



Prediksjoner av vekt- og kvalitetsfordeling for slaktevolum i oppdrettsnæringen

*En omfattende test av dyp læring og nevralt nettverk for prediktive
formål i norsk akvakultur*

Didrik Nygaard & Njål Slettebak Vågen

Veiledere: Sturla F. Kvamsdal & Leif Kristoffer Sandal

Masteroppgave, Økonomi og administrasjon,
Business Analytics

NORGES HANDELSHØYSKOLE

Dette selvstendige arbeidet er gjennomført som ledd i masterstudiet i økonomi- og administrasjon ved Norges Handelshøyskole og godkjent som sådan. Godkjenningen innebærer ikke at Høyskolen eller sensorer innestår for de metoder som er anvendt, resultater som er fremkommet eller konklusjoner som er trukket i arbeidet.

Forord

Denne masteroppgaven er skrevet som et avsluttende ledd i masterstudiet ved Norges Handelshøyskole våren 2020. Oppgaven er skrevet med utgangspunkt i vår hovedprofil, Business Analytics.

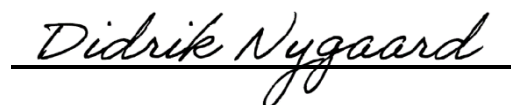
Gjennom mastergraden har det spesielt vært fokus på hvordan bedrifter kan omdanne data til nyttig informasjon og herav optimalisere driften, noe vi i vår masteroppgave ønsket å kombinere med en stor og voksende interesse for norsk akvakultur. Arbeidet med oppgaven har vært både utfordrende og lærerikt. Den mest utfordrende delen har vært å forstå og anvende de siste nyvinningene innenfor maskinlæring og nevralt nettverk, for å videre kunne implementere dette i oppdrettsnæringen.

Vi vil takke Frode Sandvik fra Svanøy Havbruk AS for å ha stilt tilgjengelige data til rådighet, for en innføring i deres produksjonsprosess og verdikjede, og for å ha besvart alle våre spørsmål.

Til slutt vil vi takke våre veiledere Sturla F. Kvamsdal og Leif Kristoffer Sandal for gode diskusjoner, samt kontinuerlige og konstruktive tilbakemeldinger.

Norges Handelshøyskole

Bergen, juni 2020



Didrik Nygaard



Njål Slettebak Vågen

Abstrakt

I denne oppgaven undersøker vi om nevralt nettverk kan forbedre prediksjon av vekt- og kvalitetsfordeling for slaktevolumet for matfisk, og hva følgene vil kunne være av en slik implementering. Nevrale nettverk benyttes i dag i en rekke bransjer på et bredt spektrum av problemer, hvor prediksjoner er et analyseområde hvor metoden har vist vellykkede resultater. Vi ser derfor på mulighetene for anvendelse av metoden på et konkret prediksjonsproblem innen en av Norges største eksportnæringer.

Oppbygging og anvendelse av prediksjonsmetoden er gjennomført med bakgrunn i teori og etablert praksis for fagfeltet maskinlæring. En mengde ulike nettverksstrukturer er utprøvd og validert, hvor strukturen med best resultat er benyttet for prediksjoner på usett data. Diskusjonsdelen i oppgaven tar for seg hovedfunnene for vårt nevralt nettverk, og hvordan vår modell gjør det sammenlignet med andre prediksjoner. Videre diskuteres mulige utbedringer, utvikling og påfølgende anvendelser av metoden.

Opgaven konkluderer med at et lite datagrunnlag i næringen per dags dato gjør at nevralt nettverk ikke vil forbedre eksisterende prediksjoner for vekt- og kvalitetsfordeling for matfisk. Vi konkluderer samtidig med at potensielle gevinster av en vellykket implementering vil kunne være store, både for salgs- og produksjonsleddet i verdikjeden. Oppgaven kommer også med konkrete forslag til hvordan næringen kan og bør opparbeide seg et tilstrekkelig datagrunnlag, og dermed muliggjøre implementering av modeller som nevralt nettverk.

Nøkkelord – Maskinlæring, Dyp læring, Nevrale nettverk, Flertype klassifisering, Norsk akvakultur, Oppdrettsnæring, Matfisk.

Innholdsfortegnelse

1	Innledning.....	1
1.1	Motivasjon.....	1
1.2	Problemstilling	3
1.3	Oppgavens struktur	3
2	Bakgrunn	4
2.1	Norsk akvakultur	4
2.1.1	Merd, lokalitet og oppdrett	4
2.1.2	Konsesjoner og maksimalt tillatt biomasse (MTB)	5
2.2	Oppdrettsnæringen	6
2.2.1	Produksjonsprosessen	7
2.2.2	Biomassemåling.....	8
2.2.3	Vektinndeling og kvalitetsklassifisering.....	9
2.2.4	Avvik i antall, vekt og vektfordeling	10
2.2.5	Potensielle gevinster	11
2.3	Nevrale nettverk	14
2.3.1	Maskinlæring og dyp læring	14
2.3.2	Styrker.....	15
2.3.3	Svakheter.....	16
2.4	Problemforklaring	17
2.5	Avgrensninger	18
3	Teori	19
3.1	Nevrale nettverk	19
3.1.1	Nevroner og perceptron	19
3.1.2	Flerlagsperceptron og nevralt nettverk.....	20
3.1.3	Aktiveringsfunksjon og normalisering	22
3.1.4	Tapsfunksjon og optimalisering.....	23
3.1.5	Nøyaktighet.....	24
3.1.6	Hyperparametre og kapasitet	25

3.1.7	Ensembler	26
3.2	Eksisterende modeller og prediksjoner i norsk akvakultur	27
3.2.1	Vekstmodeller og veksttabeller.....	27
3.2.2	Eksisterende prediksjoner	29
4	Data	32
4.1	Datasett.....	32
4.1.1	Produksjonsdata	32
4.1.2	Slakterapporter	32
4.2	Preprosessering av datasett.....	33
4.2.1	Inputvariabler	33
4.2.2	Outputvariabler	34
4.2.3	Endelig datasett.....	35
4.3	Beskrivende statistikk	35
5	Metode.....	37
5.1	Evaluering av modell	37
5.1.1	Oppdeling av datasett i trening og test.....	37
5.1.2	Dilemma omkring bias og varians	38
5.1.3	Nøyaktighet.....	42
5.2	Eksisterende prediksjoner og avvik	42
5.2.1	Gjennomsnittsfordelingen for slaktet fisk.....	43
5.3	Design av nevralt nettverk.....	44
5.3.1	Input og normalisering.....	44
5.3.2	Kryssvalidering	44
5.3.3	Lag og nevroner	45
5.3.4	Læringsrate og forfallsfrekvens	45
5.3.5	Antall modeller i hvert ensemble	46
5.3.6	Sammensetning.....	47
5.4	Endelig oppsett.....	47
5.5	Implementering med R.....	48

6	Resultater	49
6.1	Evaluere validering	49
6.2	Evaluere test.....	51
7	Diskusjon	53
7.1	Hovedfunn.....	53
7.1.1	Sammenligning av validering og test.....	53
7.1.2	Sammenligne med Svanøy.....	54
7.1.3	Svakheter ved måltallet.....	55
7.1.4	Oppsummering og videre diskusjon	56
7.2	Datagrunnlag	56
7.2.1	Datarapportering	57
7.2.2	Dataformat	60
7.2.3	MTB.....	60
7.3	Forutsetninger.....	61
7.3.1	Standardisering av data.....	62
7.3.2	Sentralisering og synliggjøring av kostnader.....	63
7.3.3	Pågående prosjekter	63
7.4	Ytterligere data.....	64
7.4.1	Ny sensorteknologi	64
7.4.2	Biomasserammer.....	65
7.4.3	Miljø.....	66
7.5	Modellen ved oppfylte forutsetninger	66
7.5.1	Variabeltilpasning.....	66
7.5.2	Kryssvalidering	67
7.5.3	Sesongvariasjoner	67
7.5.4	Videreføring av vår metode	67
7.6	Potensielle gevinster ved vellykket implementering.....	68
7.6.1	Salg	68
7.6.2	Produksjon	69
7.6.3	Lønnsomhet og driftsmarginer.....	70

7.7	Metodiske utfordringer.....	70
8	Konklusjon	72
Kilder	73
Appendiks	82
Appendiks A	Bakgrunn	83
Appendiks B	Datsett	86
Appendiks C	Beskrivende statistikk.....	89
Appendiks D	Tilpasning av nevralt nettverk	92
Appendiks E	Resultater	95
Appendiks F	Potensielle gevinster	99

Figurliste

Figur 2.1: Sammenhengen mellom et oppdrett, lokaliteter og merder.	5
Figur 2.2: Antall konsesjoner i drift per år i perioden 2008-2018 (SSB, 2019).	6
Figur 2.3: Biomasseestimering gjennom produksjonsprosessen for matfisk (Høy, Sunde, & Bjelland, 2013).	9
Figur 2.4: Fordeling av prosent feil i estimering av antall, snittvekt og total biomasse ved slaktetidspunktet, for EXACTUS-prosjektet (Høy, Sunde, & Bjelland, 2013).	11
Figur 2.5: Maskinlæring, en ny struktur for programmering (Chollet & Allaire, 2018).	15
Figur 3.1: Et perceptron med input- og outputlag (Rosenblatt, 1958).	20
Figur 3.2: Et flerlagsperceptron med to skjulte lag, samt input- og outputlag.	21
Figur 4.1: Vekt- og kvalitetsfordeling for det endelige datasettet fra Svanøy.	36
Figur 5.1: Illustrasjon for oppdeling av datasett i trening, validering og test for tidsserie kryssvalidering.	38
Figur 5.2: Illustrasjon av trade-off mellom bias og varians (Almaliki, 2018).	40
Figur 5.3: Illustrasjon av hvordan en bør balansere en modell mellom undertilpasning og overtilpasning (Almaliki, 2018).	41
Figur 5.4: Illustrasjon av ensemblene som består av mellom 1 og 30 modeller, hvor ensemble 1 består av 1 modell og ensemble 30 av 30 modeller.	46
Figur 5.5: Modellarkitekturen for det endelige oppsettet av vårt nevrale nettverk.	47
Figur 6.1: Utviklingen i gjennomsnittlig nøyaktighet for modellene, samt nøyaktigheten for ensemblet ved inkludering av flere modeller, for vår valideringsdel.	49

Figur 6.2: Utvikling i tap (Kullback-Leibler divergens) ved trening av de syv modellene som er inkludert i vårt ensemble.....	51
Figur 6.3: Utviklingen i gjennomsnittlig nøyaktighet for modellene, samt nøyaktigheten for ensemblet ved inkludering av flere modeller, for vår testdel.....	52
Figur 7.1: Strukturen for datarapportering mellom Svanøy Havbruk AS, Skaar Norway AS og Slakteriet AS.	58
Figur 7.2: Strukturen for datarapportering mellom Ocean Quality, Grieg Seafood ASA og deres slakteri.....	59

Tabelliste

Tabell 2.1: Vekt- og kvalitetsklassifisering for matfisk (United States International Trade Commission, 1990).....	10
Tabell 3.1: Tilveksttabell for regnbueørret. Tilvekst (prosent per dag) og <i>FFbio</i> (biologisk førfaktor ved temperatur 8-10 °C) (Skretting Norge, 2012).	28
Tabell 4.1: Beskrivende statistikk for inputvariablene Dag, Tid, UBvekt og TTotal.....	35
Tabell 4.2: Beskrivende statistikk for outputvariablene for kvaliteten SUP.	36
Tabell 5.1: Gjennomsnittsfordelingen til Svanøy basert på treningsdelen av datasettet.	43
Tabell 5.2: Gjennomsnittsfordelingen til Svanøy basert på trening- og valideringsdelen av datasettet.	44
Tabell 5.3: De ulike kombinasjonene benyttet for valg av læringsrate og forfallsfrekvens. *Viser standardinnstillinger for Adam	46
Tabell 6.1: Resultatene for valideringsdelen for vårt ensemble av modeller, med Svanøy sitt resultat basert på gjennomsnittsfordelingen for samme delen av datasettet.	50
Tabell 6.2: Resultatene for testdelen for vårt ensemble av modeller, med Svanøy sitt resultat basert på gjennomsnittsfordelingen for samme delen av datasettet.	51
Tabell 7.1: De potensielle gevinstene forbundet med mer presise prediksjoner. Feilestimering er her gitt som ny prosent feilestimering, altså vil 4 % representere potensielle gevinster for et prosentpoeng forbedring fra dagens 5 % feilestimering.	69

1 Innledning

1.1 Motivasjon

Algoritmer har gjennom historien hjulpet mennesket med å finne løsninger på små og store problemer. Fra babylonerne som fant kvadratrøtter for hånd, via de greske matematikerne sine tilnærminger til pi, via britenes dechiffrering under andre verdenskrig, til dagens algoritmer som slår verdens beste spillere i sjakk. I senere tid har bruken av algoritmer fulgt teknologiutviklingen og algoritmene er mer avanserte enn noen gang. Mye av denne utviklingen er drevet av 'big data' og muligheten til lagring, bearbeiding og analyse av store mengder data. Introduksjonen av 'big data' i samfunnet, både i privatlivet og i næringslivet, utvider horisonten for hva algoritmer og maskinlæring kan gi svar på.

Anvendelsesområdene er mange. I kriminalsaker, kan dommere ta i bruk risikovurderingsverktøy for å vurdere fremtidig risiko for at en forbrytelse gjentar seg (Kehl, Kessler, & Guo, 2017). Algoritmer og maskinlæring kan også bli brukt som verktøy i helsesektoren for å bedre vurdere sykdommer, gjøre diagnostisering og ta beslutninger angående behandlinger (Bakkevoll, et al., 2018). Det mest kjente eksempelet for folk flest er kanskje Elon Musk og Tesla sine selvkjørende biler. Autopiloten i disse bilene drives av en mengde algoritmer, som trenes på data fra hele flåten av biler Tesla har rundt i verden (Tesla, u.d.). Underliggende for bruken av algoritmer er ideen om at datamaskiner kan prosessere strukturerte data i en mye større skala enn det et menneske har mulighet til. En datamaskin kan ikke utføre enhver jobb mennesket i dag utfører, men når forholdene legges til rette har datamaskiner i dag en regnekapasitet som overskrider menneskehjernen på isolerte problemer (Nedelkoska & Quintini, 2018)

Disse egenskapene vil i økende grad være med å forme en rekke næringer i tiden fremover. En av næringene hvor maskinlæring har potensial er akvakulturen. Norsk akvakultur, og havbruk generelt, blir ofte omtalt som et av de store industrieventyrene i norsk historie (Lekve, 2012). Men som næringer flest står også havbruket overfor store og små utfordringer. Lus og fiskerømming er gjengangere i media, men gjennom hele verdikjeden finnes det utfordringer en ønsker bedre løsninger på. En av de sentrale utfordringene er biomassemåling, som brukes som styringsverktøy i flere deler av verdikjeden. I produksjonen brukes biomassemåling til å

optimalisere fôring og fiskens vekstpotensial, for å tilpasse produksjonstid og minimere fôrspill. I salgsleddet brukes biomassekontroll til å sikre bedre priser og at fisken kan leveres som lovet, samt redusere eventuell håndtering av ordrekanselleringer, reforhandlinger eller gjensalg av kansellerte salg. I tillegg brukes målingene for å best mulig utnytte kapasitet på brønnbåt, i slakteri og for transport (Høy, Sunde, & Bjelland, 2013). utfordringene ligger i å ha kontroll på vekst, død, rømming, samt vekt- og kvalitetsfordeling for fisken fra den settes ut i oppdrettsanlegget til den slaktes. Det er flere faktorer som gjør dette utfordrende, noe vi vil komme nærmere inn på i bakgrunnen for oppgaven.

Basert på tall fra SINTEF klarer næringen å estimere biomasse for et helt oppdrettsanlegg med forholdsvis god presisjon. Det foreligger derimot større usikkerhet for biomassen i hver enkelt merd (Høy, Sunde, & Bjelland, 2013). Siden produksjonen gjerne styres for hver enkelt merd, vil feilestimert biomasse få betydelige konsekvenser. I en utredning gjennomført av SINTEF (2009) kommer det fram at produksjon, salg, slakt og foredling, alle opplever negative konsekvenser som følge av dette.

For produksjonen er det hovedsakelig fôringen som berøres. Suboptimal fôring har betydelige økonomiske konsekvenser, da fôring utgjør mer enn 50 prosent av den totale produksjonskostnaden for laks- og ørretoppdrett (SINTEF, 2009). Uten et godt estimat på hvor mye fisk det er i merden vil det være utfordrende å følge en fôringsplan som avhenger av biomassen. Suboptimal fôring har derfor en betydelig effekt på driftseffektiviteten til oppdrettet og nøyaktige målinger av biomasse er avgjørende for å få optimalisert dette. Dette er et av hovedmotivene for å bedre biomassekontrollen i merdene.

Et annet problem er hvordan biomassekontrollen påvirker salget. I dagens fiskemarked blir opptil 80 prosent av norsk laks solgt til spotpris basert på prediksjoner om slaktevolum omkring en uke fram i tid (SINTEF, 2009). Salgs- og eksportselskapene mottar prognoser fra oppdretterne på hvor mye fisk som skal slaktes gjennom den kommende uken og kontakter kunder og avtaler salg basert på disse prognosene. Det er derimot usikkerhet knyttet til nøyaktigheten i prognosene. Med opp til 200 000 fisk i hver merd er det utfordrende å holde oversikt både med gjennomsnittsstørrelse og størrelsesfordeling i merden (Høy, Sunde, & Bjelland, 2013). Dette får konsekvenser gjennom hele den resterende verdikjeden. Ved avvik i prognosene må avtaler reforhandles, kundeforholdet svekkes ved gjentatte avvik fra avtalt salg

og i verste fall kan salg kanselleres. Fisken må da selges på nytt og transport må omdirigeres. Prognoseavvik er dermed både ressurskrevende og fører til verditap i salgsledet.

I denne oppgaven skal vi utforske hvorvidt algoritmer og maskinlæring, mer spesifikt nevrale nettverk, kan brukes for å redusere avvikene mellom biomasseestimering og slaktetall. Maskinlæring omtales gjerne som den neste industrielle revolusjon, hvor nevrale nettverk er dampmaskinen. De siste årene har flere aktører forsøkt å angripe denne problemstillingen på ulike måter. SINTEF gjennomførte prosjekt EXACTUS over tre år, fra 2010 til og med 2012, som fokuserte på biomassekontroll. Som en del av konklusjonen kommer rapporten fra prosjektet med forslag til videre utvikling av kunnskap rundt problemet. Her er modellbasert estimering et av forslagene til verktøy som kan bidra til å løse problemet.

1.2 Problemstilling

I denne oppgaven skal vi undersøke hvordan nevrale nettverk kan benyttes for å predikere fordeling av vekt og kvalitet for slaktevolumet. Studien vår skiller seg fra andre implementeringer av nevrale nettverk ved at vi prøver å predikere fordelingen for et utvalg, uten data for hvert enkelt individ i utvalget. Bruken av nevrale nettverk gjør også at studien skiller seg fra annet arbeid i havbruksnæringen, da metoden for det meste er uprøvd.

Hovedproblemstillingen vår for denne oppgaven er: *Kan nevrale nettverk forbedre prediksjon av vekt- og kvalitetsfordeling for slaktevolumet for matfisk? Og hva vil følgene kunne være av en slik implementering?*

1.3 Oppgavens struktur

Oppgaven er delt inn i 8 kapitler. I kapittel 2 presenteres bakgrunn for oppgaven med hensyn til norsk akvakultur, men også med hensyn på de mulighetene som eksisterer innenfor nevrale nettverk. I kapittel 3 ser vi nærmere på teorien tilknyttet nevrale nettverk, før vi i kapittel 4 beskriver datasettet vi har hatt til rådighet og hvordan dette er preprosessert. I kapittel 5 går vi gjennom metoden vi benytter i studien. I kapittel 6 presenteres resultatet, før vi i kapittel 7 diskuterer resultatet og videre hva som kan være følgene av resultatene. Til slutt vil vi i kapittel 8 konkludere og svare på problemstillingen.

2 Bakgrunn

I denne delen presenterer vi først bakgrunnen for oppgaven med hensyn til norsk akvakultur. Dette gjør vi gjennom først å beskrive viktige begreper og definisjoner innenfor oppdrettsnæringen. Vi ser så nærmere på selve oppdrettsnæringen, produksjonsprosessen og hvordan vekt- og kvalitetsfordelingen er for fisk i næringen i dag. Videre går vi gjennom bakgrunnen for oppgaven med hensyn til nevralt nettverk, først generelt om nevralt nettverk, etterfulgt av hvilke muligheter, styrker og svakheter som kan følge med en slik modell. Avslutningsvis presenterer vi ytterligere bakgrunn for problemstillingen med hensyn til både norsk akvakultur og nevralt nettverk, før vi til slutt gjør nødvendige avgrensninger for oppgaven.

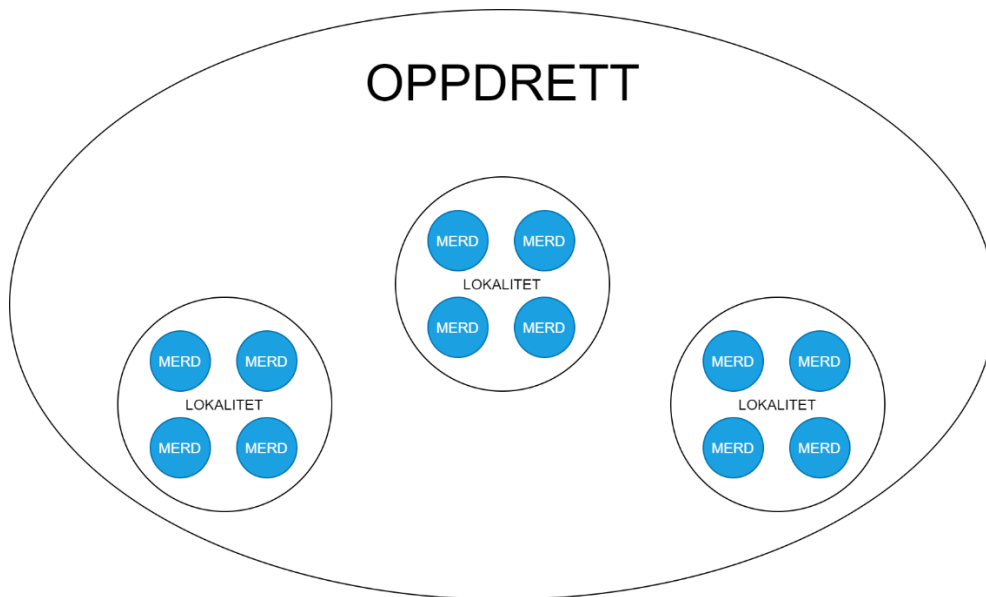
2.1 Norsk akvakultur

Vi vil i denne delen først introdusere sentrale begreper og definisjoner innenfor oppdrettsnæringen, som er essensielle både for bakgrunnen til oppgaven og oppgaven som helhet. En tydelig forståelse for disse begrepene og betydningen av disse innenfor næringen er viktig for å besvare vår problemstilling.

2.1.1 Merd, lokalitet og oppdrett

Bruk av åpen merd i sjø er den dominerende metoden for oppdrett i Norge. En merd er en stor nettkurv som henger ned i sjøen, festet til en flytende ring. En typisk ring i Norge har en omkrets på 160 meter (IntraFish, 2018b). Strømmer i sjøen sikrer at havvann flyter kontinuerlig gjennom merden og skaper et naturnært miljø for fisken. En ulempe med denne typen åpen merd er utveksling av smitte og avfallsstoffer til nærliggende miljø. Merden er også utsatt for naturkrefter og eventuelle skader på merden kan føre til rømming av fisk. Til tross for utfordringene er det fremdeles den foretrukne metoden for oppdrett (Espmark, 2019).

En eller flere merder vil sammen med en fôrflåte bygge opp en lokalitet. En lokalitet omfatter et avgrenset geografisk område i en fjord hvor en oppdretter har tillatelse til drift. Et oppdrettsanlegg kan gjerne ha flere lokaliteter, hvor en typisk lokalitet har en grense på 3 000 til 4 000 tonn biomasse (IntraFish, 2018b). Oppbyggingen av et oppdrett, med en rekke lokaliteter og merder, er presentert under i figur 2.1:



Figur 2.1: Sammenhengen mellom et oppdrett, lokaliteter og merder.


2.1.2 Konsesjoner og maksimalt tillatt biomasse (MTB)

Konsesjoner er juridiske rettigheter til å drive matfiskproduksjon i sjø. Matfisk er fisk produsert med sikte på slakting til konsum, og som ikke kommer inn under definisjonene for settefiskproduksjon og stamfisk (SSB, 1971). Konsesjonene kan beskrives som evigvarende rettigheter som fritt kan omsettes eller pantsettes. Hver enkelt tillatelse er avgrenset i maksimalt tillatt biomasse (MTB) på to nivåer; selskap- og lokalitetsnivå. For et selskap innebærer dette at en ikke på noe tidspunkt kan ha biomasse i sjøen som overstiger tillatt MTB på selskapsnivå. Tilsvarende kan ikke biomassen overstige den enkelte lokalitet sin fastsatte MTB (Osland, 2017). En konsesjon er normalt på 780 tonn MTB, med unntak av i Troms og Finnmark hvor en vanlig tillatelse er på 945 tonn MTB. En lokalitet vil derfor gjerne omfatte flere konsesjoner, da total MTB for en typisk lokalitet gjerne kan være på 3 000 – 4 000 tonn.

Dette MTB-regimet ble innført 1. januar 2005 og erstattet da et system som tidligere var basert på fôrvoter og avgrensning på merdvolum. Tildelingen av konsesjonene er en prosess som er delt i to trinn, hvor sluttproduktet er en rett til produksjon av bestemte arter, i et bestemt omfang, på bestemte lokaliteter. I første ledd er det Fiskeridirektoratet som tar stilling til hvilke søkere som skal få tilsagn om tillatelse. Ved konkurranse vil disse tilsagnene gjelde personvalget, men et slikt tilsagn gir ikke nødvendigvis rett til drift. I andre ledd er det en

koordinerende myndighet, per i dag fylkeskommunen, som behandler søknaden om godkjenningen av en lokalitet (Osland, 2017).

Av hensyn til blant annet miljø og marked, er det fra myndighetene sin side også gitt et maksimalt antall konsesjoner for å kontrollere veksten. Det er Fiskeridirektoratet som foretar utdeling av disse konsesjonene, men de må til enhver tid forholde seg til maksimalt tillatte konsesjoner (Osland, 2017). I 2018 var det totalt 1 160 konsesjoner i drift, og av figur 2.2 kan vi se at det har vært en jevn økning i antall konsesjoner i drift de siste årene (SSB, 2019).



Figur 2.2: Antall konsesjoner i drift per år i perioden 2008-2018 (SSB, 2019).

2.2 Oppdrettsnæringen

Oppdrettsnæringen innenfor norsk akvakultur er en av Norges viktigste næringer. Akvakulturen i Norge dreier seg i all hovedsak om laks, ørret og regnbueørret. Tall fra SSB (2019) viser at disse typene oppdrettsnæring innenfor akvakultur har stått for i overkant av 99 prosent av samlet slaktet matfisk i en årrekke. Andre fiskeslag som torsk og kveite, i tillegg til skalldyr, står for den resterende prosenten. I denne oppgaven vil det være produksjon av laks, ørret og regnbueørret som omtales som matfisk.

Tall fra Fiskeridirektoratet for 2018 viser at det samlet ble slaktet totalt 1 349 758 tonn matfisk i 2018 for en totalverdi på omtrent 70 milliarder kroner (Fauske, 2019). Mye av fisken eksporteres til utlandet, og gjør denne til Norges tredje største eksportnæring (SSB, 2020).

Lønnsomheten i næringen har de siste årene vært høy, med driftsmarginer på over 30 prosent i årene 2016 – 2018 (Steinseide, 2019). Driftsmarginen er forventet å falle til mer normale nivåer, sammenlignet med andre næringer, som følge av høyere råvarepriser, biologiske utfordringer og økende konkurranse fra utlandet (Blomgren, Tvetervås, Reve, Haus-Reve, & Misund, 2019). Innovasjon og nye løsninger i akvakulturen vil derfor kunne være avgjørende for å redusere kostnader, sikre gode marginer og konkurransedyktighet i årene fremover.

Vi vil i denne delen gi en oversikt over produksjonsprosessen for matfisk, før vi ser nærmere på hvordan et oppdrett gjør biomassemåling for å overholde MTB. Vi tar så for oss hvordan matfisken klassifiseres med hensyn på vekt og kvalitet. Deretter ser vi nærmere på avvikene mellom prediksjoner og faktiske verdier for vektfordeling, antall fisk og total biomasse. Til slutt ser vi på potensielle gevinster for næringen ved en reduksjon i disse avvikene.

2.2.1 Produksjonsprosessen

Produksjonen av regnbueørret, ørret og laks er relativt lik og omfatter samlet sett en prosess på rundt tre år. De første 10 – 16 månedene av prosessen går med til produksjon av smolt i ferskvann. Dette er for at fisken skal vokse seg fra gyte til smolt med en størrelse på om lag 200 gram. Deretter plasseres smolten i åpen merd i sjø. Her vil den bli fôret over en periode på 12 – 24 måneder til den blir slakteklar. Fôringen styres hovedsakelig av vekstmodeller som næringen selv har utviklet. Vekstmodellene er gjerne spesifikke, ikke bare for hvert enkelt oppdrett, men i enkelte tilfeller helt ned på lokalitetsnivå. Det kan være store variasjoner i eksterne faktorer som gjør miljøet til lokaliteter svært forskjellig, og modellene kan dermed justeres på bakgrunn av erfaringer og historiske data for en spesifikk lokalitet (F. Sandvik, personlig kommunikasjon, 19. februar 2020).

