjunktursvingninger ser ut til å ha en effekt på hvilke bedriftsøkonomiske egenskaper som virker mest inn på konkurssannsynlighet. Dette gjelder spesielt selskapets gjeld og alder.

## Abstract

This master’s thesis attempts to tackle the subject of bankruptcy prediction during periods of economic expansions and downturns. The main objective is uncovering whether it is useful to separate input data based on macroeconomic fluctuations when predicting bankruptcies. In this thesis, the usefulness of this separation is assessed in two ways. First, we evaluate whether models achieve higher prediction accuracies when input data is separated. Second, we investigate which underlying features of a company have the highest impact on its likelihood of going bankrupt in expansions and downturns, respectively. In case different features matter in economic expansions as opposed to downturns, the company might have to adjust its survival strategies thereafter. Furthermore, this knowledge might also be interesting to external actors such as banks or shareholders. Considering the objectives of this thesis, the following research questions are posed:

1. *Which financial factors have the most bearing on bankruptcy probability during economic expansion and economic downturns, respectively??*
2. *To what extent can bankruptcy prediction models for the catering industry be improved by separating input data based on economic expansions and downturns?*

The scope of this thesis is limited to Norwegian companies within the catering industry. The input data consists of 49 529 annual financial reports submitted in the time frame between 2006 and 2017. The data is separated into periods of economic expansion and periods of economic downturn using a business cycle indicator. Two methods are then used in the bankruptcy prediction: logistic regression and decision trees with Extreme gradient boosting (XGBoost). Two sets of variables are used separately: one based on Norges Bank’s SEBRA-model, and the other based on the findings of [Paraschiv et al., 2021].

The study finds that the separation of input data into expansions and downturns does not seem to result in significant improvements regarding the performance of the prediction models. However, it does conclude that changing business cycles has an impact on which variables are relevant for the probability of a business going bankrupt. This is especially the case for corporate debt and age.

# Innholdsfortegnelse

<b>1</b>	<b>Innledning</b>	<b>1</b>
1.1	Bakgrunn og motivasjon . . . . .	1
1.2	Serveringsvirksomhet i Norge . . . . .	2
1.3	Problemstilling . . . . .	3
1.4	Oppbygging av oppgaven . . . . .	4
<b>2</b>	<b>Litteratur</b>	<b>5</b>
2.1	Konjunktursykluser . . . . .	5
2.1.1	Lavkonjunktur . . . . .	5
2.1.2	Høykonjunktur . . . . .	7
2.2	Kapitalstruktur i serveringsvirksomheter . . . . .	8
2.3	Konkurs . . . . .	10
2.4	Tidligere forskning innenfor regnskapstallbasert konkursprediksjon . . . . .	10
2.4.1	Beavers univariate modell . . . . .	10
2.4.2	Altmans multivariate modeller . . . . .	12
2.4.3	Ohlson: logistisk regresjonsmodell . . . . .	14
2.4.4	SEBRA-modellen . . . . .	16
2.4.5	Variabelsett valgt ut med LASSO . . . . .	17
2.4.6	Kim og Upneja: Konkursprediksjon under konjunkturedringer . . . . .	19
2.4.7	Suzan Hol: Konkursprediksjon under konjunkturedringer . . . . .	20
2.5	Maskinlæringsteknikker . . . . .	21
2.5.1	Statistiske metoder og maskinlæring . . . . .	21
2.5.2	Beslutningstrær . . . . .	22
2.5.3	Bagging og boosting . . . . .	25
2.6	Oppsummering av littteraturkapittel . . . . .	26
<b>3</b>	<b>Forskningsmetode</b>	<b>27</b>
3.1	Datagrunnlag og preprosessering . . . . .	27

3.1.1	Datagrunnlag . . . . .	27
3.1.2	Preprossesering av data . . . . .	28
3.2	Valg av variabelsett . . . . .	29
3.2.1	Avhengig variabel . . . . .	29
3.2.2	Uavhengige variabler - Variabelsett 1 . . . . .	29
3.2.3	Uavhengige variabler - Variabelsett 2 . . . . .	31
3.3	Konjunkturindikator . . . . .	32
3.4	Valg av metode . . . . .	36
3.5	Modellevaluering . . . . .	40
3.5.1	Reciever Operating Characteristics (ROC) . . . . .	40
3.5.2	Kryssvalidering . . . . .	44
3.6	Reliabilitet og validitet . . . . .	47
<b>4</b>	<b>Resultater</b>	<b>49</b>
4.1	Resultater fra variabelsett 1 . . . . .	49
4.1.1	Logistisk regresjon . . . . .	49
4.1.2	XGBoost . . . . .	50
4.2	Resultater fra variabelsett 2 . . . . .	51
4.2.1	Logistisk regresjon . . . . .	52
4.2.2	XGBoost . . . . .	53
<b>5</b>	<b>Diskusjon</b>	<b>55</b>
5.1	Modellytelse . . . . .	55
5.2	Forklaringskraft: variabelsett 1 . . . . .	56
5.2.1	XGBoost . . . . .	56
5.2.2	Logistisk regresjon . . . . .	59
5.3	Forklaringskraft: variabelsett 2 . . . . .	60
5.3.1	XGBoost . . . . .	60
5.3.2	Logistisk regresjon . . . . .	61
<b>6</b>	<b>Konklusjon</b>	<b>63</b>

6.1	Problemstilling 1 . . . . .	63
6.2	Problemstilling 2 . . . . .	63
6.3	Utfordringer ved oppgaven . . . . .	64
6.4	Videre forskning . . . . .	64
<b>A</b>	<b>Appendiks</b>	<b>72</b>
A.1	Komplette resultater for AUC, NR og variablenes forklaringskraft: regresjon og variabler fra variabelsett 1 . . . . .	72
A.2	Komplette resultater for AUC, NR og variablenes forklaringskraft: XGBoost og variabler fra variabelsett 1 . . . . .	74
A.3	Komplette resultater for AUC, NR og variablenes forklaringskraft: regresjon og variabler fra variabelsett 2 . . . . .	76
A.3.1	Komplette resultater for AUC, NR og variablenes forklaringskraft: XGBoost og variabler fra variabelsett 2 . . . . .	78
A.4	Filtrering av datasett . . . . .	80
A.5	Variabelsett 1, basert på Norges Banks SEBRA-modell . . . . .	81
A.6	Variabelsett 2, basert på studien til [Paraschiv et al., 2021] . . . . .	83

# Figurer

1	Konkurser for aksjeselskap innenfor serveringsbransjen etter kvartal [SSB, 2022b].	3
2	Konsum i husholdninger etter år. Volumendring, årlig (prosent). Overnattings- og serveringstjenester [SSB, 2022c]	7
3	Eksempel på klassifiseringstre for kredittvurdering [Ligang and Lai, 2009]	24
4	Variasjoner i CLI i Norge mellom 2006 og 2017	33
5	Eksempel på forklaringskraft-plot skrevet ut av XGBoost	38
6	Mulige klassifiseringsutfall [Fawcett, 2006]	40
7	ROC-plot med AUC-verdi 0,5	42
8	7-fold kryssvalidering av datasettet HP	45
9	6-fold kryssvalidering av datasettet HK	46
10	2-fold kryssvalidering av datasettet LK	46



# Tabeller

1	Oversikt over sysselsetting, serveringsvirksomhet (næringskode 56) [SSB, 2022a]	2
2	Variabler som inngår i SEBRA-basis (mørke felt) og SEBRA-utvidet (hele tabellen) [Bernhardsen and Larsen, 2007]	17
3	Variabelsett brukt i modellen til [Kim and Upneja, 2021]	19
4	Variabelsett 1, basert på SEBRA-modellen [Bernhardsen and Larsen, 2007]	30
5	Oversikt over variabelsett 2	31
6	Komponenter i CLI [Bernhardsen and Larsen, 2007]	32
7	Definisjon av høy-/lavkonjunkturer i Norge mellom 2006 og 2017	35
8	Rangering av uavhengige variabler mht. forklaringskraft ved bruk av logistisk regresjon og variabler fra variabelsett 1	50
9	Rangering av uavhengige variabler mht. forklaringskraft ved bruk av XGBoost og variabler fra variabelsett 1	51
10	Rangering av uavhengige variabler mht. forklaringskraft ved bruk av logistisk regresjon og variabler fra variabelsett 2	52
11	Rangering av uavhengige variabler mht. forklaringskraft ved bruk av XGBoost og variabler fra variabelsett 2	54
12	Gjennomsnittlig AUC for alle modeller	55

# 1 Innledning

I dette introduksjonskapittelet vil vi gi en relevant bakgrunn og motivasjon for valget av å studere konkursprediksjon innen serveringsvirksomheten i Norge, under konjunkturrendringer. Det vil bli gitt en oversikt over serveringsbransjen i Norge, og så vår problemstilling for oppgaven. Vi vil beskrive vårt bidrag til forskningen innenfor dette feltet, for så å gi en oversikt over strukturen til oppgaven.

## 1.1 Bakgrunn og motivasjon

Ett av hovedmotivene for å predikere konkurs er det ansvaret bedrifter har ovenfor sine interessenter. En bedrift vil ha en rekke interessenter som ønsker å evaluere bedriftens fremtidige prestasjoner, og unngå de kostnader som vil komme av en eventuell konkurs. Det kan være aksjeeiere som tenker på investeringen sin, arbeidstakere som vil vite om de har en jobb i fremtiden eller leverandører og samarbeidspartnere som har inngått relasjonsspesifikke investeringer i bedriften [Chen et al., 1996]. Å klassifisere en bedrift feil i en konkursprediksjon kan dermed medføre store kostnader for flere interne og eksterne aktører.

Små og mellomstore bedrifter er selve drivkraften i økonomien da de samlet står for omtrent halvparten av all verdiskapningen, og utgjør mer enn 99 % av virksomheter i Norge [Næringslivets Hovedorganisasjon, 2022]. Det finnes flere bransjer som er spesielt utsatte når det kommer til konjunkturrendringer. Serveringsbransjen er en av disse bransjene som det vil gå hardest utover når en lavkonjunktur inntreffer. Denne bransjen er preget av høy likviditet, mye konkurs og stadig nye etableringer [Arbeidstilsynet, 2022]. En konkursprediksjon under lavkonjunktur for serveringsbransjen kan være til stor hjelp for både kreditorer og banker som vil låne ut penger til serveringsvirksomheter, og til virksomhetene selv som ønsker at bedriften skal stå sterkere under en lavkonjunktur.

## 1.2 Serveringsvirksomhet i Norge

Serveringsnæringen har stor betydning for samfunnet i Norge. Næringen dekker grunnleggende samfunnsmessige behov for tilberedt mat og drikke, samtidig som det er en kilde til sosialt samvær [Damvad, 2014]. Det er også mange av serveringsvirksomhetene som er verdifulle for den lokale og den nasjonale kulturen i landet. Bransjen står for omtrent to prosent av sysselsettingen i Norge, og én prosent av verdiskapningen. Dette er det normale nivået for de fleste land, bortsett fra land der denne næringen har spesielt stor kulturell og næringsmessig relevans, der nivået av sysselsatte i næringen er noe høyere.


Serveringsbransjen er av bransjene i Norge som stadig øker i omsetning, men samtidig er preget av høye konkursrater. Bransjen omfatter restauranter og kafeer, gatekjøkken, cateringvirksomhet, kantinedrift, pubvirksomhet og drift av barer ellers [Dangeti, 2017]. Det kreves lite for å starte opp et serveringssted, da det er få formelle krav som må imøtekommes før bedriften kan etableres. Dette kan være én av grunnene til den høye raten av konkurs. Bransjen er preget av mye gjennomtrekk som betyr at serveringsvirksomheter etableres og avvikles ofte [Arbeidstilsynet, 2022]. Vi ser ut fra tabell 1 at sysselsettingen har en stødig økning i antall sysselsatte for hvert år, med unntak av årene direkte etter finanskrisen i 2008, og vokser i takt med Norsk fastlandsøkonomi [Damvad, 2014].

	Sysselsatte									
	2007	2008	2009	2010	2011	2012	2014	2015	2016	2017
56 Serveringsvirksomhet	61 339	60 864	59 854	59 040	60 173	61 010	67 670	76 567	80 937	83 504

Tabell 1: Oversikt over sysselsetting, serveringsvirksomhet (næringskode 56) [SSB, 2022a]

I 2019 ble det åpnet konkurs for 5 002 bedrifter i Norge, og tvangs-avviklet 1269. Tallene for 2020 er 4 099 for konkurs, og 1 377 for tvangsavvikling, men disse tallene er ikke like representative av virkeligheten da domstolene har vært påvirket av Corona-pandemien [Brønnøysundregistrene, 2022]. Av de 5 002 bedriftene som åpnet konkurs i 2019 var 335 av dem serveringsvirksomheter [SSB, 2022b]. Lavkonjunkturen som har oppstått under utbruddet av Covid 19 har gått hardt ut over serveringsbransjen med en reduksjon i omsetning

på 18.7 % fra 2019 til 2020 [SSB, 2022c] som viser til risikoen serveringsbransjen møter ved konjunkturerendringer.



Figur 1: Konkurser for aksjeselskap innenfor serveringsbransjen etter kvartal [SSB, 2022b].

### 1.3 Problemstilling

1. *Hvilke regnskapsmessige forhold gir best forklaringskraft i konkursprediksjonsmodellene under de ulike konjunkturperiodene?*
2. *I hvilken grad endres prediksjonsevnen til konkursprediksjonsmodeller for serveringsbransjen ved å tilpasse seg konjunktursvingninger?*

Denne oppgaven vil forsøke å finne variabler i modellene som det vil være hensiktsmessig for bedriftens ledere å være oppmerksom på når det økonomiske klimaet i Norge befinner seg i en lavkonjunktur. En slik modell vil også være av interesse for eksterne aktører som banker som ønsker å gi lån til virksomhetene, og som ønsker å forsikre seg om at virksomheten ikke går konkurs skulle en lavkonjunktur inntreffe.

Modellene i oppgaven baserer seg på alle Norske aksjeselskaper i Norge i perioden 2006 til 2017, som går under serveringsvirksomhet (næringskode 56).

## 1.4 Oppbygging av oppgaven

I kapittel 2 i oppgaven vil det presenteres tidligere forskning innenfor konjunktursykluser, kapitalstruktur og konkursprediksjon. Etter det vil det i kapittel 3, bli gitt en introduksjon til forskningsmetoden og empirien som er brukt for å besvare problemstillingene. Deretter vil analysen bli gjennomgått, også vil resultatene bli diskutert og det blir gitt en konklusjon på problemstillingene.

## 2 Litteratur

### 2.1 Konjunktursykluser

Konjunktursyklus defineres som svingninger ut ifra den generelle trenden i den økonomiske aktiviteten [Benedictow and Johansen, 2005]. Trenden måles hovedsakelig ut fra real-BNP (Brutto nasjonalprodukt). De makroøkonomiske svingningene blir utløst av stokastiske sjokk som påvirker økonomien i en periode før sjokkene avtar, for så å bli erstattet med nye sjokk.

Konjunktursyklusen kan enten deles opp i to perioder ifølge [Gärtner, 2016] som består av høykonjunktur og lavkonjunktur, eller fire perioder ifølge [Benedictow and Johansen, 2005], kalt høykonjunktur, konjunkturedgang, lavkonjunktur og konjunkturoppgang. Alle disse periodene er svingninger ut fra den normale langsiktige trenden av real-BNP [Benedictow and Johansen, 2005]. Denne oppgaven deler opp dataene i to perioder og definerer høykonjunktur og lavkonjunktur som svingninger som avviker fra langtidstrenden i potensiell BNP basert på OECDs CLI-komponenter for Norge [OECD, 2022]. CLI-komponentene vil bli gått nøyere inn på i kapittel 3.3.

#### 2.1.1 Lavkonjunktur


Det finnes flere definisjoner på hva som klassifiseres som lavkonjunktur, i økonomien. Den vanligste definisjonen kommer fra forskningsinstituttet National Bureau of Economic Research (NBER). De baserer lavkonjunktur på en rekke ulike indikatorer i økonomien som nedgang i BNP, realinntekt, industriproduksjon og en stigning i arbeidsledigheten. Den økonomiske aktiviteten må ha en betydelig nedgang på tvers av økonomien, som varer mer enn noen få måneder [NBER, 2022].

En lavkonjunktur er dermed karakterisert som en negativ endring i tilførselen av penger i økonomien, relativt til den langsiktige økonomiske trenden [Knudsen, 2019]. Lavkonjunkturer er sjeldent like da de vil ha ulike opprinnelse, forløp og intensitet. Likevel har de alle en ting til felles, som er både nedgang i konsum og nedgang i etterspørsel etter produksjon

og tjenester [Kaytaz and Gul, 2014]. Det vil være i bedriftenes interesse å følge med på konjunktursvingningene da endringer i de økonomiske trendene vil påvirke de fleste av dem, både gjennom hvordan de finansierer deres langsiktige investeringer og deres daglige drift [Garcia-Sanchez et al., 2014].

En indikasjon på en lavkonjunktur er høyere nivå av arbeidsledighet, noe som gjør konsumenter mer prissensitive [Field and Pagoulatos, 1997]. I matproduksjonssektoren vil etterspørselastisiteten bli mindre elastisk når det er høykonjunktur, og den forventede årlige elastisitet blir mer uelastisk når det er lavkonjunktur [Field and Pagoulatos, 1997]. [Knudsen, 2019] fant i sin forskning at bedrifter med høy etterspørsel før en lavkonjunktur inntraff ville oppleve et større tap under lavkonjunkturer enn de bedriftene som har stødig etterspørsel.

Privat konsum står for den største andelen av BNP, og har en stor innvirkning på hvor fort økonomien kommer seg tilbake til den normale trenden etter en lavkonjunktur [Kaytaz and Gul, 2014]. Under lavkonjunkturer vil konsumentene kutte ut konsumet av luksusgoder først. Luksusgoder er de goder som ikke er nødvendige for konsumentene, og som har billigere substitutter. Konsumentene vil redusere restaurantbesøkene sine under perioder der husholdningene har en synkende realinntekt.



Figur 2: Konsum i husholdninger etter år. Volumendring, årlig (prosent). Overnattings- og serveringstjenester [SSB, 2022c]

Ifølge [Benedictow and Johansen, 2005] har private husholdningers konsum av ikke-varige forbruksvarer høy korrelasjon med BNP, med et tidsetterslep på 0. Dette indikerer at husholdningers konsum og BNP er omtrent like i svingningene sine. Som tidligere nevnt er restaurantbransjen i stadig vekst med nye etableringer, som under høykonjunkturer vil oppleve en større vekst. På grunn av at etterspørselstettheten er så høy i denne bransjen vil restauranter være spesielt utsatt for konsekvensene av konjunktursvingninger.

En lavkonjunktur kan fungere som en slags rensesprosess i økonomien da bedrifter som ikke fungerer optimalt vil gå ut av virksomhet, mens stødigere bedrifter håndterer nedgangstiden greit [Davis, 1992]. Arbeidstakerne i disse bedriftene vil da migrere til mer effektive bedrifter, uten at dette påvirker arbeidsledigheten stort.

### 2.1.2 Høykonjunktur

Når økonomien er i en oppgangsperiode vil produksjonen øke, arbeidsledigheten vil synke og bedrifter vil oppleve en økning i profitt. Under høykonjunktur er produksjonsgapet positivt. Høykonjunkturer er karakterisert som positiv endring i tilførsel av penger i økonomien



i forhold til den langsiktige økonomiske trenden, altså det motsatte av lavkonjunkturer [Knudsen, 2019]. Konjunkturoppgangen varer til produksjonsgapet når sin høyeste verdi på konjunktursyklusen, kalt en konjunkturtopp [Eika, 2007]. På dette tidspunktet er gapet mellom potensiell produksjon og faktisk produksjon på det største. Etter toppunktet vil økonomien synke og nærme seg den gjennomsnittlige trenden, men så lenge den økonomiske aktiviteten ligger over trenden vil økonomien befinne seg i en høykonjunktur.

## 2.2 Kapitalstruktur i serveringsvirksomheter

Kapitalstrukturen til en bedrift er kritisk når det kommer til deres evne til å håndtere nedgangstider. Kapitalstrukturen viser til måten bedrifter er finansiert på, om hvor stor andel av finansieringen deres består av egenkapital og gjeld. Det er utført mye forskning på dette temaet som har ført til flere teorier om hva som er optimal kapitalstruktur og hva som påvirker bedriftenes valg.

Den empiriske forskningen på temaet viser at kapitalstrukturen har en betydelig innvirkning på bedriften. Dette kan ses ved at kapitalstrukturen varierer mye fra bedrift til bedrift, og på tvers av bransjer [Upneja and Dalbor, 2001]. Bedrifter og deres interessenter vil foretrekke en intern finansiering, da dette er det som er mest stabilt i lengden, men dette forutsetter at bedriften er spesielt lønnsom. Krever bedriften mye ekstern finansiering i form av en høyere gjeldsandel, kan dette være en indikator på at lønnsomheten ikke er tilstrekkelig til å holde bedriften i drift over lengre tid.