Vekstmodellene til et oppdrett baserer seg normalt på fiskens nåværende størrelse og temperaturen i vannet. Høyere temperatur er forbundet med raskere vekst, noe som gjør at en vil ha sesongvariasjoner etter hvordan temperaturen i sjøen varierer. En vil med andre ord ha raskere vekst om sommeren og dårligere vekst om vinteren. Dette er også en av grunnene til at Troms og Finnmark har høyere MTB per konsesjon, ettersom fisken vokser saktere i nordlige deler av landet som følge av lavere gjennomsnittlig vanntemperatur (Forskrift om tildeling av matfiskkonsesjoner, 2003, Til § 7 Vederlag)

I tillegg til fôring og vanntemperatur er det også andre faktorer som påvirker fiskens vekst. I åpne merder er fisken også eksponert for sykdommer og lus (Iversen, Hermansen, Andreassen, Larsen, & Terjesen, 2013). Den vil derfor gjennomgå medisinske behandlinger og avlusing gjennom vekstperioden for å sikre fiskens kvalitet og helse. Myndighetene har klare føringer for håndteringen av lus og sykdommer som næringen må overholde, og behandlingene må gjøres i henhold til disse kravene (Mattilsynet, 2020). Mot slutten av vekstprosessen sultes fisken for å gjøre den slakteklar. Med bruk av blant annet vekstmodellene, blir det predikert verdier for total biomasse, totalt antall fisk og også den totale fordelingen av fisken i merden— som brukes når fisken selges. Det er viktig med presise prediksjoner ettersom fisken selges med bakgrunn i prediksjonene før den slaktes (SINTEF, 2009).

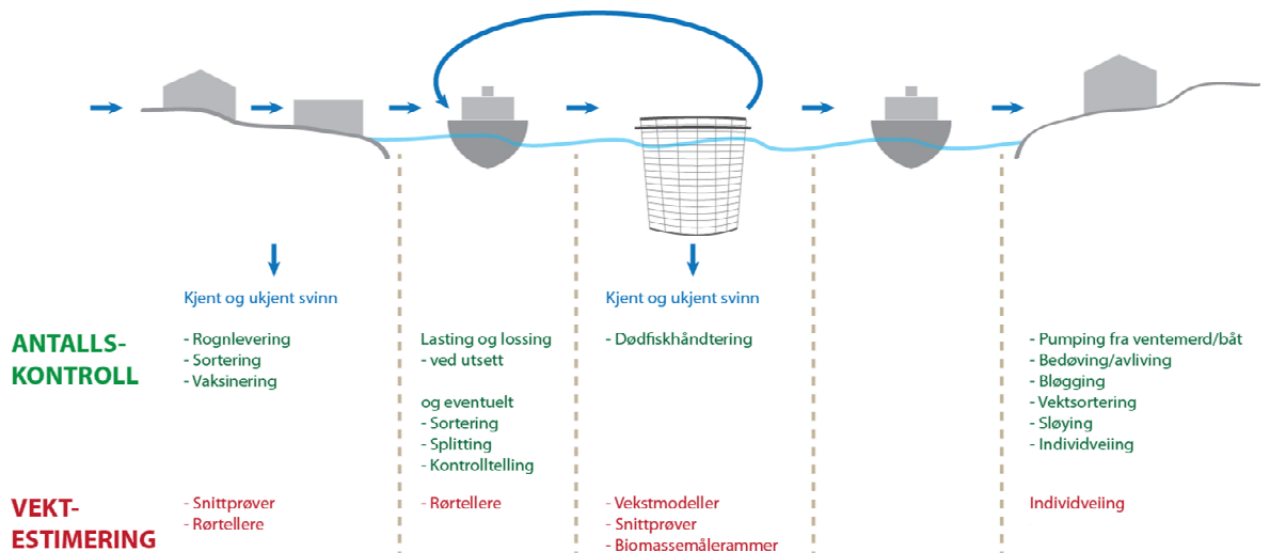
Slakteklar fisk blir etter sulting hentet fra merd ved bruk av en brønnbåt som pumper opp fisken til en innebygd brønn. Denne båten frakter så fisken fra oppdrettet til et slakteri, hvor fisken blir plassert i en åpen merd i sjø i påvente av slakt. Dette er definert som en ventemerd, og fisken blir pumpet videre herfra og inn til slakteriet ved tilgjengelig slaktekapasitet, som regel innen to dager. Etter slakt blir fisken pakket og videresendt, som dermed avslutter produksjonsprosessen (Mowi, 2019).

2.2.2 Biomassemåling

Per dags dato gjøres det biomassemålinger i form av antallskontroll og vektestimering i flere av leddene i verdikjeden. Dette er presentert i figur 2.3 under. Før utsett av smolt gjøres det antallskontroll ved rognlevering, sortering og vaksinerings. I tillegg gjøres det stikkprøver av vekt i disse ulike operasjonene. Antallskontroll gjøres enda en gang ved selve lasting til utsett, og på nytt ved lossing. I tillegg gjøres det kontroll ved eventuelle operasjoner som avlusing, sortering eller splitting. I disse operasjonene gjøres det også en vektestimering ved hjelp av rørtellere, som er tellere montert i rørene som fisken suges gjennom for utføring av disse operasjonene (Høy, Sunde, & Bjelland, 2013).

Utover dette blir det også utført delvise antallskontroller ved dødfiskhåndtering gjennom vekstperioden fra utsett til slakt (Høy, Sunde, & Bjelland, 2013). Jf. Akvakulturdriftsforskriften § 16 (2008) skal dødeligheten for akvakulturdyr kontrolleres, og døde dyr skal tas ut av produksjonsenheten minimum daglig. Det daglige uttaket av dødfisk registreres og reduserer dermed den stående beholdningen av antall fisk i merden.

Vektestimeringen i vekstperioden gjøres i hovedsak ved bruk av vekstmodeller, men i tillegg til dette kan det også bli tatt stikkprøver fra merden. De ulike leddene i verdikjeden har både kjent og ukjent svinn, som kan påvirke antall og vekt i merden (Høy, Sunde, & Bjelland, 2013). I tillegg er det også en spredning i populasjonen når det kommer til vekt og vekst. Fasitsvaret på antall og vektfordeling eksisterer først etter slakten er utført.



Figur 2.3: Biomasseestimering gjennom produksjonsprosessen for matfisk (Høy, Sunde, & Bjelland, 2013).

2.2.3 Vektinndeling og kvalitetsklassifisering

I oppdrettsbransjen er det etablert en standard hvor matfisken deles inn i ulike vekt- og kvalitetsklasser etter slakt, som presentert i tabell 2.1 under (United States International Trade Commission, 1990; IntraFish, 2018b):

		KVALITET		
		SUP	ORD	PROD
VEKT	1-2	1-2 SUP	1-2 ORD	1-2 PROD
	2-3	2-3 SUP	2-3 ORD	2-3 PROD
	3-4	3-4 SUP	3-4 ORD	3-4 PROD
	4-5	4-5 SUP	4-5 ORD	4-5 PROD
	5-6	5-6 SUP	5-6 ORD	5-6 PROD
	6-7	6-7 SUP	6-7 ORD	6-7 PROD
	7-8	7-8 SUP	7-8 ORD	7-8 PROD
	8-9	8-9 SUP	8-9 ORD	8-9 PROD


Tabell 2.1: Vekt- og kvalitetsklassifisering for matfisk (United States International Trade Commission, 1990).

Vektklassene er definert i kilogram, mens det eksisterer tre ulike hovedkategorier for kvalitet: production (PROD), ordinary (ORD) og superior (SUP). Ordinary og superior er kategorier for hel fisk som ofte eksporteres til utlandet, mens produksjonsfisken (production) må videre til foredling før den eventuelt kan eksporteres. Klassifiseringen brukes også i det globale spotmarkedet for matfisk, hvor salgene avtales og koordineres før slakten er utført (United States International Trade Commission, 1990). Salgene er gjort for de ulike klassene presentert i tabell 2.1, og baserer seg på den nevnte biomassemålingen forklart i forrige del. Nøyaktighet i prediksjonene for vekt- og kvalitetsfordeling er derfor svært viktig for å få minst mulig avvik mellom det som avtales ved salg, og det som faktisk blir slaktet. Vi vil videre se nærmere på disse avvikene.

2.2.4 Avvik i antall, vekt og vektfordeling

Som vi var inne på i innledningen er avvikene mellom predikerte og faktiske verdier for biomasse, antall og vektfordeling ofte store. Dette problemet ble nærmere undersøkt i prosjekt EXACTUS. Prosjektet ble gjennomført med 240 merder i Midt-Norge for anlegg tilhørende selskaper som Salmar, Lerøy og Marine Harvest (nå Mowi). I dette prosjektet kom det fram at det totalt sett innrapporteres liten forskjell mellom slaktet antall og det som i utgangspunktet

ble estimert ved antallskontroll. Det er også små avvik i den totale innrapporterte biomassen samlet sett for alle de undersøkte merdene. Til tross for at totale innrapportert tall for samtlige av disse merdene stemmer, er det på merdnivå vi ser de store avvikene. I figur 2.4 under er de prosentvise avvikene for antall, vekt og biomasse presentert med hver sin graf. Mange av enkeltmerkene i undersøkelsen hadde betydelig avvik som jevnt var fordelt på begge sider av null, hvor omtrent 10 prosent av merdene hadde mer enn 10 prosent avvik i estimerer av beholdning, og 50 prosent av merdene hadde mer enn 3 prosent avvik i biomasse (Høy, Sunde, & Bjelland, 2013).



Figur 2.4: Fordeling av prosent feil i estimering av antall, snittvekt og total biomasse ved slaktetidspunktet, for EXACTUS-prosjektet (Høy, Sunde, & Bjelland, 2013).

SINTEF peker i konsekvensanalysen på at dette tyder på at presisjonen i beholdningsestimeringen er lav, men at det ikke er systematiske feil i en bestemt retning. De trekker fram den symmetriske fordelingen rundt null og at denne indikerer at dette er tilfeldige feil. De hevder også at dårlig presisjon gjør optimalisering på mange viktige områder vanskelig (Høy, Sunde, & Bjelland, 2013). Som vi videre vil se av teori og metode, ønsker vi å finne underliggende sammenhenger mellom elementer ved fiskens vekstperiode og den endelige fordelingen ved slakt, og dermed redusere det som SINTEF i sitt prosjekt peker på som tilfeldige feil. Vi vil før dette ta for oss potensielle gevinster ved en slik forbedring av presisjonen.

2.2.5 Potensielle gevinster

Det er forholdsvis store potensielle gevinster ved å forbedre presisjonen for beholdningsestimeringen i salgs- og produksjonsprosessen for matfisk. Konsekvensanalysen til SINTEF (2009) viser at hvert ledd fra produksjon til slakt, foredling og pakking til salg, møter utfordringer knyttet til feilestimering. Det kommer fram at det er produksjon og salg som

blir mest berørt, mens slakt, foredling og pakking, har nok fleksibilitet til at konsekvensene ikke er av stor betydning. Vi vil videre dra fram noen potensielle gevinster som følge av mer nøyaktige prediksjoner.

2.2.5.1 Salg

I SINTEF (2009) sin analyse kommer det av intervjuer fram at vanlige tap for salgssleddet knyttet til feilestimering av biomasse ligger på 1 – 4 kr/kg. Det presiseres at inntektstapet er potensielt tap, og avhenger av størrelse på salgssapparat, type kontrakter med mer. Det poengteres også i rapporten at årsakene for inntektstap er sammensatt og kostnader påløper både for enkeltsalg og kontraktsforpliktelser, i tillegg til ekstrautgifter knyttet til transport. Feilestimeringen er gjort med bakgrunn i total biomasse, hvor en antar at 5 prosent av fisken er klassifisert i feil vektklasse (SINTEF tar ikke hensyn til kvalitet i sine beregninger). Det er dette tallet på 5 prosent vi benytter når vi videre går inn på potensielle gevinster for salgssleddet. For enkelhets skyld vil vi bruke 2 kr/kg for tap i salgssleddet ved feilestimering, som er det samme som SINTEF bruker i sine beregninger.

Bruker vi verdiene for 5 prosent feilestimering og et tap på 2 kr/kg, kan vi anta mulige gevinster basert på et gitt salgsvolum. SINTEF (2009) antar at en konsesjon på 780 tonn utgjør en produksjon på 1 300 tonn med en vekstperiode på 72 uker. Med et salgsvolum på 1 300 tonn vil den potensielle gevinsten være 130 000 kr, som beregnet i appendiks A.1.1. Tallene som SINTEF har brukt for å regne ut tapet på 2 kr/kg kan til en viss grad anses som utdaterte, da prisen for matfisk har doblet seg siden den gang (Fiskeridirektoratet, 2019). Vi anser det som rimelig å anta at kostnadene for feilestimering kan ha fulgt prisutviklingen til matfisken. Gjør vi samme beregninger med 5 prosent feilestimering og et tap på 4 kr/kg gir dette en potensiell besparelse, gitt salgsvolum på 1 300 tonn, på 260 000 kr per konsesjon, som beregnet i appendiks A.1.2. Justerer vi dette tallet med hensyn til årlig produksjon i næringen samlet sett, får vi en potensiell gevinst på rundt 270 millioner kroner, som beregnet i appendiks A.1.3. I salgssleddet eksisterer det med andre ord et betydelig potensial som burde kunne motivere næringen til forbedringer av prediksjoner for slakt. Det er verdt å presisere at tallene hentet fra SINTEF (2009) sin rapport er basert på intervjuer gjort i 2009, og videre justert med bakgrunn i markedsutviklingen. En mer oppdatert konsekvensanalyse er nødvendig for å få mer pålitelige verdier for potensielle gevinster. Videre er det også viktig å poengtere at det ikke er tatt med eventuelle strategiske konsekvenser i disse tallene. Det er rimelig å anta at bedre presisjon i

estimatene vil kunne frigjøre arbeidskapasitet, og at en vil ha en reduksjon i lønnskostnader eller en omstilling av arbeidskraft som gir verdiskaping i andre deler av salgsleddet.

2.2.5.2 Produksjon

Som for salgsleddet vil det også i selve produksjonen være potensielle gevinster ved bedre presisjon for estimatene. Hvor mye fisk som til enhver tid er i merden påvirker beslutninger som fôring, planlegging og tilpasning av produksjon. I konsekvensanalysen til SINTEF (2009) estimeres det også kostnader og tapte inntekter som følge av feilestimering i produksjonsleddet. Overestimering og underestimering har ulike potensielle gevinster, ettersom det tilknyttes ulike kostnader og inntekter til scenarioene. De videre beregningene er basert på tall for en konsesjon og 260 000 antall fisk utsatt, hvor SINTEF bruker Skretting sine vekst- og fôringsverdier for en vekstperiode på 72 uker (som vi ser nærmere på i teoridelen). Vi vil benytte oppdaterte verdier for salgspris på 50,25 kr/kg, fôrpris på 14,15 kr/kg, slaktekostnad på 3,79 kr/kg og 20 prosent sløysevinn (Fiskeridirektoratet, 2019).

SINTEF (2009) finner at en overestimering på 5 prosent for en konsesjon etter 72 uker vil gi 135 tonn mindre fisk i sjøen enn planlagt. Dette vil redusere verdien for produksjonen sammenlignet med forventet verdi på 5,4 millioner kroner, som beregnet i appendiks A.2.1. I tillegg vil det være fôret ut 142 tonn for mye fôr, som gir en ekstra kostnad på 2 millioner kroner, som beregnet i appendiks A.2.2. Justerer vi disse tallene med hensyn til årlig produksjon i næringen samlet sett, får vi en redusert verdi av produksjonen på 5,6 milliarder kroner og 2,1 milliarder kroner i overfôring, som beregnet i appendiks A.2.3 og A.2.4.

For en underestimering på 5 prosent beskriver SINTEF (2009) et uutnyttet vekstpotensial på 137 tonn. Fôrer produsenten etter planen vil følgelig merden underfôres og dermed vil dette vekstpotensialet ikke bli realisert. Hadde produsenten tilpasset fôringen sin til mengden fisk ville en kunne utnyttet dette vekstpotensialet på 137 tonn, som samtidig ville krevd ytterligere 145 tonn fôr. Dette ville gitt produsenten en gevinst på 2,9 millioner kroner, som beregnet i appendiks A.3. Justerer vi dette tallet med hensyn til årlig produksjon i næringen samlet sett, eksisterer det et uutnyttet vekstpotensial på 3 milliarder kroner, som beregnet i appendiks A.3.2.

Muligheten for gevinster både i salg- og produksjonsdelene er som vi har sett stor. Verdiene er gitt med bakgrunn i en utbedring av 5 prosent feilestimering, men det er å anta at en også i


fremtiden vil ha noen grad av feilestimering. De reelle gevinstene vil derfor være lavere. Vi vil videre bevege oss over på bakgrunn tilknyttet nevrale nettverk.

2.3 Nevrale nettverk

Måten nevrale nettverk fungerer på er inspirert av hvordan menneskehjernen fungerer. Selv om oppbyggingen av en menneskehjerne og en datamaskin i utgangspunktet er svært forskjellig, er det samtidig mulig å se klare likheter mellom hvordan informasjon prosesseres. Whitworth og Ryu (2007) har gjort en sammenligning og peker på stor likhet i at nevronene i menneskehjernen enten kan være av eller på, noe som også er tilfellet med binære verdier i en datamaskin. De siste årene har det blitt forsøkt å benytte nevronstrukturen vi kjenner fra en menneskehjerne som struktur for datamodellering (Chollet & Allaire, 2018). Vi vil i denne delen gi en overordnet introduksjon av maskinlæring, dyp læring og nevrale nettverk. Videre vil vi komme inn på noen styrker som har gjort denne typen modeller svært populære og hvorfor denne modelltypen er antatt å bli enda mer utbredt i årene som kommer. Vi vil til slutt komme inn på noen overordnede utfordringer med nevrale nettverk, som kan oppstå ved implementering av dette som et modelleringsverktøy.

2.3.1 Maskinlæring og dyp læring

Selv om tradisjonelle algoritmer effektivt kan lykkes i å løse veldefinerte logiske problemer, som for eksempel sjakk, så kan de fort komme til kort når det gjelder mer komplekse problemer uten eksplisitte regler. Bildegjenkjenning og språkoversetting er to eksempler på mer komplekse og mindre veldefinerte problemer. Sammenlignet med sjakk, hvor en har klare regler for hvor brikkene kan flyttes, er det vanskeligere å definere regler for disse problemene (Chollet & Allaire, 2018). I disse tilfellene, hvor en ikke eksplisitt kan programmere et sett med regler, er en avhengig av å ha et verktøy som er i stand til å trene seg selv for å finne sammenhenger i data. Her skiller maskinlæring seg fra tradisjonelle algoritmer, i den grad en istedenfor å ta utgangspunkt i data og definerte regler for å finne svar, selv lærer seg reglene ved å ta utgangspunkt i data og svar. Denne forskjellen er illustrert i figur 2.5. Et slikt maskinlæringssystem må trenes på en mengde data med tilhørende fasitsvar, slik at den kan bygge den strukturen som gir en sammenheng i det gitte fenomenet (Chollet & Allaire, 2018).



Figur 2.5: Maskinl ring, en ny struktur for programmering (Chollet & Allaire, 2018).

Innenfor maskinl ring har en ulike felter og typer modeller, og et av de mer avanserte feltene er kalt dyp l ring. Dyp l ring består av flere lag med fremstillinger som totalt skal gi et godt overordnet bilde av det aktuelle fenomenet. I dyp l ring er den lagbaserte fremstillingen som oftest gjort med modeller som kalles nevrale nettverk, hvor strukturen har en rekke lag plassert opp  hverandre. Betegnelsen nevrale nettverk kommer av at modellene har tatt inspirasjon fra sentrale konsepter i nevrovitenskapen. Det finnes riktignok ingen dokumentasjon p  at mekanismene en ser i nevrale nettverk n dvendigvis er lik mekanismene en ser i menneskehjernen, selv om inspirasjonen er hentet herfra. Det nevrale nettverket er dermed ikke ment   etterligne hvordan en menneskehjerne fungerer (Chollet & Allaire, 2018). Vi vil i delene for teori og metode komme tilbake til oppbyggingen av et nevralt nettverk.

2.3.2 Styrker

Det er flere styrker ved nevrale nettverk som har s rget for  kende popularitet de siste  rene. Den kanskje viktigste av disse er hvordan nettverket selv l rer og utvikler modellen, med relativt f , om noen, antagelser gjort p  forh nd til sammenhenger i data. Videre, s  generaliserer det nevrale nettverket og kan derfor l re seg sammenhenger ved bruk av presenterte data, og bruke denne kunnskapen til   predikere for usett data. I tillegg er et nevralt nettverk universelt n r det gjelder funksjonstiln rming, og nettverket vil med  nsket nøyaktighet kunne tiln rme seg enhver kontinuerlig funksjon (Zhang, Patuwo, & Hu, 1998).

Et nevralt nettverk har ogs  muligheten til   h ndtere enorme mengder data, og en slik modell er derfor spesielt godt egnet ved bruk av store datasett. I n ringslivet, samfunnet og verden generelt, samler vi stadig inn mer data, som er en av faktorene som har gjort at nevrale nettverk

har hatt en økende popularitet de siste årene. I tillegg til dette kan oppbygningen og treningen av et nevralt nettverk kreve store mengder maskinkraft, særlig for trening med enorme datasett. Ny teknologi gjør at prisen på slik maskinkraft stadig faller, og er dermed også en faktor som har gjort slike nettverk mer utbredt de siste årene. Med en fallende pris på maskinkraft fremover er det antatt at populariteten vil fortsette å øke (Chollet & Allaire, 2018).

Kombinasjonen av muligheten til å modellere ikke-lineære sammenhenger, håndteringen av store mengder data, og det at nettverk selv tilpasser seg, gjør at nevralt nettverk også har muligheten til å finne sammenhenger i data uten at en først manuelt må gjøre antagelser basert på en hypotese. Modellen vil kunne operere uten antagelser gjort av et menneske, og en vil dermed kunne unngå at en hypotese indirekte eller direkte påvirker utfallet av en modell.

2.3.3 Svakheter

En av dem som har tatt for seg svakheter og mulige utfordringer med nevralt nettverk er Steven Gonzalez, som presenterte dette i makroøkonomisk sammenheng, men hvor svakheter som presenteres også er relevante for nevralt nettverk på generell basis. Gonzalez (2000) presenterer først den manglende muligheten til å tolke resultatene, det såkalte *black-box* problemet. Nettverket har en rekke skjulte funksjoner i de ulike lagene, og det er umulig å finne hvilken effekt en enkel inputvariabel har på output. Den andre svakheten er hvordan sannsynligheten for at en finner de absolutte optimale verdiene for parametrene til nettverket er svært liten. Disse parametrene stilles ved å forsøke ulike verdier, og sannsynligheten for at den endelige modellen består av optimale sammensettingen av parametre er veldig liten. Den tredje er hvordan en modell som dette krever et stort datasett for å kunne trene optimalt. Nevrale nettverk består ofte av et enormt antall parametre som skal estimeres, og et stort antall mønstre må gjengis for at modellen skal kunne generalisere godt. Den siste svakheten han presenterer er et problem hvor modellen ikke generaliserer godt nok og lærer seg dataene den trener med for godt. Dette er et problem kjent som overtilpasning (overfitting), som vi vil komme tilbake til både i delen for teori og i metode.

Maskinkraft er også et svært sentralt tema i diskusjonen om nevralt nettverk ettersom håndtering av store mengder data krever mye prosessorkraft. Ny teknologi gjør at maskinkraft er blitt mer tilgjengelig, og at prisen på dette stadig blir lavere. Til tross for dette er det fremdeles forbundet en stor kostnad ved bruk av nevralt nettverk med store datasett. En kan derfor ofte havne i en situasjon hvor en vil måtte gjøre en avveining mellom å gjøre en modell

mer kompleks for å forbedre treffsikkerheten, eller å beholde den mindre kompleks for å redusere behovet for maskinkraft (Chollet & Allaire, 2018).

2.4 Problemforklaring

Vår problemstilling er et sammensatt problem da vi vil ha behov for å kombinere kunnskap og metoder fra to veldig forskjellige fagområder, havbruk og maskinlæring. Den er blitt utformet med bakgrunn i et av problemene som i dag eksisterer i norsk akvakultur, hvor en for matfisk på merdnivå sliter med forholdsvis store avvik mellom predikert og reell verdi for biomasse, antall, vekt- og kvalitetsfordeling for fisken. Hovedårsaken for at problemet eksisterer er vanskelighetene med å observere den biologiske veksten i fisken sitt miljø under vann og at mengdene som produseres er store. I en annen form for matproduksjon, som for eksempel landbasert gårdsdrift, vil en daglig kunne gjøre reelle observasjoner for individer både med hensyn til mat og vekst, og dermed kjenne den faktiske situasjonen dag-for-dag (Føre, et al., 2018). For matfisk i en merd mangler en observasjoner på individnivå, da for eksempel fôringen gjøres samlet sett for en hel merd. Dette gjør at den eneste reelle observasjonen en har for fisken på individnivå er etter slakt, hvor vi kjenner både vekt- og kvalitetsklassifisering.

Basert på et intervju med Christian Birkeland, digital prosessansvarlig i Grieg Seafood ASA, er de eksisterende prediksjonene i næringen i stor grad gjort med bakgrunn i modeller som er basert på historiske data og erfaringer. Disse kan typisk også ha eventuelle tilpasninger for plassering av en lokalitet og type matfisk det produseres (C. Birkeland, personlig kommunikasjon, 4. februar 2020). Med maskinlæring, mer spesifikt nevrale nettverk, søker vi å utforske mulighetene til å forbedre disse prediksjonene ved at vår modell selv vil kunne lære seg sammenhenger mellom variabler for fisken og miljøet den står i, og vekt og kvalitet for det som slaktes. Antall fisk som hentes til slakt fra en merd er ofte bestemt av produsenten, og det vil derfor ikke være aktuelt å predikere dette. Selv om vi har reelle data for fisken på individnivå ved slakt, er alle andre data i produksjonssammenheng gitt for hele merden. Vi vil derfor søke etter å predikere fordelingen til et helt slakteparti med hensyn på vekt og kvalitet ved slakt, fremfor å predikere for antall individer og deretter lage en fordeling av dette. Innenfor maskinlæring er dette omtalt som et flertype klassifiseringsproblem (multi-label classification).

2.5 Avgrensninger

Vi har sett at det i næringen per i dag eksisterer forholdsvis store avvik for prediksjoner på merdnivå. Siden den daglige driften i næringen i dag styres på merdnivå i alle ledd (planlegging, produksjon og slakt), er det også på dette nivået vi vil utforme vår modell. På dette nivået vil det ikke være hensiktsmessig å ta for oss prosessen med produksjon av smolt, og vi vil derfor avgrense oppgaven til prosessen fra utsett i merd til slakt.

Datasettet vi senere vil benytte for å trene og teste vår modell, er levert fra selskapet Svanøy Havbruk AS, heretter omtalt som Svanøy. Selskapet holder til på Svanøy i Flora kommune og består i dag av 15 ansatte. De produserer regnbueørret og stamfisk på tre lokaliteter i sjø, samt rogn og settefisk på land. All fisken selges gjennom Skaar Norway AS, heretter Skaar, som også er aksjonær, og leveres til kunder i Europa, Asia og USA (Svanøy Havbruk AS, u.d.).

Selv om Svanøy driver produksjon av en spesifikk type matfisk, regnbueørret, er prosessen tilsvarende som for produksjon av annen matfisk i åpen merd. Det vil derfor være rimelig å anta at metoden som er utarbeidet vil kunne implementeres også ved produksjon av annen type matfisk, for eksempel laks. Ved produksjon av laks har en tilsvarende variabler for produksjon—både av hensyn til miljøet fisken står i, samt daglig rapportering av fôring og dødelighet. Når det er sagt er vekten til regnbueørreten generelt noe lavere enn den er for laks, og følgelig er også vektfordelingen ved slakt noe lavere og fordelt over færre vektklasser (F. Sandvik, personlig kommunikasjon, 19. februar 2020). Skal en bruke metoden for annen matfisk vil en derfor sannsynligvis måtte gjøre noen endringer i arkitekturen til modellen. Formålet med prosjektet er å bidra til å danne et bredere kunnskapsgrunnlag rundt modellbasert biomasseestimering for næringen, og tydeliggjøre mulige gevinster.

3 Teori

Vi vil i denne delen først presentere relevant teori for nevrale nettverk og oppbygningen av et slikt nettverk, før vi videre tar for oss aktuell teori for eksisterende modeller og prediksjoner i oppdrettsnæringen.

3.1 Nevrale nettverk

Den mest fundamentale delen av ethvert nevralt nettverk er nevronene hvor alle beregninger utføres. For å etter hvert beskrive oppbygningen av vår modell og nevrale nettverk, vil vi i denne delen først ta for oss selve nevronet og hvordan dette fungerer. Vi vil videre ta for oss hvordan den enkleste kombinasjonen av nevroner gjøres i det som kalles et perceptron. Herfra beveger vi oss over til oppbygningen av et flerlagsperceptron, og videre til et fullverdig nevralt nettverk. Til slutt i denne delen vil vi ta for oss viktige parametre og elementer ved nettverkene, samt hva som kjennetegner disse.

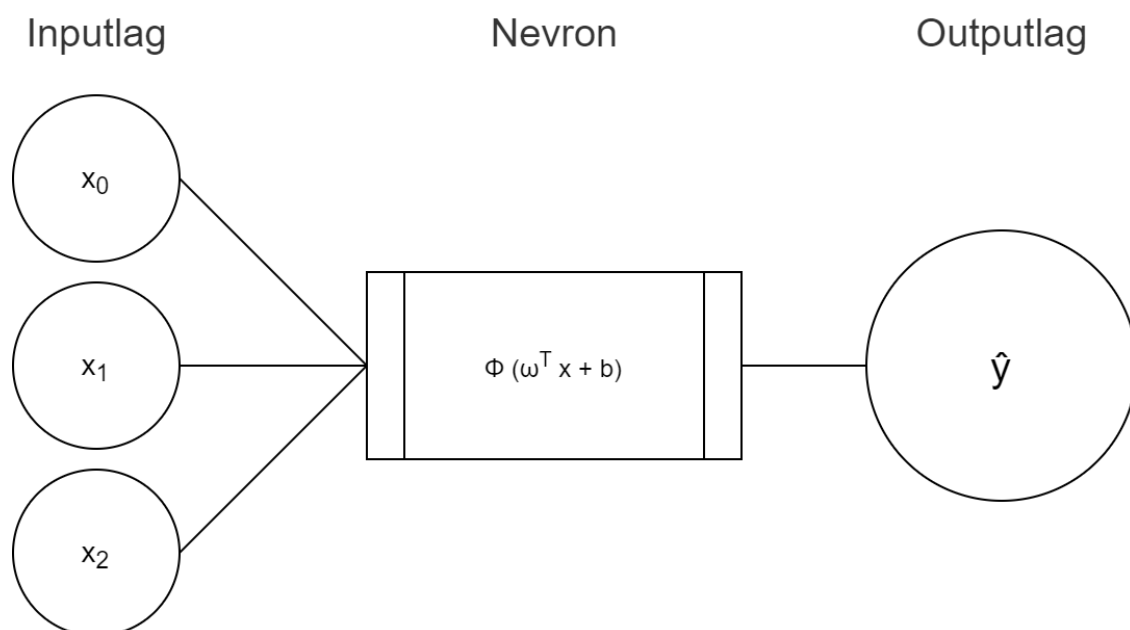
3.1.1 Nevroner og perceptron

Nevronene representerer hver og en en funksjon $\xi(x)$ som utfører en sammensetning av en lineær transformasjon og en translasjon, på et sett av vektorer x . Funksjonen ser slik ut:

$$\xi(x) = \Phi(\omega^T x + b), \quad (3.1)$$

hvor $\omega = [\omega_0, \omega_1, \dots, \omega_p]$ er en vektor bestående av vekter, $x = [x_0, x_1, \dots, x_p]$ er en vektor bestående av egenskaper, b er et mål for bias, og Φ er en elementbasert aktiveringsfunksjon.

Frank Rosenblatt (1958) var den første til å introdusere den mest grunnleggende bruken av nevroner i en prediksjonsmodell, da han i 1958 presenterte perceptronet. Rosenblatt var en amerikansk psykolog, og perceptronet ble laget for å illustrere noen av de generelle fundamentale egenskapene ved intelligente systemer, uten å bli for dypt innblandet i de spesielle og ofte ukjente forholdene som gjelder for bestemte biologiske organismer (Rosenblatt, 1958).



Figur 3.1: Et perceptron med input- og outputlag (Rosenblatt, 1958).

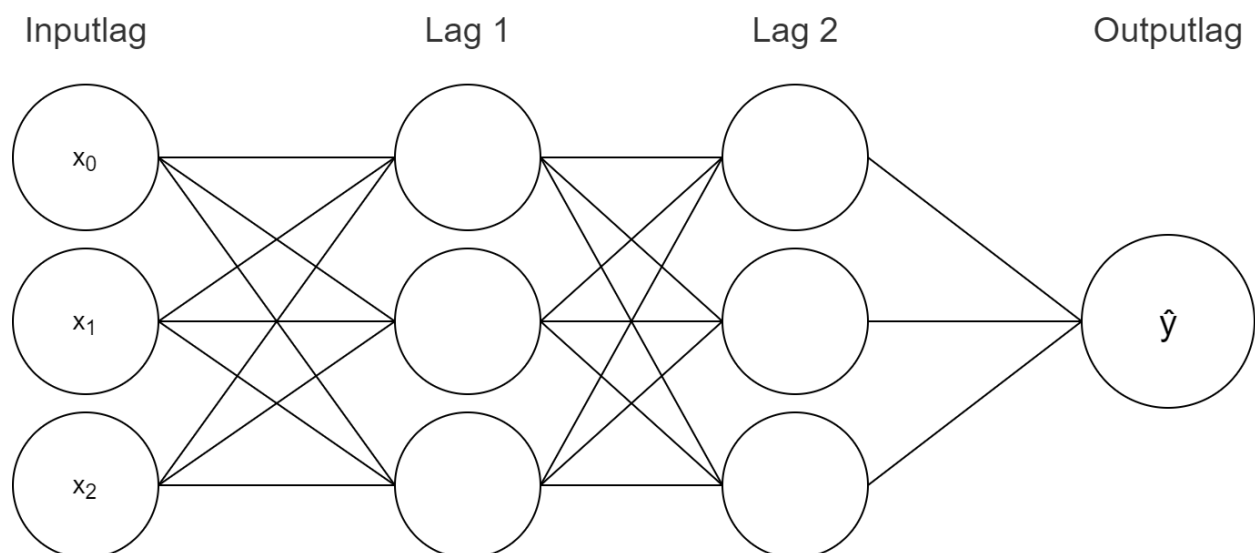
Perceptronmodellen, presentert i figur 3.1, er helt lik en enkel lineær regresjonsmodell, hvor nevronene i inputlaget (input layer) tilsvarer inputvariablene, altså *egenskapene*, mens nevronene i outputlaget (output layer) tilsvarer den avhengige variabelen, altså *målvariabelen* (target variable). Videre tilsvarer vektene, ω , de *estimerte koeffisientene*, mens målet på bias, b , tilsvarer *konstanten* (Gonzalez, 2000). Perceptronet er den enkleste versjonen av et nevralt nettverk, men generelt er modellene som tas i bruk langt mer komplekse enn denne. For at modellen skal kunne modellere ikke-lineære sammenhenger, holder det ikke med det ene laget som kjennetegner perceptronet. Videre tar en derfor i bruk flere lag, et flerlagsperceptron, som er i stand til å modellere ikke-lineære sammenhenger (Cook & Hall, 2017).

3.1.2 Flerlagsperceptron og nevralt nettverk

Kjennetegnet ved et flerlagsperceptron er at det består av to eller flere lag, hvor hvert av disse lagene inneholder tilsvarende nevroner som vi så i eksemplet med perceptronet over. Ethvert nevron representerer fremdeles en funksjon, og lagene bygger til sammen opp et nettverk av disse. Det overordnede målet med nettverket er å lage en funksjonell tilnærming av $f(x)$, kalt f^* , gjennom å bruke de midlertidige resultatene som blir produsert av lagene bestående av nevroner. Dersom vi definerer lagene som $Y = f(x; \theta)$, hvor θ består av vektene ω og vektor for bias b , så kan f^* bestå av et ubegrenset antall funksjoner f_2, \dots, f_n , slik at $f^* =$

$f_n \dots (f_2(f_1(x; \theta_1); \theta_2); \dots; \theta_n)$, hvor x representerer inputlaget og f_n outputlaget. De resterende lagene med nevroner har en definert algoritme, som bestemmer hvordan disse bistår med læring for å anslå f^* . Selv om det defineres en læringsalgoritme for de resterende lagene, er ikke oppførselen til lagene eksplisitt definert av denne. Dette gjør at disse lagene ofte kalles skjulte lag (hidden layers), som sammen med input- og outputlagene utgjør nettverket (Touretzky & Pomerleau, 1989).

For å lettere illustrere forskjellen mellom et perceptron, presentert i figur 3.1, og et flerlagsperceptron, er et flerlagsperceptron med to skjulte lag presentert under i figur 3.2. Hvert av disse lagene (lag 1 og lag 2) inneholder flere nevroner som anvender funksjonen (3.1), før en sender dette videre til neste lag.



Figur 3.2: Et flerlagsperceptron med to skjulte lag, samt input- og outputlag.

Den umiddelbare forskjellen sammenlignet med perceptronet er antallet lag, og dermed også hvordan nevronene i et lag er koblet videre til neste lag. Hvert enkelt nevron er koblet til alle nevronene i neste lag, som totalt sett skaper et tett sammenkoblet nettverk av nevroner. Et nettverk med et skjult lag, kombinert med en ikke-lineær aktiveringsfunksjon og et tilstrekkelig antall nevroner, kan stykkevis tilnærme seg enhver kontinuerlig funksjon (Hornik, Stinchcombe, & White, 1989; Kuan, 2006). Det er denne egenskapen, den universelle tilnærmingen, som gjør denne typen nettverk egnet til å gjenkjenne komplekse ikke-lineære sammenhenger ved data.

Perceptronet og flerlagsperceptronet er utgangspunktet for det vi kjenner som nevrale nettverk. Nevrale nettverk kan ha flere skjulte lag selv om flertallet av dagens modeller ikke tar i bruk mer enn et skjult lag da dette har tilstrekkelig universal tilnærming. Nevrale nettverk kan ha et tilnærmet ubegrenset antall skjulte lag, men det er ikke nødvendigvis slik at et stort antall nevroner eller skjulte lag er en fordel ettersom modellen da kan se mønster i ren støy grunnet overtilpasning (Zhang, Patuwo, & Hu, 1998).

3.1.3 Aktiveringsfunksjon og normalisering

Aktiveringsfunksjonen i et nevralt nettverk kalkulerer en vektet sum basert på input og legger til et bias for å kunne fastslå om et nevron skal aktiveres eller ikke. Uten aktiveringsfunksjonen ville nettverket håndtert problemet som en lineær regresjon, og ville ikke kunne lært seg mulige komplekse ikke-lineære sammenhenger. Glorot, Bordes og Benio introduserte i 2011 “the rectified linear unit”, forkortet “ReLU”, som etter dette har vært førstevalget for valg av aktiveringsfunksjon til skjulte lag i nevrale nettverk (Goldberg, 2016). Funksjonen (3.2) returnerer et positivt tall eller null, og dette hjelper for å redusere antall parametre i nettverket (Glorot, Bordes, & Bengio, 2011):

$$\text{ReLU}(z) = \max(0, z) = \begin{cases} 0 & z < 0 \\ z & \text{ellers} \end{cases} \quad (3.2)$$

hvor $z = (\omega^T x + b)$. Når aktiveringsfunksjonen returnerer en output som er null eller bortimot null, så vil nevronet knapt respondere. Dette indikerer at disse punktene skal ha liten betraktning når en prøver å anslå f^* . Ved bruk av ReLU som aktiveringsfunksjon er det viktig å ta hensyn til at denne funksjonen opererer uten definerte grenser eller retningslinjer, og at nettverket dermed kan bli for avhengig av enkelte datapunkter. Det er derfor viktig å normalisere inputdata før en kjører modellen med denne aktiveringsfunksjonen. Det finnes ikke et fasitsvar på hvordan en skal normalisere data, men den mest praktiserte måten å gjøre dette på er en normalisering for variabler til rekkevidden $[0,1]$ (Samudrala, 2019):

$$v(x) = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (3.3)$$

Mens ReLU er det naturlige valget som aktiveringsfunksjon for skjulte lag i et nevralt nettverk, er valg av aktiveringsfunksjon for outputlaget en egen vurdering. Den mest egnede aktiveringsfunksjonen for et outputlag i et flertype klassifiseringsproblem er i utgangspunktet Sigmoid funksjonen, som også blir kalt for en logistisk funksjon.

$$f(s) = \frac{1}{1 + e^{-s}} \quad (3.4)$$

Funksjonen returnerer en verdi i området 0 til 1, og er brukt helt uavhengig på alle elementer s (Gómez, 2018). I et scenario hvor vi ønsker å predikere en sannsynlighetsfordeling, vil dette være lite egnet ettersom summen fra outputnevronene ikke vil summere seg til 1, hvilket en er helt avhengig av for å få en reell fordeling. Dette kan en løse ved å bruke en annen aktiveringsfunksjon, kalt Softmax:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{for } j = 1, \dots, K \quad (3.5)$$

hvor z er en K -dimensjonal vektor (Bishop, 2006).

Det som er spesielt med denne aktiveringsfunksjonen sammenlignet med Sigmoid-funksjonen, er at summen av output fra samtlige nevroner i outputlaget blir 1 (Gómez, 2018; Géron, 2017). Dette gjør denne aktiveringsfunksjonen svært egnet til bruk blant annet til det som betegnes som et flerklasse klassifiseringsproblem (multi-class classification), men den har inntil nylig vært lite brukt i flertype klassifiseringsproblem. For denne typen problem er det Sigmoid som i utgangspunktet har vært den mest anvendte aktiveringsfunksjonen for outputlaget, men ny implementering viser at Softmax kan være vel så egnet til denne typen klassifiseringsproblem (Gómez, 2018; Mahajan, et al., 2018).

3.1.4 Tapsfunksjon og optimalisering

Hvert lag i modellen har parametre, θ , som defineres og tilpasses i felleskap på en slik måte at avviket mellom prediksjon og faktisk verdi blir minst mulig. Dette avviket håndteres gjennom bruk av en tapsfunksjon (loss function), som evaluerer hvor godt en spesifisert algoritme i en modell gjør det. Tilsvarende som for aktiveringsfunksjonen er typen prediksjon modellen søker å gjennomføre avgjørende for valget av denne (Parmar, 2018). Gjennomsnittet av kvadratiske feil (MSE - Mean Squared Error) er den mest brukte tapsfunksjonen for nevralt nettverk, men er svært lite egnet for et klassifiseringsproblem (Brownlee, 2020a). I et flertype klassifiseringsproblem, hvor en søker å måle feilen mellom to fordelinger, er Kullback-Leibler divergens (Kullback-Leibler divergence) en av de tapsfunksjonene som støtter dette:

$$D(P, Q) = \int p(x) \log \frac{p(x)}{q(x)} dx \quad (3.6)$$

hvor P og Q er to sannsynlighetsfordelinger, og hvor vi antar at P og Q har tetthetsfunksjonene $p(x)$ og $q(x)$ over R^k (Copas & Eguchi, 2006).

Et nevralt nettverk benytter så en optimaliserer (optimizer) for å finne de vektene som minimaliserer tapsfunksjonen. Tapsfunksjonen kan ses på som et høydimensjonalt optimeringslandskap, hvor vi søker å finne bunnen. Optimalisereren vil da igjen best kunne sammenlignes med en oppskrift som følges i søket etter et globalt minimum. Istedenfor at en tilfeldig oppdaterer vektene i nettverket, vil optimalisereren kalkulere tapet og etter et gitt antall kjøringar velge vektene som gir minst tap før den fortsetter treningen (Chollet & Allaire, 2018).

Dette tapet kalkuleres ved at modellen tar et definert antall treningsobservasjoner, et treningsparti (batch size), og gjør et tilsvarende antall prediksjoner for disse. Disse prediksjonene blir vurdert mot faktiske verdier, og det er optimalisereren som så kalkulerer feilgradienten mellom disse og oppdaterer vektene ut ifra dette. Det er også definert et parameter for hvor mange ganger modellen skal kjøre gjennom hele datasettet ved trening, altså hvor mange ganger en vil forsøke å justere disse vektene. Dette er gitt av epokeparameteret (epochs) og bør settes slik at tapet reduseres for hver ekstra epoke. Dersom denne er satt for høy vil det kunne føre til overtilpasning, mens en modell med et lavt antall epoker vil kunne slite med å lære seg sammenhenger i data (Brownlee, 2019a). For valg av optimaliserer er RMSprop en av de mest brukte innenfor dyp læring og nevralt nettverk, bare passert av optimalisereren Adam (Bashaev, 2018). Adam har i praksis blitt standardvalget blant optimaliserere grunnet dens effektivitet og gode resultater (Brownlee, 2019b). Denne optimalisereren tar blant annet parametrene læringsrate (learning rate) og forfallsfrekvens (decay rate) som input. Læringsraten spesifiserer hvor mye vektene skal justeres, mens forfallsfrekvensen definerer i hvilken grad læringsraten skal reduseres for hver epoke (Brownlee, 2019b; Kingma & Ba, 2014; Brownlee, 2019d). Det er viktig å finne riktig balanse mellom høye og lave verdier for disse, da en lav læringsrate kan resultere i at treningsprosessen blir svært lang og at modellen ikke kommer lengre enn et lokalt optimum. En høy læringsrate kan på andre siden resultere i en svært ustabil treningsprosess eller at modellen setter en suboptimal verdi for vektene i nettverket (Brownlee, 2020b).

3.1.5 Nøyaktighet

I optimaliseringen av nettverket er det også vanlig å benytte et mål på hvor godt prediksjonene treffer. Med dette får en et måltall for nøyaktigheten til modellen, hvor en gjennom treningen

vil kunne se hvordan modellen får en bedre og bedre score ved validering. Selv om dette måltallet er nyttig for validering og evaluering av modellen, brukes det ikke i treningen av modellen, og har dermed liten direkte betydning for treningen. Nytteverdien ligger mer i det å kunne bruke måltallet til justering av hyperparametre, og det vil dermed indirekte få en betydning for hvordan modellen trenes. Det mest brukte måltallet for nøyaktighet er ofte knyttet direkte til korrekte prediksjoner som en andel av totale eksempler, men i en situasjon med flere outputvariabler kan det være vanskelig å tolke denne videre (Google Developers, 2020). I målingen av nøyaktighet mellom to prosentfordelinger vil det være nærliggende å heller bruke et måltall for hvor nøyaktig modellen treffer direkte på prediksjoner av enkeltobservasjoner. Et måltall for dette kan dermed være den gjennomsnittlige nøyaktigheten til hver klasse:

$$N\acute{o}yaktighet = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (3.7)$$

hvor $Y_i - \hat{Y}_i$ er forskjellen mellom faktisk og predikert prosentfordeling for klasse i , og n er det totale antallet prediksjoner. Dersom nøyaktigheten er *null* betyr dette at alle klasser er predikert korrekt. Er nøyaktigheten forskjellig fra *null* representerer måltallet gjennomsnittlig avvik for hver predikert klasse i prosentpoeng. En lav score for nøyaktighet i vårt tilfelle vil være positivt, da dette vil bety lave avvik, som igjen betyr at prediksjonene er nøyaktige. Som nevnt vil dette måltallet ikke direkte påvirke treningen av modellen. Det vil heller ikke direkte kunne brukes til å forklare hvor *godt* modellen gjør det, men kan være et godt måltall for å sammenligne to modeller, og indirekte påvirke treningen av modellen.

3.1.6 Hyperparametre og kapasitet

Antallet skjulte lag i en modell defineres som dybden til et nettverk, mens antallet nevroner i hvert lag defineres som bredden til nettverket. Kombinasjonen av disse utgjør selve nettverksarkitekturen, og det er denne arkitekturen som bestemmer hvilket område nettverket har mulighet til å benytte for trening av modellen. Det er fleksibiliteten til dette området som igjen bestemmer det som defineres som kapasiteten til nettverket. I forbindelse med denne kapasiteten er det to svært viktige begreper å ta hensyn til når en ønsker å trene en modell. Dersom en modell har for høy kapasitet kan en risikere at modellen lærer å kjenne treningsdataene for godt. Dette problemet er kjent som overtilpasning og kan gjøre modellen sin egentlige prediksjonsevne svært dårlig. Det betyr at prediksjonene som modellen gir for et

nytt datasett også vil kunne være svært dårlige, ettersom modellen i for stor grad er basert på de enkelte observasjonene i treningsdataene (Singh, 2018).

På den andre siden kan en modell også være undertilpasset (underfitting) ved at modellen har for lav kapasitet. Ved undertilpasning er modellen for lite kompleks, og en risikerer at modellen dermed ikke greier knytte en sammenheng mellom input og output verken i datasettet for trening eller når modellen skal brukes til å predikere (Singh, 2018). I utarbeidelsen av arkitekturen til nettverket er det svært viktig å følge med på disse parametrene, og viktigheten av dette er også understreket av selve prosessen for utarbeidelse av modeller. I denne prosessen deler en et datasett opp i to deler—den største delen for trening av modellen, og den andre delen for testing av modellen.

For å unngå undertilpasning og overtilpasning forsøker en å balansere valg av modellens kapasitet imellom disse, noe som kan gjøres effektivt ved å sammenligne optimal konvergens mellom treningsdata og valideringsdata. Søken etter å finne denne balansen, og dermed den optimale kapasiteten til nettverket, er i litteraturen definert som innstilling av hyperparametre. En kan også justere selve læringsalgoritmen basert på resultatet i validering fremfor resultatet i selve treningen av modellen, og denne typen justering kalles regularisering (regularization) (Goodfellow, Bengio, & Courville, 2016). Vi vil i metoddelen av oppgaven ta opp igjen temaene undertilpasning og overtilpasning, samt diskutere hvordan vi eventuelt vil identifisere og håndtere dette.

3.1.7 Ensembler

I miljøet for prediksjon er det stor enighet om at det å kombinere ulike prediksjoner fører til økt nøyaktighet for prediksjonene (Makridakis & Hibon, 2000). Timmermann (2006) argumenterer for at dette er et resultat av en diversifiseringseffekt, og at effekten er størst dersom prediksjonene fra de inkluderte modellene er så lite korrelerte som mulig. I trening av modeller kan det ha blitt gjort ulike antagelser fra en modell til en annen, hvilket kan gjøre det gunstig å kombinere ulike modeller og prediksjonene disse produserer. En slik kombinasjon av en rekke ulike modeller er i litteraturen og i prediksjonsmiljøet betegnet som modellensembler.

Ettersom nevralt nettverk opprinnelig har en struktur med tilfeldige vekter, kan repeterende bruk av maskinlæringsalgoritmene i nettverket returnere ulike lokale optimale løsninger ved bruk av samme data og modell. Denne iboende stokastisiteten kan ha stor innvirkning på

resultatet fra en enkel nettverksarkitektur i gjentatte kjøring, og dermed også nøyaktigheten til de returnerte prediksjonene. Det finnes flere måter å håndtere denne stokastisiteten på, for eksempel ved å trene hver nettverksarkitektur flere ganger. Da kan en videre velge den arkitekturen med minst feil, eller en kan rapportere gjennomsnittlig feil for alle nettverk og dermed kunne evaluere hvor bra prediksjoner arkitekturen generelt leverer (Cook & Hall, 2017).

Hall og Cook (2017) legger også fram en annen og kanskje mer egnet metode, hvor en forsøker å utnytte variasjonen i hver treningsdel av modellen, for å lage modellensembler. For å lage disse ensemblene blir hver arkitektur trent en rekke ganger og prediksjonene fra hvert enkelt nettverk blir kombinert ved bruk av en lineær kombinasjon. Ettersom vektene ved initialiseringen av nettverket er tilfeldig, finnes det ingen måte å på forhånd vite hvilken av modellene som er best, og det er derfor vanlig å kombinere prediksjonene ved bruk av gjennomsnitt. Gitt at vi gjennomfører k antall gjentatte kjøring, er prediksjonen for observasjon i gitt av

$$\hat{y}_i^{ensemble} = \frac{1}{k} \sum_{j=1}^k \hat{y}_{ij} \quad (3.8)$$

hvor \hat{y}_{ij} er nummer j gjennomføring av treningsdel for observasjon i . Denne metoden krever svært mye maskinkraft og vil ikke la seg gjennomføre med enorme datasett. Den er derfor mest brukt og egnet til situasjoner hvor det er knapt med data (Cook & Hall, 2017).

3.2 Eksisterende modeller og prediksjoner i norsk akvakultur

Vi vil videre igjen ta for oss norsk akvakultur og relevant teori tilknyttet eksisterende modeller og veksttabeller for oppdrettsnæringen. Dette er verktøy som er essensielle i planleggingen av produksjon og for å kunne gjøre prediksjoner for vekt- og kvalitetsfordeling for slakt. Til slutt tar vi for oss disse prediksjonene og hvordan disse gjøres i dag.

3.2.1 Vekstmodeller og veksttabeller

Vekstmodeller er et av hovedverktøyene som i dag brukes i norsk akvakultur, som forenklet sett sier hvor mye fôr en skal gi fisken som står i en merd (Rosten, et al., 2011). Basert på antall fisk, og vekten fisken har ved utsett, fôrer en fisken med hensyn til temperatur og andre

variabler knyttet til miljøet i sjøen. Vekstmodellene er utviklet over lang tid og er spesifikke for fôrtype og gjerne også for hvert oppdrett. Samtidig har en i hvert oppdrett ofte tilpasninger av vekstmodell gjort på lokalitetsnivå, og i noen tilfeller gjerne helt ned på merdnivå. I tillegg til vekstmodeller, som produsentene ofte har justert gjennom en årrekke på bakgrunn av observasjoner, bruker oppdrettene også tilvekststabeller som med bakgrunn i biomasse for fisken og temperaturen i sjøen kan brukes til å beregne prosentvis tilvekst per dag (Rosten, et al., 2011). Et eksempel på en slik tilveksttabell er presentert under i tabell 3.1.

gram	Temperatur (°C)																				±
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	
30-60 g	0,46	0,66	0,88	1,10	1,33	1,57	1,80	2,10	2,30	2,60	2,90	3,10	3,40	3,60	3,90	4,20	4,40	3,95	3,50	2,95	0,74
60-100 g	0,34	0,48	0,64	0,80	0,96	1,13	1,30	1,40	1,60	1,80	2,00	2,20	2,30	2,50	2,70	2,90	3,10	2,70	2,25	1,70	0,76
100-200 g	0,30	0,42	0,56	0,71	0,85	1,00	1,15	1,32	1,50	1,65	1,80	2,00	2,15	2,30	2,50	2,65	2,80	2,40	1,90	1,30	0,78
200-300 g	0,26	0,37	0,49	0,61	0,74	0,87	1,00	1,20	1,30	1,50	1,60	1,75	1,90	2,10	2,20	2,40	2,50	2,10	1,70	1,20	0,80
300-400 g	0,21	0,30	0,40	0,56	0,70	0,80	0,95	1,10	1,20	1,35	1,50	1,60	1,75	1,90	2,05	2,20	2,30	1,95	1,55	1,10	0,82
400-600 g	0,19	0,28	0,37	0,51	0,63	0,75	0,88	1,00	1,13	1,25	1,38	1,49	1,63	1,75	1,87	2,01	2,13	1,78	1,41	1,01	0,84
600-800 g	0,17	0,25	0,33	0,46	0,56	0,67	0,78	0,89	1,01	1,12	1,23	1,34	1,46	1,57	1,68	1,79	1,91	1,62	1,28	0,90	0,87
800-1000 g	0,16	0,23	0,31	0,41	0,52	0,62	0,73	0,83	0,93	1,04	1,14	1,25	1,35	1,46	1,56	1,67	1,77	1,50	1,19	0,83	0,90
1000-1250 g	0,15	0,22	0,29	0,38	0,48	0,58	0,67	0,77	0,87	0,96	1,06	1,16	1,25	1,35	1,45	1,55	1,64	1,39	1,10	0,77	0,95
1250-1500 g	0,14	0,20	0,27	0,35	0,44	0,53	0,62	0,72	0,80	0,89	0,98	1,07	1,15	1,24	1,34	1,43	1,51	1,24	0,98	0,69	1,00
1500-2000 g	0,13	0,19	0,25	0,33	0,41	0,49	0,57	0,66	0,74	0,82	0,91	0,99	1,07	1,15	1,24	1,32	1,40	0,99	0,63	0,33	1,05
2000-2500 g	0,12	0,17	0,23	0,30	0,38	0,45	0,52	0,60	0,68	0,75	0,83	0,90	1,00	1,05	1,12	1,20	1,30	0,82	0,58	0,30	1,10
2500-3000 g	0,12	0,17	0,22	0,29	0,36	0,43	0,50	0,58	0,65	0,72	0,79	0,86	0,94	1,01	1,08	1,15	1,22	0,78	0,55	0,29	1,15
3000-3500 g	0,11	0,15	0,20	0,27	0,34	0,41	0,48	0,55	0,61	0,68	0,75	0,82	0,89	0,96	1,03	1,09	1,16	0,74	0,52	0,27	1,20
3500-4000 g	0,11	0,15	0,20	0,26	0,33	0,39	0,46	0,52	0,59	0,65	0,72	0,78	0,85	0,92	0,98	1,05	1,11	0,71	0,50	0,26	1,25
4000-4500 g	0,10	0,14	0,19	0,25	0,31	0,38	0,44	0,50	0,57	0,63	0,69	0,75	0,82	0,89	0,94	1,01	1,07	0,68	0,48	0,25	1,30

Tabell 3.1: Tilveksttabell for regnbueørret. Tilvekst (prosent per dag) og FF_{bio} (biologisk fôrfaktor ved temperatur 8-10 °C) (Skretting Norge, 2012).

Tabellen viser forventet daglig vekst for fisken målt i prosent, gitt temperaturen i vannet og størrelse på fisken. Den gir også tall på biologisk fôrfaktor for de ulike størrelsene. Biologisk fôrfaktor er definert som mengde fôr brukt per kilo fisk. Følgende vil da fôrrasjonen bli gitt av tilvekstverdien multiplisert med fôrfaktoren. Fôrrasjonen vil da være en verdi for hvor mye som skal føres gitt størrelse på fisken. Tilveksttabellene er i utgangspunktet levert direkte fra fôrprodusentene, men det er påpekt av fôrprodusentene at disse bare skal brukes som utgangspunkt og at lokale variasjoner må også tas med i vurderingen av fôrmengder (Skretting Norge, 2012).