Det er viktig å se på kapitalstrukturen til bedriftene i forhold til bedriftens livssyklus. Er bedriften i startfasen vil de ta på seg en høyere gjeldsandel. Dette er også sant for bedrifter som ønsker å vokse. I bedrifter som befinner seg mer i modningsfasen vil det være mer uvanlig at store deler av finansieringen deres er gjeld. Mindre bedrifter har en betydelig høyere kortidsgjeld enn større bedrifter [Titman and Wessels, 1988]. Titman og Wessel (1988) fant også i sin forskning at bedrifter med høyere lønnsomhet har mindre gjeld i forhold til markedsverdien på deres egenkapital.

Hvordan en håndterer kortsiktig gjeld i serveringsbransjen er ekstremt viktig. Samtidig er det viktig å ikke bare se på gjeld som langsiktig og kortsiktig gjeld, men også som en samlet enhet. Under posten kortsiktig gjeld finnes lønn og leverandørgjeld. I denne bransjen er størsteparten av leverandørgjelden bestående av lager, som også vanligvis er den største utgiftsposten i resultatregnskapet i denne bransjen [Upneja and Dalbor, 2001]. Lagerbeholdningen er som oftest bestående av ferskvarer med kort levetid, som gjør at en eventuell nedgang i etterspørselen av produkter i denne bransjen vil føre til at produktene må kastes og bedriften taper penger.

Undersøkelsene Upneja og Dalbor (2001) har gjort av serveringsbransjen i USA med børsnoterte bedrifter viser at eldre bedrifter med god profitt og høy kontantstrøm har mindre bruk for langsiktig gjeld. Undersøkelsene deres viser også til at bedrifter med høyere kontantstrøm vil ha større andel gjeld, noe som går imot stadfestede forventninger. Dette kan være på grunn av at bedrifter med evnen til å generere en større kontantstrøm, også har evnen til å vokse [Upneja and Dalbor, 2001].

Hvordan en bedrift er finansiert, og hvordan sammensetningen av ressurser og andre kapabiliteter er avgjørende for hvor godt den er rustet mot eventuelle sårbare situasjoner. Kapitalstrukturen til en bedrift vil være påvirket av bransjen bedriften befinner seg i [Talberg et al., 2008], og bedrifter med forskjellige kapitalstrukturer vil håndtere lavkonjunkturer forskjellig.

Tilgangen på kapital går pro-syklisk, som betyr at det under en lavkonjunktur vil det bli mangel på kapital for bedrifter å få tak i [Knudsen and Lien, 2014]. Når kreditorer opplever et økonomisk sjokk vil de bli mindre villige til å låne ut penger og heve rentene på de lån de allerede har utstedt, da de er redde for de negative økonomiske konsekvensene av det økonomiske sjokket.

## 2.3 Konkurs

Den eksakte definisjonen på hva konkurs er, er kompleks og vil variere fra forskjellige jurisdiksjoner. For at en skal bli begjært konkurs er skyldneren nødt til å være insolvent, som betyr at de verdier og inntekter de har ikke er nok til å dekke deres gjeld. Det er også viktig at disse betalingsproblemene ikke bare er midlertidige. ”er skyldneren insolvent, skal vedkommendes bo tas under konkurshandling når det begjæres av skyldneren eller en fordringshaver” [Konkursloven §61, 1986].

*”Skyldneren er insolvent når denne ikke kan oppfylle sine forpliktelser etter hvert som de forfaller, med mindre betalingsudyktigheten må antas å være forbigående. Insolvens foreligger likevel ikke når skyldnerens eiendeler og inntekter til sammen antas å kunne gi full dekning for skyldnerens forpliktelser, selv om oppfyllelsen av forpliktelsene vil bli forsinket ved at dekning må søkes ved salg av eiendelene”* [Konkursloven §61, 1986].

De som kan begjære et selskap konkurs er kreditorer som ikke har blitt betalt, og som har bevis på at skyldneren heller ikke er i stand til å betale den gjelden de innehar [Norges Domstoler, 2022].

## 2.4 Tidligere forskning innenfor regnskapstallbasert konkursprediksjon

De første konkursprediksjonene startet i kjølvannet av børskrakket som oppstod i 1929, som et forsøk på å unngå at en slik tragedie skulle gjenta seg. Bureau of Business Research publiserte i 1930 en rapport fra en studie av diverse forholdstall i sviktende industriselskaper. Studien analyserte 24 forholdstall blant 29 ulike selskaper for å bestemme felles egenskaper de sviktende bedriftene hadde [Bellovary et al., 2007].

### 2.4.1 Beavers univariate modell

I 1966 publiserte William H. Beaver sin artikkel der han konkluderte med at årsresultatet delt på den totale gjelden var den beste metoden for å predikere konkurs. Hans forskning ble en av de mest anerkjente innenfor univariate modeller for konkursprediksjon. Med sin nye

modell var det mulig å forutse konkurs opptil fem år frem i tid [Beaver, 1966]. I studien ble 79 bedrifter som hadde gått konkurs parett opp mot 79 ikke-konkursbedrifter. For å forbedre prediksjonsevnen foreslo han å benytte flere nøkkeltall på samme tid. I sin studie startet han med 30 nøkkeltall, som ble valgt ut fra tidligere studier innen konkursprediksjon. De 30 nøkkeltallene ble etterhvert redusert til seks gjennom en utvelgningsprosess:

1.  $\frac{\text{Kontantstrøm}}{\text{Samlet gjeld}}$
2.  $\frac{\text{Netto resultat}}{\text{Totalkapital}}$
3.  $\frac{\text{Samlet gjeld}}{\text{Totalkapital}}$
4.  $\frac{\text{Arbeidskapital}}{\text{Totalkapital}}$
5.  $\frac{\text{Omløpsmidler}}{\text{Kortsiktig gjeld}}$

#### 6. Likvide eiendeler – kortsiktig gjeld

Beavers forholdstall baserte seg på å analysere kontantstrømmen til bedriftene, og disse forholdstallene ble delt opp i seks grupper der ett forholdstall fra hver gruppe endte opp i den endelige modellen. Et tall ble valgt ut fra hver gruppe for å unngå høy korrelasjon mellom variablene, men samtidig var det viktig at modellen skulle inneholde så mye informasjon som mulig [Beaver, 1966]. For å finne gjennomsnitt til de seks variablene vurderte han fire påstander:

1. Jo større reservoar av likvide eiendeler, dess mindre sjanse for konkurs.
2. Jo større netto kontantstrøm fra drift, jo lavere sannsynlighet for konkurs.
3. Økende driftsutgifter fører til økende sannsynlighet for konkurs.
4. Økende gjeld fører til økende sannsynlighet for konkurs.

Resultatene av Beavers studie fra 1966 viste at det var signifikante forskjeller i gjennomsnittsverdiene til de bedriftene som hadde gått konkurs, og de som ikke hadde gått konkurs. Forskjellene var tydelige allerede fem år fra en eventuell konkurs, med en økende verdi dess

nærmere bedriften var fra å gå konkurs. Likhetene mellom bedriftene som gikk konkurs var en lavere kontantstrøm, samt et lavere reservoar av likvide eiendeler. Prediksjonsevnen til de forskjellige forholdstallene sank dess nærmere konkursdatoen bedriftene kom, og Beaver konkluderte da med at modellen predikerte ikke-konkursbedrifter bedre enn konkurs [Beaver, 1966].

## 2.4.2 Altmans multivariate modeller

### Z-scoremodellen

Edward I. Altman publiserte sin studie innenfor konkursprediksjon i 1968, der modellen hans var en av de første som var basert på multivariat diskriminantanalyse. Konkursprediksjon hadde opp til da bestått av enkeltstående indikatorer eller finansielle parametere for å finne forskjellen på solvens og insolvens [Prusak, 2018]. Altmans studie var et stort gjennombrudd for konkursprediksjon, og hans modeller ble etterfulgt av en rekke nye modeller som ville forbedre konkursprediksjonen. Z-score-modellen består av flere finansielle faktorer som påvirker bedrifter. Modellen hadde som fordel å analysere et helt sett av forklaringsvariabler på samme tid, samtidig som den tok til høyde for interaksjonen mellom variablene [Altman, 1968]. Dette i motsetning til tidligere univariate modeller der hver variabel ble analysert hver for seg.

I studien så Altman på store, børsnoterte amerikanske selskaper innenfor produksjon som hadde blitt slått konkurs i tidsperioden 1946-1965. Dataen i denne studien besto av 33 konkursslåtte selskaper, og like mange ikke-konkursslåtte selskaper. Z-score modellen besto av nøkkeltall Altman hadde funnet gjennom tidligere forskning, med spesielt vekt på Beaver sin studie fra 1966. Disse nøkkeltallene delte han inn i fem kategorier bestående av likviditet, soliditet, lønnsomhet, gjeldsgrad og aktivitet [Altman, 1968]. Modellen predikerte konkurs med god treffsikkerhet, og selv om multivariat diskriminantanalyse ble utsatt for kritikk forblir det en av de mest populære konkursprediksjonsmodellene [Bellovary et al., 2007].

Altman (1968) diskriminantfunksjon har formen:

$$Z = v_1x_1 + v_2x_2 + \dots + v_nx_n$$

De individuelle variabelverdiene blir endret til en Z-verdi (diskriminant-score) som vil bli brukt til å klassifisere objektet en ser på:

$$\begin{aligned} v_1, v_2, \dots, v_n: & \text{Diskriminante koeffisienter} \\ x_1, x_2, \dots, x_n & \text{Uavhengige variabler} \end{aligned}$$

I studien begynte Altman med 22 nøkkeltall, som ble redusert ned til fem gjennom en iterativ prosess for å finne de nøkkeltallene som kombinert predikerte konkurs best. Nøkkeltallene blir de uavhengige variablene i modellen, og vil multipliseres med de diskriminante koeffisientene for å få Z-score. Formelen til Z-score-modellen med variablene og de estimerte koeffisientene som [Altman, 1968] fant i sin studie, er som følgende:

$$Z = 0.012X_1 + 0.014X_2 + 0.033X_3 + 0.006X_4 + 0.999X_5$$

Der;

$$\begin{aligned} X_1 &= \frac{\text{Arbeidskapital}}{\text{Totalkapital}} \\ X_2 &= \frac{\text{Tilbakeholdt overskudd}}{\text{Totalkapital}} \\ X_3 &= \frac{\text{EBIT}}{\text{Totalkapital}} \\ X_4 &= \frac{\text{Markedsverdi egenkapital}}{\text{Samlet gjeld}} \\ X_5 &= \frac{\text{Omsetning}}{\text{Totalkapital}} \end{aligned}$$

### Zeta-modellen

I 1977 publiserte Altman et al. en ny studie innenfor konkursprediksjon der ZETA-modellen ble presentert, som var ment til å være en forbedring av Z-score-modellen [Altman et al., 1977]. I denne modellen ville de ta hensyn til den stadige endringen i bedrifters størrelse og finansielle profil. I tillegg ville modellen fange opp eventuelle endringer i bedrifters regnskapsstandarder og regnskapsskikk ved å analysere regnskapets fotnoter. Studien er basert på både små og store selskaper innenfor produksjon eller detaljhandel, med 52 bedrifter som hadde gått

konkurs og 58 ikke-konkursselskaper i tidsperioden 1962-1975. Studien startet med 27 variabler de mente kunne ha betydning for selskapets økonomiske tilstand. Variabler som ikke var signifikante for modellen ble eliminert, til det til slutt gjensto syv signifikante nøkkeltall. Ingen av de syv nøkkeltallene dukket opp i den originale Z-score-modellen.

De syv variablene modellen består av er som følgende:

$$\begin{aligned}
 x_1 &= \text{Totalkapitalrentabilitet} \\
 x_2 &= \text{Stabilitet i inntektene} \\
 x_3 &= \text{Rentedekningsgrad} \\
 x_4 &= \text{Kumulativ profitt} \left( \frac{\text{Markedsverdi egenkapital}}{\text{Samlet gjeld}} \right) \\
 x_5 &= \text{Likviditet} \\
 x_6 &= \text{Egenkapitalprosent} \\
 x_7 &= \text{Størrelse (målt i totalkapital)}
 \end{aligned}$$

### Den reviderte Altman Z-score-modellen

I 2000 reviderte [Altman, 2000] Z-score-modellen, og kalte den nye modellen den reviderte fire-variabel Z-score-modellen. Her ville Altman fjerne eventuelle industrieffekter som negativt påvirket modellen. For å gjøre det tok han ut variabelen Omsetning/Totalkapital. For denne modellen ble også variablenes koeffisienter og avskjæringspunkt kalkulert på nytt, og modellen så nå slik ut:

$$Z^{II} = 6,56X_1 + 3,26X_2 + 6,72X_3 + 1,05X_4$$

Har den avhengige variabelen  $Z^{II}$  en verdi på under 1.1 indikerer det konkurs hos en bedrift, og en verdi over 2.6 viser til en bedrift i god økonomisk tilstand. Verdier mellom disse grensene viser til en gråsoner, hvor en bør vise forsiktighet med å klassifisere en bedrift som enten konkurs eller ikke konkurs.

#### 2.4.3 Ohlson: logistisk regresjonsmodell

James A. Ohlson var en av de som kritiserte den metodiske fremgangsmåten Altman brukte i sin multivariate diskriminantanalyse [Ohlson, 1980]. Han mente det var problematisk at

varians-kovarians-matrisen måtte være den samme for selskapene som ikke gikk konkurs og for de selskapene som gikk konkurs. [Ohlson, 1980] mente også at det at det var en normalfordeling av nøkkeltallene i modellen var et problem. Han mente dette ikke var sannsynlig og foreslo i sin studie å bruke en logistisk regresjonsmodell, O-score modellen, på et større utvalg bedrifter. Logistisk regresjon egner seg godt i tilfeller der den avhengige variabelen er dikotomisk, slik som konkurs/ikke-konkurs.

I virkeligheten vil andelen insolvente selskaper være en liten prosent av alle selskaper. For å representere virkeligheten på en mer presis måte ble det i Ohlsons studie analysert 105 konkursslåtte selskaper og 2 058 ikke-konkursslåtte selskaper for perioden 1970-1976. Modellen besto av 9 uavhengige variabler som ble valgt ut basert på tidligere forskning innenfor konkursprediksjon. Ohlsons O-score modell er som følger:

$$O = -1,32 - 0,407X^1 + 6,06X^2 - 1,43X^3 + 0,0757X^4 - 2,37X^5 - 1,83X^6 + 0,285X^7 - 1,72X^8 - 0,521X^9$$

$$x_1 = \text{Log}\left(\frac{\text{Totalkapital}}{\text{BNP prisindeks}}\right)$$

$$x_2 = \frac{\text{Total gjeld}}{\text{Totale eiendeler}}$$

$$x_3 = \frac{\text{Arbeidskapital}}{\text{Totalkapital}}$$

$$x_4 = \frac{\text{Kortsiktig gjeld}}{\text{Omløpsmidler}}$$

$x_5 = \text{Dummy}$ . Dersom samlet gjeld er større enn totalkapital: lik 1. Ellers lik 0

$$x_6 = \frac{\text{Netto resultat}}{\text{Totalkapital}}$$

$$x_7 = \frac{\text{Driftsresultat}}{\text{Totalkapital}}$$

$x_8 = \text{Dummy}$ . Negativt resultat de siste to år = 1, ellers 0

$$x_9 = \frac{\bar{\Delta} \text{ Resultat}}{|\text{Resultat}_t| + |\text{Resultat}_{(t-1)}|}$$

Formel for konkurssannsynlighet med bruk av logistisk regresjon er:

$$P(Y = 1) = \frac{e^{(b_0 + b_1 + x_1 + \dots + b_n x_n + e)}}{1 + e^{(b_0 + b_1 x_1 + \dots + b_n x_n + e)}}$$



#### 2.4.4 SEBRA-modellen

SEBRA-modellen ble utviklet i 2001 av Eivind Bernhardsen for å predikere konkurs for Norges Bank, og blir fortsatt brukt av sentralbanken for å vurdere kredittrisikoen til norske banker i foretakssonen. Den justerte sebramodellen hos Norges Bank tar for seg en rekke regnskapsmessige variabler funnet i bedriftenes årsregnskaper, og supplerer med informasjon om alder, størrelse og bedriftenes spesifikke bransje [Bernhardsen and Larsen, 2007].

I SEBRA-modellen brukes det generell additiv modell (GAM). GAM bygger på generell lineær modell, som blir beskrevet av [Berg, 2007] som en generalisering av multiplere regresjonsmodell. GAM er en utvidelse av generell lineær modell, og har evnen til å fange opp flere sammenhenger mellom den avhengige og de uavhengige variablene på grunn av den ikke-lineære formen som finnes i generell lineær modell [Hastie and Tibshirani, 1995]. Dette gir en fin balanse mellom en modell som fanger opp komplekse sammenhenger, samtidig som den er tolkbar nok til å kunne bruke den til konkursprediksjoner på en hensiktsmessig måte.

I 2007 ble SEBRA-modellen revidert etter det ble funnet en del svakheter med den opprinnelige modellen. Det ble opprettet to nye modeller, SEBRA-basis og SEBRA-utvidet som skal ta hensyn til eventuelle endringer i hvordan en måler de forskjellige forklaringsvariablene i årsregnskapene. Dette kan være endringer i regnskapsloven over hvordan regnskapet skal føres [Bernhardsen and Larsen, 2007]. I SEBRA-basis inngår de opprinnelige variablene, samtidig som det er blitt introdusert noen bransjevariabler.

Tabell 2 viser en oversikt over variabeldefinisjonene og hvilke typer variabler som inngår i variabelsettet, samt om hvorvidt de varierer basert på bransje eller foretak. Den viser også hvilke som inngår i henholdsvis SEBRA-basis og SEBRA-utvidet.

Variabeldefinisjon	Kategori	Variabeltype	Variierer over
Ordinært resultat før av- og nedskrivninger i prosent av total gjeld		Nøkkeltall Gjennomsnitt Standardavvik Korrelasjon med Norgesporteføljen	Foretak/år Bransje/år Bransje/år Bransje/år Bransje
Egenkapital i prosent av total kapital		Nøkkeltall Gjennomsnitt Indikator	Foretak/år Bransje/år Foretak/år
Likvider minus kortsiktig gjeld i prosent av omsetning		Nøkkeltall	Foretak/år
Alder (år) = 1, 2, 3, ..., 8		Indikatorer	Foretak/år
Sum eiendeler i faste kroner		Nøkkeltall	Foretak/år
Leverandørgjeld i prosent av total kapital		Nøkkeltall	Foretak/år
Skyldige offentlige avgifter i prosent av total kapital		Nøkkeltall	Foretak/år

Tabell 2: Variabler som inngår i SEBRA-basis (mørke felt) og SEBRA-utvidet (hele tabellen) [Bernhardsen and Larsen, 2007]

I likhet med basis-versjonen av SEBRA-modellen, har SEBRA-utvidet med variabler som størrelsen på leverandørgjeld, ubetalte offentlige avgifter og bedriftsstørrelse. De nye variablene har en direkte eller en indirekte relasjon til størrelsen på foretaket. Variabelen for utbytte er i de to modellene ekskludert [Bernhardsen and Larsen, 2007]. [Eklund et al., 2001] nevner i sin studie at noe av konjunkturvariasjonene blir fanget opp, men at dette ikke skjer på en god nok måte.

#### 2.4.5 Variabelsett valgt ut med LASSO

Studien til [Paraschiv et al., 2021] tester hvorvidt alternative feature selection metoder for konkursprediksjon er bedre enn tradisjonelle, populære modeller tidligere brukt innen forsknin-

gen. Datasettet som ble brukt i analysen til [Paraschiv et al., 2021] er det samme datasettet som brukes i denne oppgaven. Her er det brukt 155 regnskapsbaserte input-variabler som er hentet fra tidligere litteratur innenfor konkursprediksjon. De 10 variablene som gav best resultater i form av in-sample fit, out-of-sample performance og stabilitet ble valgt ut av maskinlæringsteknikken «least absolute shrinkage and selection operator» (LASSO).