Justeringene som gjøres for vekstmodeller og tilveksttabeller på lokalitetsnivå kommer som en konsekvens av en varierende fôrfaktor. Fôrfaktoren er definert som

$$\text{Fôrfaktor} = \frac{\text{fôrinntak}}{\text{vektendring}} \quad (3.9)$$

Formelen betegner altså hvor mye fôr som går med på å produsere en viss biomasse (Veterinærinstituttet, 2004). Denne faktoren er svært avhengig av det underliggende miljøet i sjøen, og selv om nåværende biomasse og vanntemperatur er de to definerende variablene i vekstmodellen, er det også andre variabler som har avgjørende betydning for hvor mye utfôret mengde som trengs for å få tilsvarende biologisk produksjon. Et eksempel på en slik variabel kan være oksygennivået i sjøen, som en har sett har stor påvirkning på matfisk i settekar (Rosten T. , 2009). Dette gjør at en langs den norske kysten ser stor variasjon i fôrfaktoren selv i områder hvor temperaturen er den samme (Skretting Norge, 2012).

3.2.2 Eksisterende prediksjoner

Som nevnt innledningsvis, i bakgrunnen for oppgaven, gjøres det prediksjoner for slaktevolum og fordeling av denne også i dagens situasjon. I all hovedsak selges oppdrettsfisk til spotpris basert på prediksjoner som er gjort for slaktevolumet gitt slakt en uke fram i tid (SINTEF, 2009). At prediksjonene stemmer godt overens med den faktiske situasjonen i merdene er derfor essensielt til å kunne oppfylle kontrakter og avtaler for salg. I disse prediksjonene spiller vekstmodellene og tabellene en nøkkelrolle. Vekstfaktoren (VF) er også et nyttig verktøy i planleggingen av produksjonen og beregnes som en vekstrate korrigert for temperaturen i perioden faktoren beregnes for. Denne har siden den ble introdusert i næringen på 90-tallet vært svært mye brukt, hovedsakelig for å sammenligne effektiviteten mellom ulike generasjoner eller utsett (på en lokalitet), noe den er svært egnet til da den er relativt stabil i store deler av produksjonsperioden, og inneholder korrigerings for temperatur i perioden (Veterinærinstituttet, 2004; Iversen & Kosmo, 2018). Denne er definert som:

$$\text{Vekstfaktor} = \text{VF} = 1000 * \frac{V_t^{\frac{1}{3}} - V_0^{\frac{1}{3}}}{DGR} \quad (3.10)$$

hvor V_t er fiskevekt etter t dager. DGR er her døgngader (sum av døgnets gjennomsnittstemperaturer etter vekststart) for sjøen i perioden, og er med andre ord underliggende også gitt som en funksjon av tiden. Dette betyr at VF i utgangspunktet også er

en funksjon av tiden, men her betraktes som tilnærmet en konstant. Denne kan oppdretterne dermed bruke for å regne ut ventet sluttvekt (V) for fisken etter t dager:

$$\text{Sluttvekt}_t = \left(V_0^{\frac{1}{3}} + \left(\frac{VF}{1000} \right) * DGR \right)^3 \quad (3.11)$$

Vekstfaktor og beregning av sluttvekt er et nyttig verktøy når et oppdrett selger fisken før den er slaktet, da den gjennom årlige registreringer gjør det mulig å holde rede på utviklingen av vekstresultat (Veterinærinstituttet, 2004). Denne kan brukes i planlegging av produksjonen, og følgelig også til å gjøre et anslag for sluttvekt og dermed salgsvekst for fisken. Ofte gjøres produksjon, slakt og salg av fisk av ulike selskap, men uavhengig av dette er salgsledet helt avhengig av å ha en gitt mengde og fordeling av fisk for salg. Disse salgene baserer seg da på en prediksjon av vekt- og kvalitetsfordeling levert av oppdrettet til salgsledet.

Formatet på prediksjonene som overleveres avhenger gjerne av størrelsen til et oppdrett, og større produsenter har gjerne systemer hvor predikert slaktevolum innrapporteres lang tid i forveien. Disse prediksjonene oppdateres med bakgrunn i vekstmodeller før endelige prediksjoner typisk leveres en uke før slakt (SINTEF, 2009). Videre blir salget gjennomført med bakgrunn i denne siste prediksjonen. En produsent som følger denne metoden er Grieg Seafood AS, heretter omtalt som Grieg. Sammen med Bremnes Seashore AS eier de salgsselskapet Ocean Quality AS, med eierandeler på henholdsvis 60 og 40 prosent (Grieg Seafood ASA, u.d.). Det leveres oppdaterte regneark med prediksjoner fra Grieg før den aktuelle fisken skal slaktes. Disse prediksjonene oppdateres fram til siste uke før slakt, hvor Ocean Quality selger fisken til sine kunder basert på det endelige predikerte slaktevolumet (C. Birkeland, personlig kommunikasjon, 4. februar 2020). Det eksisterer med andre ord systematisert oversendelse av prediksjoner, og det vil være forholdsvis enkelt for Grieg og/eller Ocean Quality å gjøre en historisk sammenligning av det predikerte og faktiske slaktevolumet. Dette forutsetter at de har historiske data lett tilgjengelige, og at innrapporterte regneark er arkivert på en slik måte at data lett kan brukes til analyseformål. Denne systematiserte oversendelsen av predikert slaktevolumet av fisk er helt nødvendig for en leverandør av Grieg sin størrelse, som totalt omsatte for 7,8 milliarder i 2018 (Proff, u.d.).

På den andre siden er det også en rekke mindre oppdrett i bransjen som har andre format på overlevering av predikert slaktevolum (F. Sandvik, personlig kommunikasjon, 19. februar 2020). Svanøy, som totalt omsatte for 131 millioner i 2018, er et eksempel på et slik oppdrett

som blir relativt lite sett i forhold til Grieg (Proff, u.d.). Svanøy leverer riktignok også prediksjoner til et separat salgsselskap, Skaar, som også er en av de større aksjonærene i Svanøy (Skaar Norway AS, u.d.). Rapportering av prediksjoner er den samme, ved at Svanøy før slakt jevnlig leverer prediksjoner til Skaar fram til de en uke før slakt leverer en endelig prediksjon. Innrapporteringene av antatt slaktevolum blir i dette tilfellet gjort muntlig over telefon, fremfor med regneark som var tilfellet for Grieg og Ocean Quality (F. Sandvik, personlig kommunikasjon, 19. februar 2020). En vil med andre ord enkelt kunne se avvik mellom prediksjon og faktisk slaktevolum like etter slakt har blitt utført, men den muntlige rapporteringen gjør det umulig å hente ut historiske tall for avvik mellom predikerte og faktiske slaktevolum. Vi mener at det virker rimelig å anta at Svanøy har tilsvarende avvik som andre oppdrett, og det er dette vi videre vil fokusere på når vi bruker SINTEF sine rapporter og tall for avvik.

4 Data

Som tidligere nevnt er data vi bruker i denne oppgaven hentet fra og satt sammen ved hjelp av produksjonssjef i Svanøy Havbruk AS, Frode Sandvik. I denne delen av oppgaven gir vi en oversikt over hvordan dette datasettet er satt sammen, og videre hvordan det er tilpasset for bruk i henhold til metoden beskrevet i neste del av oppgaven. Dette gjør vi gjennom først å beskrive hvordan det opprinnelige datasettet er bygget opp, før vi videre forklarer hvordan vårt preprosesserte datasett er delt opp i input- og outputvariabler. Vi vil så kort beskrive det endelige datasettet med tilhørende beskrivende statistikk.

4.1 Datasett

Data mottatt fra Svanøy er hentet fra to ulike kilder, et datasett med produksjonsdata hentet fra Svanøy, og et datasett med slaktedata hentet fra slakteriet som Svanøy benytter, Slakteriet AS. Vi vil videre beskrive disse datasettene hver for seg, før vi beskriver hvordan disse datasettene er slått sammen og preprosessert.

4.1.1 Produksjonsdata

Datasettet for produksjonsdata er levert direkte fra Svanøy i xlsx-format. Hver utsatt generasjon har sitt eget regneark, som inneholder produksjonsdata for hvilke merder generasjonen ble fordelt over. Produksjonsdata er i denne oppgaven en samlebetegnelse som omfatter navnet på merden, dato for utsett av fisken og gjennomsnittsvekten på fisken ved utsett. I tillegg inneholder datasettet produksjonsdata som daglige registreringer for fôring, antall dødfisk, totalvekt dødfisk og gjennomsnittlig vanntemperatur siste døgn. Dette er hovedparametrene som blir målt med forholdsvis lite avvik for hele produksjonen. Datasettet inneholder i tillegg estimer gjort av Svanøy for antall fisk og gjennomsnittsvekten til fisken. Dette datasettet, fra Svanøy, inneholdt totalt åtte generasjoner for slakt som vi vil presentere noe beskrivende statistikk for til slutt i kapitlet.

4.1.2 Slakterapporter

Slaktedata er hentet ved hjelp av produksjonssjef ved Svanøy, men kommer opprinnelig fra slakteriet de benytter, Slakteriet AS. Slakteriet AS betegner disse som slakte og kvalitetsrapporter, da de inneholder informasjon om både vekt- og kvalitetsfordeling for

slakten. Vekt- og kvalitetsfordelingen er tilsvarende som beskrevet i bakgrunnen for oppgaven, og oppgir slaktet volum, vekt og antall, fordelt i disse klassene. Rapportene inneholder også annen deskriptiv informasjon som navnet på båten fisken er hentet med, oppholdet til fisken i ventemerden, totalt antall kilogram sløyd fisk, en mer detaljert kvalitetsvurdering om fisken på overordnet nivå, informasjon om utkast m.m. Rapportene er levert i pdf-format, og på forespørsel om å få tilsendt data i mer letthåndterlig format, hadde ikke slakteriene mulighet til å hente ut dette. Det krevde derfor en svært manuell transkriberingsprosess, for å få alle verdier over i et håndterlig format. Totalt fikk vi overlevert 51 slakterapporter, som korresponderte med alt av slakt for de åtte generasjonene med fisk produsert av Svanøy. Beskrivende statistikk vil først bli gitt ved endelig sammensetting av datasett i del 4.3.

4.2 Preprosessering av datasett

Vi vil i neste hoveddel beskrive metoden og modellen for vår oppgave, og tilpasser datasettet i henhold til denne. På samme måte er flere parametre ved modellen i metoden satt med bakgrunn i datasettet, som også er grunnen til at vi i vår oppgave beskriver vårt datasett og preprosesserte datasett før vi beskriver metoden. Vi vil i de neste delene beskrive hvordan vi preprosesserte datasettet med hensyn på input- og outputvariabler, før vi kort beskriver vårt endelige datasett.

4.2.1 Inputvariabler

Denne oppgaven har ikke som mål å avdekke hvilke inputvariabler som best predikerer slaktefordelinger, men om metoden vi utformer, sammen med eksisterende variabler, kan brukes til prediksjon av vekt- og kvalitetsfordeling for slakt. Inputvariablene er hentet fra produksjonsdata, og består i utgangspunktet av År, Dag (dag i året), Tid (antall dager i sjø), Generasjon, UBvekt (gjennomsnittsvekt utsett i gram). I tillegg til dette har vi variabler for fôring (kilogram), antall dødfisk, vekt dødfisk (kilogram) og gjennomsnittlig vanntemperatur (celsius). En utfordring med sammensetningen av datasettet er at vi bare har outputvariabler, som vil være vekt- og kvalitetsfordeling, ved slakt. Vi må derfor tilpasse produksjonsdataen slik at outputvariablene har tilhørende inputvariabler som gir et bilde av historikken og veksten, ikke bare et øyeblikksbilde av hvordan forholdene er i merden ved dagen for slakt. Siden fordelingen av størrelse skjer gjennom vekst, og derfor over tid, transponerer vi produksjonsdata til å vise utvikling over tid. Dette gjør vi ved å summere data for de respektive

variablene for et gitt intervall tilbake i tid fra slakt, med unntak av temperatur hvor vi tar gjennomsnittet for de ulike intervallene. Vi har valgt å bruke et intervall på 1, 2, 5 og 10 måneder, samt en variabel for hele perioden i sjø. Vi benytter 30 dager som størrelsen for en måned, og intervallet vil være beregnet fram til en uke før slakt. For eksempel vil intervallet på en måned inneholde data fra perioden 37 – 7 dager før slakt. Vi benytter data fra én uke før slakt, da det er på dette tidspunktet produsenten typisk leverer endelig prediksjon av vekt- og kvalitetsfordeling til salgsløddet i verdikjeden. Vi har på bakgrunn av dette variablene F01, F02, F05, F10 og FTotale for fôring (kilogram), DA01, DA02, DA05, DA10 og DATotale for antall døde fisk, DM01, DM02, DM05, DM10 for vekt for dødfisk (kilogram), og T01, T02, T05, T10 og TTotale for gjennomsnittlig vanntemperatur (celsius). Oversikten over disse variablene er presentert i appendiks B.1. Produksjonsdata inkluderer også Svanøy sine estimer for gjennomsnittsvikt og antall fisk, men vi vil ikke benytte disse da vi ved trening av vår modell kun vil benytte faktiske verdier.

En annen vurdering som er gjort i arbeidet med å sette sammen et komplett datasett er hvordan en skal håndtere merdsplitting. Splitting av merder kan skje av ulike grunner, for eksempel i sammenheng med kapasitetsutnyttelse og begrensninger for masse i en merd. Ved splitting av merd, vil de to merdene fisken overføres til, ha felles data for produksjonen fram til gjennomføring av splittingen. For disse tilfellene benytter vi estimerte andel for fisk i de nye merdene som fordelingsnøkkel for produksjonsdata fram til splitting (fôring, antall dødfisk, vekt dødfisk). Det er rimelig å anta at Svanøy ved splitting av merder benytter rørtellere, og estimert antall fisk vil derfor være den beste fordelingsnøkkel.

4.2.2 Outputvariabler

Et av målene ved denne oppgaven er å predikere vekt- og kvalitetsfordeling ved slakt, og det er derfor dette som vil være våre outputvariabler hentet fra slakterapportene. Klasser for vekt og kvalitet er de samme som for næringen ellers, og antallet fisk er delt i intervaller på 1 kilogram mellom 0 – 6 kilogram. Kvalitetsklassene er SUP, ORD og PROD. Dette betyr at vi totalt har 6 vektklasser for hver kvalitetsklasse, og i alt 18 klasser. I noen tilfeller er slakterapportene delt opp i PROD A og PROD B, men grunnet svært få fisk i hver av disse, velger vi å slå de sammen slik at de samlet utgjør PROD.

Antallene fra hver slakt gjør vi om til prosentvise fordelinger, slik at vi totalt har 18 outputvariabler for fordelingen til hver slakt. Variablene vil være mellom 0 og 1, og de samlede outputvariablene for slakten vil summert være 1.

4.2.3 Endelig datasett

Det endelige datasettet er et sammensatt datasett av slaktedata og tilhørende produksjonsdata for Svanøy i perioden 2018 til 2020, hvor slaktene ble utført i 2019 og 2020. Vi har totalt 51 observasjoner (slakt), hvor hver observasjon har 25 inputvariabler og 18 outputvariabler som er presentert over og med en liste i appendiks B.1. Inputvariablene består av produksjonsdata, mens outputvariablene består av faktisk vekt- og kvalitetsfordeling. Datagrunnlaget er begrenset til disse årene og observasjonene, ettersom ytterligere historikk for slaktedata ikke er tilgjengelig. Vi kunne fått produksjonsdata for ytterligere generasjoner fra Svanøy, men dette ville vært uten tilhørende slakterapporter. Vi vil videre kort presenterte noe beskrivende statistikk for det endelige datasettet, før vi videre beskriver metoden for oppgaven.

4.3 Beskrivende statistikk

Totalt inneholder datasettet produksjon- og slaktedata for 51 slakt. Det er totalt slaktet 934 139 fisk, noe som tilsvarer omtrent 3 000 tonn. Gjennomsnittsvekten ved utsett varierte mellom 102 og 263 gram. En slakt har i gjennomsnitt stått 352 dager fra utsett av fisken til prediksjonen gjøres, noe som vil si at et parti i gjennomsnitt står i sjøen 352 dager pluss 7 dager før slakt blir utført. Største andelen av slaktene er gjort på høsten, som vi ser av variabelen Dag med et gjennomsnitt på 239 og median på 225. Gjennomsnittlig vanntemperatur for slakt var på 10,64 grader. Tabell 4.1 viser beskrivende statistikk for de nevnte inputvariablene. For resterende inputvariabler legges tilsvarende beskrivende statistikk ved i appendiks C.1.

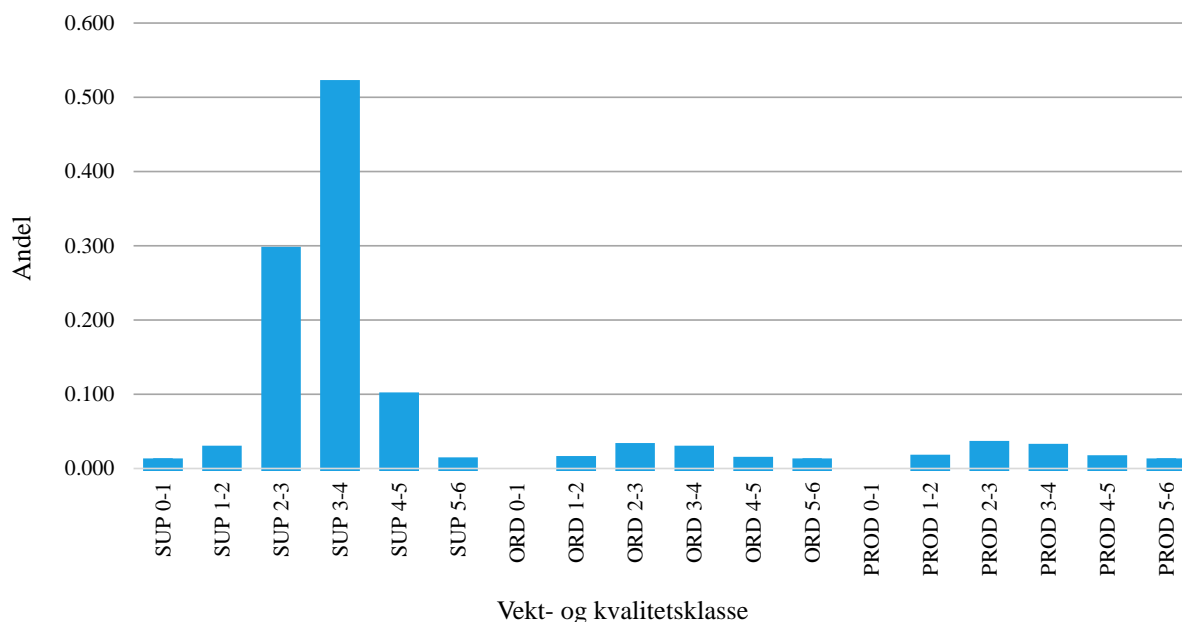
	Min	Median	Max	Gjennomsnitt
Dag	55	239	352	225
Tid	295	352	404	352
UBvekt	102	183	263	178
TTtotal	8,78	9,85	10,64	9,76

Tabell 4.1: Beskrivende statistikk for inputvariablene Dag, Tid, UBvekt og TTtotal.

Outputvariablene våre viser videre at majoriteten av antallet slaktet fisk blir klassifisert i klassen SUP 3-4. Denne klassen utgjør alene 51 prosent av totalt antall slaktet fisk. Tabell 4.2 viser beskrivende statistikk for outputvariablene for kvaliteten SUP, som utgjør over 90 prosent av totalt antall slaktet fisk. Fullstendig tabell med beskrivende statistikk for alle klasser legges ved i appendiks C.2, men den totale fordeling er her presentert med figur 4.1.

	Min	Median	Max	Gjennomsnitt	Akk. Gjennomsnitt
SUP 0-1	0,000	0,000	0,001	0,000	0,000
SUP 1-2	0,003	0,014	0,041	0,017	0,018
SUP 2-3	0,078	0,249	0,742	0,285	0,303
SUP 3-4	0,112	0,559	0,672	0,510	0,812
SUP 4-5	0,000	0,062	0,333	0,089	0,901
SUP 5-6	0,000	0,000	0,018	0,002	0,903

Tabell 4.2: Beskrivende statistikk for outputvariablene for kvaliteten SUP.



Figur 4.1: Vekt- og kvalitetsfordeling for det endelige datasettet fra Svanøy.

5 Metode

I denne delen av oppgaven introduserer vi hvordan vi vil evaluere vår modell, før vi forklarer oppbygningen av modellen, og videre hvordan den endelige arkitekturen til modellen ser ut. Til slutt forklarer vi kort hvilke verktøy og programmeringsspråk vi har brukt for å utforme modellen.

5.1 Evaluering av modell

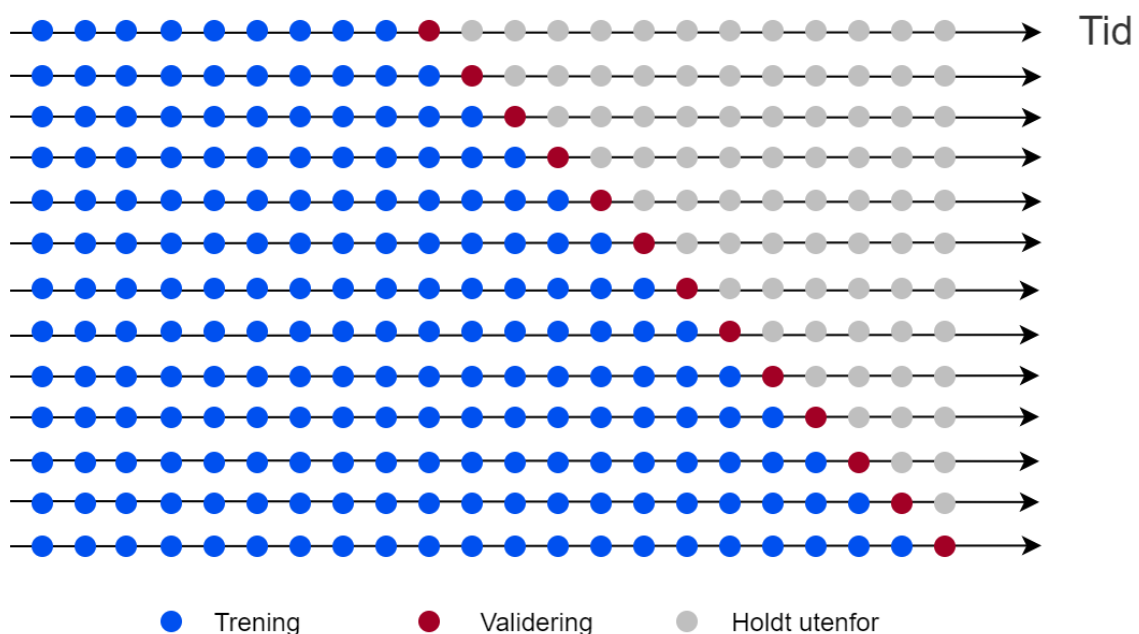
Når en jobber innenfor maskinlæring er et av de viktigste valgene som gjøres hvordan en skal validere modeller. Valideringen vil ikke bare gi deg en bedre forståelse av modellen, men representerer også et svært verdifullt måltall på hvor godt modellen gjør det, altså i hvilken grad modellen er objektiv og greier å generalisere over et helt datasett. Det finnes en rekke måter en kan validere en modell på, men fundamentet for enhver metode for validering er hvordan en velger å dele opp datasettet. Målet med oppdelingen er å forstå hvordan modellen vil gjøre det dersom vi mater den med data på samme format, men som den ikke har sett før. For at en modell skal være pålitelig er det derfor svært viktig å ta hensyn til hvilken type data en har, og velge oppdelingen av data basert på dette (Grootendorst, 2019). Det ville for eksempel vært et dårlig valg å benytte en tilfeldig oppdeling av et datasett bestående av tidsseriedata. I et slikt eksempel kan en risikere at modellen selv kjenner fasiten vi prøver trene den til å predikere, ved at modellen også får matet fremtidig informasjon. Dette er typisk kjent som se-fremover bias (look-ahead bias) (Hyndman & Athanasopoulos, 2018). Vi vil i denne delen først forklare hvilken oppdeling vi gjør av vårt datasett, før vi videre ser nærmere på bias-varians dilemmaet og hvordan vi vil håndtere dette. Avslutningsvis forklarer vi hvordan vi skal måle nøyaktigheten og hvordan vi skal bruke dette til å evaluere vår modell.

5.1.1 Oppdeling av datasett i trening og test

I prosessen med å lage en modell ved bruk av nevralt nettverk og maskinlæring generelt, er det etablert en praksis hvor en deler opp datasettet i deler for trening, validering og test. Dette er helt essensielt da den eneste måten en kan måle hvor godt modellen har generalisert i møte med nye data, er ved å faktisk teste den på data modellen ikke har sett før. Ved bruk av en oppdeling i trening, validering og test, så kan vi trene den ved bruk av treningsdelen, justere hyperparametrene basert på hvordan modellen gjør det med valideringsdelen og evaluere

modellen basert på nye data som modellen ikke har sett før plassert i testdelen. På denne måten kan en få et estimat av hvor feil den trente generelle modellen gjør det (Géron, 2017).

For å håndtere mulig se-fremover bias vil vi til enhver tid sørge for at data som vi tester modellen på, er fram i tid sett i forhold til data som modellen trener med. På tidspunktet vi ønsker å predikere vekt- og kvalitetsfordeling, er det viktig at modellen ikke allerede har trent med fremtidige datapunkter. Dette håndterer vi ved å dele opp datasettet med bakgrunn i dato. Samtidig implementerer vi tidsserie kryssvalidering (cross-validation) som er illustrert med figur 5.1 under (Hyndman & Athanasopoulos, 2018). Ved å gjøre dette trener vi modellen på en større og større del av vårt datasett, og validerer den til enhver tid på fremtidige data. Etersom modellen trenes flere ganger med et større og større datasett er dette en metode som er krevende både med hensyn på tid og prosessorkraft.



Figur 5.1: Illustrasjon for oppdeling av datasett i trening, validering og test for tidsserie kryssvalidering.

5.1.2 Dilemma omkring bias og varians

I maskinlæring og nevralt nettverk er det vanlig å måle ytelsen til en modell ved bruk av et feilbegrep for prediksjoner. Dette begrepet kan ifølge Brownlee (2019c) deles opp i tre komponenter: bias, varians, og ureduserbar feil. Singh (2018) presenterer en matematisk forenkling av hvordan disse tre henger sammen og utgjør total feil for en modell:

$$\text{Total feil} = \text{bias}^2 + \text{varians} + \text{ureduserbar feil} \quad (5.1)$$


Vi vil i denne delen gå igjennom de tre ulike komponentene og se på hvordan avveiningen mellom bias og varians er en trade-off. Vi vil så videre forklare hvordan vi kan kjenne igjen bias og varians når vi skal evaluere vår modell, og hvordan vi vil håndtere dette.

Bias komponenten refererer til i hvilken grad modellen tar overforenklede forutsetninger når den prøver tilnærme seg målfunksjonen (target function) under trening. Dersom en modell har høy bias vil den ta flere forutsetninger, og dermed returnere høyt tap både under trening og validering. Dette er et tilfelle av undertilpasning, som nevnt i teoridelen. Dersom en ser for seg en lineær algoritme, er dette et godt eksempel på et slikt tilfelle, da algoritmen er svært lite fleksibel, men kjører raskt og er enkel å forstå (Brownlee, 2019c).

Varians referer derimot til hvor mye predikerte verdier varierer hver gang modellen får nye data å trene med. Ideelt sett ønsker vi at denne skal variere så lite som mulig fra et datasett for trening til et annet. Dersom det er lite varians er modellen god på å generalisere og den forstår de underliggende trådene mellom input- og outputvariablene. I en situasjon hvor modellen ikke generaliserer godt, og predikerte verdier varierer stort avhengig av hvilket datasett modellen er trent med, har vi høy varians. Som vi var inne på innledningsvis er dette et fenomen som er kjent som overtilpasning, hvor modellen sliter med å finne de underliggende trådene (Brownlee, 2019c).

Bias og varians er noe vi til enhver tid jobber for å redusere. I tillegg eksisterer det også en tredje type feil, som kategoriseres som ureduserbare feil. Dette er den typen feil som eksisterer uansett valg av algoritme og parametre, som oftest som en konsekvens av at et datasett er ufullstendig og/eller har iboende tilfeldigheter (Brownlee, 2019c).

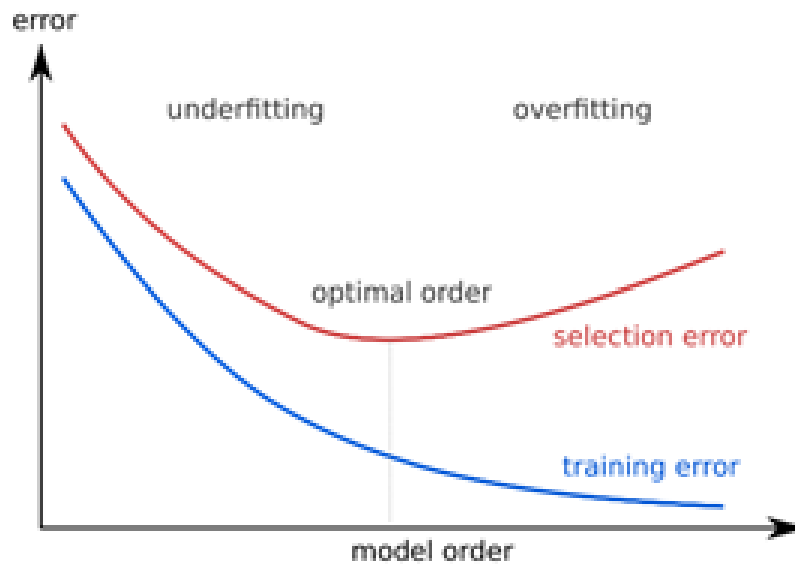
I alle implementeringer av maskinlæring og nevralt nettverk er det et mål om lav bias og lav varians. To lave verdier av disse vil lede til at modellen leverer gode prediksjoner, hvilket er målet i enhver prediksjonsmodell (Brownlee, 2019c). Generelt er det likevel slik at enkle algoritmer som har lav grad av kompleksitet, har lav varians og høy bias. På motsatt side har mer komplekse algoritmer høy varians, men lav bias. Etersom det er en avveining mellom disse, hvor lav kompleksitet fører til lav varians og høy kompleksitet til lav bias, kan dette betegnes som en trade-off. En modell kan ikke ha lav og høy kompleksitet samtidig (Brownlee, 2019c; Almaliki, 2018).