Variablene som ble funnet med bruk av LASSO:

$$x_1 = \text{Log}\left(\frac{\text{Leverandørgjeld}}{\text{Sum eiendeler}}\right)$$

$$x_2 = \text{Dummy. Sum gjeld er større enn sum eiendeler} = 1, \text{ ellers } 0$$

$$x_3 = \frac{\text{Sumkortsiktig gjeld} - \text{sumbankinnskudd, kontanter og lignende}}{\text{sum eiendeler}}$$

$$x_4 = \frac{\text{Årsresultat}}{\text{Sum eiendeler}}$$

$$x_5 = \frac{\text{Skyldige offentlige avgifter}}{\text{Sum eiendeler}}$$

$$x_6 = \frac{\text{Annen rentekostnad}}{\text{Sum eiendeler}}$$

$$x_7 = \text{Dummy. Sum innskud egenkapital er mindre enn sum egenkapital} = 1, \text{ eller } 0$$

$$x_8 = \text{Log}(\text{Alder})$$

$$x_9 = \frac{\text{Sum varer}}{\text{Sum omløpsmidler}}$$

$$x_{10} = \frac{\text{Sum bankinnskudd, kontanter og lignende}}{\text{Sum omløpsmidler}}$$

De 10 variablene treffer innenfor fire av de fem ulike kategoriene som er foreslått av [Altman, 1968] og [Altman, 2007]. De fem kategoriene består av likviditet, profitt, gjeld, soliditet og aktivitet. Ingen av variablene treffer innenfor kategorien aktivitet, men dette har vist seg å være en kategori med liten signifikans.

Variabelsettet som ble funnet i artikkelen til [Paraschiv et al., 2021] viser seg å være det som gir høyest profitt, profittmargin, ROA og RORWA. Fire av variablene er variabler som også inngår i SEBRA-modellen. De resterende variablene som de to settene ikke har til felles, korrelerer med hverandre.

#### 2.4.6 Kim og Upneja: Konkursprediksjon under konjunktorendringer

[Kim and Upneja, 2021] utforsker i sin artikkel konkursprediksjon i restaurantbransjen i USA, og forsøker å forbedre prediksjonen ved å ta hensyn til konjunktursvingninger. De har i deres forskning valgt å se på børsnoterte selskaper i perioden 1980-2017. De endte opp med et datasett på 2 747 bedrifter der 1 432 av bedriftene var kategorisert som konkurs, og 1 315 var kategorisert som ikke-konkurs. I sine modeller bruker de en blanding av markedsvariabler, regnskapsvariabler og en makrovariabel. Tabell 3 viser en oversikt over disse.

Group	Variables
Profitability	OFCAID
	ROCE
	Accumulated RE
Solvency	D/E ratio
	CCC
Liquidity	Current ratio
	KZ index
	Market capitalization
Activity	Stock price
	P/E ratio
Growth	Tobin`s Q
Macro-economic	NBER Recession indicator

Tabell 3: Variabelsett brukt i modellen til [Kim and Upneja, 2021]

For prediksjonen brukte de maskinlæringsteknikken «majority voting ensemble with decision trees». Datasettet ble delt opp i tre deler for hele perioden, lavkonjunktur og høykonjunktur for å se hvilke variabler som er mest signifikante under de forskjellige konjunkturfasene. For å dele opp datasettet brukte de NBER sin lavkonjunkturindikator, som viste lavkonjunktur i årene 1981, 1981, 1992, 2002, 2003 og 2010. Lavkonjunkturårene hadde til sammen 297 observasjoner [Kim and Upneja, 2021].

Resultatene de fikk fra denne forskningen var at bedrifter i restaurantbransjen med lav OCFAID (kontantstrøm etter betalte renter og utbytte), høy KZ-indeks (avhengighet av ekstern finansiering) og lav aksjepris måtte være ekstra påpasselig når det kommer til lavkonjunkturer. [Kim and Upneja, 2021] fant at markedsverdi, et mål på likviditet, hadde størst forklaringskraft under høykonjunkturer. Modellen rangerte lønnsomhet og soliditet som henholdsvis nummer to og tre.

#### **2.4.7 Suzan Hol: Konkursprediksjon under konjunkturrendringer**

Studien til [Hol, 2006], gjør en konkursprediksjon på ikke-børsnoterte selskaper med data fra 90-tallet, for å se sammenheng mellom konjunkturer og konkurs i Norske selskaper. For å se på effektene av konjunktursvingningene er det her brukt makroøkonomiske tall inne i modellen. Om lag 19 000 observasjoner for selskaper som var konkurs eller ikke-konkurs ble studert for å se effekten av høy- og lavkonjunktur. I studien ble det også laget en modell der dummy-variabler er benyttet for årstall, men det konkluderes med at dette ikke er nyttig når det kommer til å predikere frem i tid.

I Hols modell er det inkludert en dummy for hoteller og restauranter, og en dummy for eiendom og tjenester for å få med spesielle effekter som opptrer innenfor disse bransjene. Makrovariablene benyttet i studien er vekst i BNP, BNP-gapet, en produksjonsindeks og pengemengde M1. De finansielle variablene er tre måneders rentesats, kontanter/gjeldforholdet, finansiell dekning, likviditet, soliditet og størrelse.

Studien konkluderer med at makrovariablene er signifikante når det kommer til sannsynligheten for å predikere konkurs. En bedrift har større sannsynlighet for å gå konkurs når BNP ligger under trenden, enn når BNP ligger over trenden. I motsetning er vekst i økonomisk aktivitet ikke signifikant i konkursprediksjonen. Svakheter med studien er at det ikke er nok data til å dekke en hel konjunktursyklus, og Hol foreslår at videre forskning ser på flere økonomiske sykluser [Hol, 2006].

## 2.5 Maskinlæringsteknikker

Ettersom teknologien har utviklet seg, har forskningen på konkursprediksjon fulgt etter. Selv om de klassiske, statistiske modellene stadig benyttes, viser nyere forskning til at maskinlæringsteknikker benyttes med fordel når det kommer til store datasett innen konkursprediksjon. Maskinlæringsteknikker er metoder som har muligheten til å lære uten at de er nødt til å være presist programmert til jobben de skal utføre [Samuel, 2000].

### 2.5.1 Statistiske metoder og maskinlæring

Det finnes i tidligere litteratur en rekke eksempler på bruk av forskjellige metoder for konkursprediksjon. Disse kan deles inn i to grupper: statistiske metoder og maskinlæringsmetoder. Statistikk er den grenen av matematikk som omhandler innsamling, analyse, tolkning, presentasjon og organisering av numerisk data. Den kan videre deles inn i deskriptiv og inferensiell statistikk. Førstnevnte brukes til å oppsummere data ved bruk av for eksempel gjennomsnitt, standardavvik og frekvens, mens inferensiell statistikk gjør beregninger for et utdrag, for så å trekke konklusjoner for hele datasettet basert på disse beregningene. Statistiske modeller bruker statistiske metoder på data for å finne underliggende sammenhenger ved å analysere variablenes signifikans [Dangeti, 2017]. Lineær regresjon og diskriminantanalyse, som ble beskrevet tidligere i dette kapittelet, er eksempler på statistiske læremetoder [James et al., 2013].

Maskinlæring er en gren av datavitenskap som lærer fra tidligere observasjoner, og bruker denne kunnskapen til å ta fremtidige beslutninger. Målet ved maskinlæring er å generalisere et mønster basert på tidligere data, for så å påføre dette på nye data [Dangeti, 2017]. Maskinlæring kan deles inn i tre kategorier:

1. *Overvåket læring*: Opplæring av maskiner til å oppdage sammenhenger mellom gitte uavhengige variabler og en responsvariabel. Dette inkluderer både klassifikasjons- og regresjonsproblemer.
2. *Uovervåket læring*: Ingen spesifisering av responsvariabelen. Målet er å finne skjulte

mønster og sammenhenger i dataene. Clustering er et eksempel på uovervåket læring [James et al., 2013].

3. *Forsterkende læring*: Lærer opp maskinen ved å gi tilbakemeldinger. Den tar først en rekke beslutninger uten overvåking, og gir deretter en vurdering. Basert på denne vurderingen, revurderer maskinen sine beslutninger [Dangeti, 2017].

Selv om det er forskjeller på de tre formene for maskinlæring, er det fullt mulig å kombinere disse for å oppnå best mulige resultater for et gitt problem. Dersom det finnes mange variabler, og det ikke finnes noe forhåndskunnskap om sammenhengen mellom dem, kan det for eksempel være nyttig å starte med uovervåket læring for å redusere dimensjonene i datasettet. Videre kan overvåket læring gjøres for å finne sammenhengen mellom de gjenstående variablene og en responsvariabel [Dangeti, 2017]. Beslutningstrær, støttevektormaskiner og nevralt nettverk er eksempler på maskinlæringsteknikker [James et al., 2013]. Videre i kapitlet skal det gjennomgås maskinlæringsteknikken beslutningstrær, og bagging og boosting.

### 2.5.2 Beslutningstrær

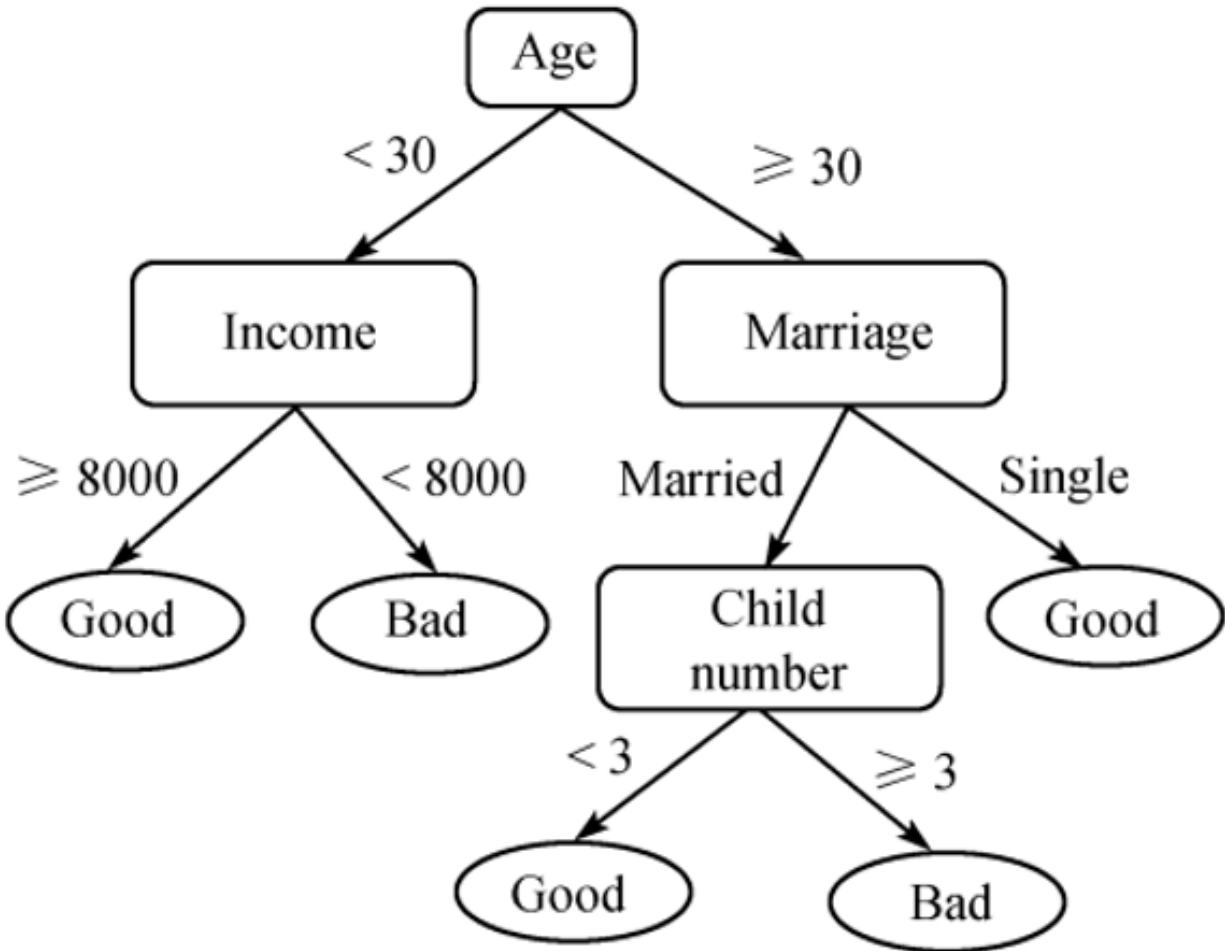
Beslutningstrær er en maskinlæringsmetode som deler området for mulige verdier av de uavhengige variablene  $(X_1, X_2, \dots, X_P)$  inn i distinkte og ikke-overlappende områder  $(R_1, R_2, \dots, R_J)$ . Metoden danner tre-strukturer bestående av noder og løv. Noden er beslutningen som gjøres angående hvilket område  $R_J$  en gitt observasjon tilhører, mens løv er det endelige resultatet av beslutningene i hver node. Et beslutningstre består gjerne av en rekke beslutninger (noder) som tas sekvensielt, helt til en kommer fram til et løv som avgjør prediksjonen for den nye observasjonen. Figur 3 viser et eksempel på et beslutningstre, hvor nodene representeres av firkanter og løvene av sirkler.

Det finnes to hovedformer for beslutningstrær: regresjonstrær og klassifiseringstrær. Førstnevnte benyttes for å predikere en kvantitativ respons i form av en tallverdi, mens sistnevnte gir kvalitativ respons (f.eks. ”konkurs” / ”ikke konkurs”). For regresjonstrær er prediksjonen av en ny observasjon gitt ved gjennomsnittsverdien for treningsobservasjonene som tilhører det området  $R_J$  som den nye observasjonen plasseres i [James et al., 2013]. En

kan for eksempel tenke seg at en i første node av en modell får opprettet to områder: R1 og R2. I treningssettet var gjennomsnittsverdien for responsvariabelen lik 10 i R1 og 20 i R2. Dersom en ny observasjon plasseres i R1, vil beslutningstreet predikere at  $x$  er lik 10.

Ved bruk av klassifiseringstrær brukes ikke gjennomsnittsverdier fra testsettet til å predikere, men heller den mest hyppige responsen i den gitte regionen  $R_J$  [James et al., 2013]. Dersom ”konkurs” i treningsdataene var den mest hyppige responsen i region  $R_J$ , og den nye observasjonen plasseres i denne regionen av beslutningstreet, predikeres responsen ”konkurs” for denne observasjonen. Figur 3 viser en grafisk framstilling av et beslutningstrær som predikerer enten ‘god’ eller ‘dårlig’ kredittscore basert på alder, inntekt, sivilstatus og antall barn som uavhengige variabler.





Figur 3: Eksempel på klassifiseringstre for kredittvurdering [Ligang and Lai, 2009]

Det finnes en rekke fordeler ved å benytte beslutningstrær for både regresjon og klassifisering, sammenlignet med andre metoder. For det første har resultatene av beslutningstrær god tolkbarhet: De kan fremstilles grafisk, og forstås intuitivt uten behov for inngående forståelse av hvordan modellen fungerer. Dette gjør modellen enkel å presentere for andre [James et al., 2013]. Videre har beslutningstrær den fordelen at de kan håndtere datasett som har mange manglende verdier eller feilverdier, i tillegg til at metoden kan benytte både numeriske og nominelle verdier [Maimon and Rokash, 2010]. Likevel finnes det også ulemper ved bruk av beslutningstrær. For det første, har beslutningstrær generelt sett ikke like god prediksjonsnøyaktighet som mange andre modeller. For det andre, har trær en tendens til å være lite robuste. Dette innebærer at en relativt liten endring i data kan forårsake en stor endring i det endelige estimerte beslutningstreet [James et al., 2013].

### 2.5.3 Bagging og boosting

Bagging og boosting er metoder som kan benyttes for å forbedre prediksjonsnøyaktigheten til blant annet beslutningstre-modeller. Selv om denne oppgaven benytter boosting, er det også nyttig å kjenne til bagging, ettersom disse metodene er nokså like. Bagging er en teknikk foreslått av [Breiman, 1996] som kan brukes med mange klassifiserings- og regresjonsmetoder for å redusere variansen i prediksjonen, og dermed forbedre prediksjonsprosessen. Bagging fungerer på den måten at den tar mange prøver fra datasettet og bruker den samme prediksjonsmåten på hver prøve. Dette kalles for bootstrapping. Ved bagging genereres et beslutningstre for hver enkelt prøve som tas fra datasettet, uavhengige av hverandre. Gjennomsnittet av prediksjonene til alle beslutningstrærne utgjør det endelige resultatet av baggingen. For bagging av klassifikasjonstrær brukes ofte ‘simple voting’, hvilket betyr at den mest hyppige prediksjonen blir stående som den endelige etter at bagging er fullført [Sutton, 2005].

Boosting skiller seg fra bagging ved at bootstrapping og generering av beslutningstrær ikke skjer parallelt, men sekvensielt. Dette innebærer at hvert tre lages ved å bruke informasjon fra de tidligere trærne. Boosting bruker ikke bootstrapping for å hente ut prøver fra datasettet, men tilpasses heller en modifisert versjon av det opprinnelige datasettet [James et al., 2013]. Mens bagging bruker et enkelt gjennomsnitt av alle prediksjonene for å komme frem til et endelig resultat, bruker boosting et vektet gjennomsnitt av resultatene fra de ulike prøvene. Videre er ikke metoden for utvalg av prøve fra datasettet den samme for hver gang. Ved boosting blir det også lagt mer vekt på de observasjonene som ble feilaktig predikert i det forrige treet når en ny prøve fra datasettet skal velges ut. På denne måten er boosting en iterativ prosess som bruker ulik vektning, i motsetning til et enkelt gjennomsnitt av prediksjoner som brukes ved bagging [Sutton, 2005].

## 2.6 Oppsummering av litteraturkapittel

I dette kapitlet ble det introdusert definisjoner og teori innenfor konjunktursykluser og konkurs. Det ble så gitt en forklaring på kapitalstruktur innenfor serveringsbransjen. Videre ble det gitt en oversikt over tidligere arbeid innenfor konkursprediksjon der det først ble introdusert statistiske metoder, med Beaver sin univariate modell, så Atlman sine multivariate modeller. Deretter ble Ohlsons logistiske regresjonsmodell forklart, og videre Berhardsens SEBRA-modell for Norges Bank. Etter dette ble det introdusert nyere forskning fra Paraschiv et al. der de presenterer et variabelsett som gav best resultat for konkursprediksjon. Videre ble tidligere forskning med søkelys på konkursprediksjon under konjunkturedringer beskrevet. Den tidligere forskningen ble eksemplifisert ved rapportene til Kim og Upneja fra 2020, og Hol fra 2006. Til slutt ble maskinlæringsteknikker forklart, med fokus på maskinlæringsteknikken beslutningstrær og videre en innføring i bagging og boosting. Konkursprediksjon er et felt det har blitt forsket mye på, men det er lite litteratur som kobler det til konjunktursvningninger. Denne oppgaven skal forsøke å analysere temaet nærmere med hjelp av både maskinlæring og en statistisk metode . I det påfølgende kapitlet vil vi gå inn på den metodiske tilnærmingen for å gjennomføre denne analysen.

## 3 Forskningsmetode

Det finnes en rekke ulike metoder for å predikere konkurs. [Bellovary et al., 2007] gir en omfattende oversikt over ulike metoder brukt for konkursprediksjon fra 1930-tallet til 2007. Artikkelen trekker fram diskriminantanalyse som en svært populær metode for konkursprediksjon i begynnelsen, mens andre metoder som logistisk regresjon og nevralt nettverk ble introdusert ettersom teknologien tillatte det. Med andre ord er det et betydelig antall avgjørelser som må tas med hensyn til metode ved gjennomføring av konkursprediksjon. I dette kapitlet gjøres det rede for de metodiske valgene i denne oppgaven for å best besvare problemstillingen. Det er blant annet gjort beslutninger med hensyn til bruk av variabler, estimeringsmetode og modellevaluering. Dette kapitlet har som mål å forklare og rettferdiggjøre disse beslutningene. I slutten av kapitlet vil oppgavens reliabilitet og validitet diskuteres.

### 3.1 Datagrunnlag og preprosessering

Her følger en beskrivelse av datagrunnlaget for oppgaven. I sin opprinnelige form inneholdt datasettet store mengder informasjon som var irrelevant for oppgavens problemstilling. Dette nødvendiggjorde preprosessering av datagrunnlaget, noe som også beskrives i dette delkapitlet.

#### 3.1.1 Datagrunnlag

Datasettet som danner grunnlaget for denne oppgaven, inneholder alle ukonsoliderte årsregnskaper for norske aksje- og allmennaksjeselskaper i regnskapsårene mellom 2006 og 2019 [Wahlstrøm, 2022]. I tillegg inneholder datasettet alle årsregnskap rapportert til norske myndigheter av selskap av andre organisasjonsformer enn aksjeselskap. Datasettet inneholder totalt 3 876 923 årsregnskap.