Figur 5.2: Illustrasjon av trade-off mellom bias og varians (Almaliki, 2018).

Den forenklede formelen (5.1) er over presentert med figur 5.2 som illustrerer hvordan en bør forholde seg til avveiningen mellom lav bias og lav varians. Det optimale for et nevralt nettverk og maskinlæring generelt er å finne en balanse mellom disse som også gjør den totale feilen for modellen lavest mulig. Dette er vanskelig da vi ikke kjenner den underliggende målfunksjonen, noe som gjør det umulig å kalkulere eksakte verdier av bias og varians (Singh, 2018).

Under evaluering av vår modell benyttes etablerte teknikker som sørger for å unngå situasjoner med overtilpasning eller undertilpasning. Teknikkene baserer seg i stor grad på sammenligning av feil for prediksjoner gjort i treningsdelen med feil for prediksjonene gjort i testdelen. Figur 5.3 viser hva vi ønsker å oppnå med dette. Dersom både treningsfeil og testfeil er høy, kan dette tyde på at modellen overforenkler og at vi har en situasjon med undertilpasning. I en situasjon hvor modellen har lav feil i treningsdelen, men høy feil i testdelen, kan modellen ha lagt for mye vekt på detaljer i datasettet, og vi har en situasjon med overtilpasning (Almaliki, 2018; Singh, 2018).



Figur 5.3: Illustrasjon av hvordan en bør balansere en modell mellom undertilpasning og overtilpasning (Almaliki, 2018).

For å balansere bias og varians i vår modell og dermed unngå overtilpasning og undertilpasning, finnes det ulike fremgangsmåter for hvordan en kan gjøre dette. Den kanskje enkleste måten å redusere overtilpasning på er å samle inn mer data og dermed ha mulighet til å gjøre datasettet for trening større. Ved å gi modellen mer data å trene med, vil den kunne generalisere bedre og dermed bedre forstå sammenhengen mellom input og output. Samtidig er det nødvendigvis ikke slik at det er en sammenheng mellom mer data og redusert overtilpasning, ettersom dette også kan introdusere mer støy og dermed gjøre det enda vanskelig å generalisere (Almaliki, 2018). Å samle inn mer data er riktignok også enklere sagt enn gjort, da en i mange tilfeller allerede har fått tak i så mye data som mulig. Det finnes likevel flere teknikker en kan bruke for å redusere overtilpasning nevnt innledningsvis i oppgaven, som for eksempel regularisering. I et nevralt nettverk kan en implementere dette ved bruk av dropoutlag. På et overordnet nivå fungerer dette ved at modellen under trening blir straffet dersom den vokser seg for kompleks, og at den dermed selv prøver å unngå dette (Almaliki, 2018).

I en situasjon med undertilpasning er løsningen gjerne langt enklere da en typisk ofte har valget om å bevisst gjøre modellen mer kompleks. For vår modell vil dette innebære å legge til ytterligere skjulte lag og nevroner.

5.1.3 Nøyaktighet

Som nevnt i teoridelen har vi definert et eget måltall for nøyaktigheten til modellen. Dette måltallet er en naturlig del av evalueringen av modellen, og brukes som et utgangspunkt for justering av hyperparametre. Selv om måltallet ikke direkte kan vurdere hvor godt en modell gjør det, er det egnet for å sammenligne ulike modeller og ensembler. Dette gjør at måltallet, selv om det ikke er benyttet direkte for treningen av modellen, er naturlig å bruke som en pekepinn i valget mellom flere modeller og ensembler. Vi benytter det definerte måltallet, se formel (3.7) fra teoridelen, altså det gjennomsnittlig absolutte avviket mellom estimert og faktisk fordeling for vekt- og kvalitetsfordelingen til fisken. For hvert ensemble vil vi i tillegg rapportere største avvik i prosentpoeng (for eksempel 9 prosentpoeng avvik i ensemblet bestående av 15 modeller). Vi vil også rapportere tilsvarende medianavvik i prosentpoeng for hvert ensemble, som sammen med største avvik og nøyaktigheten vil gi ytterligere sammenligningsgrunnlag mellom ensemblene.

5.2 Eksisterende prediksjoner og avvik

I arbeidet med en modell for prediksjoner for vekt- og kvalitetsfordeling på merdnivå i oppdrettsnæringen, vil det være naturlig å også benytte de eksisterende prediksjonene ved evaluering av modellen. Som vi har vært inne på i teoridelen er det forskjellig fra produsent til produsent hvorvidt salgsløddet er internt i oppdrettsfirmaet, eller om et eksternt firma tar hånd om denne delen av verdikjeden. Hvordan prediksjonene overleveres er også svært ulikt for ulike produsenter, og hvor systematisert dette er gjort avhenger i stor grad av størrelsen til produsenten. Mens vi har sett at de største produsentene har systematisert innrapportering, har de minste gjerne mindre systematiserte ordninger for dette, og de har dermed også mindre muligheter for å hente ut historiske tall for disse prediksjonene. Det vil også være relevant å knytte resultatene våre opp mot SINTEF sitt estimerte gjennomsnittsavvik på 5 prosent. Dette er avvik som ikke tar hensyn til kvalitetsfordeling og en vil derfor ikke direkte kunne sammenligne avviket med resultatene fra vår modell. Dette vil likevel kunne gi et uttrykk for hvordan modellen gjør det i forhold til dagens situasjon.

Som vi har sett av datadelen over, har ikke Svanøy historiske data for predikerte slakteverdier. Predikerte verdier blir innrapportert muntlig over telefon, og det finnes ingen registrering av disse verdiene utover salgene som salgsselskapet gjør. Dette betyr at vi, med vårt datasett, ikke

vil ha disse tallene å sammenligne med, og at vi dermed ikke vil kunne si hvorvidt vår modell har gitt bedre prediksjoner sammenlignet med de prediksjonene som Svanøy tidligere har gjort selv. For andre produsenter som implementerer modellen vil det derimot være rimelig å anta at det eksisterer historiske data for prediksjoner gjort for fordelingen til fisken, og at en dermed har dette som sammenligningsgrunnlag når en skal evaluere hvor godt modellen gjør det.

5.2.1 Gjennomsnittsfordelingen for slaktet fisk

Basert på data overlevert fra Svanøy har vi en gjennomsnittsfordeling for all slaktet fisk presentert i del 4.3 om beskrivende statistikk. Den enkleste prediksjonen Svanøy kan gjøre for kommende slakt er å anta samme fordeling som gjennomsnittsfordelingen for tidligere slakt. Uten annet direkte sammenligningsgrunnlag, vil det være naturlig å sammenligne seg med denne fordelingen, og modellen vår bør som et minimum levere bedre prediksjoner enn denne. Etersom vi i vårt resultat vil evaluere både validering og test, vil vi benytte en gjennomsnittsfordeling for Svanøy basert på slaktedata for henholdsvis treningsdelen (uten validering og test) og valideringsdelen (uten test). Disse gjennomsnittsfordelingene er presentert i tabell 5.1 og tabell 5.2 under:

		Vekt					
		0-1	1-2	2-3	3-4	4-5	5-6
Kvalitet	SUP	0	0,015	0,292	0,515	0,077	0,001
	ORD	0	0,004	0,024	0,018	0,002	0,000
	PROD	0	0,005	0,025	0,019	0,003	0,000

Tabell 5.1: Gjennomsnittsfordelingen til Svanøy basert på treningsdelen av datasettet.

		Vekt					
		0-1	1-2	2-3	3-4	4-5	5-6
Kvalitet	SUP	0,000	0,016	0,277	0,505	0,094	0,002
	ORD	0,000	0,004	0,023	0,019	0,002	0,000
	PROD	0,000	0,005	0,025	0,022	0,005	0,000

Tabell 5.2: Gjennomsnittsfordelingen til Svanøy basert på trening- og valideringsdelen av datasettet.

5.3 Design av nevralt nettverk

5.3.1 Input og normalisering

Når nettverket utfører trening og validering vil det selv identifisere hvilke input og nevroner som er viktige når modellen skal predikere output. Dersom en modell er presentert med et stort antall inputvariabler vil den til en viss grad selv vurdere hvilke av disse den skal vektlegge, og dermed hvilke av disse som har størst betydning for prediksjonene. Vi normaliserer inputvariablene både for trening- og testdelene ved å bruke formelen (3.3), som benytter minimum- og maksimumsverdi for hver variabel. For å unngå mulig se-fremover bias normaliserer vi inputvariablene først etter vi har delt data i trening og test, hvor test er normalisert ved bruk av min og maks i trening. I en situasjon hvor normalisering utføres før denne oppdelingen, kan et datasett indirekte inneholde informasjon om mulige fremtidige minimum- og maksimumsverdier. Vi normaliserer ikke outputvariablene våre ettersom disse representerer en fordeling.

5.3.2 Kryssvalidering

Fra datadelen over har vi sett at datasettet overlevert fra Svanøy totalt består av 51 observasjoner. Som nevnt i evalueringen av modellen er datasettet delt opp med hensyn på dato for å håndtere se-fremover bias. Vi implementerer også kryssvalidering for en initial modell, og ser at det er en tendens til at modellene med få observasjoner har høyere tap og dårligere nøyaktighet. Et plot for den initiale modellen, som trener med en større og større del av datasettet, er presentert i appendiks D.1. Som nevnt over er kryssvalidering svært krevende både med hensyn på tid og prosessorkraft, samtidig som vi videre vil implementere ensembler

som også er å regne som prosessorkrevende. Vi vil derfor ikke benytte kryssvalidering i vårt endelige ensemble av modeller, ettersom dette samlet sett blir for tid- og prosessorkrevende. I en situasjon hvor maskinkraft ikke er en bindende ressurs, ville kryssvalidering vært et nyttig verktøy for å validere robustheten til modellen. Datasettet vi videre benytter til trening og validering er på henholdsvis 38 og 5 observasjoner. Testdelen vi holder helt utenfor modellen er på 8 observasjoner.

5.3.3 Lag og nevroner

Det er i praksis ikke et fasitsvar på antallet skjulte lag og antall nevroner et nevralt nettverk bør bestå av. Dette er helt avhengig av hvilken anvendelse nettverket skal ha, datasettet som skal benyttes og en rekke andre faktorer. Det er likevel slik at ytelsesdiagnostikk viser at i et nevralt nettverk med et enkelt skjult lag er 6 nevroner et godt utgangspunkt for videre undersøkelser og testing (Makridakis, Spiliotis, & Assimakopoulos, 2018). Vi vil benytte dette som utgangspunkt for modellen, og deretter prøve å forbedre nettverket gjennom å øke antallet skjulte lag og nevronene i hvert lag. Dette gjør vi metodisk ved å justere et og et parameter. Fra utgangspunktet med et skjult lag og 6 nevroner forsøker vi videre med 2 og 3 skjulte lag. For å strukturere og begrense antall muligheter benytter vi alltid et fallende antall nevroner i de ulike lagene, og varierer antallet nevroner mellom verdiene 6, 12 og 24. Det er igjen umulig å vite hvilken nettverksarkitektur som er ideell, og som for andre innstillinger i nettverket ville en i en situasjon hvor maskinkraft ikke er en bindende ressurs, testet med ytterligere verdier. Antallet nevroner for input- og outputlag er bestemt av antallet input- og outputvariabler, som vi fra data-delen av oppgaven her sett er henholdsvis 25 og 18.

5.3.4 Læringsrate og forfallsfrekvens

For valgt optimaliserer, Adam, er standardverdier for læringsrate og forfallsfrekvens henholdsvis 0,001 og 0. Som nevnt spesifiserer læringsraten hvor mye vektene til modellen skal oppdateres, mens forfallsfrekvensen reduserer læringsraten for hver epoke. Vi setter disse i sammenheng med hverandre, da en høy læringsrate bør ha tilsvarende høy forfallsfrekvens. Vi justerer disse i kombinasjoner for hver av de ulike arkitekturerne. Kombinasjonene vi benytter er presentert i tabell 5.3. Sammen med de mulige arkitekturerne har vi totalt 49 mulige kombinasjoner.


Læringsrate	Forfallsfrekvens
0,0001	0
0,001*	0*
0,001	0,00001
0,01	0
0,01	0,00001
0,01	0,0001
0,01	0,001

Tabell 5.3: De ulike kombinasjonene benyttet for valg av læringsrate og forfallsfrekvens.

*Viser standardinnstillinger for Adam

5.3.5 Antall modeller i hvert ensemble

For hver enkelt kombinasjon av arkitektur, læringsfrekvens og forfallsrate er en modell trent gjentatte ganger for å danne ensembler. For hver modell som trenes produseres et ensemble med de hittil trente modellene. Det trenes 30 modeller for hver kombinasjon av arkitektur og hyperparametre, som samlet produserer et sett med 30 ulike ensembler illustrert i figur 5.4. Vi har begrenset mengden modeller i et ensemble til 30. Nøkkeltallene nøyaktighet, største avvik og medianavvik rapporteres for hvert ensemble.




Figur 5.4: Illustrasjon av ensemblene som består av mellom 1 og 30 modeller, hvor ensemble 1 består av 1 modell og ensemble 30 av 30 modeller.

5.3.6 Sammensetning

I vår metodiske trening av ensembler har vi 49 ulike kombinasjoner av modellstrukturer. For hver av disse produseres 30 sett med ensembler. Dette utgjør totalt 1 440 ulike ensembler som kan brukes til prediksjon. For hver modellstruktur registreres nøkkeltallene for det ensemblet med best nøyaktighetsmål, som utgjør sammenligningsgrunnlaget for valg av endelig modellstruktur. Registrerte nøkkeltall for disse 49 modellstrukturene legges ved i appendiks D.2. Det endelige ensemblet er valgt basert på en helhetsvurdering med bakgrunn i nøyaktighet, men også medianavvik og maksimum avvik i prosentpoeng.

5.4 Endelig oppsett

I denne delen vil vi kort introdusere den endelige arkitekturen for det nevrale nettverket, basert på design og sammensetningen beskrevet i forrige del.



Figur 5.5: Modellarkitekturen for det endelige oppsettet av vårt nevrale nettverk.

Den endelige arkitekturen er presentert i figur 5.5. Nettverket består av et inputlag, to skjulte lag og et outputlag. Nettverket har 25 inputvariabler, som presentert i delen for datasett over. Dette blir så sendt gjennom de to skjulte lagene, som har henholdsvis 24 og 12 nevroner. Disse tre lagene benytter hver for seg ReLU som aktiveringsfunksjon, før de sender sin output videre til neste lag. Det siste laget, outputlaget, består av 18 nevroner som benytter Softmax som aktiveringsfunksjon. Outputlaget produserer en sannsynlighetsfordeling for vekt- og kvalitetsfordeling for en slakt. Læringsraten modellen benytter er 0,01 og forfallsfrekvens 0,00001. Det brukes et ensemble bestående av 7 modeller.

Det endelige oppsettet for modellen er gjort med bakgrunn i datasett og beskrevet metode. Fremgangsmåten vil kunne brukes for tilsvarende problem, men endelig oppsett vil kunne variere med andre data.

5.5 Implementering med R

Modellen er implementert ved bruk av programmeringsspråket R (versjon 3.6.1). Koden er skrevet ved bruk RStudio versjon 1.3.959. Det er mulig å reprodusere miljøet, og koden kan bli gjort tilgjengelig ved forespørsel.


Vårt nevralt nettverk er implementert ved bruk av Keras versjon 2.2.5 som benytter Tensorflow versjon 2.0.0 i bakgrunnen. Vi kommuniserer med Keras gjennom å bruke R-pakken Keras (Allaire & Chollet, 2020). Vi benytter *readxl* for å laste inn vårt datasett (Wickham & Bryan, 2019), *tibbletime* for å sette en index (Vaughan & Dancho, 2020), *tibble* for å forenkle format (Müller & Wickham, 2020), *rsample* for å tilrettelegge for kryssvalidering (Kuhn, Chow, & Wickham, 2020), *margrittr* for å kunne bruke pipes (Bache & Wickham, 2014), *dplyr* for å bearbeide datasettet (Müller, Henry, François, & Wickham, 2020), og til slutt *ggplot2*, *gridExtra* og *ggpubr* for visualiseringer (Kassambara, 2020; Wickham, et al., 2020; Auguie, 2017).

6 Resultater

I denne delen presenteres resultatene for modellen vår. Først går vi gjennom hvilke resultater vi ser for valideringsdelen, hvor vi ser på ensemblet i helhet før vi videre presenterer resultat for beste ensemble. Deretter presenterer vi resultat for testdelen med tilsvarende ensemble.

6.1 Evaluere validering

Den endelige modellarkitekturen gir et sett med ensembler presentert i figur 6.1. Figuren viser ensemblene sin nøyaktighet (se formel (3.7) i teorikapittelet) i tillegg til gjennomsnitt og distribusjon av nøyaktigheten til enkeltmodellene som er inkludert i ensemblene. Det lysegrå området viser ekstremalpunkter for modellene som så langt er lagt til i ensemblet. Fra figuren har vi at modell nummer 3 er den beste enkeltmodellen av de 30 vi trener. Dårligste enkeltmodell er modell nummer 10. Det mørkegrå området viser rekkevidden for interkvartilen med hensyn på nøyaktigheten til hver enkeltmodell. Den blå linjen viser gjennomsnittlig nøyaktighet for de enkeltmodellene som er inkludert i hvert ensemble. Det blir flere og flere modeller i hvert ensemble, og det er derfor naturlig at den blå linjen får mindre og mindre utslag for hver modell en legger til.



Figur 6.1: Utviklingen i gjennomsnittlig nøyaktighet for modellene, samt nøyaktigheten for ensemblet ved inkludering av flere modeller, for vår valideringsdel.


Når det kommer til selve ensemblet, presterer ensemblet med syv modeller best for våre valideringsdata. Vi ser at nøyaktigheten veldig raskt blir bedre i starten med en økning i antall modeller i ensemblet, før utviklingen avtar og flater ut. Vi presenterer resultatene for ensemblet med syv modeller, sammen med prediksjonen basert på Svanøy sin gjennomsnittlige fordeling. Resultatene for valideringsdelen er presentert i tabell 6.1.

	Ensemblet	Svanøy fordeling
Nøyaktighet	0,008	0,030
Maksimum avvik	0,106	0,231
Medianavvik	0,004	0,004

Tabell 6.1: Resultatene for valideringsdelen for vårt ensemble av modeller, med Svanøy sitt resultat basert på gjennomsnittsfordelingen for samme delen av datasettet.

Fra tabellen ser vi at modellen vår presterer bedre for alle måltall. Gjennomsnittlig nøyaktighet er nærmere 2,2 prosentpoeng bedre med ensemblet. Maksimum avvik i prediksjonene i prosentpoeng er 10,6 for ensemblet sammenlignet med 23,1 prosentpoeng for gjennomsnittlig fordeling. Medianavviket er forholdsvis likt for de to. Studerer vi avvikene mellom våre prediksjoner og den virkelige fordelingen, ser vi at de største enkeltavvikene for klassene er positive. De største enkeltavvikene er med andre ord tilfeller hvor klassene er tildelt for mye fisk sammenlignet med faktisk fordeling. Avvikene for ensemblet og gjennomsnittsfordelingen til Svanøy, sammen med prediksjoner og faktiske verdier for valideringsdelen legges ved i appendiks E.1.

I tillegg til å presentere resultatene vil vi også vurdere valideringskonvergeringen for treningen. Figur 6.2 viser hvordan tapet for de syv modellene som er inkludert i ensemblet utvikler seg gjennom treningen. Vi ser at valideringstapet har minst variasjon ved rundt 30 epoker. Samtidig som variasjonen i tap øker med antall epoker reduseres valideringstapet gjennom hele treningen. Vi ser ingen store tegn på overtilpasning, men det er tydelig at modellen håndterer våre treningsdata bedre enn valideringsdata. Dette kan være tegn på at modellen ikke universalt klarer å tilpasse seg optimalt.



Figur 6.2: Utvikling i tap (Kullback-Leibler divergens) ved trening av de syv modellene som er inkludert i vårt ensemble.

6.2 Evaluere test


Fra valideringsdelen har vi at ensemblet med syv modeller er det ensemblet med best ytelse. Det vil derfor være denne vi vil bruke for å gjøre prediksjoner på testsettet. Dette er det beste estimatet for hvor godt vi kan klare å predikere usette fordelinger. Tabell 6.2 presenterer resultatet fra ensemblet sine prediksjoner for testsettet sammen med tilsvarende resultater for Svanøy sin fordeling.

	Ensemblet	Svanøy fordeling
Nøyaktighet	0,017	0,014
Maksimum avvik	0,139	0,142
Medianavvik	0,007	0,002

Tabell 6.2: Resultatene for testdelen for vårt ensemble av modeller, med Svanøy sitt resultat basert på gjennomsnittsfordelingen for samme delen av datasettet.

For testdelen ser vi verdiene er ganske like for ensemblet som for gjennomsnittsfordelingen. Nøyaktigheten ligger på henholdsvis 0,017 og 0,014, maksimum avvik for ensemblet er på 13,9 prosentpoeng sammenlignet med 14,2 for fordelingen, og medianavvikene er på henholdsvis 0,7 prosentpoeng og 0,2 prosentpoeng. Dersom vi også for denne delen ser nærmere på de faktiske avvikene mellom våre prediksjoner og den faktiske fordelingen, ser vi at det er negative avvik for nesten alle vektklasser av SUP-kvaliteten. Modellen har altså predikert for lite fisk til SUP-klassene og for mye til de to andre. Avvikene for ensemblet og gjennomsnittsfordelingen, sammen med prediksjoner og faktiske verdier for testdelen legges ved i appendiks E.2.

Figur 6.3 under viser hvordan de ulike ensemblene ville gjort det basert på verdier fra testdelen, og kan brukes for å vurdere om en har valgt riktig ensemble når en prøver dette på usett data. I figuren ser vi at utviklingen i nøyaktigheten til ensemblene er noe lik som for valideringsdelen. Nøyaktigheten forbedres i starten og er best med seks og syv modeller i ensemblet. Tilsvarende er nøyaktigheten best for ensemblet med syv modeller i valideringsdelen. Den beste enkeltmodellen for testdelen er den 19. modellen som trenes, mens den dårligste enkeltmodellen er modell nummer 12. Overordnet ser valg av ensemblet med syv modeller ut til å ha vært optimalt da dette ensemblet gjør det best på begge datasett.



Figur 6.3: Utviklingen i gjennomsnittlig nøyaktighet for modellene, samt nøyaktigheten for ensemblet ved inkludering av flere modeller, for vår testdel.

7 Diskusjon

7.1 Hovedfunn

Hovedfunnene fra resultatdelen diskuteres først med tanke på hvordan modellen vår gjør det generelt, ved å sammenligne resultatene vi får i validering- og testdelen. Videre ser vi på hvordan modellen gjør det sammenlignet med gjennomsnittsfordelingen til Svanøy. Deretter gjør vi rede for noen svakheter ved måltallet, før vi til slutt oppsummerer hovedfunnene og tar opp hvordan disse motiverer til videre diskusjon.

7.1.1 Sammenligning av validering og test

I tråd med oppdeling av vårt datasett, får vi nøkkeltall rapportert for valideringsdelen under trening. Testdelen er holdt helt utenfor trening av modellen, og det er først etter modellen er ferdig laget vi forsøker å predikere verdier for denne delen av datasettet. Det er testdelen som vil reflektere hvor godt modellen faktisk gjør det på usett data, og det er dermed denne delen som skal vektlegges ved evaluering av modellen. Vi vil i denne delen kort sammenligne resultatene for de to delene, før vi i neste del vil sammenligne resultatene av modellen med Svanøy sin totale fordeling for slakt.

Som vi har sett fra resultatene over rapporterer vi en nøyaktighet for validering og test på henholdsvis 0,008 og 0,017. For valideringssettet bommer vi altså i snitt 0,8 prosentpoeng i hver klasse vi predikerer, som over en hel slakt utgjør 14,4 prosentpoeng. Med et lite datasett er det ikke forventet at modellen presterer bedre enn SINTEF sine estimater på 5 prosent feilestimering. Det er derimot tydelig fra resultatet at modellen finner sammenhenger i datasettet. Samtidig ser vi at en gjennomsnittlig feilestimering på 1,7 prosentpoeng i hver klasse for testdelen ikke er et godt resultat, da dette summeres til 30,6 prosentpoeng over en hel slakt. Den store forskjellen mellom hva vi ser for valideringsdelen og for testdelen tyder på at modellen ikke har klart å generalisere godt nok.

En av årsakene til dette kan være at testdelen har observasjoner som ikke er representative, og at testdelen derfor ikke reflekterer den reelle ytelsen for modellen. På samme måte kan det være at valideringsdelen ikke er representativ. Grunnen til at dette er problematisk er at modellen, i treningen, justeres for å tilpasse seg enkelte sammenhenger som finnes i valideringssettet.

Gjennom tilpasning av hyperparametre blir modellen god på å plukke opp sammenhenger som den finner igjen i valideringssettet, men sliter med å tilpasse seg overordnede sammenhenger som gjelder for andre observasjoner.

Dette er et problem som i stor grad kan løses ved ytterligere data som vi kommer tilbake til senere i diskusjonen. Et større antall observasjoner i de ulike delene vil sikre at vi har et representativt utvalg både for validering og for test. Modeller er mer utsatt for slike variasjoner i resultatene dersom datamengden er liten. Unormale observasjoner, som strider imot sammenhengene modellen har lært, vil med små datasett i trening, validering- og testdelene være utslagsgivende.

Dersom vi ser nærmere på verdiene for største avvik og median ser vi det samme her, hvor test gjør det dårligere enn validering. Forskjellen i største avvik i de to delene er stor, mens vi ser en noe mindre forskjell i median. Dette underbygger at problemet knyttet til våre mulige utvalg for validering og test ikke er representative. I den videre vurderingen av modellen vil det være naturlig å sammenligne vår modell med den enkleste mulige prediksjonen, nemlig gjennomsnittsfordelingen for Svanøy sine slakt. Det er dette vi vil ta for oss i neste del.

7.1.2 Sammenligne med Svanøy

Som nevnt innledningsvis i metoden har ikke Svanøy sine prediksjoner for slakt vært tilgjengelige, da de ikke har historikk for disse prediksjonene. Som et alternativ benytter vi Svanøy sin gjennomsnittsfordeling som prediksjon for hver slakt. Som et minstekrav burde modellen vår være mer nøyaktig enn denne.

I resultatene for valideringsdelen ser vi at nøyaktighetsmålet for modellen vår og Svanøy sin fordeling er på henholdsvis 0,008 og 0,030. For valideringsdelen predikerer altså modellen vår med vesentlig bedre nøyaktighet enn det gjennomsnittsfordelingen ville gjort. Vi ser tilsvarende bedre verdier for maksimum avvik og medianavvik for vår modell.

Resultatene fra testdelen viser det motsatte, hvor nøyaktigheten for vår modell og gjennomsnittsfordelingen til Svanøy er på henholdsvis 0,017 og 0,014. Gjennomsnittsfordelingen til Svanøy er for testdelen nærmere den faktiske fordelingen enn det modellens prediksjoner er. Vi ser derimot at maksimum avvik er marginalt lavere for modellen med en verdi på 13,9 prosentpoeng, sammenlignet med 14,2 prosentpoeng avvik for

gjennomsnittsfordelingen. Medianavviket for vår modell er vesentlig dårligere enn for gjennomsnittsfordelingen.

Fra sammenligningen mellom validering og test for modellen, har vi sett at det leveres prediksjoner med varierende nøyaktighet. Ved gjentatte kjøring av samme modellstruktur og antallet modeller i ensemblet, ser vi tilsvarende resultater med noen mindre forskjeller i nøyaktighet. Når vi videre også ser store forskjeller i sammenligningen mellom validering og gjennomsnittsfordeling, og mellom test og gjennomsnittsfordeling, kan det tyde på at utvalget av observasjoner i validering ikke er representative for datasettet. Dette ser vi ved at faktiske fordelinger i valideringsdelen i stor grad avviker fra gjennomsnittsfordelingen til Svanøy. Ettersom det er valideringsdelen vi har brukt for å løpende validere og justere våre hyperparametre, vil utfallet av en lite representativ valideringsdel være en modell som er justert for å finne sammenhenger den ikke finner igjen ved usett data.

For å håndtere problemet med en lite representativ valideringsdel, vil det være naturlig å øke antallet observasjoner i denne delen og dermed gjøre dette settet mer pålitelig. Datasettet for modellen består av totalt 51 observasjoner fordelt i deler for trening, validering og test. Med bare åtte av disse observasjonene (15 prosent) til test, vil det være problematisk å gjøre denne delen enda mindre. Problemet med pålitelighet i resultatene ville da bare flyttes til testdelen. Samtidig vil det å hente observasjoner fra treningsdelen også være problematisk da denne i utgangspunktet også er relativt liten. Med en mindre treningsdel kan en risikere at modellens evne til å finne sammenhenger reduseres betraktelig. Utfordringen her er dermed størrelsen på datasettet. Et større datasett vil sikre et større antall observasjoner i hver del, og delene vil kunne anses som representative. Modellen vil da bedre kunne finne sammenhenger i treningsdelen, valideringen vil gi mer korrekte tilbakemeldinger på hvordan modellen skal justeres, og testdelen vil være stor nok til å kunne trekke pålitelige konklusjoner om hvor godt modellen predikerer.

7.1.3 Svakheter ved måltallet

En av svakhetene ved måltallet benyttet i modellen er den manglende synliggjøringen av hvordan de enkelte observasjonene ser ut. Studerer vi nærmere prediksjonene for testdelen, vedlagt i appendiks E.2.2, ser vi at modellen fordeler noe fisk selv til klasser hvor det i treningsdelen av datasettet fra Svanøy ikke er noe fisk. Modellen fordeler altså fisk til klasser hvor den egentlig burde oppfattet at Svanøy historisk ikke har hatt fisk. En modell som er trent

med et stort antall epoker vil kunne klare å unngå dette, men vil igjen kunne introdusere overtilpasning. En måte å unngå dette problemet på er å fjerne klassen med svært få eller ingen fisk, for å fokusere på de klassene som inneholder mest fisk. Samtidig har vi valgt å ha disse med i vår modell ettersom det er tilfeller hvor Svanøy slakter fisk også i disse klassene. En fjerning av disse klassene ville kunnet påvirke modellen positivt ved at vi ikke lenger hadde gitt den muligheten til å predikere for klassene hvor den faktiske fordelingen er null. Det er for øvrig også å anta at en fjerning av disse klassene ville gitt en dårligere rapportert nøyaktighet, ettersom avvikene i de nevnte klassene typisk er små, og at disse dermed påvirker gjennomsnittlig avvik positivt.

7.1.4 Oppsummering og videre diskusjon

Vi identifiserer med bakgrunn i diskusjonen om hovedfunn at datamengden er den største svakheten ved denne studien. Uten tilstrekkelig datamengde vil det ikke være mulig å anvende vår modell, da dette er en forutsetning for nevrale nettverk. Vi velger derfor videre å sentrere diskusjonen rundt hvorfor datagrunnlaget er mangelfullt og hvilke forutsetninger som må oppfylles for å løse dette problemet. Etter dette tar vi for oss mulighetene for ytterligere data og variabler, før vi videre vil se nærmere på hvordan problemet vil se ut dersom forutsetningene er oppfylt. Til slutt tar vi for oss potensielle gevinster ved en vellykket implementering.

7.2 Datagrunnlag

Som vi har sett av resultatene og diskusjonen over kan en av årsakene til at modellen gjør det noe dårligere enn ventet være manglende tilgang på data, som har ført til et svært lite datasett. Datasettet fra Svanøy på 51 observasjoner fordelt over ni måneder, kunne med fordel ha vært langt større med tanke på antallet observasjoner og tidsperiode. I forsøk på å utvide vårt datasett har vi vært i kontakt med flere produsenter innenfor produksjon av regnbueørret, men også for matfisk generelt. Det er en samling av årsaker fra produsentene sin side som har gjort at de ikke har ønsket å overlevere data, men noen av de årsakene som går igjen er at arbeidsmengden som kreves for å hente ut ønsket informasjon er stor, eller at de ikke har denne informasjonen tilgjengelig. Som vi har sett flere tilfeller på, er det ikke uvanlig å ha et separat selskap enten internt eller eksternt for salgsleddet i verdikjeden. Dette kan gjøre at for eksempel salgsdata er desentralisert og svært lite tilgjengelig for produsenten. Dette kan igjen gjøre at det ikke finnes historikk for avvik mellom estimert fisk og den mengden fisk som faktisk ble slaktet, og i beste

tilfelle at det vil kreve mye arbeid for produsenten å hente ut denne informasjonen for å beregne disse avvikene. Vi vil i denne delen diskutere mulige årsaker til hvorfor data fra næringen ikke er gjort mer tilgjengelig, om ikke eksternt, så i hvert fall internt.

7.2.1 Datarapportering

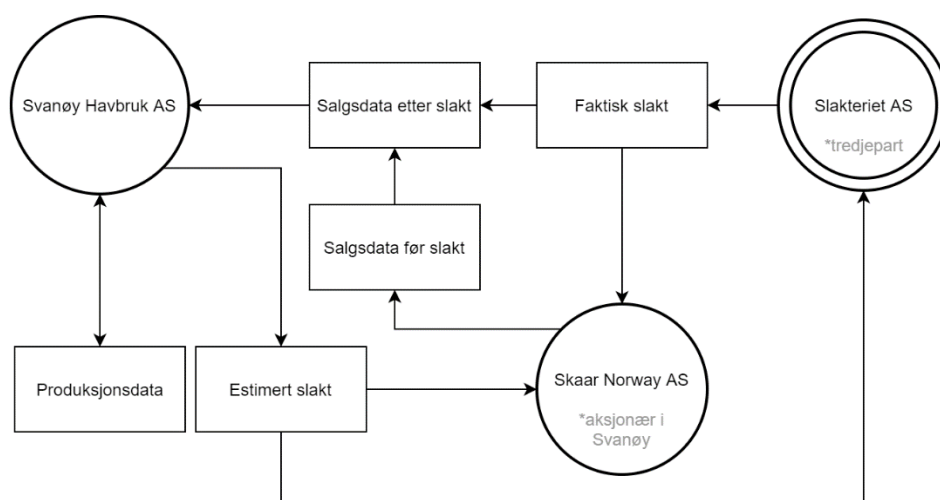
Vi vil i denne delen ta for oss selve rapporteringen av data og hvordan rutiner og mulige strukturelle barrierer kan påvirke dette. Dette gjør vi ved å se på to konkrete eksempler for rapportering av data for to produsenter av matfisk. Vi vil først se på situasjonen i Svanøy, før vi i neste del ser på situasjonen i Grieg, hvor vi i begge tilfeller vil peke på elementer i strukturen som kan påvirke prosessen for innsamling av data. Videre vil vi så ta for oss hvordan et differensierende dataformat i forholdene mellom produksjon, slakt og salg også kan være en årsak til at data ikke eksisterer og/eller er lite tilgjengelig. Til slutt i denne delen vil vi ta for oss MTB, og se hvordan dette kan påvirke insentivene til å samle inn data.

7.2.1.1 Svanøy Havbruk AS, Skaar Norway AS og Slakteriet AS

En av årsakene til at det ikke eksisterer lett tilgjengelige data kan være strukturelle barrierer hos en produsent, og prosessen for rapportering av data for produsenten. Svanøy er et av de selskapene som har en struktur hvor en av majoritetseierne, Skaar, også er deres salgsselskap. Videre er slakteriet som slakter fisken for dem, Slakteriet AS, et frittstående selskap. Strukturen påvirker rapporteringen av data, som er illustrert i figur 7.1. Svanøy leverer estimert slakt til Skaar, som gjennomfører salg basert på disse tallene. Samtidig blir fisk levert til slakt hos Slakteriet AS, som slakter dette og leverer endelige tall for slakt både til salgsselskapet Skaar, og produsenten Svanøy. Ved avvik mellom solgt fisk og slaktet fisk tar salgsselskapet Skaar kontakt med kunder og justerer salgene slik at solgt fisk tilsvarer slaktet fisk.

Av strukturen for datarapportering ser vi at det i utgangspunktet bare er et ledd i verdikjeden som har tilgjengelig all informasjon, nemlig produsenten Svanøy. De har tilgjengelig produksjonsdata, muntlige innrapporterte estimerte fordelinger for slakt, samt faktiske fordelinger ved slakt. Det betyr med andre ord at en endring til skriftlige prediksjonsrapporter levert til salgsselskapet ville gjort det mulig å hente ut historikk for denne informasjonen. Data ville da blitt lettere tilgjengelig, noe som ville gjort det enklere å hente ut denne for analyse. Selv om Svanøy er det eneste leddet som sitter på alle innrapporterte data fra leddene i verdikjeden, er det ikke nødvendigvis i dette leddet en opplever problematikk i avvikene

mellom prediksjon og faktisk slakt. Slik strukturen er i dag vil det i all hovedsak være Skaar som opplever problemer med disse avvikene, ettersom det er de som må ta kontakt med kunder på nytt og avtale nye salg basert på den fisken som faktisk er slaktet. Det er som nevnt i bakgrunnskapittelet (2.2.5.2) forbundet en tapt inntekt på 4 kr/kg for disse nye salgene. Ettersom det er Skaar som får problemer med avvikene, men det er Svanøy som leverer prediksjonene, er de ikke gitt at Svanøy tar lærdom av feilestimeringen. Dersom Skaar synliggjør disse tapte inntektene ovenfor Svanøy, vil dette kunne føre til et ønske om bedre innsamling av data. Som en konsekvens av dette vil man få muligheter til å utvikle bedre modeller for prediksjoner.

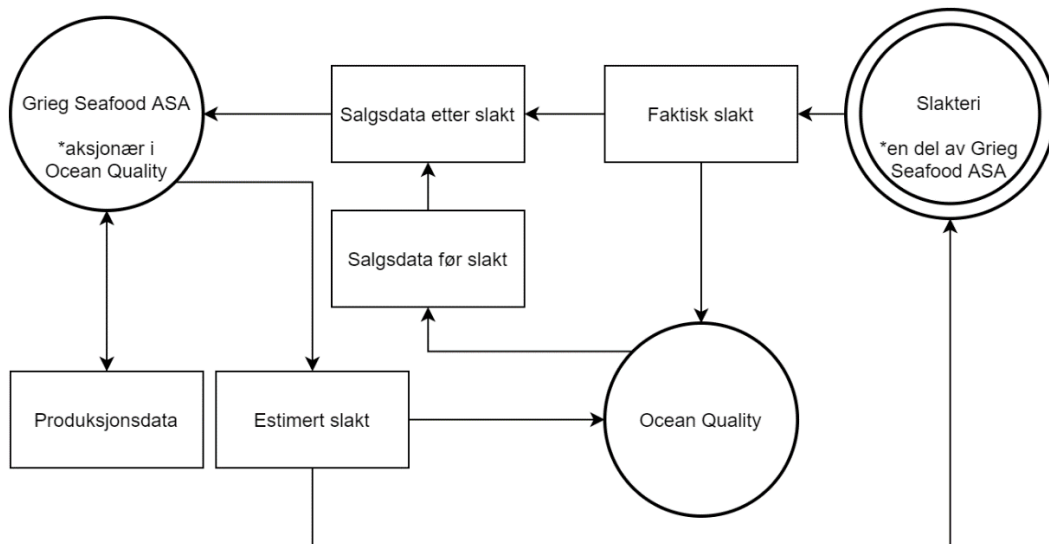


Figur 7.1: Strukturen for datarapportering mellom Svanøy Havbruk AS, Skaar Norway AS og Slakteriet AS.

7.2.1.2 Grieg Seafood ASA og Ocean Quality AS

Grieg er en annen aktør i næringen som selger fisken sin gjennom et utskilt salgsselskap, Ocean Quality. I motsetning til eierskapsforholdet mellom Svanøy og Skaar, er det i dette tilfelle Grieg som er aksjonær i Ocean Quality. Grieg opererer også i en helt annen målestokk enn det Svanøy gjør, og har langt flere lokaliteter sammenlignet med Svanøy. Her sendes estimerte slaktevolum med størrelse- og kvalitetsfordeling fra Grieg sine produksjonenheter til Ocean Quality, mens ferdig slaktet volum rapporteres til Ocean Quality direkte fra slakteriene som også er en del av Grieg. Dermed sitter Ocean Quality på data for predikert og faktisk slakt, og det er også dette leddet som må ta konsekvensene ved eventuelle avvik. Tilsvarende som for Svanøy og Skaar, må salgsløpet reforhandle salgene med kundene slik at solgt fisk samsvarer med slaktet fisk.

Produksjonsdata fra de ulike lokalitetene til Grieg er brukt her for å tilpasse vekstmodeller, men er også innrapportert til Grieg som sentralt kan tilpasse sine modeller (C. Birkeland, personlig kommunikasjon, 4. februar 2020). Prosessen for innrapportering av data er illustrert med figur 7.2 under:



Figur 7.2: Strukturen for datarapportering mellom Ocean Quality, Grieg Seafood ASA og deres slakteri.

Av strukturen for innrapportering av data, ser vi at det i tilfelle med Grieg og Ocean Quality også er produsenten som eneste ledd i verdikjeden som har all informasjon tilgjengelig. Grieg har tilgjengelig produksjonsdata fra sine lokaliteter i tillegg til innrapporterte fordelinger for estimert og faktisk slakt. Selv om de har denne informasjonen tilgjengelig er det Ocean Quality som utfører opprinnelig salg og reforhandling av salg, og det er dermed ikke Grieg direkte som blir påvirket av eventuelle avvik mellom prediksjon og faktisk slakt. Arbeidet og tapte inntekter forbundet med reforhandlingene, er i all hovedsak mest synlig for Ocean Quality. Likevel er Grieg åpenbart også indirekte påvirket av dette som største aksjonær i selskapet. Dersom Ocean Quality gjør dette inntektstapet mer synlig ovenfor Grieg, vil dette kunne sette økt fokus på å forbedre disse prediksjonene som start med bedre strukturert rapportering og innsamling av data. Oppsummert er det hos Grieg problemet med prediksjoner oppstår, men det er Ocean Quality som først og fremst opplever dette som et problem.

7.2.2 Dataformat

I den grad det i dag eksisterer en prosess for innrapportering av data, så er en essensiell karakteristikkk ved innrapporteringen også hvilket format data blir rapportert i. I eksempelet med Svanøy og Skaar over, er produksjonsdata lett tilgjengelige for Svanøy som enkelt kan eksportere data fra produksjonssystem til regneark eller lignende, altså data som enkelt kan benyttes i annet arbeid. Slaktedataene som rapporteres fra Slakteriet AS til Skaar og tilbake til Svanøy, er derimot i pdf-format. Innhenting av data fra dette formatet er langt mer manuell, komplisert og vil være uhåndterbar ved store mengder data. En slik innsamlingsprosess er også vanskelig å automatisere ettersom filene ofte i liten grad lar seg avlese av andre systemer. Slakteriet AS oppbevarer i all hovedsak historisk slakt på dette formatet, og har ikke mulighet til å hente ut andre format enn dette for historiske data. Dato på dette formatet er generelt svært lite egnet for analytiske formål, og vil i liten grad kunne vise historikk over lengre perioder, som vi også ser av størrelsen på datasettet som vi har mottatt. Dataene kan for praktiske formål ansees utilgjengelige.

På den andre siden er situasjonen for Grieg og Ocean Quality at slaktedata overleveres i regnearkformat (C. Birkeland, personlig kommunikasjon, 4. februar 2020). Selv om data i lettleselig format lettere kan benyttes til analytiske formål, er det også andre karakteristikker ved lagringsformat som påvirker mulighetene for dette. For alle praktiske hensikter er det nemlig slik at alt av innrapporterte data bør ha samme struktur og format, slik at en kan bruke data fra ulike deler av verdikjeden i en og samme analyse. Strukturen i de dataene som er lagret i regnearkformatet bør være tilsvarende som for andre innrapporterte data. Tidlig fokus på strukturering av data vil spare en for mye arbeid i fremtiden, hvor ønsket data enkelt kan hentes ut uten for mye manuelt arbeid.

7.2.3 MTB

Ifølge SINTEF (2009) er den største andelen rapporterte avvik mellom estimerte og faktiske slaktetall positive, hvor positive avvik er tilfeller hvor det stod mer fisk i merden enn det som ble estimert. Andelen avvik som er positive er 65 prosent, hvor de resterende 35 prosentene var tilfeller hvor det stod mindre fisk i merden enn det som ble estimert. Som nevnt i bakgrunnen for oppgaven må alle produsenter forholde seg til MTB, som er gitt både på lokalitets- og selskapsnivå. Produsentene må til enhver tid ha mindre fisk totalt sett i merdene enn det denne grensen definerer, og det er rimelig å anta at produsentene ville produsert ytterligere fisk om

de hadde muligheten til dette. Da de må overholde MTB har de ikke muligheten til dette, og vil istedenfor til enhver tid jobbe for å maksimere sin produksjon mens de samtidig overholder MTB. I dette arbeidet er et av nøkkeltallene i produksjonen de prediksjonene som gjøres underveis og leder til de endelige prediksjonene som gjøres like før slakt. Disse predikasjonene er avgjørende når produsenter tar viktige beslutninger, for eksempel angående hva som er optimal fôringsmengde. Fôring står for mer enn 50 prosent av produksjonskostnadene til matfisk generelt, og suboptimal fôring fører til kostnader som kunne vært unngått (SINTEF, 2009).

Selv om bedre prediksjoner på sin side kan føre til mer effektiv fôring, er det også faktorer som gjør at produsentene ikke nødvendigvis utelukkende har insentiver til å forbedre disse prediksjonene. Som vi har sett av avvikene som SINTEF peker på i sin rapport, estimerer produsentene i all hovedsak mindre fisk enn det som egentlig står i merden. En forbedring av prediksjonene vil med andre ord kunne gjøre at disse blir høyere enn tidligere ettersom avvikene i dag er positive og det egentlig står mer fisk enn det en tror i merden. Dersom en leverer høyere prediksjoner, vil dette på sin side kunne føre til at en beveger seg nærmere eller over MTB, og en på sikt derfor må redusere produksjonen sett i forhold til i dag. I dette tilfellet vil det være et spørsmål om gevinstene (bedre salg, optimal fôring) med bedre prediksjoner vil overveie gevinsten med dårligere prediksjoner (mer fisk enn i alternativet). En kan trekke det så langt som til å si at det kanskje fra produsenten sin side vil være bedre å ikke vite helt hvor mye fisk som står i merdene, dersom dette fører til at en kan ha en større produksjon enn i alternativet hvor en vet nøyaktig hvor mye fisk som står i merdene. Samtidig er det å anta at bedre prediksjoner, hvor en vet med større nøyaktighet hvor mye fisk som står i merdene, kan brukes til å optimalisere driften og dermed potensielt balansere effekten av mindre fisk i merden.

7.3 Forutsetninger

Uten en løsning på de overnevnte problemene vil det være vanskelig å utarbeide nye modeller med implementering av dyp lærling og nevralt nettverk. Denne typen modeller krever som nevnt store datasett for å finne underliggende egenskaper og sammenhenger. Datagrunnlaget som eksisterer i oppdrettsnæringen i dag er i den grad det eksisterer for lite, og for ustrukturert til å implementere en modell som et nevralt nettverk. Det vil kreve store mengder forarbeid for å strukturere informasjonen, og felles utarbeidelse av standarder på tvers av produsentene i

bransjen vil bedre tilrettelegge for dette. Med bakgrunn i nevnte problemer vil vi i denne delen adressere hvordan dette kan tilrettelegges, og videre presentere forutsetningene som bør legges til grunn. Vi vil først ta for oss standardisering og sentralisering av data før vi videre ser på hvilken rolle synliggjøring av kostnader og tapte inntekter har for forutsetningene. Til slutt i denne delen vil vi se nærmere på pågående prosjekter i næringen knyttet til disse forutsetningene.

7.3.1 Standardisering av data

Det første næringen bør utarbeide er bransjestandarder for hva som skal registreres og lagres av data. Det er i dette tilfelle ikke bare snakk om hvilke data, men også hvordan data skal håndteres og registreres. En slik standardisering vil være fordelaktig av flere grunner, først og fremst ettersom datagrunnlaget for hvert enkelt selskap vil bli mer oversiktlig og enklere å håndtere. Vi kan typisk dele slik standardisering opp i standarder for datapunkter, formatering og strukturering.

Standard datapunkter vil i tillegg til å gjøre data mer oversiktlig for hvert enkelt selskap, også muliggjøre samarbeid og sammenligning på tvers av selskaper. Kanskje viktigst av alt vil standardiserte datapunkter bidra til å styrke muligheten for å gå fra data til innsikt, og muligheten til å utvikle en beste praksis innenfor næringen (Wathne & Nondal, 2019). Vi ser allerede en rekke initiativer i næringen som vi kommer tilbake til i delen for pågående prosjekter under. I vårt tilfelle ville standard datapunkter gjort at vi kunne kombinert datasett fra flere aktører, som ville styrket generaliseringen av modellen samt økt vårt datagrunnlag betraktelig.

På samme måte som at datapunktene burde standardiseres, vil det også være hensiktsmessig med standarder for formatering og strukturering. I vårt tilfelle var dette en utfordring i flere faser av studien, da våre datasett hadde tre forskjellige format. Produksjonsdata var lagret i xlsx-format, slaktedata i pdf-format, mens prediksjonsdata var i muntlig format og dermed ikke tilgjengelig. Databehandling og klargjøring blir svært krevende med stor variasjon i dataformatet, og selv for et mindre datasett er dette en svært tidkrevende prosess. Med en felles overordnet standard for formatering og strukturering vil prosessen i beste fall kunne automatiseres. I tillegg til at selve klargjøringen blir enklere å gjennomføre vil det også åpne for mer hensiktsmessige variabeltilpasninger (feature engineering). I vårt tilfelle gjorde vi enkle aggregeringer og gjennomsnitt over bestemte tidsperioder for å få et bilde av

vekstperioden til fisken. Med en standard struktur for hvordan data lagres ville det være enklere å tilpasse dataen slik at den bedre illustrerer utviklingen til fisken. Det følger av dette at standardisering av datapunkter, formatering og strukturer langt på vei vil forbedre muligheten for modellbaserte styringsverktøy i havbruksnæringen.

7.3.2 Sentralisering og synliggjøring av kostnader

Et annet viktig moment for å gjøre data lettere tilgjengelig er hvor den aktuelle dataen er lagret. I avsnitt 7.2.1 har vi diskutert hvordan data i dag lagres i de instansene den blir registrert. For å gjøre modellbaserte prediksjoner mulig vil det være en fordel å ha alt av data samlet på et sted, med standarder for format og struktur som nevnt over. Dersom alle leddene i verdikjeden, fra smolt til solgt fisk, lagrer data på et sted, vil innsatsen knyttet til datainnsamling og modellering reduseres betraktelig. Videre vil dette føre til at en enklere kan tilpasse valg av variabler og datamengde for modeller.

For å få til en sentralisering av data, samt standardiserte datapunkter, format og struktur, bør mulighetene og konsekvensene av dette synliggjøres. En synliggjøring av disse, vil kunne øke satsingen på digitalisering i havbruksnæringen. Som diskutert over er problemet i dag ofte synlig først for et senere ledd i verdikjeden, mens muligheten til forbedring eksisterer i et tidligere ledd. I et sammensatt problem som dette vil en synliggjøring av kostnader og tapte inntekter for hele verdikjeden være en sentral forutsetning for at problemet blir adressert.

7.3.3 Pågående prosjekter

Det finnes selskaper som allerede har tatt tak i problemstillingen knyttet til forutsetningene med standarder for datapunkter, format og struktur. Vi vil videre trekke fram to aktuelle eksempler som på hver sin måte er med på å legge til rette for modellbasert estimering som styringsverktøy i norsk akvakultur.

AquaCloud er et bransjedekkende initiativ, satt i gang av NCE Seafood Innovation Cluster, som har som mål å implementere kunstig intelligens i styringssystemene til havbruksnæringen. Opprinnelig var målet å hjelpe produsenter med å bekjempe luse-problemet som næringen i flere år har hatt store utfordringer med (NCE Seafood, u.d.). Det viste seg derimot at datagrunnlaget var for mangelfullt, og det opprinnelige prosjektet, AquaCloud 1.0, ble satt på vent. Istedenfor ble AquaCloud 2.0 lansert med mål om å utvikle digitale standarder for

akvakulturen. Standardene omfatter sensordata, miljødata og fiskehelsesdata som skal benyttes for kommunikasjon og analyse på tvers av aktørene i bransjen.

Grieg er en annen aktør som etter hvert også setter fokus på det manglende datagrunnlaget. Vi har i tidligere avsnitt sett på hvordan strukturelle barrierer kan føre til at informasjon blir gjort lite tilgjengelig eller mistet gjennom verdikjeden. I en pressemelding fra mai 2020 melder Grieg og Bremnes Seashore AS at de avslutter samarbeidet som er salgsselskapet Ocean Quality. Selskapene skal nå etablere egne salgssavdelinger, hvor Ocean Quality blir en del av Bremnes Seashore AS, mens Grieg skal opprette sin egen avdeling. I den samme nyhetsmeldingen sier konsernsjef i Grieg, Andreas Kvarme, følgende om hvorfor avgjørelsen ble tatt og utsiktene videre: «En egen salgsorganisasjon er avgjørende for å best mulig kunne levere på nedstrømsdelen av strategien, og gir oss mulighet til å styrke samhandlingen mellom produksjonsnettverket vårt og salg» (Hansen, 2020). I utsagnet snakker de om nedstrømsdelen i strategien og samhandlingen mellom produksjon og salg. Dette er en av de forutsetningene vi har identifisert som essensielle, og er noe som Grieg allerede har jobbet med i noen år gjennom deres prosjekt for «precision farming» (Birkeland, 2018). Med denne forutsetningen oppfylt vil en ha et sikrere datagrunnlag for å etablere nye modeller, som eksempelvis modellen presentert i dette studiet.

7.4 Ytterligere data

I tillegg til å oppfylle forutsetningene over vil nye data for andre variabler i verdikjeden kunne bidra til å danne et enda bedre datagrunnlag for modeller som nevralt nettverk. Dette kan for eksempel være ytterligere data fra produksjonsprosessen, som for miljøet som fisken står i, i sjø. Det er flere elementer med miljøet som kan være interessant å se på, og som vil påvirke hvordan fisken vokser. Vi vil i dette avsnittet diskutere ulike innovasjoner i næringen, hvor målet er å samle inn ytterligere og forbedrede data, som følgelig vil muliggjøre mer nøyaktige modeller som inkluderer ytterligere inputvariabler.

7.4.1 Ny sensorteknologi

En viktig brikke i prosessen med å samle inn data, er hvordan selve registreringen av datapunkt blir gjort og hvilke måleinstrumenter som benyttes i denne prosessen. Innenfor havbruksnæringen forsøker flere aktører aktivt å utvikle maskinvare som skal gi produsentene data fra merder i sanntid, kontra dagens løsninger hvor telling og vektestimater gjøres når fisken

håndteres i spesielle faser av produksjonen. Eksempler på slik maskinvare er avanserte kameraer som benytter ny sensorteknologi, og som nå forsøkes implementert i norsk akvakultur. Et av de ledende selskapene som utvikler slike kameraer ved hjelp av ny teknologi er Optoscale. Takket være ny teknologi kan disse kameraene ta opp 200 bilder hvert sekund, og Optoscale hevder at avviket for merden da vil ligge innenfor en gjennomsnittlig 2 prosent feilmargin (Optoscale, u.d.). Produsenter innenfor norsk akvakultur prøver ut disse avanserte kameraene i en økende skala, og Optoscale har etter hvert kunder i hele Norge som har implementert deres systemer for biomassemåling.

Et av de selskapene som har implementert deres system for sin virksomhet i Norge, er en av de største lakseprodusentene i verden, Cermaq. De inngikk tidlig i år et samarbeid for å optimalisere fôring og tilvekst (IntraFish, 2018a; Berge, 2020). Slike sensorer vil kunne gi ytterligere data og tilnærmede fasitsvar for fordelingen i merden, ved flere tidspunkt enn ved nåværende situasjon. I den nåværende situasjonen predikeres endelig slakt- og vektfordeling, basert på datasett som kun består av datasett hvor vi har fasitsvaret, altså ved slakt. I en situasjon hvor vi kjenner fasitsvaret for merden for eksempel på daglig basis, i hvert fall med hensyn til vekt, vil modellen få langt flere datapunkter å trene med, og dermed levere mer nøyaktige endelige prediksjoner. Samtidig åpner det for å predikere en vektfordeling tidligere i produksjonen. Cermaq har som mål å benytte kameraene til å optimalisere fôring og tilvekst, og en prognose for vektfordeling gjennom produksjonstiden vil gjøre denne optimaliseringen mulig.

7.4.2 Biomasserammer

En annen teknologi som også er forsøkt implementert for innsamling av ytterligere data for fisk i merd, er såkalte biomasserammer. Dette er rammer som er senket ned i merden, hvor disse så registrerer fisk ved gjennomsvømming. Problemet med disse rammene har typisk vært at fisken som svømmer igjennom målerammen totalt sett ikke gir et representativt utvalg for en merd, spesielt i tilfeller for lokaliteter hvor det er forholdsvis værhardt. I EXACTUS-prosjektet ble dette studert nærmere av Høy, Sunde og Bjelland (2013), som ved ulik dybdeplassing, type materiale brukt for oppheng, og tidshorisont, fikk ulike resultater. Dersom rammene oppnår bedre målinger, tilsvarer dette ytterligere data som vil kunne danne et bedre datagrunnlag for modellbasert estimering for vekt- og kvalitetsfordeling.

7.4.3 Miljø

I tillegg til de to overnevnte mulighetene til å samle inn ytterligere data, og de nevnte forutsetningene, er det også aktuelt for ytterligere innsamling av data med eksisterende utstyr i merdene. Per i dag er gjengangeren blant produsentene å måle vanntemperaturen, som vi også har sett er et nøkkeltall for veksten til fisken, og følgelig en viktig input for veksttabellene. Det er likevel ytterligere karakteristik i tillegg til vanntemperaturen i merden, som vil påvirke veksten til fisken. Dette kan for eksempel være oksygenivået i vannet, som har vist seg å også ha signifikant påvirkning for fisk i et settekar og som dermed er antatt å ha betydning også i åpen merd (Rosten T. , 2009). Det er relativt lite teknologi som behøves for å registrere dette, og slik data kan brukes som en inputvariabel i et nevralt nettverk som kan finne sammenhenger mellom denne og endelig slaktet fisk.