I tillegg til informasjon som tradisjonelt inkluderes i årsregnskap, inneholder datasettet også annen informasjon om årsregnskap og selskapene de representerer. Dette inkluderer for

eksempel summen av selskapets eiendeler, samt sum inntekter. Datasettet inneholder ikke konsernregnskap. For årsregnskapene til morselskap som eksisterer i datasettet, tas det kun hensyn til selve morselskapet og ikke konsernet. På denne måten unngås det dobbel telling av datterselskap.

### 3.1.2 Preprossesering av data

Kun selskaper som tilhører restaurantbransjen har blitt analysert i denne oppgaven. Hensikten med å begrense omfanget til én bransje var hovedsakelig å gjøre det enklere å analysere resultatene ut fra et bedriftsøkonomisk perspektiv. Det faktum at alle observasjoner i datasettet tilhørte serveringsbransjen gjorde det noe enklere å gjøre generaliseringer angående underliggende økonomiske faktorer, og dermed foreslå tydeligere forklaringer på resultatene. Alle selskaper med næringskoder (NACE) ulik 56 ble derfor fjernet fra datasettet. Videre inkluderes kun norske aksjeselskaper i oppgaven, og derfor ble selskaper som hadde landskode ulik 'NO' fjernet. I tillegg ble selskaper av andre organisasjonsformer enn 'AS' filtrert ut. Basert på anbefalinger fra tidligere litteratur, inkludert [Bernhardsen and Larsen, 2007], er også selskaper med sum eiendeler under 500 000 kr ekskludert fra oppgavens datagrunnlag.

Videre ble det bestemt å se bort fra regnskapsårene 2018 og 2019. Årsaken til dette er knyttet til melding av konkurs for selskapene i datasettet. Konkursvariabelen i datasettet er en binær variabel som viser 'True' eller 'False'. Dersom 'True' vises, betyr dette at selskapet har meldt seg konkurs og at det har gått minst tre år siden sist leverte årsregnskap. Dette betyr at det for årene 2018 og 2019 er en risiko for at det finnes selskaper som i praksis er konkurs, men som ikke er merket konkurs i datasettet. Betingelsen om tre passerte år etter siste avlagte årsregnskap understøttes av [Bernhardsen, 2001], hvor det ble funnet at alle selskaper var erklært konkurs innen det tredje året etter siste årsregnskap. Som følge av filtreringen av datasettet beskrevet ovenfor, ble størrelsen på datagrunnlaget redusert fra 3 876 923 til 49 529 observasjoner. Det siste steget i preprosseseringen var å, basert på en konjunkturindikator, dele datasettet inn etter år med økonomisk oppgangstid og økonomisk nedgangstid. Dette beskrives i delkapittel 3.3.

## **3.2 Valg av variabelsett**

Oppgaven tar for seg to forskjellige sett med variabler som testes på alle konjunkturperiodene. Det første variabelsettet er basert på den utvidede SEBRA-modellen utviklet for Norges Bank, og det andre variabelsettet er basert på studien til [Paraschiv et al., 2021]. Den avhengige variabelen er ‘konkurs’/‘ikke konkurs’, og beholdes lik for alle modeller i oppgaven. Videre følger en kort beskrivelse av den avhengige og de uavhengige variablene som brukes til modellering i denne oppgaven.

### **3.2.1 Avhengig variabel**

Den eneste avhengige variabelen som omfattes av denne oppgaven indikerer hvorvidt et gitt selskap er konkurs eller ikke. Denne variabelen benyttes i samtlige modeller som presenteres. Dette er en dummy-variabel, som innebærer at den kun har to mulige utfall: 1 for “konkurs” og 0 for “ikke konkurs”.

### **3.2.2 Uavhengige variabler - Variabelsett 1**

De uavhengige variablene i variabelsett 1 hentes fra den utvidede SEBRA-modellen utviklet av [Bernhardsen and Larsen, 2007]. Tabell 4 viser en oversikt over variabeldefinisjoner og hvilke typer variabler som inngår i variabelsettet, samt om hvorvidt de varierer basert på bransje eller foretak. Den viser også hvilke som inngår i henholdsvis SEBRA-basis og SEBRA-utvidet. I denne oppgaven benyttes variablene fra SEBRA-utvidet, altså alle variablene i tabell 4. En mer detaljert forklaring på variabelsettene finnes i Appendix 5

Tag	Navn	Type	Formel
V1	Resultat	Kontinuerlig	$\frac{\text{Ordinært resultat for av – og nedskrivninger}}{\text{Total gjeld}}$
V2	Egenkapitalprosent	Kontinuerlig	$\frac{\text{Egenkapital}}{\text{Totalkapital}}$
V3	Innskutt egenkapital	Dummy	Sum innskutt egenkapital er mindre enn sum egenkapital = 1 Sum innskutt egenkapital er større enn sum egenkapital = 0
V4	Likviditetsprosent	Kontinuerlig	Sum eiendeler i faste kroner
V5	Leverandørgjeldsprosent	Kontinuerlig	$\frac{\text{Leverandørgjeld}}{\text{Totalkapital}}$
V6	Avgiftsprosent	Kontinuerlig	$\frac{\text{Skyldige offentlige avgifter}}{\text{Totalkapital}}$
V7	Logaritme av alder	Kontinuerlig	Log(alder)

Tabell 4: Variabelsett 1, basert på SEBRA-modellen [Bernhardsen and Larsen, 2007]

Tabell 4 viser tag, navn, variabeltype og formel for utregning av variablene fra variabelsett 1. I denne oppgaven gjøres en justering av aldersvariabelen V7. I SEBRA-modellene benyttes 8 ulike dummyvariabler  $a_1$ – $a_8$  for å indikere selskapets alder. Dersom et gitt selskap for eksempel er 5,5 år gammelt, vil variabel  $a_1$  til  $a_5$  være lik 1, mens variabel  $a_6$  til  $a_8$  vil vise 0. I stedet for å bruke dummyvariabler, ble det i denne oppgaven besluttet å heller definere aldersvariabelen som logaritmen av selskapets alder. På denne måten slås variablene  $a_1$ – $a_8$  sammen til én: V7. Hovedårsaken til denne endringen er tolkbarhet og oversiktighet. Dersom selskapets alder er knyttet til én enkelt verdi, blir det enklere å inkludere denne variabelen i en diskusjon angående forklaringskraft, og sammenligningen med andre variabler blir mer oversiktlig.

### 3.2.3 Uavhengige variabler - Variabelsett 2

Tag	Navn	Type	Formel
Z1	Likviditet	Kontinuerlig	$\frac{\text{Leverandørgjeld}}{\text{Sum eiendeler}}$
Z2	Gjeld	Dummy	Sum gjeld er større enn sum eiendeler = 1 Sum gjeld er ikke større en sum eiendeler = 0
Z3	Gjeld	Kontinuerlig	$\frac{\text{Sum kortsiktig gjeld} - \text{sum bankinnskudd kontanter og lignende}}{\text{sum eiendeler}}$
Z4	Lønnsomhet	Kontinuerlig	$\frac{\text{Årsresultat}}{\text{Sum eiendeler}}$
Z5	Likviditet	Kontinuerlig	$\frac{\text{Skyldige offentlige avgifter}}{\text{Sum eiendeler}}$
Z6	Soliditet	Kontinuerlig	$\frac{\text{Annen rentekostnad}}{\text{Sum eiendeler}}$
Z7	Soliditet	Dummy	Sum innskutt egenkapital er mindre enn sum egenkapital = 1 Sum innskutt egenkapital er ikke mindre enn sum egenkapital = 0
Z8	Alder	Kontinuerlig	Logaritmen av alder
Z9	Likviditet	Kontinuerlig	$\frac{\text{Sum varer}}{\text{Sum omløpsmidler}}$
Z10	Likviditet	Kontinuerlig	$\frac{\text{Sum bankinnskudd kontanter og lignende}}{\text{Sum omløpsmidler}}$

Tabell 5: Oversikt over variabelsett 2

Variabelsett 2 består av 10 variabler som ble funnet til å være de viktigste variablene i konkursprediksjonen gjort av [Paraschiv et al., 2021]. Fire av variablene i variabelsett 2 er variabler som også inngår i variabelsett 1 fra SEBRA-modellen. De resterende variablene som de to settene ikke har til felles, korrelerer med hverandre. En oversikt over variablene i sett to kan ses i tabell 5, og en mer utdypende forklaring finnes i Appendix 6.

Variabelsett 2 er brukt i denne oppgaven for å inkludere funn fra nyere forskning innenfor konkursprediksjon. Dette gir resultater å sammenligne modellene basert på variabelsett 1 opp mot.




### 3.3 Konjunkturindikator

Konjunkturindikatoren er en variabel som anvendes for å dele variabelsettene inn i høykonjunktur (HK) og lavkonjunktur (LK). Det opprinnelige datasettet, som inneholder alle årstall, vil heretter refereres til som hele perioden (HP). Konjunkturindikatoren er utviklet av OECD, og er kjent som ‘composite leading indicators’ (CLI). Denne består av seks makroøkonomiske variabler som blant annet eksporttall til Storbritannia, konsumprisindeks og børsindeks på Oslo Børs. Tabell 6 viser en oversikt over konjunkturindikatorens komponenter.

<b>Komponenter</b>	<b>Kilde</b>
Eksport til Storbritannia (i USD)	<u>Statistisk Sentralbyrå</u>
Produksjon, gruvedrift og steinbrudd – Beholdning av ordrer for eksport sa (% balanse)	Statistisk Sentralbyrå
<u>Produksjon: tendens sa (% balanse)</u>	Statistisk Sentralbyrå
Produksjon, gruvedrift og steinbrudd – <u>Generell vurdreing</u> av utsiktene for foretaket i neste kvartal sa (% balanse)	Statistisk Sentralbyrå
KPI (2015=100)	Statistisk Sentralbyrå
Aksjepriser: OSE20GI indeks (2015=100)	Oslo Børs

Tabell 6: Komponenter i CLI [Bernhardsen and Larsen, 2007]

En lavkonjunktur er i denne oppgaven definert som perioder hvor CLI ligger under verdien 100, som er et langtidsgjennomsnitt. Tilsvarende, defineres høykonjunkturer som perioder hvor CLI-verdien er over 100. Figur 4 viser utviklingen i CLI i Norge mellom 2006 og 2017.



Figur 4: Variasjoner i CLI i Norge mellom 2006 og 2017

CLI, eller tilsvarende konjunkturindikatorer, har blitt brukt i tidligere studier av konkursprediksjon blant serveringsbedrifter. [Kim and Upneja, 2021] delte data inn i høy- og lavkonjunktur basert på konjunkturindikatoren til National Bureau of Economic Research (NBER). Deres studie definerte konjunktorene slik at perioder fra kurvens toppunkt til bunnpunkt ble regnet som lavkonjunktur, mens perioder fra bunnpunkt til toppunkt ble regnet som høykonjunktur. I denne oppgaven er det derimot besluttet å ta utgangspunkt i langtidsgjennomsnittet. Årsaken til dette kan illustreres av grafens posisjon og utvikling i året 2009: selv om CLI (og dermed tilstanden i økonomien), er økende, viser den fortsatt lave verdier sammenlignet med det som er gjennomsnittet. Selv om økonomiens tilstand var i oppgang dette året, var det altså likevel et år hvor økonomien gikk relativt tregt.

CLI oppdateres månedlig. Dette gjør at noen av årene som er inkludert i datasettet har perioder med både høy- og lavkonjunktur. I slike tilfeller blir året definert som et lavkonjunktursår dersom et flertall av årets måneder viste CLI-verdi på mindre enn 100. En oversikt over hvordan årene 2006 til 2017 defineres med hensyn til konjunktur i denne oppgaven kan ses i tabell 7. CLI-verdiene danner grunnlaget for en dummy-variabel, som er lik 1 i tilfelle høykonjunktur, og 0 for lavkonjunktur.

	Type	Formel	Konjunktur
2006	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2007	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2008	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2009	Dummy	Oppgang = 1, Nedgang = 0	Nedgang
2010	Dummy	Oppgang = 1, Nedgang = 0	Nedgang
2011	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2012	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2013	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2014	Dummy	Oppgang = 1, Nedgang = 0	Oppgang
2015	Dummy	Oppgang = 1, Nedgang = 0	Nedgang
2016	Dummy	Oppgang = 1, Nedgang = 0	Nedgang
2017	Dummy	Oppgang = 1, Nedgang = 0	Oppgang

Tabell 7: Definisjon av høy-/lavkonjunkturer i Norge mellom 2006 og 2017

### 3.4 Valg av metode

I denne oppgaven er det benyttet analytisk kvantitativ forskningsmetode. Denne type forskning går hovedsakelig ut på å teste hypoteser, spesifisere og tolke forhold ved å analysere tilgjengelig informasjon. Både statistiske og maskinlæringsbaserte estimeringsteknikker har historisk blitt bruk for å gjøre konkursprediksjon. [Alaka et al., 2018] trekker fram lineær regresjon, diskriminantanalyse, beslutningstrær, nevrale nettverk og støttevektormaskiner som de vanligste metodene å bruke. I denne oppgaven er det besluttet å bruke beslutningstrær og lineær regresjon. Videre følger en kort begrunnelse av disse valgene.


Beslutningstrær har en rekke positive sider. Modellen er ikke en såkalt ‘black box’-modell, som er et begrep for modeller som kun viser input og resultater, men ikke hvordan modellens interne beregninger foregår. Dette gjør beslutningstrær relativt enkle å tolke med hensyn til resultater og beregninger som gjøres, som videre forbedrer modellens generelle tolkbarhet. Denne typen modell kan også fremstilles grafisk, noe som gjør dem enkle å tyde på tross av manglende forkunnskap [James et al., 2013]. Dessuten er beslutningstrær er også gode til å tilpasse seg uferdige og kvalitative datasett. Dette er en nyttig egenskap, da virkeligheten ofte vil være at datasett er mangelfulle. I tillegg er estimering av beslutningstrær relativt lite tidkrevende sammenlignet med andre metoder [Kim and Upneja, 2014]. Mulighet til å enkelt kunne tolke variablene og deres betydning for prediksjonene var spesielt viktig for denne oppgavens problemstilling, og en avgjørende årsak til at beslutningstrær ble valgt. I tillegg var det et ønske om å bruke en tilsvarende metode som Kim og Upneja (2020). Dette for å sikre en viss sammenlignbarhet.

Det er også hensiktsmessig å trekke fram noen kjente svakheter ved denne typen modeller. [James et al., 2013] trekker fram to ulemper ved bruk av beslutningstrær. Den første er at beslutningstrær generelt sett ikke har den samme prediksjonsnøyaktigheten som andre modeller for regresjon og klassifisering. Videre har beslutningstrær en tendens til å være lite robuste. Dette medfører at en liten endring i datagrunnlaget kan forårsake en stor forandring i det endelige estimerte treet. Denne ulempen kan likevel dempes betydelig ved hjelp

av metoder som bagging, random forests eller boosting. Denne oppgaven bruker sistnevnte metode for å sørge for at modellen er robust.

Denne oppgaven benytter extreme gradient boosting (XGBoosting), som foreslått av [Chen and Guestrin, 2016]. En av de største fordelene ved å bruke denne metoden for boosting av beslutningstrær er dens skalerbarhet. Dette systemet er langt raskere enn de fleste andre metoder for boosting på én enkelt maskin, og kan skaleres opp til et stort antall eksempler i distribuerte eller minne-begrensede tilfeller. Den økte hastigheten oppnås ved at beregningen av boostede trær skjer parallelt. Denne metoden er i tillegg designet for å kunne håndtere manglende data, noe som var en nyttig i dette arbeidet.

XGBoost har også en innebygd funksjon som rangerer de uavhengige variablene etter forklaringskraft. For hver XGBoost-modell som bygges skrives et plot ut, og disse plottene gir grunnlag for forklaringskraft-resultatene som presenteres i kapittel 5. Eksempel på et slikt plot, slik de skrives ut av XGBoost-funksjonen, kan ses i figur 5.



Figur 5: Eksempel på forklaringskraft-plot skrevet ut av XGBoost

Den horisontale aksene i figuren ovenfor viser *gain*, som i XGBoost fungerer som et mål på variabelens forklaringskraft. Konkret viser denne verdien hvor mye en gitt variabel bidrar til en økning i modellens nøyaktighet. Variabler med høy *gain*-verdi er viktigere for å generere en prediksjon enn variabler med lav *gain*. I denne oppgaven tas det derfor utgangspunkt i *gain*-verdien for å si noe om variablenes forklaringskraft, og det er disse verdiene som presenteres i kapittel 5. En ulempe ved bruk av XGBoost til å tolke variabelers forklaringskraft er at modellen ikke produserer resultater med fortegn på samme måte som regresjonsmodeller gjør. Dette gjør det ikke mulig å direkte se om hvorvidt en gitt variabel har positiv eller negativ påvirkning på responsvariabelen. Med bakgrunn i teoretiske perspektiver på bedriftsøkonomi, er det for mange variabler derimot mulig å tolke om hvorvidt den uavhengige variabelen i realiteten har et positivt eller negativt fortegn. Ved presentasjon av og diskusjon om XGBoost-modellene i kapittel 5 og 6 vil slike tolkninger gjøres hvor det ses på som mulig

og hensiktsmessig.

I tillegg til beslutningstrær var det et ønske om å i tillegg benytte en statistisk læringsmodell. Dette for å ha en alternativ modell som eventuelt kunne bekrefte funnene til beslutningstre-modellen, særlig med hensyn til de ulike variabelenes forklaringskraft. Dette ville også gi en modell å sammenligne med når det gjelder prediksjonsnøyaktighet. Slik ville en alternativ modell hjelpe med å si noe om hvor god den opprinnelige, beslutningstre-baserte modellen var. Ifølge [Alaka et al., 2018], er logistisk regresjon en av de mest brukte statistiske modellen innen konkursprediksjon. Av den grunn virket det derfor mest hensiktsmessig å bruke en logistisk regresjons-modell som en statistisk læringsmodell å sammenligne med.

Denne oppgaven bruker en logit-modell. Denne typen modellering skiller seg fra ordinære regresjonsmodeller på hovedsakelig to måter. For det første, er responsen eksponentielt fordelt. Dette betyr at distribusjonen av responsvariabelen ikke trenger å være normalfordelt, slik som ved for eksempel lineær regresjon. Videre er gjennomsnittet av responsvariabelen lineært sammenhengende med forklaringsvariablene [de Jong and Heller, 2008]. Logit-modeller har også fordelene av å gi sannsynlighetsutfall, og derfor ikke kreve å konvertere resultatet til en sannsynlighetsprosent, noe som kan være en feilkilde [Ohlson, 1980]. Forklaringskraften til de uavhengige variablene er av interesse i denne oppgaven, og modellenes regresjonskoeffisienter brukes til å tolke disse. Av denne grunn er regresjonsmodellene standardisert slik at de har et gjennomsnitt på null og standardavvik på 1. Dette sikrer at regresjonskoeffisientene sammenlignes på samme skala.

Det er i tillegg til XGBoost og logistisk regresjon brukt discrete hazard-modell. Dette er en metode for å se på risikoen for at konkurs vil inntreffe over flere år, der det justeres for risikoperider, tar hensyn til tidsvarierende prediktorer. Samtidig bruker metoden mer data for å gi bedre resultater på prediksjonen. Ved å bruke denne metoden unngår en å eventuelt få feilaktige svar da metoden tar hensyn til en bedrifts endringer over tid, i motsetning til statiske modeller fra tidligere forskning innenfor konkursprediksjon [Shumway, 2001].



## 3.5 Modellevaluering

For å vurdere modellenes evne til å svare på oppgavens forskningsspørsmål, brukes det i denne oppgaven receiver operating characteristics (ROC). Videre følger en kort beskrivelse av denne evalueringsmetoden og hvorfor den benyttes her.

### 3.5.1 Receiver Operating Characteristics (ROC)

Ulempene ved bruk av klassifikasjonsnøyaktighet har ført til at receiver operating characteristics (ROC) har blitt mer populært innen maskinlæring [Fawcett, 2006]. Likevel er dette evalueringskriteriet fortsatt ganske sjeldent innenfor konkursprediksjon. Kun 2,4 % av alle artiklene om konkursprediksjon som omtales i oversiktsartikkelen til [Kirkos, 2012] benytter ROC-verdi til evaluering. På tross av ROC sin sjeldenhet innenfor dette forskningsfeltet, er det likevel bestemt å benytte det her. Denne oppgavens modeller plasserer observasjonene i én av to klasser; ”konkurs” eller ”ikke konkurs”. Svarene som gis av modellene kan generelt sett oppsummeres av tabell:

	p	n
Y	Ekte positiv	Falsk positiv
N	Falsk negativ	Ekte negativ

Figur 6: Mulige klassifiseringsutfall [Fawcett, 2006]


Vi regner her responsen ”konkurs” som positiv og ”ikke konkurs” som negativ. Når modellene predikerer at en observasjon (et selskap) er enten konkurs eller ikke, kan fire utfall oppstå:

1. Ekte positiv: Modellen predikerer konkurs, og selskapet gikk faktisk konkurs.
2. Falsk positiv: Modellen predikerer konkurs, men selskapet gikk ikke faktisk konkurs.
3. Ekte negativ: Modellen predikerer ikke konkurs, og selskapet gikk ikke faktisk konkurs.
4. Falsk negativ: Modellen predikerer ikke konkurs, men selskapet gikk faktisk konkurs.