7.5 Modellen ved oppfylte forutsetninger

Med oppfylte forutsetninger har en et tilstrekkelig stort datasett med hensyn til antallet inputvariabler, men også med hensyn på det totale antallet observasjoner for en treningsdel, valideringsdel og testdel. I en slik situasjon vil metoden og modellen vår være høyaktuell, og en vil anta et langt bedre resultat. I denne delen vil vi se nærmere på nettopp hvilke konsekvenser oppfylte forutsetninger og ytterligere data ville medført for vår metode. Vi vil først kort ta for oss mulighet dette hadde åpnet for variabeltilpasning, før vi videre ser på hvordan metodens kryssvalidering ville fungert. Vi vil etter dette se på hvordan modellen ville tatt høyde for sesongvariasjoner, og hvordan den kunne vært videreført til andre deler av produksjonen.

7.5.1 Variabeltilpasning

Selv om vi gjennomfører preprosessering av data, samt normaliserer de ulike variablene, ville oppfylte forutsetninger og ytterligere data, gjort det mer aktuelt med ytterligere variabeltilpasning. Dette ville åpnet muligheten for eksempel til å lage nye inputvariabler basert på forhold mellom eksisterende variabler. Slike variabler, som i størst mulig grad skal referere verdiene i det originale datasettet, kan gjøre at modellen lærer seg nye sammenhenger som den ellers ikke ville oppfattet. En annen aktuell variabeltilpasning vil være periodene hver enkelt variabel omfatter. I vårt datasett benytter vi periodene en, to, fem og ti måneder, i tillegg til

hele vekstperioden samlet sett. En ytterligere justering av disse ville, med forutsetningene oppfylt, vært aktuelt å vurdere for å forbedre prediksjonene til modellen.

7.5.2 Kryssvalidering

Vi har i vår metode i all hovedsak ikke benyttet kryssvalidering, da dette kombinert med våre ensembler ville blitt svært krevende med tanke på tid og prosessorkraft. Dersom våre forutsetninger hadde vært oppfylt og vi hadde tilgang på mer datakraft, ville det vært naturlig å implementere dette for å vurdere robustheten til modellen. Mange kjøring over et stort datasett kan introdusere overtilpasning, og kryssvalidering kan dermed også være gunstig for å trene og validere med ulike deler av datasettet. Dette gjøres ved at en i å benytte et akkumulerende antall observasjoner, benytter rullerende vindu, og dermed trener og validerer med ulike observasjoner ved hver kjøring. Dette kunne ytterligere optimalisert modellen i en situasjon med mye data, og gitt mindre tap og bedre nøyaktighet for prediksjonene.

7.5.3 Sesongvariasjoner

Fra bakgrunnen har vi sett at fisken har raskere vekst om sommeren og lavere vekst vinterstid. Ved oppfylte forutsetninger vil datasettet bestå av observasjoner fra et større tidsrom, og det vil være å anta at modellen lettere vil kunne oppfatte sesongvariasjoner. Datasettet består i dag av to inputvariabler som sammen forteller hvilket år (År) og på hvilken dag i året slakten ble utført (Dag). Sammen med inputvariabelen for antall dager som fisken har stått i sjøen før slakt (Tid), vil disse indirekte inneholde informasjon om tidsperioden fisken har stått i merden. Ettersom modellen kun er trent med slakt gjort innenfor et år, 2019, vil dette typisk være for lite data til å oppfatte sammenhenger som sesongvariasjoner. Med oppfylte forutsetninger vil det være mulig å gjøre sesongvariasjoner synlig for modellen.

7.5.4 Videreføring av vår metode

Ved oppfylte forutsetninger, med tanke på kontinuerlig måling av biomasse, vil det være naturlig å forsøke videreføring av vår modell til andre deler av produksjonen av matfisk. Vi har i delen for bakgrunn og teori sett hvordan oppdrettsnæringen i dag bruker faktorer for vekst og fôr, for å beregne henholdsvis antatt vekst og riktig fôrmengde for en periode. Det trenger ikke å være snakk om store justeringer for at vår modell skal kunne brukes til å predikere vekst og riktig fôrmengde, men dette vil blant annet kreve andre input- og outputvariabler. Dersom

en bedre kjenner hvor mye fisk som faktisk står i merden, vil det kunne gi gevinster blant annet ved at en reduserer sjansen for suboptimal fôring.

7.6 Potensielle gevinster ved vellykket implementering

I bakgrunnen går vi gjennom potensielle gevinster i både salgs- og produksjonsleddet som følge av bedre prediksjoner for vekt- og kvalitetsfordeling. Tallene var hentet fra SINTEF (2009), og var basert på produksjon med en konsesjon gjennom et helt år. For å gi et bilde på hvordan dette kan se ut for næringen, har vi benyttet aktørene Svanøy, Grieg og Ocean Quality, og sett på hvordan vår modell vil kunne realisere de potensielle gevinstene av forbedrede prediksjoner.

7.6.1 Salg

Fra datasettet mottatt fra Svanøy, kan vi se at årlig produksjon av matfisk ligger omkring 3 000 tonn. Benytter vi formelen for potensiell gevinst i salgsleddet, får vi ved en antatt feilestimering på 5 prosent, en potensiell årlig gevinst forbundet med salg på 600 000 kroner, som beregnet i appendiks F.1. I Svanøy sitt tilfelle vil det være Skaar som i første ledd vil høste godene av dette, men det er naturlig å anta at Svanøy på lang sikt også vil kunne få bedre pris for sin produksjon som en konsekvens av bedre prediksjoner for vekt- og kvalitetsfordeling. Dersom vi skalerer dette opp til Ocean Quality sitt salgsvolum, vil de ha en potensiell årlig gevinst forbundet med salg på 25,1 millioner kroner, som beregnet i appendiks F.2 (Grieg Seafood ASA, 2020). Vi ser med andre ord at kostnadene forbundet med feilestimering med første øyekast kan virke relativt små, men at disse over tid aggregeres til betydelig summe for salgsselskapene.

I første omgang er det disse kostnadene modellen vår håndterer, og dermed de tilhørende potensielle gevinstene, vi forsøker å realisere. Vi har sett at vår modell trent med tilgjengelig data fra Svanøy, ikke gjør det bedre enn selv den enkleste prediksjonsmetoden. Videre har vi sett på tiltak som kan bidra til å forbedre prediksjonskraften til modellen. Det er vanskelig å si noe om kostnader tilknyttet implementeringen av disse tiltakene, da det vil variere med de ulike tiltakene, samt størrelsen på selskapet, nåværende struktur, kompetanse i verdikjeden med mer. Dersom vi holder kostnaden for implementering utenfor, vil de potensielle gevinstene forbundet med salg for de to aktørene, kunne være som illustrert i tabell 7.1. SINTEF (2009) antar i dag 5 prosent feilestimering, og en vil følgelig kunne anta at en fungerende modell vil kunne forbedre presisjonen noe, presentert med prosentvise steg i tabellene. Det vil som nevnt

kunne være utfordrende å få til en satsning på slike modeller, da slike tiltak må gjøres tidlig i verdikjeden, mens effekten av tiltakene gjerne ikke er synlig før i salgsleddet. Det vil derfor være fordelaktig om metoden også hadde gjort seg relevant allerede i produksjonsleddet.

Feilestimering	Svanøy	Ocean Quality
4 %	120 000	5 021 200
3 %	240 000	10 042 400
2 %	360 000	15 063 600
1 %	480 000	20 084 800
0 %	600 000	25 106 000

Tabell 7.1: De potensielle gevinstene forbundet med mer presise prediksjoner. Feilestimering er her gitt som ny prosent feilestimering, altså vil 4 % representere potensielle gevinster for et prosentpoeng forbedring fra dagens 5 % feilestimering.

7.6.2 Produksjon

Slik som metoden er utformet i denne studien, vil den ikke ha noen anvendelse tidlig i produksjonsprosessen. Som nevnt i diskusjonen for muligheten til å innhente ytterligere data, vil introduksjonen av ny sensorteknologi som biomassekameraer, kunne produsere pålitelige og kontinuerlige målinger av stående biomasse i merden, og dermed aktualisere metoden også for produksjonsleddet. Treningen av modellen vil kunne tilpasses registreringen av produksjonsvolumet på et tidligere tidspunkt, og levere prediksjoner for produksjonen som vil kunne brukes i produksjonsplanleggingen.

Fra bakgrunnen har vi potensielle konsekvenser ved over- og underestimering av biomasse. Konsekvensene for overestimering var lavere produksjonsverdi enn forventet, samt høyere fôrforbruk enn nødvendig. Gitt en 5 prosent feilestimering, ble kostnadene beregnet til henholdsvis 5,4 millioner og 2 millioner per konsesjon per år. For tilsvarende underestimering ble potensiell årlig gevinst, dersom vekstpotensialet ble fullstendig utnyttet, beregnet til 2,9 millioner per konsesjon per år. Med en årlig produksjon for Svanøy på 3 000 tonn, vil kostnadene for overestimering tilsvare 12,5 millioner i lavere produksjonsverdi, beregnet i appendiks F.3.1 og 4,6 millioner i overføring, beregnet i appendiks F.3.2. Tilsvarende mulige kostnader knyttet til uutnyttet vekstpotensial ved underestimering vil være 6,78 millioner, som beregnet i appendiks F.4. Beregningene av disse kostnadene har noe usikkerhet knyttet til seg,

da den opprinnelige beregningen av SINTEF baserte seg på spesifikke vekstmål fra Skretting som vil variere basert på lokasjon, konsesjonsutnyttelse, naturlige forhold og en mengde andre faktorer.

Vi ser her at kostnadene knyttet til feilestimering i produksjonsprosessen er vesentlig høyere enn kostnadene forbundet med salg. Dette betyr at en videreføring av metoden, som følge av ny sensorteknologi (som biomassekamera) med pålitelige målinger, potensielt kan gi store gevinster i begge leddene av verdikjeden. Videreføring av metoden vil også sikre at begge leddene har insentiver for å innføre og utvikle tiltakene som trengs for at metoden skal prestere bedre. Vi vil nå kort se på hvordan lønnsomheten og driftsmarginen i næringen kan være en faktor som påvirker i hvilken grad oppdretterne ønsker å realisere gevinstene fra produksjonsleddet og salgslødd, før vi videre går over på konklusjonen for studiet.

7.6.3 Lønnsomhet og driftsmarginer

Vi tok innledningsvis i bakgrunnen også for oss hvordan lønnsomheten i oppdrettsnæringen generelt er svært god, med driftsmarginer på over 30 prosent i årene 2016 – 2018 (Steinseide, 2019). Selv om marginene i bransjen har vært svært høye de siste årene, er det som nevnt forventet at disse vil falle i årene fremover grunnet blant annet høyere råvarepriser og økende konkurranse fra utlandet (Blomgren, Tveterås, Reve, Haus-Reve, & Misund, 2019). Ved fallende marginer, vil det være økt fokus på redusering av kostnader og realisering av potensielle gevinster. De potensielle gevinstene ved implementering av en fungerende modell for prediksjoner av vekt- og kvalitetsfordeling, vil kunne kompensere for fallet i driftsmargin og dermed opprettholde lønnsomheten i næringen. Som vi har vært inne på i delen for pågående prosjekter (7.3.3), er det allerede bevegelser i næringen, hvor det nå legges til rette for at modellbaserte prediksjoner skal kunne implementeres.

7.7 Metodiske utfordringer

Vi vil i denne delen kort ta for oss utfordringer tilknyttet validitet og reliabilitet med bakgrunn i de metodiske valgene vi har gjort. Dette er elementer som har blitt kommentert hele veien, men som igjen kommenteres her for å tydeliggjøre disse utfordringene.

Basert på våre hovedfunn og den videre diskusjonen tilknyttet det manglende datagrunnlaget i studien og oppdrettsnæringen generelt, er det naturlig å videre ta opp validiteten ved studien

og resultatene. Validitet handler om i hvilken grad resultatene ved studien faktisk er relevant for hva vi har forsøkt å måle (Saunders, Lewis, & Thornhill, 2016). Det er med andre ord snakk om relevans, og hvor generaliserbare funnene våre er. Oppdelingen av datasettet i trening, validering og test, beskrevet innledningsvis i metoden, er helt essensiell for å sikre validiteten. Vi får på denne måten testet vår modell med usette data, og kan i noen grad trekke slutninger om hvordan modellen ville gjort det ved implementering. Som vi har problematisert i våre hovedfunn og videre diskusjon, er derimot datagrunnlaget i studien og oppdrettsnæringen generelt, ikke tilfredsstillende stort nok. Det er dermed vanskelig å trekke pålitelige konklusjoner fra resultatene knyttet til vår modell. Det poengteres gjennom diskusjonen at resultatene potensielt kunne vært forbedret med et større datagrunnlag, og et større datagrunnlag i næringen generelt ville gjort det enklere å generalisere vår modell for hvordan den ville gjort det generelt i næringen.

Det er også aktuelt å vurdere reliabiliteten eller konsistensen for studien, altså om en kan forvente de samme resultatene dersom en gjentar studien med tilsvarende metode (Saunders, Lewis, & Thornhill, 2016). Store deler av oppgaven er dedikert til å beskrive fremgangsmåte for vår metode, samt hvordan datainnsamlingen og selve analysen er gjennomført. Som nevnt i metoddelen 5.5, kan også selve modellen gjøres tilgjengelig ved forespørsel, og en vil dermed kunne gjennomføre studien på nytt og med det datagrunnlaget som næringen har i dag, forvente samme resultater. Vi har underveis i studien pekt på maskinkraft som en bindende ressurs for vår studie, og det er å anta at en med mer tilgjengelig maskinkraft og tid, vil kunne finne andre modellstrukturer og hyperparametre som vil kunne forbedre modellen ytterligere og få andre resultater. I tillegg er det diskutert hvordan ytterlige data vil påvirke resultatet, og hvilke steg næringen bør ta for å sikre et slikt datagrunnlag. Vi har også kommentert hvordan det ved dyp læring og nevrale nettverk trenes en særegen modell ved hver kjøring og at en dermed vil kunne ha noe avvik i resultatene for hver kjøring, men at en i all hovedsak forventer samme resultat.

8 Konklusjon

Målet med denne studien har vært å bidra til arbeidet med biomassemåling i havbruket, mer spesifikt norsk akvakultur. Bidraget viser hvordan modellbasert prediksjon med bruk av nevralt nettverk, kan benyttes for å predikere vekt- og kvalitetsfordeling for endelig slaktevolum. Med vårt tilgjengelige datasett, har vi ikke funnet noe som tyder på at metoden kan forbedre eksisterende prediksjoner. Modellen presterer ikke bedre enn selv den enkleste mulige prediksjonsmetoden, gjennomsnittlig fordeling fra tidligere slakt, som vil være vel så godt egnet som utgangspunkt for prediksjon av fremtidige slakt. Størrelsen på datasettet gjør det vanskelig å trekke en konklusjon, da nevralt nettverk i utgangspunktet krever et større datasett. Det virker rimelig å anta at metoden ville levert bedre resultater med et større datasett. Vi har derfor i diskusjonen sett på hva som er forutsetningene for at en skal kunne bygge opp et slikt datagrunnlag, samt hvilke steg produsentene og næringen samlet sett kan ta for å oppfylle disse forutsetningene.

Vi har i studien også sett på de potensielle gevinstene ved bedre prediksjoner, som samlet sett for salgsleddet i næringen beløper seg til 270 millioner kroner. Det er i første omgang disse kostnadene vi kan redusere ved å benytte vår metode. Samtidig viser vi også at videre utvikling av metoden og ved hjelp av ny sensorteknologi, potensielt kan benytte modellen også i produksjonsplanleggingen. Vi har sett hvordan de potensielle gevinstene i produksjonsleddet varierer for type feilestimering, men i begge tilfeller ligger i milliardklassen.

Opgaven tar også opp hvordan kostnader og potensielle gevinster skjuler seg mellom ulike ledd i verdikjeden, og hvordan dette gjør utfordringen mer kompleks. En synliggjøring av disse kostnadene vil kunne motivere aktørene i næringen til handling, og en samhandling mellom leddene er vesentlig for å finne en løsning på prediksjonsproblemene.

Det er bevegelser i næringen, hvor Grieg integrerer salgsleddet helt i sin egen verdikjede, og sensorteknologi blir utprøvd i stadig økende skala. Vi forventer at dette i nærmeste framtid vil føre til et skjerpet fokus på biomassemåling og konsekvensene dette har. Vi mener at denne studien kan være med på å danne et grunnlag for videre arbeid med nevralt nettverk som prediksjonsmetode, og senere en eventuell implementering av denne i næringen.

Kilder

- Akvakulturdriftsforskriften. (2008). *Forskrift om drift av akvakulturanlegg (akvakulturdriftsforskriften)*. Hentet 19. Mars 2020 fra https://lovdata.no/dokument/SF/forskrift/2008-06-17-822/KAPITTEL_2#%C2%A716
- Allaire, J., & Chollet, F. (2020). *keras: R Interface to 'Keras'*. Hentet Januar 17., 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=keras>
- Almaliki, Z. (2018). *Bias-variance dilemma?* Hentet 19. April, 2020 fra Towardsdatascience: <https://towardsdatascience.com/bias-variance-dilemma-74e5f1f52b12>
- Auguie, B. (2017). *gridExtra: Miscellaneous Functions for "Grid" Graphics*. Hentet 15. Mai, 2020 fra The Comprehensive R Archive Network: [gridExtra: Miscellaneous Functions for "Grid" Graphics](https://cran.r-project.org/package=gridExtra)
- Bache, S., & Wickham, H. (2014). *magrittr: A Forward-Pipe Operator for R*. Hentet 17. Januar, 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=magrittr>
- Bakkevoll, P., Makhlysheva, A., Budrionis, A., Chomutare, T., Linstad, L., Nordsleta, A., . . . Blixgård, H. (2018). *Health analytics Kunstig intelligens – nye muligheter for helsetjenesten*. Tromsø: Nasjonalt senter for e-helseforskning.
- Berge, A. (2020). *Cermaq inngår samarbeid med OptoScale for å optimalisere føring og tilvekst*. Hentet 3. Mars, 2020 fra iLaks: <https://ilaks.no/cermaq-inngar-samarbeid-med-optoscale-for-a-optimalisere-foring-og-tilvekst/>
- Birkeland, C. (2018). *Precision Farming*. Hentet 17. Mars, 2020 fra Grieg Seafood: <https://docplayer.me/112853627-Grieg-seafood-precision-farming-22-november-2018-christian-birkeland-digital-offiser.html>
- Bishop, C. (2006). *Pattern Recognition and Machine Learning*. Singapore: Springer.
- Blomgren, A., Tveterås, R., Reve, T., Haus-Reve, S., & Misund, B. (2019). *En konkurransedyktig og kunnskapsbasert havbruksnæring*. Oslo: Handelshøyskolen BI.

- Brownlee, J. (2019a). *Difference Between a Batch and an Epoch in a Neural Network*. Hentet 26. April, 2020 fra Machine Learning Mastery: <https://machinelearningmastery.com/difference-between-a-batch-and-an-epoch/>
- Brownlee, J. (2019b). *Gentle Introduction to the Adam Optimization Algorithm for Deep Learning*. Hentet 27. April, 2020 fra Machinelearningmastery: <https://machinelearningmastery.com/adam-optimization-algorithm-for-deep-learning/>
- Brownlee, J. (2019c). *Gentle Introduction to the Bias-Variance Trade-Off in Machine Learning*. Hentet 19. April, 2020 fra Machine Learning Mastery: <https://machinelearningmastery.com/gentle-introduction-to-the-bias-variance-trade-off-in-machine-learning/>
- Brownlee, J. (2019d). *How to Configure the Learning Rate When Training Deep Learning Neural Networks*. Hentet 29. April, 2020 fra Machine Learning Mastery: <https://machinelearningmastery.com/learning-rate-for-deep-learning-neural-networks/>
- Brownlee, J. (2020a). *How to Choose Loss Functions When Training Deep Learning Neural Networks*. Hentet 25. April, 2020 fra Machine Learning Mastery: <https://machinelearningmastery.com/how-to-choose-loss-functions-when-training-deep-learning-neural-networks/>
- Brownlee, J. (2020b). *Understand the Impact of Learning Rate on Neural Network Performance*. Hentet 26. April, 2020 fra Machine Learning Mastery: <https://machinelearningmastery.com/understand-the-dynamics-of-learning-rate-on-deep-learning-neural-networks/>
- Bushaev, V. (2018). *Understanding RMSprop — faster neural network learning*. Hentet 25. April, 2020 fra Towardsdatascience: <https://towardsdatascience.com/understanding-rmsprop-faster-neural-network-learning-62e116fcf29a>
- Chollet, F., & Allaire, J. (2018). *Deep Learning with R* (1. utg.). USA: Manning Publications Co.
- Cook, T., & Hall, A. (2017). Macroeconomic Indicator Forecasting with Deep Neural Networks. *Federal Reserve Bank of Kansas City Research Working Paper*(17-11).

- Hentet 19. Mars, 2020 fra <https://www.kansascityfed.org/publications/research/rwp/articles/2017/macroeconomic-indicator-forecasting-deep-neural-networks>
- Copas, J., & Eguchi, S. (2006). Interpreting Kullback-Leibler Divergence with the Neyman-Pearson Lemma. *Journal of Multivariate Analysis*, 97, 2034-2040.
- Espmark, Å. (2019). *Ulike typer oppdrettsanlegg*. Hentet 7. Mars, 2020 fra Nofima: <https://nofima.no/verdt-a-vite/ulike-typer-oppdrettsanlegg/>
- Fauske, M. (2019). *Hvor stor er oppdrettsnæringen i Norge?* Hentet 10. Mars, 2020 fra Fiskeridirektoratet: <https://www.fiskeridir.no/Akvakultur/Nyheter/2019/0519/Hvor-stor-er-oppdrettsnaeringen-i-Norge>
- Fiskeridirektoratet. (2019). *Lønnsomhetsundersøkelser for laks og regnbueørret*. Hentet 16. Mai, 2020 fra Fiskeridirektoratet: <https://www.fiskeridir.no/Akvakultur/Tall-og-analyse/Statistiske-publikasjoner/Loennsomhetsundersoekelser-for-laks-og-regnbueoerret>
- Føre, M., Frank, K., Norton, T., Svendsen, E., Alfredsen, J., Dempster, T., . . . Berckmans, D. (2018). Precision fish farming: A new framework to improve production in aquaculture. *Biosystems Engineering*, 173, 176-193.
- Forskrift om tildeling av matfiskkonsesjoner. (2003). *Forskrift om tildeling av konsesjoner for matfiskoppdrett av laks og ørret i sjøvann (FOR-2003-10-17-1245)*. Hentet 5. Mai, 2020 fra <https://lovdata.no/dokument/LTI/forskrift/2003-10-17-1245>
- Géron, A. (2017). *Hands-On Machine Learning with Scikit-Learn & TensorFlow* (1. utg.). USA: O'Reilly Media.
- Glorot, X., Bordes, A., & Bengio, Y. (2011). Deep Sparse Rectifier Neural Networks. *Proceedings of the fourteenth international conference on artificial intelligence and statistics*, 315-323.
- Goldberg, Y. (2016). A Primer on Neural Network Models for Natural Language Processing. *Journal of Artificial Intelligence Research*, 57, 345-420.

- Gómez, R. (2018). Hentet 22. April, 2020 fra Understanding Categorical Cross-Entropy Loss, Binary Cross-Entropy Loss, Softmax Loss, Logistic Loss, Focal Loss and all those confusing names.
- Gonzalez, S. (2000). Neural Networks for Macroeconomic Forecasting: A Complementary Approach to Linear Regression Models. *Working Papers-Department of Finance Canada*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Google Developers. (2020). *Machine Learning Glossary*. Hentet 30. April, 2020 fra Google Developers Machine Learning: <https://developers.google.com/machine-learning/glossary>
- Grieg Seafood ASA. (2020). *Passion for improvement - Annual Report 2019*. Hentet 11. Juni, 2020 fra Grieg Seafood ASA: https://www.griegseafood.no/wp-content/uploads/2020/06/GSF_AR_2019_Spreads.pdf
- Grieg Seafood ASA. (u.d.). *Salg*. Hentet 20. April, 2020 fra Grieg Seafood: <https://www.griegseafood.no/salg/>
- Grootendorst, M. (2019). *Validating your Machine Learning Model*. Hentet 18. Mars, 2020 fra Towardsdatascience: <https://towardsdatascience.com/validating-your-machine-learning-model-25b4c8643fb7>
- Hansen, M. (2020). *Grieg Seafood ASA and Bremnes Seashore as to establish seperate sales organizations*. Hentet 27. Mai, 2020 fra Grieg Seafood: <https://www.griegseafood.no/grieg-seafood-asa-and-bremnes-seashore-as-to-establish-separate-sales-organizations/>
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366.
- Høy, E., Sunde, L., & Bjelland, H. (2013). Hvor mye laks er det egentlig i merden? *Norsk Fiskeoppdrett*, 2. Hentet 4. Mars, 2020 fra https://www.sintef.no/globalassets/upload/fiskeri_og_havbruk/havbruksteknologi/exactus/dokument/exactus-nfo-artikkel_paaskrift.pdf

- Hyndman, R., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (1. utg.). Melbourne, Australia: OTexts. Hentet 28. Mars, 2020 fra <https://otexts.com/fpp2/>
- IntraFish. (2018a). *Liste: Verdens 15 største lakseoppdrettere*. Hentet 3. Mars, 2020 fra IntraFish: <https://www.intrafish.no/nyheter/liste-verdens-15-storste-lakseoppdrettere/2-1-413930>
- IntraFish. (2018b). *Ordforklaringer*. Hentet 26. Februar, 2020 fra IntraFish: <https://www.intrafish.no/nyheter/ordforklaringer/2-1-429925>
- Iversen, A., & Kosmo, J. (2018). *Kan vekstindeksene sammenlignes?* Hentet 15. Juni, 2020 fra Kyst: <https://www.kyst.no/article/kan-vekstindeksene-sammenlignes-1>
- Iversen, A., Hermansen, Ø., Andreassen, O., Larsen, T., & Terjesen, B. (2013). *Et økonomisk godt år for oppdretterne av laks og regnbueørret i 2018*. Tromsø: Nofima. Hentet 18. April, 2020 fra <https://nofima.brage.unit.no/nofima-xmlui/handle/11250/284305>
- Kassambara, A. (2020). *ggpubr: 'ggplot2' Based Publication Ready Plots*. Hentet 21. Mai, 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=ggpubr>
- Kehl, D., Kessler, S., & Guo, P. (2017). *Algorithms in the Criminal Justice System: Assessing the Use of Risk Assessments in Sentencing*. Responsive Communities Initiative, Berkman Klein Center for Internet & Society,. Hentet 14. Mars, 2020 fra Harvard Law School: <http://nrs.harvard.edu/urn-3:HUL.InstRepos:33746041>
- Kingma, D., & Ba, J. (2014). Adam: A Method for stochastic optimization. *CoRR*, *abs/1412.6980*.
- Kuan, C.-M. (2006). Artificial Neural Networks No. 06-A010. *IEAS Working Paper : Academic research*. Hentet 20. Mars, 2020 fra <https://EconPapers.repec.org/RePEc:sin:wpaper:06-a010>
- Kuhn, M., Chow, F., & Wickham, H. (2020). *rsample: General Resampling Infrastructure*. Hentet 5. April, 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=rsample>

- Lekve, O. (2012). *Norsk oppdrettsnæring*. Hentet 5. Mars, 2020 fra BarentsWatch: <https://www.barentswatch.no/artikler/Norsk-oppdrettsnaring/>
- Mahajan, D., Girshick, R., Ramanathan, V., He, K., Paluri, M., Li, Y., . . . van der Maaten, L. (2018). Exploring the Limits of Weakly Supervised Pretraining. Hentet 10. April, 2020 fra https://research.fb.com/wp-content/uploads/2018/05/exploring_the_limits_of_weakly_supervised_pretraining.pdf
- Makridakis, S., & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International Journal of Forecasting*, 16, 451-476.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE*, 13(3).
- Mattilsynet. (2020). *Tema Lakselus*. Hentet 13. Mai, 2022 fra Mattilsynet: https://mattilsynet.no/fisk_og_akvakultur/fiskehelse/fiske_og_skjellsykdommer/lakselus/
- Mowi. (2019). *Salmon Farming Industry Handbook*. Hentet 11. Februar, 2020 fra Mowi: <https://corpsite.azureedge.net/corpsite/wp-content/uploads/2019/06/Salmon-Industry-Handbook-2019.pdf>
- Müller, K., & Wickham, H. (2020). *tibble: Simple Data Frames*. Hentet 19. Mars, 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=tibble>
- Müller, K., Henry, L., François, R., & Wickham, H. (2020). *dplyr: A Grammar of Data Manipulation*. Hentet 17. Januar, 2020 fra <https://cran.r-project.org/package=dplyr>
- NCE Seafood. (u.d.). *AquaCloud- The use of artificial intelligence in sea lice management*. Hentet 29. Mai, 2020 fra NCE Seafood: http://www.seafoodinnovation.no/article/213/AquaCloud_The_use_of_artificial_intelligence_in_sea_lice_management
- Nedelkoska, L., & Quintini, G. (2018). Automation, skills use and training. *OECD Social, Employment and Migration Working Papers*, No. 202. doi:<https://doi.org/10.1787/2e2f4eea-en>

- Optoscale. (u.d.). *Om Optoscale*. Hentet 23. Mai, 2020 fra Optoscale: <https://www.optoscale.no/>
- Osland, A. (2017). *Tildelingsprosessen*. Hentet 19. Februar, 2020 fra Fiskeridirektoratet: <https://www.fiskeridir.no/Akvakultur/Tildeling-og-tillatelser/Tildelingsprosessen>
- Parmar, R. (2018). *Common Loss functions in machine learning*. Hentet 21. Mars, 2020 fra Towardsdatascience: <https://towardsdatascience.com/common-loss-functions-in-machine-learning-46af0ffc4d23>
- Proff. (u.d.). *Grieg Seafood ASA*. Hentet 19. Mai, 2020 fra Proff: <https://www.proff.no/regnskap/grieg-seafood-asa/bergen/hovedkontortjenester/IFNKVPY10NZ/>
- Proff. (u.d.). *Svanøy Havbruk AS*. Hentet 19. Mai, 2020 fra Proff: <https://proff.no/regnskap/svan%C3%B8y-havbruk-as/svan%C3%B8ybukt/akvakultur/IGCNNTX000M/>
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, 65(6), 386.
- Rosten, T. (2009). Oksygen i vann - hva er det beste for fisken? *Vann*, 367-374.
- Rosten, T., Ulgenes, Y., Henriksen, K., Terjesen, B., Biering, E., & Winther, U. (2011). *Oppdrett av laks og ørret i lukkede anlegg - forprosjekt*. SINTEF Fiskeri og havbruk AS.
- Samudrala, S. (2019). *Machine Intelligence: Demystifying Machine Learning, Neural Networks and Deep Learning*. India: Notion Press.
- Saunders, M., Lewis, P., & Thornhill, A. (2016). *Research Methods for Business Students* (7. utg.). Harlow: Pearson Education Limited.
- Singh, S. (2018). *Understanding the Bias-Variance Tradeoff*. Hentet 17. April, 2020 fra Towardsdatascience: <https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229>

- SINTEF. (2009). *Konsekvensanalyse - utredning rundt følgene av feilestimering av biomasse i sjøbasert oppdrett*. SINTEF Fiskeri og havbruk AS. Hentet 25. Mars, 2020 fra https://www.sintef.no/globalassets/upload/fiskeri_og_havbruk/havbruksteknologi/exactus/dokument/akvarena_endelig_rapport_konsekvensanalyse_feilestimering_biomasse-05102009.pdf
- Skaar Norway AS. (u.d.). *About*. Hentet 19. April, 2020 fra Skaar Norway: <https://www.skaarnorway.com/about/>
- Skretting Norge. (2012). *Fôr*. Hentet 16. April, 2002 fra Skretting Norge Guidelines: <https://www.skrettingguidelines.com/readimage.aspx?pubid=cd8a45bd-0e6e-409c-a2ee-1da2b7d19b06>
- SSB. (1971). *Variabeldefinisjon Matfisk*. Hentet 25. Februar, 2020 fra Statistisk sentralbyrå: <https://www.ssb.no/a/metadata/conceptvariable/vardok/2373/nb>
- SSB. (2019). *Akvakultur*. Hentet 19. Mars, 2020 fra Statistisk sentralbyrå: <https://www.ssb.no/jord-skog-jakt-og-fiskeri/statistikker/fiskeoppdrett/aar>
- SSB. (2020). *Utenrikshandel med varer*. Hentet 14. Juni, 2020 fra Statistisk sentralbyrå: <https://www.ssb.no/utenriksokonomi/statistikker/muh/aar>
- Steinseide, A. (2019). *Et økonomisk godt år for oppdretterne av laks og regnbueørret i 2018*. Hentet 26. Mai, 2020 fra Fiskeridirektoratet: <https://www.fiskeridir.no/Akvakultur/Nyheter/2019/0819/Et-oekonomisk-godt-aar-for-oppdretterne-av-laks-og-regnbueoerret-i-2018>
- Svanøy Havbruk AS. (u.d.). *Om oss*. Hentet 21. Februar, 2020 fra Svanøy Havbruk: <https://www.svanoyhavbruk.no/om-oss>
- Tesla. (u.d.). *Autopilot*. Hentet 2. Mars, 2020 fra Tesla: https://www.tesla.com/no_NO/autopilotAI
- Timmermann, A. (2006). Forecast combinations. *Handbook of economic forecasting, 1*, 135-196.