I tilfelle falskt positivt resultat sies det å ha skjedd en type-1-feil, mens feil av type 2 skjer dersom prediksjonen er falsk negativ. Informasjonen i tabellen gjør det mulig å regne ut to nøkkeltall som gjør det mulig å tegne et ROC-plot: ekte positivrate (1) og falsk positivrate (2).

1.  $\frac{\text{Antall ekte positive resultat}}{\text{Antall positive resultat}}$
2.  $\frac{\text{Antall falske positive resultat}}{\text{Antall positive resultat}}$

Et ROC-plot er todimensjonalt, med ekte positivrate langs vertikal akse og falsk positivrate langs horisontal akse. Plottet gir grunnlag for utregning av AUC-verdien, som er arealet begrenset av ROC-kurven og X-aksen. Videre i oppgaven omtales dette evalueringskriteriet kun som AUC. Et eksempel på et slikt plot kan ses i figur 7.



Figur 7: ROC-plot med AUC-verdi 0,5

AUC-verdien gir uttrykk for sannsynligheten for at en tilfeldig utvalgt positiv prediksjon faktisk er høyere enn en tilfeldig utvalgt negativ prediksjon [Fawcett, 2006]. Figur 7 viser et tilfelle hvor denne verdien er lik 0,5. Dette vil si at klassifiseringen i praksis ikke er bedre enn å tilfeldig gjette svaret, ettersom sannsynligheten for å få riktig svar er 50 %. Dersom AUC-verdien derimot hadde vært 1, ville dette indikert at modellen klassifiserer riktig i alle tilfeller. Ved bruk av klassifiseringsmodeller er det altså et mål å oppnå en AUC-verdi som er så nærme 1 som mulig.

Et alternativt evalueringsmål for modeller som predikerer konkurssannsynlighet, som er mye brukt i litteraturen [Kirkos, 2012], er klassifikasjonsnøyaktighet.

Klassifikasjonsnøyaktighet, eller treffprosent, er et mål på hvor mange tilfeller som klassifiseres korrekt av modellen som en andel av det totale antallet tilfeller modellen prøvde å predikere. Fordelen med denne måten å evaluere modeller på er at den er enkel å gjennomføre, samt svært enkel å tolke.

Samtidig finnes det også ulemper ved å bruke klassifikasjonsnøyaktighet. For det første er denne evalueringsmetoden best egnet i tilfeller der klassene som skal predikeres har omtrent like mange tilhørende tilfeller. Dette kan ikke sies å være tilfelle i denne oppgaven, hvor antall konkurssmeldte selskap er på ca. 3,5 % av det totale antallet. I et slikt tilfelle, ville en modell enkelt kunne oppnå 96,5 % klassifikasjonsnøyaktighet ved bare å predikere alle tilfellene som «ikke konkurs». Et slikt tilfelle ville gitt et falskt inntrykk av høy nøyaktighet, og dette gjør det vanskelig å ha full tillit til klassifikasjonsnøyaktighet som evalueringskriterium. En annen ulempe ved denne metoden er at den ikke tar hensyn til kostnaden av feilklassifisering. Av disse årsakene synes AUC bedre egnet til å evaluere modeller som benyttes i denne oppgaven. En stor overvekt av observasjonene i det brukte datasettet tilhører én klasse ("ikke konkurs"), og dette gjør ROC-plot til en god evalueringsmetode. Videre virker det relevant å bruke en metode som kan gi et bilde av kostnaden ved feilklassifisering, noe klassifiseringsnøyaktighet ikke kan. AUC gjør det mulig å få oversikt over fordelingen av feilprediksjoner, da den skiller mellom falske negative og falske positive svar. Dette kan gjøre det mulig for brukere av modellen å bedre vurdere dens nytte, sammenlignet med klassifikasjonsnøyaktighet. For eksempel kan det tenke seg at et forsikringsselskap som vurderer å gi tilbud til et selskap, vil være særlig interessert i å bruke konkursprediksjons-modeller med lav falsk negativ-rate. Dersom modellen feilaktig predikerer at selskapet ikke vil gå konkurs, men den gjør det likevel, vil dette kunne medføre betydelige økonomiske tap for forsikringsselskapet. Det kan tenkes at en slik bruker vil ha større aksept for en falsk positivrate.

I tillegg til AUC, vil også nøyaktighetsratio (NR) for modellene presenteres i denne oppgaven. NR er differansen mellom AUC og 0,5 multiplisert med 2 [Tian et al., 2015], og er mye brukt i litteraturen om konkursprediksjon. Verdier for nøyaktighetsratio varierer mellom 0 og 1. En score på 0 indikerer at modellen tilsvarende en tilfeldig prognose, mens en verdi på 1 tilsvarende en modell som gjør perfekte prediksjoner. Ifølge [Hosmer et al., 2013] er NR-verdier på mellom 0,4 og 0,6 ansett som akseptable, og NR på mer enn 0,6 ses på som utmerket.

### 3.5.2 Kryssvalidering

Et velkjent problem forbundet med alle modeller, inkludert modeller for konkursprediksjon, er muligheten for overtilpasning [James et al., 2013]. Overtilpasning skjer i tilfeller hvor modellen ikke lærer mønstre i datasettet, men heller memorerer datasettet den bruker til å trene. Dette fører til at modellen kan predikere observasjonene den er trent på med høy nøyaktighet, men blir uegnet til bruk på nye data. Denne potensielle svakheten nødvendiggjør en oppdeling av dataene i treningssett og testsett, slik at modellen kan testes på data som ikke er brukt til å trene på. Dersom en modell oppnår gode resultater på et testsett, vil dette styrke tilliten til at modellen vil kunne gjøre gode prediksjoner på framtidige data. Testing av modellen på nye data i et testsett kalles validering av modellen.

Det finnes ulike måter å gjennomføre validering på. Den enkleste metoden er å dele opp i ett treningssett og ett testsett, for så å gjennomføre trening og testing én gang. En annen metode er ‘Leave-one-out’ kryssvalidering (LOOCV). Her brukes alle observasjoner i datasettet til trening, med unntak av én som brukes til testing. Denne prosessen gjentas flere ganger, helt til alle observasjonene i datasettet har blitt brukt som testobservasjon én gang. Modellen evalueres basert på gjennomsnittsverdien av evalueringskriteriet for alle testene som er gjort [James et al., 2013].

Modellene i denne oppgaven bruker n-fold kryssvalidering. Ved bruk av denne metoden deles datasettet inn i n antall ‘folds’, eller deler. Hver fold består av henholdsvis trenings- og testdata, slik at modellen trenes og testes n antall ganger. Resultatene av modellen finnes av

gjennomsnittsverdiene fra alle delene (Kirkos, 2012). Som tidligere nevnt undersøker denne oppgaven tre ulike datasett: hele perioden (HP), år med økonomisk oppgang (HK) og år med økonomisk nedgang (LK). Ettersom den brukte konjunkturindikatoren betegner flere år som HK enn LK, har de tre datasettene et ulikt antall år.

Ettersom det er flere år i datasettet som regnes som oppgangstider enn nedgangstider, og datasettet HP inneholder alle år, er de tre datasettene delt opp i et ulikt antall deler. HP er delt opp i syv deler, HK i fem og LK i tre. Figur 8, 9 og 10 viser oppdelingen i hhv. HP, HK og LK.

Ettersom datasettet er tidsseriedata, er det viktig å ikke bruke data fra senere tidspunkt til å trene prediksjoner for tidligere data. Dette fordi kryssvalidering antar at det ikke er noen sammenheng mellom observasjonene, altså at de er uavhengige av hverandre. Dette stemmer ikke for tidsseriedata, hvor tidsdimensjonen til observasjonene betyr at man ikke kan dele tilfeldig inn i trenings- og testsett. Det er for eksempel ønskelig å unngå situasjoner hvor for eksempel årsregnskap fra 2014-2017 brukes til modelltrening, og 2014 brukes til testing. Det brukes derfor i dette arbeidet såkalt 'sliding window'. Denne metoden foretar oppdeling i henhold til n-fold kryssvalidering, men sikrer samtidig at modellen ikke testes på eldre data enn den ble trent på.

Hele perioden (HP)												
Fold #	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
1	Trening					Test						
2												
3												
4												
5												
6												
7												
# observasjoner	2 596	2 709	2 742	2 804	2 862	3 004	3 266	3 467	3 702	3 955	4 269	4 587
# konkurr	103	125	125	110	106	118	117	116	133	119	139	162
konkurs i %	3,97 %	4,61 %	4,56 %	3,92 %	3,70 %	3,93 %	3,58 %	3,35 %	3,59 %	3,01 %	3,26 %	3,53 %

Figur 8: 7-fold kryssvalidering av datasettet HP

Høykonjunktur (HK)								
<i>Fold #</i>	2006	2007	2008	2011	2012	2013	2014	2017
<b>1</b>	Trening		Test					
<b>2</b>								
<b>3</b>								
<b>4</b>								
<b>5</b>								
<b>6</b>								
<b># observasjoner</b>	2 596	2 709	2 742	3 004	3 266	3 467	3 702	4 587
<b># konkurs</b>	103	125	125	117	117	116	133	162
<b>konkurs i %</b>	3,97 %	4,61 %	4,56 %	3,89 %	3,58 %	3,35 %	3,59 %	3,53 %

Figur 9: 6-fold kryssvalidering av datasettet HK

Lavkonjunktur (LK)				
<i>Fold #</i>	2009	2010	2015	2016
<b>1</b>	Trening	Test		
<b>2</b>				
<b># observasjoner</b>	2 804	2 862	3 955	4 269
<b># konkurs</b>	110	106	119	162
<b>konkurs i %</b>	3,92 %	3,70 %	3,01 %	3,79 %

Figur 10: 2-fold kryssvalidering av datasettet LK

### 3.6 Reliabilitet og validitet

Det er i enhver forskningsstudie relevant å vurdere resultatenes reliabilitet og validitet for å måle kvaliteten på studiet. Her følger en kort drøfting av disse.

Den reliabiliteten og validiteten en gir til sekundærdataen kommer av hvilken metode dataen ble oppsamlet, og kilden til dataen. En høy reliabilitet betyr at innhenting av dataen og de analyseteknikker en bruker for å generere resultatene, vil gi de samme resultatene hvis de utføres på et annet tidspunkt av andre. Bias innenfor datainnhenting er det som er den vanligste feilen når det kommer til reliabiliteten til en studie [Saunders et al., 2009]. Da det i denne oppgaven blir brukt kvantitative sekundærdata i analysene, anser vi analysene som reliable. Det er også liten sjanse for at studien ikke kunne være replikerbar, da metodene som er benyttet er godt dokumentert og oppgaven er transparent med fremgangsmåten. Hør grad av reliabilitet er ikke nok i seg selv for å vurdere kvaliteten på et studie, og en er dermed nødt til å kombinere reliabiliteten med studiens validitet.

Studiens validitet sier noe om i hvor stor grad resultatene egner seg til å trekke gyldige konklusjoner angående det man studerer [Store Norske Leksikon, 2022]. Begrepet omhandler også hvor godt resultatene, og de konklusjonene som følger, kan generaliseres til å si noe om andre bransjer, land eller tidsperioder enn de studien tar for seg. Dette kalles ekstern validitet.

Analysen gjennomført i denne oppgaven benytter et omfattende datasett som inkluderer årsregnskap fra alle registrerte serveringsselskaper i Norge i den aktuelle tidsperioden. Dette gjør at datagrunnlaget for analysene er så stort som mulig. Dette styrker konklusjonens generaliserbarhet til å også gjelde for fremtidige norske serveringsselskap.

Videre benytter studien som nevnt kryssvalidering i sin analyse. Dette innebærer at modellene alltid testes og vurderes på nye data (som de ikke har trent på). Modeller som oppnår høye AUC-verdier på testsett, kan sies å ha lav bias. De er altså fleksible nok til å også kunne brukes på nye datasett med nøyaktige resultater. Som kapittel 4 vil vise, har samtlige



modeller i oppgaven relativt høye AUC-verdier på testsett. Dette indikerer at konklusjonene som følger av resultatene er generaliserbare, og dermed høy validitet.

En mulig svakhet med hensyn til oppgavens eksterne validitet er det faktum at konjunktursvingninger ikke utspiller seg på samme måte hver gang. Et sentralt mål ved å utvikle prediksjonsmodeller er å kunne si noe om framtidige hendelser basert på dagens tilgjengelige informasjon. Det er derimot ingen garanti for at de samme makroøkonomiske forholdene kommer å gjelde ved hver lavkonjunktur (eller hver høykonjunktur). Noen ganger er nedgangen mild, andre ganger er den sterk. Det vil også være variasjon i offentlige myndigheters reaksjon etter hvem som har politisk makt. Dette vil igjen påvirke lavkonjunktorens effekt på selskapers konkursrisiko. Det er altså rimelig å forvente noe variasjon i makroøkonomiske forhold under konjunkturer, og dette svekker oppgavens eksterne validitet noe.

Selv om oppgavens generaliserbarhet til framtidige norske serveringsselskaper virker å være god, er det ikke sikkert at de samme konklusjonene vil gjelde for utenlandske selskap. Ulike lovverk og retningslinjer for rapportering av årsregnskap, ulike muligheter for statlig støtte under økonomiske kriser, ulike markedsstrukturer og en rekke andre forhold kan gjøre at resultatene ikke blir de samme dersom man ser på utenlandske selskap.

## 4 Resultater

Dette kapittelet tar for seg resultatene fra de estimerte modellene. Først presenteres resultater fra modellene med variabler fra SEBRA-modellen. Disse kommenteres med hensyn til variablenes forklaringskraft, samt evalueringsmål for modellene. Deretter gjøres det samme for modellene som brukte uavhengige variabler fra variabelsett 2.

### 4.1 Resultater fra variabelsett 1

Her presenteres resultater for modeller som benytter de uavhengige variablene fra variabelsett 1. Resultater for logistisk regresjon vises først, etterfulgt av modeller som bruker XGBoost som estimeringsmetode.

#### 4.1.1 Logistisk regresjon

Tabell 8 viser regresjonskoeffisientene til de uavhengige variablene, samt AUC og NR for treningsdata og testdata for modellene som brukte variabler fra SEBRA-modellen og logistisk regresjon som estimeringsmetode. Modellen for hele perioden (HP) hadde AUC på 0,803 for treningsdata og 0,806 for testdata. Samtidig hadde modellene for høykonjunktur (HK) og lavkonjunktur (LK) tilnærmet like verdier, med henholdsvis 0,794 og 0,802 for treningsdata. Videre hadde disse to periodene test-AUC på hhv. 0,794 og 0,805.

Nøyaktighetsratioen (NR) for HP-modellen er på 0,607 for treningsdata og 0,612 for testdata. For HK-modellen er NR lik 0,588 og 0,587 for henholdsvis trenings- og testdata. For LK-modellen, er nøyaktighetsratioen 0,604 for treningsdata og 0,609 for testdata. HP- og LK-modellene med logistisk regresjon og variabelsett 1 ga altså svært gode resultater etter Hosmer et. al. (2013) sin tolkning av NR-verdier. En kan se av resultatene at både AUC- og NR-verdier er marginalt bedre for HP-modellen enn for de to andre modellene. Disse resultatene indikerer altså at en oppdeling av datasett etter konjunkturer har liten eller ingen positiv effekt på modellens ytelse ved bruk av regresjon som estimeringsteknikk.

	Tag	Kategori	HP	HK	LK
Ordinært resultat før av- og nedskrivninger / Total gjeld	V1	Resultat	-0,089	-0,081	0,016
Egenkapital / Totalkapital	V2	Egenkapitalprosent	0,048	0,056	-0,038
Innskutt egenkapital < Sum egenkapital = 1, ellers 0	V3	Innskutt egenkapital	-0,764	-0,713	-0,797
(Bankinnskudd ol. - Kortsiktig gjeld) / Driftsinntekter	V4	Likviditetsprosent	0,212	0,100	0,005
Leverandørgjeld / Totalkapital	V5	Leverandørgjeldprosent	0,200	0,236	0,206
Skyldige offentlige avgifter / Totalkapital	V6	Avgiftsprosent	0,178	0,182	0,231
Selskapets alder i antall år	V7	Alder	-0,556	-0,586	-0,475
Intercept			-3,763	-3,960	-3,631
AUC (Treningsdata)			0,803	0,794	0,802
AUC (Testdata)			0,806	0,794	0,805
NR (Treningsdata)			0,607	0,588	0,604
NR (Testdata)			0,612	0,587	0,609

Tabell 8: Rangering av uavhengige variabler mht. forklaringskraft ved bruk av logistisk regresjon og variabler fra variabelsett 1

Med hensyn til forklaringskraft viser tabell 8 at variabel V3, som gir uttrykk for innskutt egenkapital, gjennomgående er den viktigste variabelen i alle tre modeller. Den variabelen med nest høyest forklaringskraft er variabel V7, selskapets alder. Videre synes det å være nokså liten forskjell på høy- og lavkonjunktur med hensyn til hvilke variabler som har størst betydning for konkurssannsynlighet. Resultatene viser at variabel V3, innskutt egenkapital, er noe viktigere i lavkonjunktur, mens alder på selskapet har større innvirkning på konkurssannsynlighet i høykonjunkturer.

#### 4.1.2 XGBoost

Tabell 9 viser forklaringskraften (gain) til variablene V1-V7, samt AUC og NR for hhv. treningsdata og testdata for modellene som brukte variabler fra variabelsett 1 og XGBoost som estimeringsmetode. Modellen for hele perioden (HP) hadde trenings-AUC på 0,796 og 0,791 for testdata. Samtidig hadde modellene for HK og LK henholdsvis 0,800 og 0,820 som AUC-verdier på treningsdata. Videre hadde begge disse to periodene test-AUC på henholdsvis 0,785 og 0,778. NR-verdiene viser 0,592 og 0,582 for henholdsvis trenings- og testdata i HP-modellen. For HK-modellen, var resultatet en nøyaktighetsratio på 0,6 og 0,569. Videre hadde LK-modellen NR på 0,639 og 0,556. En kan se at XGBoost-modellene har en litt lavere ytelse enn modellene som brukte logistisk regresjon, spesielt når det gjelder

prediksjoner på testdata. Likevel er alle modellene å regne som akseptable i henhold til Hosmer et al. (2013) sin rangering. I likhet med modellene som brukte logistisk regresjon som estimeringsteknikk, viser disse resultatene at oppdelingen av datasettet i HK og LK ikke ser ut til å ha noen meningsfull positiv effekt på modellenes ytelse. HK- og LK-modellene yter noe bedre på treningsdata, men HK-modellen oppnår høyere AUC-verdier på testdata.

	Tag	Kategori	HP	HK	LK
Ordinært resultat før av- og nedskrivninger / Total gjeld	V1	Resultat	0,126	0,159	0,056
Egenkapital / Totalkapital	V2	Egenkapitalprosent	0,333	0,267	0,285
Innskutt egenkapital < Sum egenkapital = 1, ellers 0	V3	Innskutt egenkapital	0,032	0,016	0,030
(Bankinnskudd ol. - Kortsiktig gjeld) / Driftsinntekter	V4	Likviditetsprosent	0,121	0,130	0,115
Leverandørgjeld / Totalkapital	V5	Leverandørgjeldprosent	0,157	0,184	0,191
Skyldige offentlige avgifter / Totalkapital	V6	Avgiftsprosent	0,091	0,109	0,113
Selskapets alder i antall år	V7	Alder	0,142	0,137	0,194
AUC (Treningsdata)			0,796	0,800	0,820
AUC (Testdata)			0,791	0,785	0,778
NR (Treningsdata)			0,592	0,600	0,639
NR (Testdata)			0,582	0,569	0,556

Tabell 9: Rangering av uavhengige variabler mht. forklaringskraft ved bruk av XGBoost og variabler fra variabelsett 1

Tabell 9 viser videre at V2 (egenkapitalprosent) har størst forklaringskraft i alle de tre modellene. Resultatene viser videre at V5 (leverandørgjeldprosent) rangerer høyere enn V7 (alder) under høykonjunktur, mens det motsatte er tilfelle under lavkonjunktur. Samtidig er den faktiske forklaringskraften til både V5 og V7 større i LK enn i HK. I tillegg ser V1 (resultat) ut til å ha større forklaringskraft i HK enn i LK.

## 4.2 Resultater fra variabelsett 2

Her presenteres resultater for modeller som benytter de uavhengige variablene fra variabelsett 2. Resultater for logistisk regresjon vises først, etterfulgt av modeller som bruker XGBoost som estimeringsmetode.

#### 4.2.1 Logistisk regresjon

Tabell 10 viser regresjonskoeffisientene til de uavhengige variablene, samt AUC og NR for AUC og NR for hhv. treningsdata og testdata for modellene som brukte variabler fra variabelsett 2 og logistisk regresjon som estimeringsmetode. Modellen for hele perioden hadde AUC på 0,829 og 0,826 for hhv. trenings- og testsett. Samtidig hadde modellene for HK og LK trenings-AUC på hhv. 0,825 og 0,832. Videre hadde begge modellene AUC på ca. 0,82 ved evaluering av treningssett.

Når det gjelder nøyaktighetsratio, oppnår HP-modellen 0,659 for treningsdata og 0,651 for testdata. For HK-modellen er verdiene henholdsvis 0,65 og 0,639, mens LK-modellen oppnår 0,664 og 0,638. Altså er ytelsen til alle modellene som bruker logistisk regresjon og variabelsett 2 å regne som utmerket i henhold til [Hosmer et al., 2013] sin rangering. Også disse resultatene indikerer at modellene for HK og LK ikke oppnår bedre ytelse enn modellen for hele perioden når testet for AUC.

	Tag	Kategori	HP	HK	LK
Leverandørgjeld / totale eiendeler	Z1	Likviditet	0,227	0,245	0,244
Dummy: 1 hvis total gjeld overstiger totale eiendeler	Z2	Gjeld	0,573	0,531	0,647
(Nåværende gjeld - kortsiktig likviditet) / totale eiendeler	Z3	Gjeld	-0,130	-0,106	-0,230
Netto omsetning / totale eiendeler	Z4	Lønnsomhet	0,241	0,184	-0,105
Betalbar skatt / totale eiendeler	Z5	Likviditet	0,253	0,229	0,231
Rentekostnad / totale eiendeler	Z6	Soliditet	0,346	0,315	0,128
Dummy: 1 hvis innskutt egenkapital er mindre enn total EK	Z7	Soliditet	0,015	0,027	-0,019
Log (alder i antall år)	Z8	Alder	-0,573	-0,593	-0,522
Lagerbeholdning / omløpsmidler	Z9	Likviditet	0,070	0,087	0,057
Korttids-likviditet / omløpsmidler	Z10	Likviditet	-0,183	-0,180	-0,117
Intercept			-3,908	-3,798	-3,944
			0,829	0,825	0,832
AUC (Treningsdata)			0,826	0,820	0,819
NR (Treningsdata)			0,659	0,650	0,664
NR (Testdata)			0,651	0,639	0,638

Tabell 10: Rangering av uavhengige variabler mht. forklaringskraft ved bruk av logistisk regresjon og variabler fra variabelsett 2

Det framkommer av disse resultatene i tabell 10 at Z8 (selskapets alder) er den uavhengige variabelen med størst forklaringskraft i perioder med høykonjunktur. Samtidig viser resul-

tatene at Z2 (gjeld) har størst forklaringskraft under lavkonjunktur. I tillegg er variabel Z1 (likviditet) den tredje viktigste variabelen under lavkonjunktur, mens den er rangert som nummer 5 i høykonjunktur. Dette indikerer at selskapets likviditet har større innvirkning på konkurssannsynlighet i økonomiske nedgangstider enn i oppgangstider.

#### 4.2.2 XGBoost

Tabell 11 viser forklaringskraften (gain) til variablene Z1-Z10, samt AUC og NR for hhv. treningsdata og testdata for modellene som brukte variabler fra variabelsett 2 og XGBoost som estimeringsmetode. Modellen for hele perioden hadde trenings- og test-AUC på ca. 0,83. Samtidig hadde modellene for HK og LK henholdsvis 0,825 og 0,832 som AUC-verdier på treningsdata. Videre hadde begge disse to periodene test-AUC på ca. 0,82.

Nøyaktighetsratioen for HP-modellen er 0,659 og 0,651 for henholdsvis treningsdata og testdata. For HK-modellen, er NR lik 0,65 og 0,639 for henholdsvis treningsdata og testdata. For LK-modellen, er NR lik 0,664 for treningsdata og 0,638 for testdata. Også disse resultatene viser at oppdelingen av HP inn i HK og LK har liten effekt på modellenes AUC.

	Tag	Kategori	HP	HK	LK
Leverandørgjeld / totale eiendeler	Z1	Likviditet	0,227	0,245	0,244
Dummy: 1 hvis total gjeld overstiger totale eiendeler	Z2	Gjeld	0,573	0,531	0,647
(Nåværende gjeld - kortsiktig likviditet) / totale eiendeler	Z3	Gjeld	-0,130	-0,106	-0,230
Netto omsetning / totale eiendeler	Z4	Lønnsomhet	0,241	0,184	-0,105
Betalbar skatt / totale eiendeler	Z5	Likviditet	0,253	0,229	0,231
Rentekostnad / totale eiendeler	Z6	Soliditet	0,346	0,315	0,128
Dummy: 1 hvis innskutt egenkapital er mindre enn total EK	Z7	Soliditet	0,015	0,027	-0,019
Log (alder i antall år)	Z8	Alder	-0,573	-0,593	-0,522
Lagerbeholdning / omløpsmidler	Z9	Likviditet	0,070	0,087	0,057
Korttids-likviditet / omløpsmidler	Z10	Likviditet	-0,183	-0,180	-0,117
Intercept			-3,908	-3,798	-3,944
AUC (Treningsdata)			0,829	0,825	0,832
AUC (Testdata)			0,826	0,820	0,819
NR (Treningsdata)			0,659	0,650	0,664
NR (Testdata)			0,651	0,639	0,638

Tabell 11: Rangering av uavhengige variabler mht. forklaringskraft ved bruk av XGBoost og variabler fra variabelsett 2

Resultatene fra tabell 11 viser at Z2 (gjeld) er den variabelen med størst forklaringskraft i perioder med lavkonjunktur. For høykonjunktur, indikerer modellen at selskapets alder har mest å si for konkurssannsynlighet.

## 5 Diskusjon

Dette delkapittelet har til hensikt å gi en oppsummering av resultatene presentert ovenfor, samt diskutere resultatene i lys av økonomiske egenskaper ved serveringsbransjen som muligens kan gi en forklaring på resultatene. Det rettes særlig søkelys mot variablenes forklaringskraft under høy- og lavkonjunktur, men kapittelet inkluderer også en diskusjon angående modellytelse. I tillegg gjøres det en kort sammenligning av resultatene opp mot funnene til Kim og Upneja (2020).

### 5.1 Modellytelse

Som nevnt, er det her hensiktsmessig å legge størst vekt på AUC ved vurdering av modellens ytelse. Tabell 12 viser gjennomsnittlig AUC på testdata for alle modellene.

		EP	EE	ED	Gjennomsnitt
Variabelsett 1	XGBoost	0,791	0,785	0,778	0,785
	Logistisk regresjon	0,806	0,794	0,805	0,802
Variabelsett 2	XGBoost	0,801	0,797	0,791	0,796
	Logistisk regresjon	0,826	0,820	0,819	0,822
Gjennomsnitt		0,806	0,799	0,798	

Tabell 12: Gjennomsnittlig AUC for alle modeller

Ved sammenligning av variabelsett 1 og 2, viser disse resultatene at variabelsett oppnådde noe høyere AUC-verdier enn variabelsett 1. Å gå fra variabelsett 1 til variabelsett 2 ga en økning i AUC på 1,4 %, mens 2,4 % skilte regresjonsmodellene. Videre ser en av tabell 12 at logistisk regresjon viste seg å være den beste estimeringsteknikken med hensyn til AUC. For modellene som brukte variabelsett 1 var forskjellen mellom XGBoost og regresjon på 2,1 %, mens ulikheten var 3,2 % ved bruk av variabelsett 2. Av de totalt 12 modellene som ble bygd, viste det seg at de mest nøyaktige konkursprediksjonene ble gjort av modellen som evaluerte hele tidsperioden (HP), brukte logistisk regresjon som estimeringsteknikk og uavhengige variabler fra variabelsett 2. Den svakeste modellen med hensyn til AUC var LK-modellen som



brukte XGBoost som estimeringsteknikk og uavhengige variabler fra variabelsett 1.

Det er mulig å se flere ulike årsaker til at regresjonsmodellene oppnådde høyere AUC-verdier for dette datasettet. I delkapittel 2.5.2 ble det nevnt at en av svakhetene til beslutningstrær som estimeringsteknikk er at de har en tendens til å oppnå lavere prediksjonsnøyaktighet enn mange andre teknikker [James et al., 2013]. Selv om prediksjonsnøyaktighet ikke har blitt bruk som evalueringskriterium her, kan det tenkes at denne svakheten også gjenspeiles i AUC-verdiene. Videre har modeller som bruker XGBoost store muligheter for tilpasning i form av justering av parametere. Eksempler på slike parametere er læringsrate, antall iterasjoner og maksimal dybde på trærne. Det kan tenkes at dersom det hadde blitt brukt enda mer tid på finjustering av disse parametere, ville XGBoost-modellene i denne oppgaven oppnådd noe høyere AUC-verdier.

Det er verd å legge merke til at det ikke ble oppnådd noen høyere ytelse (mht. AUC) som følge av å dele opp datasettet etter konjunktursvingninger. Modellene for høykonjunktur hadde i gjennomsnitt 7 prosentpoeng lavere AUC enn modellene som tok for seg hele tidsperioden. Videre hadde modellene for lavkonjunktur i gjennomsnitt 8 prosentpoeng lavere AUC enn HP-modellene. I studien til Kim og Upneja fra 2021 ble det samme konkludert. Det ble her funnet at HP-modellen hadde en klassifikasjonsnøyaktighet på 88 %, mens HK og LK hadde henholdsvis 87 % og 81 %. Det faktum at denne masteroppgaven benytter AUC og ikke klassifikasjonsnøyaktigheten gjør at resultatene ikke er perfekt sammenlignbare. Dette er likevel en indikasjon på at funnene i vår studie understøtter funnene til Kim og Upneja (2020) som tilsier at HP-modellene presterer noe bedre enn HK- og LK-modeller.

## **5.2 Forklaringskraft: variabelsett 1**

### **5.2.1 XGBoost**

Resultatene produsert av modellene som brukte variabelsett 1 med maskinlæringsteknikken XGBoost viser at egenkapitalprosent (V2) er den viktigste variabelen i settet for alle perioder. Variabelen uttrykker forholdet mellom selskapets egenkapital og dets totale kapital. I

tillegg til å si noe om selskapets egenkapital, kan også informasjon om selskapets gjeld leses fra denne variabelen, ettersom totalkapital er summen av egenkapital og gjeld. Det er kjent at stor gjeld vil kunne gjøre et selskap insolvent dersom de ikke har verdier og inntekter til å dekke denne gjelden. Det virker derfor logisk at egenkapitalstrukturen til selskapet har høy forklaringskraft i modellene. Selv om XGBoost-modeller ikke kan produsere fortegn i sine resultater, virker det videre sannsynlig at en lavere egenkapitalprosent vil medføre en høyere konkurssannsynlighet. Dette ettersom en høy gjeldsgrad har en tendens til å medføre større sannsynlighet for at selskapet får problemer med å betale gjelden sin og dermed går konkurs.

Tabell 9 viser at egenkapitalprosent har en noe høyere forklaringskraft (gain-verdi) under lavkonjunktur enn i høykonjunktur, med gain-verdier på henholdsvis 0,285 og 0,267. En mulig forklaring på dette kan være at kreditorer av ulike slag vil være mindre villige til å omstrukturere lån eller reforhandle betingelser for gjeld som selskapet har tatt på seg, etter som de selv er under press som følge av de vanskelige økonomiske forholdene. Det kan derfor tenkes at selskaper med høy gjeld vil ha færre muligheter til å finne alternative måter å holde seg solvente på, og at de derfor har en høyere sannsynlighet for å gå konkurs. I høykonjunkturer er det mer sannsynlig at konkursutsatte selskaper med høy gjeld vil ha større fleksibilitet og forhandlingsmuligheter med sine kreditorer, og at dette gjør det enklere å unngå konkurs selv om selskapet har høy gjeld.

LK-modellen rangerer selskapets alder i år som variabelen med nest høyest forklaringskraft, med en gain-verdi på 0,194. I HK-modellen har denne variabelen en gain-verdi på 0,137, og er den variabelen med tredje høyest forklaringskraft. En mulig årsak til at alder på selskapet ser ut til å ha mye å si for konkurssannsynlighet er at eldre bedrifter over tid har opparbeidet seg større eiendeler som kan likvideres for å betale ned gjeld. I tillegg har disse selskapene hatt tid til å opparbeide seg et større forbindelsesnettverk, samt sterkere forbindelser til institusjoner som er viktige i økonomiske nedgangstider (som for eksempel banker). Det kan tenkes at eldre bedrifter, som generelt sett også er større, er viktigere kunder for banker enn for eksempel en oppstartsbedrift. Dette vil gjøre bankene mer villige til å tilby gode lånebetingelser eller reforhandle lånebetingelser dersom selskapet skulle få problemer med å

betale gjelden sin. I tillegg er det mulig at eldre og større bedrifter under økonomiske kriser vil ha en større politisk påvirkning, og i større grad har mulighet til å presse for statlig krisestøtte til sin bedrift. Eldre selskapers tendens til å ha større eiendeler som kan likvideres eller brukes som sikkerhet, samt deres større innflytelse på institusjoner under krisetider kan være årsaker til at alder ser ut til å være en viktig forklaringsvariabel, og videre være noe viktigere i lavkonjunktur enn i høykonjunktur.

Den uavhengige variabelen V5 uttrykker forholdet mellom selskapets leverandørgjeld og total kapital, og er den variabelen med tredje størst forklaringskraft blant modellene som brukte variabelsett 1 og XGBoost. I likhet med variabelen egenkapitalprosent (V2) reflekterer denne også gjelden til selskapet. Derfor vil årsakene til at V5 har høy forklaringskraft i stor grad være de samme som ble diskutert for V2 tidligere i delkapittelet. Med gain-verdier på henholdsvis 0,184 for HK-modellen og 0,191 for LK-modellen, ser denne variabelen ut til å ha noe større forklaringskraft i lavkonjunktur enn i høykonjunktur. Leverandørgjeld betales som regel tilbake til kreditor innen 12 måneders tid, og er derfor å regne som kortsiktig gjeld. Et selskap som har mye gjeld med kort betalingsfrist, vil være mer sårbare for uforutsette hendelser som gjør at betalingsevnen faller. Bedrifter som ikke har reserver å gå på eller muligheter for å ta opp gjeld vil være avhengig av en god lønnsomhet når det oppstår nedgangstider. Det er større risiko å operere i bransjer med store svingninger i inntjening enn bransjer som har en relativt stabil inntekt [Eklund et al., 2001]. Dette vil påvirke bedriftens evne til å planlegge for fremtiden, og også dens muligheter for å skaffe seg ekstern finansiering om det skulle være nødvendig. Samtidig vil slike bransjer tiltrekke seg de som er risikosøkende eller useriøse, da det er kan være potensiale for å tjene gode penger i en slik bransje. Dette fører til at det vil være en større andel konkurs i bransjer som er preget av store inntjeningssvingninger.

Eksempler på hendelser som kan forstyrre forretningsdriften er finanskrisen i 2008 og nedstengningene som fulgte av Covid-19-pandemien i 2020 og 2021. Plutselige svekkelser i selskapets evne til å tjene penger, kan føre til problemer med å tilbakebetale gjeld. Dersom mye av gjelden til selskapet har kort innbetalingsfrist, kan dette føre til store problemer.

I økonomiske kriser kan det videre tenkes av leverandørene selv er helt avhengige av å få innbetalt denne gjelden for å betale sine egne kreditorer, og derfor er lite villige til å re-forhandle lånebetingelser slik at gjelden blir enklere å betale. Dette utgjør en mulig forklaring på hvorfor disse modellene viser at leverandørgjeld har noe større forklaringskraft i lavkonjunktur enn i høykonjunktur. Dette resultatet støtter et funn i en masteroppgave av [Aae and Azouaghe, 2021] skrevet ved Norges miljø- og biovitenskapelige universitet. Denne studien finner også at leverandørgjeld har høy forklaringskraft både i normalår og i årene hvor deler av økonomien var stengt ned som følge av Covid-19-restriksjoner. Samtidig viste studien at leverandørgjeld er litt viktigere i pandemiår enn i normalår.

### 5.2.2 Logistisk regresjon

Resultatene fra modellene med variabelsett 1 og logistisk regresjon som estimeringsteknikk hadde flere likhetstrekk med modellene som brukte XGBoost. For eksempel, styrker disse resultatene de som ble diskutert i forrige delkapittel når det gjelder alder og leverandørgjeldsprosent store betydning for konkurssannsynlighet. Dette gjelder både i høy- og lavkonjunktur. De underliggende bedriftsøkonomiske årsakene til at disse variablene har høy forklaringskraft vil være de samme som de som ble diskutert ovenfor.

En interessant forskjell mellom funnene til hhv. XGBoost og logistisk regresjon er at XGBoost vurderte egenkapitalprosent som en betydelig variabel, mens logistisk regresjon resulterer i en svært lav forklaringskraft for denne variabelen. Samtidig gir regresjonsmodellene høye koeffisienter for innskutt egenkapital (V3), mens XGBoost hadde lave gain-verdier for denne variabelen. Regresjonstabellen (tabell 8) viser negative fortegn for innskutt egenkapital i både HP-, HK- og LK-modellen. Dette indikerer at høyere innskutt egenkapital medfører at selskapet har lavere sannsynlighet for å gå konkurs. Resultatene viser videre at innskutt egenkapital har større forklaringskraft under lavkonjunktur enn under høykonjunktur. En mulig årsak til dette kan være at selskaper som har mindre innskutt egenkapital enn bokført verdi på egenkapitalen viser til at de ikke har tap i regnskapsåret. (Eklund et al, 2001) Er den bokførte egenkapitalen mindre enn den innskutte egenkapitalen viser dette til at selskapet har begått tap dette regnskapsåret. Dette viser da til dårlig soliditet

## 5.3 Forklaringskraft: variabelsett 2

### 5.3.1 XGBoost

Den naturlige logaritmen av alder,  $Z8$ , er variabelen med høyest forklaringskraft i høykonjunktur med en verdi på 0,147. Gain-verdiene i XGBoost viser som nevnt ikke fortegn for variablene slik som regresjonsmodeller kan, men det er rimelig å anta at en høyere alder på selskapet vil medføre lavere konkurssannsynlighet. Dette stemmer overens med teorien om at bedrifter som er eldre vil stå sterkere når det oppstår finansielle problemer. Aldersvariabelen har høy forklaringskraft under alle tre periodene, men har en noe høyere påvirkning på modellen for høykonjunkturperioden. [Eklund et al., 2001] forklarer at alderen på en bedrift kan være en avgjørende faktor. Er bedriften nyetablert vil det være større sannsynlighet for at bedriften går konkurs, da det å tilegne seg tilstrekkelig kunnskap innenfor bedriftsøkonomi tar tid. Det er også mer krevende for nyetablerte bedrifter å skaffe seg kapital og også viktige forbindelser i form av leverandører og kunder.

Dummy-variabelen  $Z2$  identifiserer bedrifter hvis totale gjeld overstiger dens totale eiendeler, og har høyest forklaringskraft i lavkonjunkturer. Bedrifter med en høyere andel gjeld enn eiendeler kan ha vanskeligheter for å betale ned denne, og dette gjelder spesielt i perioder med lav inntjening. Selskaper med høyere gjeld enn eiendeler vil også ha mindre muligheter til å ta opp ekstra gjeld for å dekke opp for inntektstapet som ofte oppstår i lavkonjunkturer. Dette gjør disse bedriftene enda med utsatt under lavkonjunktur. Dette kan forklare hvorfor gain-verdien for  $Z2$  har større forklaringskraft i lavkonjunktur enn i høykonjunktur.

Likviditet ( $Z1$ ) er variabelen med tredje høyest forklaringskraft i lavkonjunkturer med en gain-verdi på 0,244 på modellen under lavkonjunktur når XGBoost blir brukt som metode. Variabelen  $Z1$  tar for seg leverandørgjeld skalert mot sum eiendeler. Leverandørgjelden viser den kortsiktige gjelden bedriften har til sine leverandører. Som tidligere nevnt består leverandørgjeld for det meste av lager, som vanligvis er den største utgiftsposten en finner innenfor serveringsvirksomheter. Det er da ikke overraskende at denne variabelen har høy signifikans når det kommer til konkursprediksjon i denne bransjen. For noen bedrifter vil

en unormalt høy leverandørgjeld indikere likviditetsproblemer [Eklund et al., 2001]. Det er også slik at bransjer som er karakteriseres av høy gjennomsnittlig leverandørgjeld har en høyere andel konkurs enn andre bransjer. Å ta på seg leverandørgjeld i stedet for bankgjeld gjør det lettere å unngå kredittvurderinger og annen oppfølging. En mangel på tilstrekkelig likviditet er en av de vanligste årsakene til konkurs.

Z5 er skyldige offentlige avgifter delt på sum eiendeler. Skyldige offentlige avgifter i prosent av totalkapitalen gir en indikator på bedriftens likviditet. [Beaver, 1966] mente det var mindre sannsynlig at bedrifter med høyere grad av likviditet vil gå konkurs under nedgangstider. Dette stemmer overens med resultatene presentert tidligere. Bedrifter vil være ekstra nøye med å betale skatter og avgifter i tide for å slippe å få eventuelle anmerkninger som gir et varsel om at bedriftens økonomi er dårlig. Er avgiftsprosenten unormalt høy kan det bety at bedriften har problemer med å betale for seg, dvs. de har svak likviditetsgrad [Eklund et al., 2001]. Mangel på likviditet er en av de hyppigste grunnene til at bedrifter går konkurs [Andersen, 2022].

### 5.3.2 Logistisk regresjon

Metoden logistisk regresjon har gitt forskjellige resultater fra XGBoost. Her er forklaringsvariablene rangert i rekkefølge etter koeffisientverdiens absoluttverdi for variabelsett 2 under lavkonjunktur: Z2 (0,647), Z8 (0,522), Z1(0,244), Z5 (0,231) og Z3 (0,230).

Resultatene viser at selskapets alder (Z8) er den variabelen med nest høyest forklaringskraft både i XGBoost-modellene og i regresjonsmodellene. Mulige grunner til at alder har høy innvirkning på konkurssannsynlighet har blitt diskutert ovenfor. Det er likevel verd å merke at både XGBoost-modellene og regresjonsmodellene som bruker variabelsett 2 viser at alder har noe større betydning i høykonjunktur enn i lavkonjunktur, mens det motsatte var tilfelle for variabelsett. En mulig årsak til at det å være en eldre bedrift ser ut til å være en enda større fordel i gode økonomiske tider enn i dårlige, kan være at disse selskapene over lengre tid har opparbeidet seg både kapital og forbindelser. Dette kan gjøre de i stand til å utvide driften mer og utnytte at økonomien går godt, og dermed utkonkurrere de mindre

bedriftene.

Forklaringsvariabelen med tredje høyest koeffisientverdi er leverandørgjeld delt på totale eiendeler ( $Z1$ ), med en verdi på 0,244 under lavkonjunktur. Koeffisienten til denne variabelen er gjennomgående positiv, som betyr at en høyere verdi på denne variabelen gir en større sjanse for konkurs. Variabelen viser kortsiktig gjeld minus bankinnskudd o.l. skalert på eiendeler.

## 6 Konklusjon

### 6.1 Problemstilling 1

*Hvilke regnskapsmessige forhold gir best forklaringskraft i konkursprediksjonsmodellene under de ulike konjunkturperiodene?*

Resultatene av analysene i denne oppgaven viser variabelsett 2 med bruk av logistisk regresjon gir de beste modellene, med tanke på AUC-verdier. Konklusjonen blir da at under lavkonjunktur er de mest signifikante regnskapsmessige variablene rangert som Z2 (gjeld), Z8 (alder) og Z1 (likviditet). Under høykonjunktur er det variablene Z8 (alder), Z2 (gjeld) og Z6 (soliditet) som har høyest forklaringskraft, mens under hele perioden er både Z2 (gjeld) og Z8 (alder) på førsteplass, etterfulgt av Z6 (soliditet). Analysen viser at serveringsvirksomheter med en høyere gjeld enn eiendeler, lav alder og dårlig likviditet i form av leverandørgjeldsprosent bør være ekstra påpasselige under lavkonjunkturer. Det vil også være av interesse for serveringsvirksomheters eksterne aktører å være oppmerksomme på disse regnskapsmessige forholdene i denne bransjen for å unngå investeringer i virksomheter som ikke vil overleve lavkonjunkturer.

### 6.2 Problemstilling 2

*I hvilken grad endres prediksjonsevnen til konkursprediksjonsmodeller for serveringsbransjen ved å tilpasse seg konjunktursvingninger?*

Modellenes AUC-verdier endrer seg minimalt over de forskjellige konjunkturperiodene og for de forskjellige datasettene, der alle AUC-verdier ligger innenfor akseptable (AUC (0.7, 0.8)) eller utmerkede nivåer (AUC (0.8, 0.9)) [Hosmer et al., 2013]. Metoden logistisk regresjon viste seg å gi en marginalt bedre prediksjonsevne for de to variabelsettene som ble analysert, selv om XGBoost er en mer avansert metode. Logistisk regresjon er en av de mest brukte metodene innenfor konkursprediksjon, med flere nyere studier som benytter seg av metoden ([Shumway, 2001]; [Campbell et al., 2008]; [Tian et al., 2015]; [Paraschiv et al., 2021]).



### 6.3 Utfordringer ved oppgaven

Oppgavens resultater er sprikende, på den måten at de to benyttede estimeringsteknikkene kom fram til nokså ulike svar på hvilke variabler som hadde størst forklaringskraft i hhv. HK og LK. Dette gjør det noe vanskelig å konkludere med hva som faktisk er tilfellet i den virkelige verden, utover hva modellene i denne oppgaven indikerer. Det er et nokså tydelig behov for å teste ut flere estimeringsteknikker for å komme fram til et sikrere svar som kan ha tillit hos beslutningstakere og andre interessenter.

Utfordringer ved å benytte seg av regnskapsmessige tall er at denne informasjonen kan være utsatt for regnskapsmessig fleksibilitet for å skjule dårlige tall. Regnskapsinformasjonen kan være for aggressiv eller for konservativ, og derfor ikke representere virkeligheten på en tilfredsstillende måte. En aggressiv regnskapsføring vil ofte bli brukt når en bedrift er i økonomisk krise, og vil skjule dette for eventuelle interessenter [Ronen and Yaari, 2008].

### 6.4 Videre forskning

Denne oppgaven inkluderte konjunktursvingninger i konkursprediksjonen, som er et relativt lite utforsket felt innen konkursprediksjon. Dette arbeidet legger som sådan til rette for videre forskning på inkludering av konjunktursvingninger og andre makroøkonomiske variabler som en del av konkursprediksjon. For å gjøre videre forskning på dette temaet ville det være interessant å se på ulike datasett, som for eksempel flere bransjer for å se om de regnskapsmessige forklaringsvariablene varierer innenfor de ulike bransjene. Det vil også være interessant å se på serveringsvirksomheter internasjonalt for å undersøke hvordan resultatene eventuelt varierer i ulike land. Videre hadde det vært en mulighet å se om det er andre variabler som kan benyttes i analysen for å forbedre prediksjonsevnen til modellene, og om det hadde vært mulig å benytte makroøkonomiske variabler til dette. I stedet for å dele opp datasettet basert på en konjunkturindikator, ville en kanskje fått en annen innsikt dersom de faktorene som indikatoren er basert på hadde blitt brukt direkte som uavhengige variabler i modellene. Ligang et. al. gjorde i 2010 en utforskende studie for å undersøke om makroøkonomiske variabler kunne bidra til å forbedre prediksjonsevnen til allerede brukte modeller, som for

eksempel regresjon og KNN. Resultatene viste at inkludering av disse variablene ga en nokså liten, men positiv effekt på prediksjonsevnen [Ligang et al., ].

Kontinuerlig utvikling og popularisering av nye estimeringsteknikker gir alltid gode muligheter for videre forskning. I denne studien ble det oppdaget betydelige forskjeller i funnene ved sammenligning av regresjon og XGBoost. Det hadde vært interessant å teste et langt større antall ulike estimeringsteknikker, og muligens kommet fram til et gjennomsnittlig svar på hvilke variabler som har størst forklaringskraft i henholdsvis høykonjunktur og lavkonjunktur. Dette hadde gjort at en kunne konkludert med langt større sikkerhet enn det som er gjort i denne oppgaven.

## Litteratur

- [Aae and Azouaghe, 2021] Aae, H. L. and Azouaghe, S. (2021). En sammenligning av maskinlæringsteknikker innenfor konkursprediksjon av norske selskaper [masteroppgave]. *Norges miljø- og biovitenskapelige universitet*.
- [Alaka et al., 2018] Alaka, H., Oyedele, L., Owolabi, H., Kumar, V., Ajayi, S., Akinade, O., and Bilal, M. (2018). Systematic review of bankruptcy prediction models: Towards a framework for tool selection. *Expert System with Application*, 94:164–184.
- [Altman, 1968] Altman, E. (1968). Financial ratios, discriminant analysis and the prediction of corporate bankruptcy. *The Journal of Finance*, 23(4):589–609.
- [Altman, 2000] Altman, E. (2000). Predicting financial distress of companies: Revisiting the z-score and zeta. *Handbook of Research Methods and Applications in Empirical Finance*, 5.
- [Altman, 2007] Altman, E. (2007). Modelling credit risk for smes: Evidence from the u.s. market. *Abacus*, 43:332–357.
- [Altman et al., 1977] Altman, E., Haldeman, R., and Narayanan, P. (1977). Zeta analysis a new model to identify bankruptcy risk of corporations. *Journal of Banking Finance*, 1(1):29–54.
- [Andersen, 2022] Andersen, V. (2022). Likviditet - bedriftens viktigste styringspartner. [Hentet 08.03.2022] <https://www.regnskapnorge.no/faget/artikler/regnskap/likviditet--bedriftens-viktigste-styringsparameter/>.
- [Arbeidstilsynet, 2022] Arbeidstilsynet (2022). Overnattings- og serveringsbransjen. [Hentet 07.02.2022].
- [Beaver, 1966] Beaver, W. (1966). Financial ratios as predictors of failure. *Journal of Accounting Research*, 4:71–111.
- [Bellovary et al., 2007] Bellovary, J., Giacominio, D., and Akers, M. (2007). A review of bankruptcy prediction studies: 1930 to present. *Journal of Financial Education*, 33:1–42.

- [Benedictow and Johansen, 2005] Benedictow, A. and Johansen, P. (2005). Prognoser for internasjonal økonomi. *Økonomiske analyser*, 2:13–20.
- [Berg, 2007] Berg, D. (2007). Bankruptcy prediction by generalized additive models. *Applied Stochastic Models in Business and Industry*, 23(2):129–143.
- [Bernhardsen, 2001] Bernhardsen, E. (2001). A model of bankruptcy prediction. *Working Papers from Norges Bank*, 10.
- [Bernhardsen and Larsen, 2007] Bernhardsen, E. and Larsen, K. (2007). Modelling av kredittrisiko i foretakssektoren - videreutvikling av sebra-modellen. *Penger og kreditt*, pages 60–66.
- [Breiman, 1996] Breiman, L. (1996). Bagging predictors. *Machine Learning*, 24(2):123–140.
- [Brønnøysundregistrene, 2022] Brønnøysundregistrene (2022). Statistikk fra konkursregisteret. [Hentet 22.02.2022] <https://www.brreg.no/produkter-og-tjenester/statistikk/statistikk-fra-konkursregisteret/>.
- [Campbell et al., 2008] Campbell, J., Hilscher, J., and Szilagyi, J. (2008). In search of distress risk. *The Journal of Finance*, 63(6):2899–2939.
- [Chen et al., 1996] Chen, N., Ribeiro, B., Vieira, A., Duarte, J., and Neves, J. (1996). A genetic algorithm-based approach to cost-sensitive bankruptcy prediction. *Expert Systems with Applications*, 38(10):12939–12945.
- [Chen and Guestrin, 2016] Chen, T. and Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Fransisco, CA, USA*, pages 785–794. 13.-17. August 2016.
- [Damvad, 2014] Damvad (2014). Utredning om norsk serveringsnæring. [Hentet 09.05.2022] <https://www.regjeringen.no/contentassets/24511bb545cd41eb93333bf0f31f8ea4/serveringsbransjen.pdf>.
- [Dangeti, 2017] Dangeti, P. (2017). *Statistics for Machine learning*. Packt.

- [Davis, 1992] Davis, S. (1992). Gross job creation, gross job destruction, and employment reallocation. *The Quarterly Journal of Economics*, 107(3):819–863.
- [de Jong and Heller, 2008] de Jong, P. and Heller, G. (2008). *Generalized Linear Models for Insurance Data*. Cambridge University Press.
- [Eika, 2007] Eika, T. (2007). En oljesmurt økonomi. med harelabb over 35 års konjunkturhistorie. *Samfunnsspeilet*, 5(6):106–111.
- [Eklund et al., 2001] Eklund, T., Larsen, K., and Bernhardsen, E. (2001). Modell for analyse av kredittrisiko i foretakssektoren. *Penger og kreditt*, 2(1).
- [Fawcett, 2006] Fawcett, T. (2006). An introduction to roc analysis. *Pattern Recognition Letters*, 27(8):861–874.
- [Field and Pagoulatos, 1997] Field, M. and Pagoulatos, E. (1997). The cyclical behaviour of price elasticity of demand. *Southern Economic Journal*, 64:118.
- [Garcia-Sanchez et al., 2014] Garcia-Sanchez, J., Mesquita, L., and Vassolo, R. (2014). What doesn't kill you makes you stronger: The evolution of competition and entry-order advantages in economically turbulent contexts. *Strategic Management Journal*, 35(13):1972–1992.
- [Gärtner, 2016] Gärtner, M. (2016). *Macroeconomics*. Pearson.
- [Hastie and Tibshirani, 1995] Hastie, T. and Tibshirani, R. (1995). Discriminant adaptive nearest neighbor classification and regression. In Touretzky, D., Mozer, M., and Hasselmo, M., editors, *Advances in Neural Information Processing Systems*, volume 8. MIT Press.
- [Hol, 2006] Hol, S. (2006). The influence of the business cycle on bankruptcy probability. *International transactions in operational research*, 14(1):75–90.
- [Hosmer et al., 2013] Hosmer, D., Lemeshow, S., and Sturdivant, R. (2013). *Applied Logistic Regression*. John Wiley Sons, Inc.
- [James et al., 2013] James, G., Witten, D., Hastie, T., and Tibshirani, R. (2013). *An Introduction to Statistical Learning*. Springer.

- [Kaytaz and Gul, 2014] Kaytaz, M. and Gul, M. (2014). Consumer response to economic crisis and lessons for marketers: The turkish experience. *Journal of Business Research*, 67(1):2701–2706.
- [Kim and Upneja, 2014] Kim, S. Y. and Upneja, A. (2014). Predicting restaurant financial distress using decision tree and adaboosted decision tree models. *Economic Modelling*, 36(1):354–362.
- [Kim and Upneja, 2021] Kim, S. Y. and Upneja, A. (2021). Majority voting ensemble with decision trees for business failure prediction during economic downturns. *Journal of Innovation and Knowledge*, 6(2):112–123.
- [Kirkos, 2012] Kirkos, E. (2012). Assessing methodologies for intelligent bankruptcy prediction. *Artificial Intelligence Review*, 43(1):83–123.
- [Knudsen, 2019] Knudsen, E. S. (2019). Bad weather ahead: Pre-recession characteristics and the severity of recession impact. *Journal of Business Research*, 104:118–130.
- [Knudsen and Lien, 2014] Knudsen, E. S. and Lien, L. (2014). Investments in recessions. *Journal of Business Research*, 31:3–36.
- [Konkursloven §61, 1986] Konkursloven §61 (1986). Lov om gjeldsforhandling og konkurs (lov-1984-06-08-58). [Hentet 29.04.2022][§61] <https://lovdata.no/dokument/NL/lov/1984-06-08-58>.
- [Ligang and Lai, 2009] Ligang, Z. and Lai, K. K. (2009). Benchmarking binary classification models on data sets with different degrees of imbalance. *Frontiers of Computer Science China*, 3(2):205–216.
- [Ligang et al., ] Ligang, Z., Lai, K. K., and Yen, J. Bankruptcy prediction incorporating macroeconomic variables using neural network. *International Conference on Technologies and Applications of Artificial Intelligence*, pages 80–85.
- [Maimon and Rokash, 2010] Maimon, O. and Rokash, L. (2010). *Data Mining and Knowledge Discovery Handbook*. Springer.

- [NBER, 2022] NBER (2022). Business cycle dating. [Hentet 27.02.2022] <https://www.nber.org/research/business-cycle-dating>.
- [Norges Domstoler, 2022] Norges Domstoler (2022). Konkurs. [Hentet 03.03.2022] <https://www.domstol.no/gjeld-og-konkurs/konkurs/>.
- [Næringslivets Hovedorganisasjon, 2022] Næringslivets Hovedorganisasjon (2022). Fakta om små og mellomstore bedrifter (smb). [Hentet 11.03.2022] <https://www.nho.no/tema/sma-og-mellomstore-bedrifter/artikler/sma-og-mellomstore-bedrifter-smb/>.
- [OECD, 2022] OECD (2022). Composite leading indicators (cli). [Hentet 18.01.2022] <https://data.oecd.org/leadind/composite-leading-indicator-cli.htm>.
- [Ohlson, 1980] Ohlson, J. (1980). Financial ratios and the probabilistic prediction of bankruptcy. *Journal of Accounting Research*, 18(1):109–131.
- [Paraschiv et al., 2021] Paraschiv, F., Schim, M., and Wahlstrøm, R. R. (2021). Bankruptcy prediction of privately held smes using feature selection methods. Tilgjengelig ved SSRN 3911490 og <https://dx.doi.org/10.2139/ssrn.3911490>.
- [Prusak, 2018] Prusak, B. (2018). Review of research into enterprise bankruptcy prediction in selected central and eastern european countries. *International Journal of Financial Studies*, 6(3):60.
- [Ronen and Yaari, 2008] Ronen, J. and Yaari, V. (2008). Earnings management: emerging insights in theory, practice, and research. *Journal of Management and Governance*, 14(1):87–89.
- [Samuel, 2000] Samuel, A. (2000). Some studies in machine learning using the game of checkers. *IBM Journal of research and development*, 44(1):206–226.
- [Saunders et al., 2009] Saunders, Lewis, and Thornhill (2009). *Research methods for business students*. Pearson Education.
- [Shumway, 2001] Shumway, T. (2001). Forecasting bankruptcy more accurately: A simple hazard model. *The Journal of Business*, 74(1):101–124.

- [SSB, 2022a] SSB (2022a). Konkurser, etter næring (sn2007), organisasjonsform, statistikkvariabel og kvartal. [Hentet 05.05.2022] <https://www.ssb.no/statbank/table/07165/chartViewColumn/>.
- [SSB, 2022b] SSB (2022b). Opna konkursar. [Hentet 27.02.2022] <https://www.ssb.no/statbank/table/10790/tableViewLayout1/>.
- [SSB, 2022c] SSB (2022c). Overnattings- og serveringsvirksomhet. hovedtall. foreløpige tall, etter næring (sn2007), statistikkvariabel og år. [Hentet 10.03.2022] <https://www.ssb.no/statbank/table/07439/tableViewLayout1/>.
- [Store Norske Leksikon, 2022] Store Norske Leksikon (2022). Validitet. [Hentet 21.05.2022] <https://snl.no/validitet>.
- [Sutton, 2005] Sutton, C. (2005). Classification and regression trees, bagging, and boosting. *Handbook of Statistics*, 24:303–329.
- [Talberg et al., 2008] Talberg, M., Winge, C., Frydenberg, S., and Westergaard, S. (2008). Capital structure across industries. *International Journal of the Economics of Business*, 15(2):181–200.
- [Tian et al., 2015] Tian, S., Yu, Y., and Guo, H. (2015). Variable selection and corporate bankruptcy forecasts. *Journal of Banking Finance*, 52(1):89–100.
- [Titman and Wessels, 1988] Titman, S. and Wessels, R. (1988). The determinants of capital structure choice. *The Journal of Finance*, 43(1):1–19.
- [Upneja and Dalbor, 2001] Upneja, A. and Dalbor, M. (2001). An examination of capital structure in the restaurant industry. *International Journal of Contemporary Hospitality Management*, 13(2):54–59.
- [Wahlstrøm, 2022] Wahlstrøm, R. R. (2022). Financial statements of companies in norway. DOI: 10.48550/arXiv.2203.12842.



# A Appendiks

## A.1 Komplette resultater for AUC, NR og variablenes forklaringskraft: regresjon og variabler fra variabelsett 1

Variabelsett 1	Hele perioden							Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	
<i>AUC (Trening)</i>	0,795	0,811	0,798	0,806	0,803	0,801	0,809	0,803
<i>AUC (Test)</i>	0,811	0,815	0,787	0,816	0,801	0,805	0,806	0,806
<i>NR (Trening)</i>	0,590	0,622	0,596	0,612	0,606	0,602	0,618	0,607
<i>NR (Test)</i>	0,622	0,630	0,574	0,632	0,602	0,610	0,612	0,612
<i>V1</i>	-0,081	-0,095	-0,044	-0,079	-0,099	-0,121	-0,104	-0,089
<i>V2</i>	0,012	0,076	0,002	-0,006	0,085	0,066	0,098	0,048
<i>V3</i>	-0,762	-0,754	-0,766	-0,772	-0,764	-0,786	-0,746	-0,764
<i>V4</i>	0,096	0,264	0,246	0,216	0,201	0,222	0,237	0,212
<i>V5</i>	0,231	0,224	0,212	0,194	0,199	0,172	0,169	0,200
<i>V6</i>	0,142	0,172	0,162	0,190	0,267	0,115	0,198	0,178
<i>V7</i>	-0,554	-0,567	-0,581	-0,543	-0,537	-0,530	-0,582	-0,556
<i>Intercept</i>	-3,943	-3,713	-3,759	-3,722	-3,714	-3,780	-3,710	-3,763

Variabelsett 1	Høykonjunktur						Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	
<i>AUC (Trening)</i>	0,807	0,773	0,772	0,812	0,799	0,800	0,794
<i>AUC (Test)</i>	0,745	0,809	0,812	0,785	0,816	0,795	0,794
<i>NR (Trening)</i>	0,614	0,546	0,544	0,624	0,598	0,600	0,588
<i>NR (Test)</i>	0,490	0,618	0,624	0,570	0,632	0,590	0,587
<i>V1</i>	-0,173	-0,122	-0,036	-0,082	-0,090	0,019	-0,081
<i>V2</i>	0,020	0,075	0,211	0,001	-0,019	0,046	0,056
<i>V3</i>	-0,764	-0,700	-0,653	-0,780	-0,732	-0,648	-0,713
<i>V4</i>	0,096	0,002	0,138	0,048	0,154	0,163	0,100
<i>V5</i>	0,324	0,276	0,221	0,243	0,179	0,176	0,236
<i>V6</i>	0,149	0,124	0,220	0,198	0,159	0,244	0,182
<i>V7</i>	-0,593	-0,513	-0,562	-0,637	-0,613	-0,600	-0,586
<i>Intercept</i>	-4,261	-3,836	-3,997	-4,135	-3,860	-3,672	-3,960

<b>Variabelsett 1</b>	<b>Lavkonjunktur</b>		
	<i>Fold 1</i>	<i>Fold 2</i>	<b>Gjennomsnitt</b>
<i>AUC (Trening)</i>	0,803	0,801	0,802
<i>AUC (Test)</i>	0,803	0,806	0,805
<i>NR (Trening)</i>	0,606	0,602	0,604
<i>NR (Test)</i>	0,606	0,612	0,609
<i>V1</i>	0,000	0,032	0,016
<i>V2</i>	-0,077	0,000	-0,038
<i>V3</i>	-0,811	-0,784	-0,797
<i>V4</i>	0,010	0,000	0,005
<i>V5</i>	0,184	0,228	0,206
<i>V6</i>	0,217	0,245	0,231
<i>V7</i>	-0,484	-0,467	-0,475
<i>Intercept</i>	-3,597	-3,665	-3,631

## A.2 Komplette resultater for AUC, NR og variablenes forklaringskraft: XGBoost og variabler fra variabelsett 1

Variabelsett 1	Hele perioden							Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	
<i>AUC (Trening)</i>	0,795	0,782	0,802	0,801	0,784	0,801	0,808	0,796
<i>AUC (Test)</i>	0,778	0,829	0,768	0,778	0,790	0,802	0,793	0,791
<i>NR (Trening)</i>	0,590	0,564	0,604	0,602	0,568	0,602	0,616	0,592
<i>NR (Test)</i>	0,556	0,658	0,536	0,556	0,580	0,604	0,586	0,582
<i>V1</i>	0,119	0,085	0,138	0,115	0,078	0,172	0,178	0,126
<i>V2</i>	0,353	0,316	0,336	0,397	0,353	0,298	0,280	0,333
<i>V3</i>	0,043	0,056	0,025	0,004	0,051	0,030	0,018	0,032
<i>V4</i>	0,111	0,175	0,137	0,118	0,093	0,094	0,120	0,121
<i>V5</i>	0,156	0,168	0,151	0,134	0,169	0,174	0,148	0,157
<i>V6</i>	0,059	0,040	0,098	0,105	0,078	0,128	0,128	0,091
<i>V7</i>	0,159	0,160	0,138	0,127	0,178	0,104	0,129	0,142

Variabelsett 1	Høykonjunktur						Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	
<i>AUC (Trening)</i>	0,791	0,804	0,799	0,796	0,802	0,807	0,800
<i>AUC (Test)</i>	0,776	0,808	0,786	0,779	0,778	0,781	0,785
<i>NR (Trening)</i>	0,582	0,608	0,598	0,592	0,604	0,614	0,600
<i>NR (Test)</i>	0,552	0,616	0,572	0,558	0,556	0,562	0,569
<i>V1</i>	0,199	0,148	0,191	0,151	0,163	0,106	0,159
<i>V2</i>	0,229	0,221	0,237	0,468	0,228	0,217	0,267
<i>V3</i>	0,036	0,005	0,000	0,000	0,021	0,036	0,016
<i>V4</i>	0,096	0,185	0,096	0,108	0,109	0,184	0,130
<i>V5</i>	0,263	0,193	0,208	0,122	0,200	0,121	0,184
<i>V6</i>	0,089	0,095	0,094	0,089	0,137	0,150	0,109
<i>V7</i>	0,089	0,153	0,175	0,076	0,142	0,187	0,137

<b>Variabelsett 1</b>	<b>Lavkonjunktur</b>		
	<i>Fold 1</i>	<i>Fold 2</i>	<b>Gjennomsnitt</b>
<i>AUC (Trening)</i>	0,819	0,82	0,820
<i>AUC (Test)</i>	0,775	0,78	0,778
<i>NR (Trening)</i>	0,638	0,640	0,639
<i>NR (Test)</i>	0,550	0,562	0,556
<i>V1</i>	0,100	0,012	0,056
<i>V2</i>	0,332	0,238	0,285
<i>V3</i>	0,036	0,023	0,030
<i>V4</i>	0,091	0,139	0,115
<i>V5</i>	0,142	0,241	0,191
<i>V6</i>	0,086	0,140	0,113
<i>V7</i>	0,212	0,176	0,194

### A.3 Komplette resultater for AUC, NR og variablenes forklaringskraft: regresjon og variabler fra variabelsett 2

Variabelsett 2	Hele perioden							Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	
<i>AUC (Trening)</i>	0,823	0,837	0,837	0,829	0,830	0,820	0,829	0,829
<i>AUC (Test)</i>	0,839	0,840	0,798	0,815	0,821	0,832	0,834	0,826
<i>NR (Trening)</i>	0,646	0,674	0,674	0,658	0,660	0,640	0,658	0,659
<i>NR (Test)</i>	0,678	0,680	0,596	0,630	0,642	0,664	0,668	0,651
<i>Z1</i>	0,246	0,217	0,251	0,218	0,228	0,228	0,202	0,227
<i>Z2</i>	0,600	0,706	0,654	0,596	0,455	0,456	0,547	0,573
<i>Z3</i>	-0,156	-0,120	-0,128	-0,064	-0,185	-0,147	-0,108	-0,130
<i>Z4</i>	-0,082	0,604	0,860	0,695	-0,160	-0,109	-0,118	0,241
<i>Z5</i>	0,195	0,250	0,244	0,260	0,250	0,301	0,272	0,253
<i>Z6</i>	0,102	0,624	0,893	0,718	0,094	0,034	-0,041	0,346
<i>Z7</i>	-0,046	-0,015	0,097	0,087	0,020	-0,017	-0,022	0,015
<i>Z8</i>	-0,570	-0,610	-0,627	-0,610	-0,593	-0,534	-0,469	-0,573
<i>Z9</i>	0,105	0,077	0,087	0,064	0,038	0,040	0,081	0,070
<i>Z10</i>	-0,139	-0,084	-0,117	-0,161	-0,268	-0,243	-0,268	-0,183
<i>Intercept</i>	-3,729	-3,925	-3,956	-3,946	-3,912	-3,934	-3,954	-3,908

Variabelsett 2	Høykonjunktur						Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	
<i>AUC (Trening)</i>	0,838	0,809	0,811	0,844	0,830	0,819	0,825
<i>AUC (Test)</i>	0,783	0,839	0,845	0,795	0,823	0,832	0,820
<i>NR (Trening)</i>	0,676	0,618	0,622	0,688	0,660	0,638	0,650
<i>NR (Test)</i>	0,566	0,678	0,690	0,590	0,646	0,664	0,639
<i>Z1</i>	0,349	0,238	0,196	0,267	0,244	0,179	0,245
<i>Z2</i>	0,571	0,521	0,529	0,637	0,529	0,396	0,531
<i>Z3</i>	-0,134	-0,078	-0,033	-0,094	-0,183	-0,113	-0,106
<i>Z4</i>	-0,101	-0,050	0,555	0,956	-0,127	-0,131	0,184
<i>Z5</i>	0,200	0,158	0,253	0,257	0,214	0,293	0,229
<i>Z6</i>	0,098	0,060	0,554	0,989	0,128	0,060	0,315
<i>Z7</i>	0,029	-0,050	-0,026	0,168	0,058	-0,020	0,027
<i>Z8</i>	-0,599	-0,559	-0,599	-0,634	-0,571	-0,596	-0,593
<i>Z9</i>	0,184	0,105	0,095	0,078	0,028	0,033	0,087
<i>Z10</i>	-0,053	-0,213	-0,171	-0,147	-0,200	-0,298	-0,180
<i>Intercept</i>	-3,740	-3,548	-3,691	-3,984	-3,932	-3,893	-3,798

<b>Variabelsett 2</b>	<b>Lavkonjunktur</b>		
	<i>Fold 1</i>	<i>Fold 2</i>	<b>Gjennomsnitt</b>
<i>AUC (Trening)</i>	0,839	0,825	0,832
<i>AUC (Test)</i>	0,812	0,826	0,819
<i>NR (Trening)</i>	0,678	0,650	0,664
<i>NR (Test)</i>	0,624	0,652	0,638
<i>Z1</i>	0,232	0,256	0,244
<i>Z2</i>	0,713	0,582	0,647
<i>Z3</i>	-0,266	-0,195	-0,230
<i>Z4</i>	-0,104	-0,105	-0,105
<i>Z5</i>	0,221	0,242	0,231
<i>Z6</i>	0,147	0,110	0,128
<i>Z7</i>	-0,049	0,011	-0,019
<i>Z8</i>	-0,570	-0,473	-0,522
<i>Z9</i>	0,049	0,066	0,057
<i>Z10</i>	-0,101	-0,132	-0,117
<i>Intercept</i>	-3,916	-3,973	-3,944

A.3.1 Komplette resultater for AUC, NR og variablenes forklaringskraft: XG-Boost og variabler fra variabelsett 2

Variabelsett 2	Hele perioden							Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	Fold 7	
<i>AUC (Trening)</i>	0,808	0,817	0,806	0,807	0,816	0,797	0,818	0,810
<i>AUC (Test)</i>	0,801	0,821	0,793	0,797	0,782	0,802	0,809	0,801
<i>NR (Trening)</i>	0,616	0,634	0,612	0,614	0,632	0,594	0,636	0,620
<i>NR (Test)</i>	0,602	0,642	0,586	0,594	0,564	0,604	0,618	0,601
<i>Z1</i>	0,185	0,110	0,155	0,132	0,118	0,202	0,154	0,151
<i>Z2</i>	0,103	0,183	0,159	0,188	0,133	0,086	0,090	0,135
<i>Z3</i>	0,071	0,113	0,061	0,050	0,091	0,071	0,136	0,085
<i>Z4</i>	0,280	0,163	0,224	0,186	0,223	0,262	0,221	0,223
<i>Z5</i>	0,077	0,095	0,771	0,120	0,097	0,106	0,111	0,197
<i>Z6</i>	0,071	0,063	0,079	0,076	0,058	0,043	0,031	0,060
<i>Z7</i>	0,002	0,002	0,001	0,002	0,000	0,000	0,003	0,001
<i>Z8</i>	0,165	0,211	0,195	0,188	0,185	0,168	0,166	0,183
<i>Z9</i>	0,029	0,021	0,016	0,025	0,034	0,015	0,022	0,023
<i>Z10</i>	0,016	0,038	0,034	0,033	0,060	0,047	0,066	0,042

Variabelsett 2	Høykonjunktur						Gjennomsnitt
	Fold 1	Fold 2	Fold 3	Fold 4	Fold 5	Fold 6	
<i>AUC (Trening)</i>	0,795	0,836	0,850	0,834	0,861	0,807	0,831
<i>AUC (Test)</i>	0,791	0,814	0,821	0,780	0,801	0,775	0,797
<i>NR (Trening)</i>	0,590	0,672	0,700	0,668	0,722	0,614	0,661
<i>NR (Test)</i>	0,582	0,628	0,642	0,560	0,602	0,550	0,594
<i>Z1</i>	0,227	0,186	0,161	0,271	0,141	0,079	0,178
<i>Z2</i>	0,050	0,061	0,078	0,004	0,043	0,001	0,039
<i>Z3</i>	0,087	0,082	0,197	0,083	0,105	0,147	0,117
<i>Z4</i>	0,283	0,275	0,155	0,236	0,243	0,244	0,239
<i>Z5</i>	0,089	0,082	0,123	0,069	0,119	0,150	0,105
<i>Z6</i>	0,067	0,063	0,068	0,053	0,066	0,074	0,065
<i>Z7</i>	0,000	0,000	0,024	0,000	0,004	0,001	0,005
<i>Z8</i>	0,148	0,178	0,141	0,227	0,174	0,211	0,180
<i>Z9</i>	0,046	0,038	0,032	0,009	0,039	0,058	0,037
<i>Z10</i>	0,003	0,034	0,045	0,004	0,066	0,036	0,031

<b>Variabelsett 2</b>	<b>Lavkonjunktur</b>		
	<i>Fold 1</i>	<i>Fold 2</i>	<b>Gjennomsnitt</b>
<i>AUC (Trening)</i>	0,817	0,824	0,821
<i>AUC (Test)</i>	0,801	0,781	0,791
<i>NR (Trening)</i>	0,634	0,648	0,641
<i>NR (Test)</i>	0,602	0,562	0,582
<i>Z1</i>	0,192	0,154	0,173
<i>Z2</i>	0,095	0,167	0,131
<i>Z3</i>	0,113	0,060	0,087
<i>Z4</i>	0,087	0,199	0,143
<i>Z5</i>	0,093	0,141	0,117
<i>Z6</i>	0,115	0,044	0,079
<i>Z7</i>	0,000	0,000	0,000
<i>Z8</i>	0,180	0,114	0,147
<i>Z9</i>	0,054	0,026	0,040
<i>Z10</i>	0,071	0,096	0,084



#### A.4 Filtrering av datasett

<b>Kategori</b>	<b>Kriterium</b>
Organisasjonsform	AS
Sum eiendeler	> 500 000
Næringskode	56
Landskode	NO
Siste regnskapsår	2017

## A.5 Variabelsett 1, basert på Norges Banks SEBRA-modell

Her følger en mer utdypende beskrivelse av de syv forklaringsvariablene i variabelsett 1.

### Resultat (V1)

Variabel V1 viser til ordinært resultat før av- og nedskrivning i prosent av den totale gjelden.

$$\frac{\text{Ordinært resultat før av- og nedskrivninger}}{\text{Sum gjeld}}$$

### Egenkapitalprosent (V2)

Summen av gjeld og egenkapital gir totalkapitalen. Egenkapital i prosent av totalkapitalen beregnes på følgende måte:

$$\frac{\text{Sum egenkapital}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

### Innskutt egenkapital (V3)

Innskutt egenkapital er en dummyvariabel som koder 1 dersom innskutt egenkapital er mindre enn sum egenkapital. Hvis innskutt egenkapital er større enn sum egenkapital, er V3 lik 0. Variabelen beregnes på følgende måte:

$$\text{Innskutt egenkapital (V3)} = \text{Sum innskutt egenkapital} < \text{Sum egenkapital} = 1, \text{ ellers } 0$$

Ifølge [Eklund et al., 2001] viser dummyvariabelen innskutt egenkapital til om hvorvidt selskapet har et bokført tap. Egenkapitalens sammensetning vil vise om hvorvidt den gitte egenkapitalandelen kommer av akkumulert inntjening eller om det er innskutt egenkapital.

### Likviditetsprosent (V4)

Likviditetsprosenten beregnes på følgende måte:

$$\frac{\text{Sum bankinndkudd, kontanter og lignende} - \text{Sum kortsiktig gjeld}}{\text{Sum driftsinntekter}}$$

### **Leverandørgjeld (V5)**

Variabelen leverandørgjeld viser til leverandørgjeldsprosenten, og blir beregnet på følgende måte:

$$\frac{\text{Leverandørgjeld}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

Leverandørgjeldsprosenten viser til en virksomhets likviditet.

### **Avgiftsprosent (V6)**

Variabelen avgiftsprosent blir beregnet som følgende:

$$\frac{\text{Skyldige offentlige avgifter}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

### **Logaritme av alder (V7)**

I denne oppgaven blir benyttes logaritmen av selskapets alder. Virksomhetenes alder er antall år den har eksistert ved utgangen av det gitte regnskapsåret. Det vil si, det er den differansen mellom selskapets stiftelsesdata og 31. desember i det gitte året.

$$\text{Logaritme av alder (V7)} = \text{Log}(\text{alder i antall år})$$

## A.6 Variabelsett 2, basert på studien til [Paraschiv et al., 2021]

**Likviditet (Z1)** Variabelen Z1 viser leverandørgjeld i prosent av egenkapitalen, og beregnes på følgende måte:

$$\frac{\text{Leverandørgjeld}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

**Gjeld (Z2)** Dummy-variabelen Z2 indikerer om hvorvidt selskapets totale gjeld er større enn totale eiendeler. Er verdien på gjelden større enn totale eiendeler, vil dummy-variabelen kode 1. Variabelen beregnes på følgende måte:

$$\text{Sum gjeld er større enn sum eiendeler} = 1, \text{ ellers } 0$$

**Gjeld (Z3)** Variabelen Z3 viser til kortsiktig gjeld i prosent av totalkapitalen. Variabelen beregnes på følgende måte:

$$\frac{\text{Sum kortsiktig gjeld} - \text{sum bankinnskudd kontanter og lignende}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

**Lønnsomhet (Z4)** Variabelen Z4 viser årsresultatet i prosent av totalkapitalen:

$$\frac{\text{Årsresultat}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

**Likviditet (Z5)** Variabelen Z5 viser til skyldige offentlige avgifter i prosent av totalkapitalen:

$$\frac{\text{Skyldige offentlige avgifter}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

**Soliditet (Z6)** Variabelen Z6 viser til annen rentekostnad i prosent av totalkapitalen. Variabelen beregnes på følgende måte:

$$\frac{\text{Annen rentekostnad}}{\text{Sum egenkapital} + \text{Sum gjeld}}$$

**Soliditet (Z7)** Variabelen Z7 er en dummy-variabel som koder 1 hvis innskutt egenkapital er mindre enn total egenkapital. Variabelen beregnes på følgende måte:

$$\text{Sum innskutt egenkapital} < \text{Sum egenkapital} + \text{Sum gjeld} = 1, \text{ eller } 0$$

Ifølge [Eklund et al., 2001] viser dummyvariabelen innskutt egenkapital til om hvorvidt selskapet har et bokført tap. Egenkapitalens sammensetning vil vise om den gitte egenkapitalandelen kommer av akkumulert inntjening eller om det er innskutt egenkapital.

**Alder (Z8)** For variabel Z8 brukes logaritmen av selskapets alder. Virksomhetenes alder er antall år virksomheten har eksistert ved utgangen av det gitte regnskapsåret. Det vil si, det er den differansen mellom selskapets stiftelsesdato, og 31. desember for det gitte året.

$$Z8 = \text{Logaritmen av selskapets alder i antall år}$$

**Likviditet (Z9)** Variabelen Z9 viser til varerlager i prosent av omløpsmidler. Variabelen beregnes på følgende måte:

$$\frac{\text{Sum varer}}{\text{Sum omløpsmidler}}$$

**Likviditet (Z10)** Variabelen Z10 viser til bankinnskudd, kontanter og lignende i prosent av omløpsmidler. Variabelen beregnes på følgende måte:

$$\frac{\text{Sum bankinnskudd, kontanter og lignende}}{\text{Sum omløpsmidler}}$$