- Touretzky, D., & Pomerleau, D. (1989). What's Hidden in the Hidden Layers? *Byte*, 14(8), 227-233.
- United States International Trade Commission. (1990). *Fresh and chilled atlantic salmon from Norway*. Hentet 8. Mars, 2020 fra United States International Trade Commission: https://www.usitc.gov/publications/701_731/pub2272.pdf
- Vaughan, D., & Dancho, M. (2020). *tibbletime: Time Aware Tibbles*. Hentet 18. Mars, 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=tibbletime>
- Veterinærinstituttet. (2004). *Kultiveringsveilederen*. Hentet fra Veterinærinstituttet: http://multiconsult.eurest.no/nor/content/download/3784/34296/file/4.3.1_F%C3%B4ring_av_fisk.pdf
- Wathne, E., & Nondal, G. (2019). *Digitaliseringens tid*. Hentet 29. April, 2020 fra Tekfisk: https://fiskeribladet.no/tekfisk/nyheter/?lukk_cookieinfo=ja&artikkel=68573
- Whitworth, B., & Ryu, H. (2007). A Comparison of Human and Computer Information Processing. *Information Science reference*, 1, ss. 230-239.
- Wickham, H., & Bryan, J. (2019). *readxl: Read Excel Files*. Hentet Mars 10., 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=readxl>
- Wickham, H., Chang, W., Henry, L., Pedersen, T., Takahashi, K., Wilke, C., . . . Dunnington, D. (2020). *ggplot2: Create Elegant Data Visualisations Using the Grammar of Graphics*. Hentet 15. Mai, 2020 fra The Comprehensive R Archive Network: <https://cran.r-project.org/package=ggplot2>
- Zhang, G., Patuwo, B., & Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14(1), 35-62.

Appendiks

Appendiks A Bakgrunn

A.1 Potensiell gevinst salgsledd

A.1.1 Potensiell gevinst salgsledd | Konsesjon | Markedspris 2009

$$0,05 * 1\,300\,000 \text{ kg} * 2 \text{ kr/kg} = 130\,000 \text{ kroner}$$

*Antar 5 prosent feilestimering, årlig produksjon på 1 300 tonn og potensiell gevinst på 2 kr/kg.

A.1.2 Potensiell gevinst salgsledd | Konsesjon | Markedspris 2018

$$0,05 * 1\,300\,000 \text{ kg} * 4 \text{ kr/kg} = 260\,000 \text{ kroner}$$

*Antar 5 prosent feilestimering, årlig produksjon på 1 300 tonn og potensiell gevinst på 4 kr/kg.

A.1.3 Potensiell gevinst salgsledd | Næringen | Markedspris 2018

$$0,05 * 1\,350\,000\,000 \text{ kg} * 4 \text{ kr/kg} = 270\,000\,000 \text{ kr} \approx 270 \text{ millioner kroner}$$

*Antar 5 prosent feilestimering, årlig salgsvolum på 1 350 000 tonn og potensiell gevinst på 4 kr/kg.

A.2 Potensielle gevinster produksjonsledd | Overestimering

A.2.1 Lavere produksjonsverdi enn forventet | Konsesjon

$$135\,000 \text{ kg} * 0,8 * 50,25 \text{ kr/kg} = 5\,427\,000 \text{ kr} \approx 5,4 \text{ millioner kroner}$$

*Antar 135 tonn mindre fisk, 20 prosent sløyvesvinn og salgspris 50,25 kr.

A.2.2 Forhøyet kostnad produksjonsledd overføring | Konsesjon

$$142\,000\text{ kg} * 14,15\text{ kr/kg} = 2\,009\,300\text{ kr} \approx 2\text{ millioner kroner}$$

*Antar 142 tonn overføring og fôrpris 14,15 kr/kg.

A.2.3 Lavere produksjonsverdi enn forventet | Næringen

$$\frac{1\,350\,000\,000\text{ kg}}{1\,300\,000\text{ kg}} * 135\,000\text{ kg} * 0,8 * 50,25\text{ kr/kg} = 5\,635\,730\,769\text{ kr}$$
$$\approx 5,6\text{ milliarder kroner}$$

*Antar 135 tonn mindre fisk per konsesjon, 20 prosent sløyvesvinn og salgspris 50,25 kr.

A.2.4 Forhøyet kostnad produksjonsledd overføring | Næringen

$$\frac{1\,350\,000\,000\text{ kg}}{1\,300\,000\text{ kg}} * 142\,000\text{ kg} * 14,15\text{ kr/kg} = 2\,086\,581\,769\text{ kr}$$
$$\approx 2,1\text{ milliarder kroner}$$

*Antar 142 tonn overføring per konsesjon og fôrpris 14,15 kr/kg.

A.3 Potensielle gevinster produksjonsledd | Underestimering

A.3.1 Potensiell gevinst produksjonsledd | Konsesjon

$$\left(137\,000\text{ kg} * 0,8 * 50,25\text{ kr/kg}\right)$$
$$- \left(\left(145\,000\text{ kg} * 14,15\text{ kr/kg}\right) + \left(137\,000\text{ kg} * 3,79\text{ kr/kg}\right)\right)$$
$$= 2\,936\,420\text{ kr} \approx 2,9\text{ millioner kroner}$$

*Antar 137 tonn vekstpotensial, 20 prosent sløyvesvinn, salgspris 50,25 kr/kg, fôrpris 14,15 kr/kg, ytterligere 145 tonn fôr og slaktekostnad 3,79 kr/kg.

A.3.2 Potensiell gevinst produksjonsledd | Næringen

$$\begin{aligned} & \left(\frac{1\,350\,000\,000\text{ kg}}{1\,300\,000\text{ kg}} \right) \\ & * \left(\left(137\,000\text{ kg} * 0,8 * 50,25\text{ kr/kg} \right) \right. \\ & \left. - \left(\left(145\,000\text{ kg} * 14,15\text{ kr/kg} \right) + \left(137\,000\text{ kg} * 3,79\text{ kr/kg} \right) \right) \right) \\ & = 3\,049\,359\,231\text{ kr} \approx 3\text{ milliarder kroner} \end{aligned}$$

*Antar 137 tonn vekstpotensial per konsesjon, 20 prosent sløysevinn, salgspris 50,25 kr/kg, fôrpris 14,15 kr/kg, ytterligere 145 tonn fôr per konsesjon og slaktekostnad

Appendiks B Datasett

B.1 Variabeloversikt

Nummer	Variabelnavn	Variabelbeskrivelse	Bruk
1	Merd	Navn på merden som fisken har stått i	
2	Dato	Dato for gjennomført slakt	
3	År	År for gjennomført slakt	Input
4	Dag	Dag nummer i året for gjennomført slakt (0-365)	Input
5	Tid	Antall dager fisken har stått i sjø ved slakt	Input
6	Generasjon	Generasjonsidentifikator	Input
7	UBvekt	Gjennomsnittsvekt ved utsett (gram)	Input
8	F01	Fôring siste måned før slakt (kilogram)	Input
9	F02	Fôring siste to måneder før slakt (kilogram)	Input
10	F05	Fôring siste fem måneder før slakt (kilogram)	Input
11	F10	Fôring siste ti måneder før slakt (kilogram)	Input
12	FTotal	Total fôring før slakt (kilogram)	Input
13	DA01	Antall dødfisk siste måned før slakt	Input
14	DA02	Antall dødfisk siste to måneder før slakt	Input
15	DA05	Antall dødfisk siste fem måneder før slakt	Input
16	DA10	Antall dødfisk siste ti måneder før slakt	Input
17	DATotal	Totalt antall dødfisk før slakt	Input
18	DM01	Total vekt for dødfisk siste måned før slakt (kilogram)	Input
19	DM02	Total vekt for dødfisk siste to måneder før slakt (kilogram)	Input
20	DM05	Total vekt for dødfisk siste fem måneder før slakt (kilogram)	Input
21	DM10	Total vekt for dødfisk siste ti måneder før slakt (kilogram)	Input

Nummer	Variabelnavn	Variabelbeskrivelse	Bruk
22	DMTotal	Total vekt for dødfisk før slakt (kilogram)	Input
23	T01	Gjennomsnitt vanntemperatur siste måned før slakt (celsius)	Input
24	T02	Gjennomsnitt vanntemperatur siste to måneder før slakt (celsius)	Input
25	T05	Gjennomsnitt vanntemperatur siste fem måneder før slakt (celsius)	Input
26	T10	Gjennomsnitt vanntemperatur siste ti måneder før slakt (celsius)	Input
27	TTTotal	Gjennomsnitt vanntemperatur før slakt (celsius)	Input
28	Antall	Antall slaktet fisk	
29	Nettovekt	Gjennomsnitt vekt slaktet fisk	
30	NSup01	Antall fisk slaktet klassifisert som SUP 0-1	
31	NSup12	Antall fisk slaktet klassifisert som SUP 1-2	
32	NSup23	Antall fisk slaktet klassifisert som SUP 2-3	
33	NSup34	Antall fisk slaktet klassifisert som SUP 3-4	
34	NSup45	Antall fisk slaktet klassifisert som SUP 4-5	
35	NSup56	Antall fisk slaktet klassifisert som SUP 5-6	
36	NOrd01	Antall fisk slaktet klassifisert som ORD 0-1	
37	NOrd12	Antall fisk slaktet klassifisert som ORD 1-2	
38	NOrd23	Antall fisk slaktet klassifisert som ORD 2-3	
39	NOrd34	Antall fisk slaktet klassifisert som ORD 3-4	
40	NOrd45	Antall fisk slaktet klassifisert som ORD 4-5	
41	NOrd56	Antall fisk slaktet klassifisert som ORD 5-6	
42	NProd01	Antall fisk slaktet klassifisert som PROD 0-1	
43	NProd12	Antall fisk slaktet klassifisert som PROD 1-2	
44	NProd23	Antall fisk slaktet klassifisert som PROD 2-3	
45	NProd34	Antall fisk slaktet klassifisert som PROD 3-4	

Nummer	Variabelnavn	Variabelbeskrivelse	Bruk
46	NProd45	Antall fisk slaktet klassifisert som PROD 4-5	
47	NProd56	Antall fisk slaktet klassifisert som PROD 5-6	
48	ASup01	Andelen fisk slaktet klassifisert som SUP 0-1	Output
49	ASup12	Andelen fisk slaktet klassifisert som SUP 1-2	Output
50	ASup23	Andelen fisk slaktet klassifisert som SUP 2-3	Output
51	ASup34	Andelen fisk slaktet klassifisert som SUP 3-4	Output
52	ASup45	Andelen fisk slaktet klassifisert som SUP 4-5	Output
53	ASup56	Andelen fisk slaktet klassifisert som SUP 5-6	Output
54	AOrd01	Andelen fisk slaktet klassifisert som ORD 0-1	Output
55	AOrd12	Andelen fisk slaktet klassifisert som ORD 1-2	Output
56	AOrd23	Andelen fisk slaktet klassifisert som ORD 2-3	Output
57	AOrd34	Andelen fisk slaktet klassifisert som ORD 3-4	Output
58	AOrd45	Andelen fisk slaktet klassifisert som ORD 4-5	Output
59	AOrd56	Andelen fisk slaktet klassifisert som ORD 5-6	Output
60	AProd01	Andelen fisk slaktet klassifisert som PROD 0-1	Output
61	AProd12	Andelen fisk slaktet klassifisert som PROD 1-2	Output
62	AProd23	Andelen fisk slaktet klassifisert som PROD 2-3	Output
63	AProd34	Andelen fisk slaktet klassifisert som PROD 3-4	Output
64	AProd45	Andelen fisk slaktet klassifisert som PROD 4-5	Output
65	AProd56	Andelen fisk slaktet klassifisert som PROD 5-6	Output

Appendiks C Beskrivende statistikk

C.1 Inputvariabler

	Min	Median	Max	Gjennomsnitt
År	2019	2019	2020	2019
Dag	55	239	352	225
Tid	295	352	404	352
Generasjon	1	4	8	4
UBvekt	102	183	263	178
F01	23 161	47 733	102 301	53 451
F02	49 763	99 379	180 325	103 365
F05	115 185	216 731	315 353	214 744
F10	166 878	294 940	417 369	300 094
FTotal	175 067	298 424	441 789	313 086
DA01	59	447	1 837	449
DA02	133	712	2 370	805
DA05	837	1 406	2 744	1 544
DA10	1 453	3 908	8 315	4 403
DATotal	2 110	4 717	9 453	5 408
DM01	237	1 455	6 227	1 570
DM02	454	2 395	8 097	2 650
DM05	1 971	4 036	8 839	4 174
DM10	2 747	6 261	11 795	5 878
DMTotal	2 926	6 495	11 960	6 098
T01	6	13	16	12
T02	6	13	17	12
T05	8	11	13	11

	Min	Median	Max	Gjennomsnitt
T10	9	10	11	10
TTotal	9	10	11	10

C.2 Vekt- og kvalitetsfordeling

C.2.1 SUP

	Min	Median	Max	Gjennomsnitt	Akk. gjennomsnitt
SUP 0-1	0,000	0,000	0,001	0,000	0,000
SUP 1-2	0,003	0,014	0,041	0,017	0,018
SUP 2-3	0,078	0,249	0,742	0,285	0,303
SUP 3-4	0,112	0,559	0,672	0,510	0,812
SUP 4-5	0,000	0,062	0,333	0,089	0,901
SUP 5-6	0,000	0,000	0,018	0,002	0,903

C.2.2 ORD

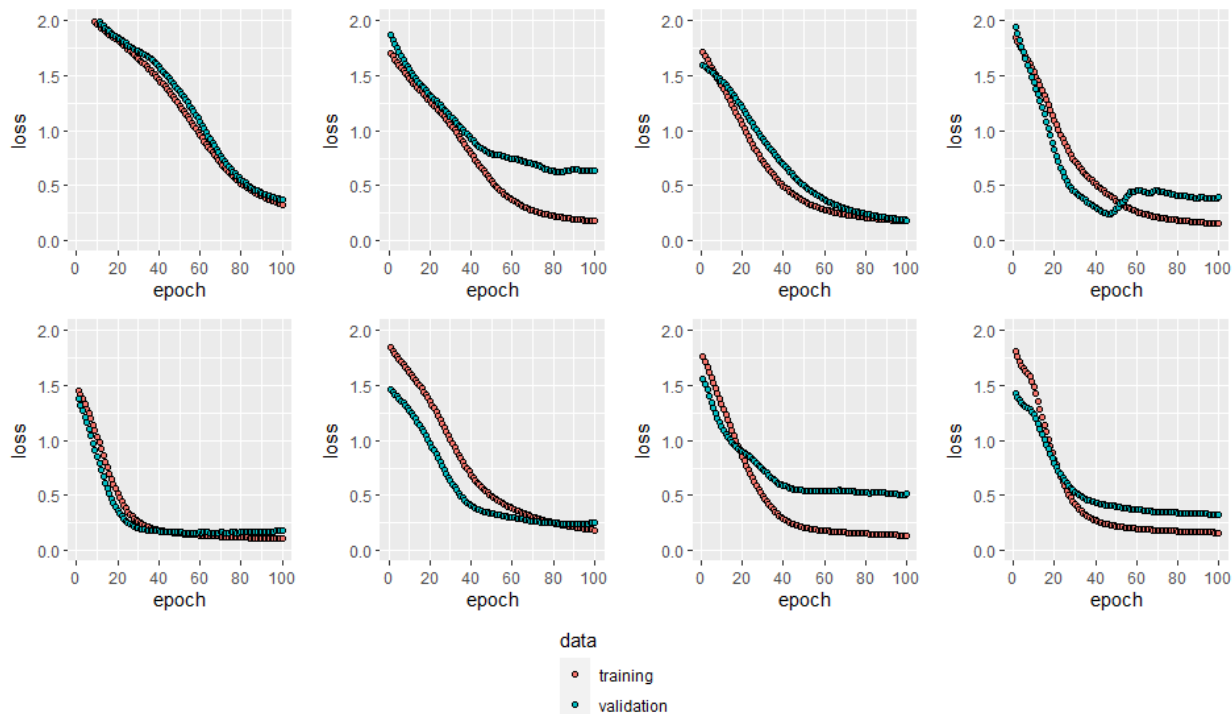
	Min	Median	Max	Gjennomsnitt	Akk. gjennomsnitt
ORD 0-1	0,000	0,000	0,000	0,000	0,000
ORD 1-2	0,000	0,003	0,014	0,003	0,003
ORD 2-3	0,006	0,017	0,075	0,021	0,024
ORD 3-4	0,002	0,012	0,004	0,017	0,041
ORD 4-5	0,000	0,001	0,011	0,002	0,044
ORD 5-6	0,000	0,000	0,000	0,000	0,044

C.2.3 PROD

	Min	Median	Max	Gjennomsnitt	Akk. gjennomsnitt
PROD 0-1	0,000	0,000	0,000	0,000	0,000
PROD 1-2	0,000	0,004	0,033	0,005	0,005
PROD 2-3	0,009	0,018	0,147	0,024	0,029
PROD 3-4	0,002	0,010	0,191	0,020	0,049
PROD 4-5	0,000	0,000	0,035	0,004	0,053
PROD 5-6	0,000	0,000	0,001	0,000	0,053

Appendiks D Tilpasning av nevralt nettverk

D.1 Kryssvalidering



D.2 Valg av modellstruktur og hyperparametre

Nevroner	Lærings-rate	Forfalls-frekvens	Epoker	Nøyaktig-het	Maks-avvik i pp.	Median-avvik i pp.	Modeller i ensemblet
(6)	0,0001	0	100	0,060	0,382	0,040	19
(6)	0,001	0	100	0,025	0,289	0,010	1
(6)	0,001	0,00001	100	0,026	0,242	0,010	27
(6)	0,01	0	100	0,018	0,300	0,006	18
(6)	0,01	0,00001	100	0,018	0,367	0,005	1
(6)	0,01	0,0001	100	0,015	0,133	0,006	1
(6)	0,01	0,001	100	0,019	0,283	0,006	21
(12)	0,0001	0	100	0,047	0,363	0,031	13
(12)	0,001	0	100	0,019	0,263	0,008	4
(12)	0,001	0,00001	100	0,016	0,123	0,006	1
(12)	0,01	0	100	0,011	0,207	0,003	2
(12)	0,01	0,00001	100	0,012	0,220	0,006	6

Nevroner	Lærings- rate	Forfalls- frekvens	Epoker	Nøyaktig- het	Maks avvik i pp.	Median- avvik i pp.	Modeller i ensemblet
(12)	0,01	0,0001	100	0,013	0,279	0,003	1
(12)	0,01	0,001	100	0,015	0,276	0,005	15
(24)	0,0001	0	100	0,033	0,302	0,018	6
(24)	0,001	0	100	0,018	0,207	0,009	1
(24)	0,001	0,00001	100	0,018	0,215	0,008	5
(24)	0,01	0	100	0,010	0,203	0,004	13
(24)	0,01	0,00001	100	0,010	0,123	0,005	5
(24)	0,01	0,0001	100	0,011	0,191	0,004	19
(24)	0,01	0,001	100	0,011	0,194	0,005	28
(24,12)	0,0001	0	100	0,035	0,268	0,017	5
(24,12)	0,001	0	100	0,018	0,221	0,008	9
(24,12)	0,001	0,00001	100	0,018	0,223	0,007	4
(24,12)	0,01	0	100	0,010	0,186	0,004	4
(24,12)	0,01	0,00001	100	0,008	0,106	0,004	7
(24,12)	0,01	0,0001	100	0,010	0,145	0,005	3
(24,12)	0,01	0,001	100	0,013	0,252	0,004	1
(24,6)	0,0001	0	100	0,046	0,318	0,031	11
(24,6)	0,001	0	100	0,019	0,193	0,009	3
(24,6)	0,001	0,00001	100	0,019	0,283	0,009	5
(24,6)	0,01	0	100	0,011	0,135	0,004	4
(24,6)	0,01	0,00001	100	0,012	0,125	0,004	9
(24,6)	0,01	0,0001	100	0,009	0,095	0,003	1
(24,6)	0,01	0,001	100	0,012	0,093	0,007	1
(12,6)	0,0001	0	100	0,054	0,349	0,032	7
(12,6)	0,001	0	100	0,024	0,227	0,011	30
(12,6)	0,001	0,00001	100	0,022	0,234	0,010	4
(12,6)	0,01	0	100	0,015	0,156	0,005	30
(12,6)	0,01	0,00001	100	0,014	0,188	0,004	28
(12,6)	0,01	0,0001	100	0,011	0,217	0,004	1
(12,6)	0,01	0,001	100	0,016	0,166	0,006	4
(24,12,6)	0,0001	0	100	0,036	0,313	0,020	8
(24,12,6)	0,001	0	100	0,021	0,194	0,007	6
(24,12,6)	0,001	0,00001	100	0,021	0,191	0,008	28

Nevroner	Lærings- rate	Forfalls- frekvens	Epoker	Nøyaktig- het	Maks avvik i pp.	Median- avvik i pp.	Modeller i ensemblet
(24,12,6)	0,01	0	100	0,015	0,105	0,004	30
(24,12,6)	0,01	0,00001	100	0,010	0,172	0,003	2
(24,12,6)	0,01	0,0001	100	0,010	0,138	0,003	9
(24,12,6)	0,01	0,001	100	0,010	0,074	0,004	3

Appendiks E Resultater

E.1 Resultater for validering

E.1.1 Virkelig fordeling

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	0,014	0,093	0,439	0,269	0,012	0,000	0,005	0,019	0,039	0,008	0,000	0,000	0,007	0,020	0,047	0,027	0,001
0,000	0,018	0,097	0,465	0,252	0,009	0,000	0,005	0,015	0,023	0,006	0,000	0,000	0,007	0,023	0,048	0,032	0,000
0,000	0,019	0,098	0,374	0,308	0,018	0,000	0,006	0,020	0,034	0,009	0,000	0,000	0,006	0,022	0,050	0,035	0,000
0,000	0,018	0,091	0,417	0,274	0,014	0,000	0,003	0,013	0,032	0,009	0,000	0,000	0,009	0,032	0,057	0,030	0,000
0,001	0,041	0,412	0,473	0,015	0,000	0,000	0,002	0,011	0,006	0,000	0,000	0,000	0,006	0,024	0,009	0,000	0,000

E.1.2 Ensembleprediksjoner

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	0,019	0,110	0,413	0,260	0,009	0,000	0,010	0,022	0,040	0,014	0,000	0,000	0,008	0,021	0,043	0,028	0,000
0,000	0,016	0,120	0,475	0,240	0,005	0,000	0,007	0,020	0,036	0,009	0,000	0,000	0,006	0,018	0,032	0,017	0,000
0,000	0,016	0,095	0,422	0,292	0,008	0,000	0,008	0,019	0,038	0,013	0,000	0,000	0,006	0,016	0,038	0,029	0,000
0,000	0,015	0,092	0,421	0,299	0,008	0,000	0,008	0,018	0,037	0,013	0,000	0,000	0,006	0,015	0,038	0,030	0,000
0,000	0,030	0,306	0,449	0,075	0,002	0,000	0,008	0,030	0,018	0,005	0,000	0,000	0,010	0,037	0,023	0,005	0,000

E.1.3 Avvik ensembleprediksjoner mot virkelig fordeling

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	0,005	0,017	-0,026	-0,009	-0,004	0,000	0,005	0,004	0,001	0,006	0,000	0,000	0,001	0,001	-0,003	0,001	-0,001
0,000	-0,002	0,023	0,010	-0,012	-0,005	0,000	0,002	0,005	0,013	0,003	0,000	0,000	-0,001	-0,005	-0,016	-0,015	0,000
0,000	-0,004	-0,004	0,048	-0,016	-0,010	0,000	0,002	-0,001	0,004	0,004	0,000	0,000	0,001	-0,006	-0,012	-0,006	0,000
0,000	-0,003	0,000	0,004	0,025	-0,006	0,000	0,004	0,005	0,005	0,004	0,000	0,000	-0,003	-0,017	-0,020	0,000	0,000
-0,001	-0,011	-0,106	-0,024	0,061	0,002	0,000	0,006	0,019	0,012	0,005	0,000	0,000	0,004	0,013	0,014	0,005	0,000

E.1.4 Avvik gjennomsnittsfordeling Svanøy mot virkelig fordeling

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	-0,001	-0,199	-0,076	0,192	0,012	0,000	0,001	-0,005	0,021	0,006	0,000	0,000	0,002	-0,005	0,027	0,025	0,001
0,000	0,003	-0,196	-0,050	0,175	0,009	0,000	0,001	-0,009	0,005	0,004	0,000	0,000	0,002	-0,002	0,029	0,030	0,000
0,000	0,004	-0,194	-0,140	0,231	0,017	0,000	0,003	-0,004	0,015	0,007	0,000	0,000	0,000	-0,003	0,031	0,032	0,000
0,000	0,003	-0,201	-0,098	0,197	0,013	0,000	0,000	-0,011	0,014	0,007	0,000	0,000	0,004	0,007	0,038	0,028	0,000
0,001	0,026	0,119	-0,042	-0,062	-0,001	0,000	-0,002	-0,013	-0,013	-0,002	0,000	0,000	0,001	-0,001	-0,010	-0,002	0,000

E.2 Resultater for test

E.2.1 Virkelig fordeling | Test

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	0,032	0,419	0,495	0,017	0,000	0,000	0,001	0,008	0,002	0,000	0,000	0,000	0,006	0,015	0,004	0,000	0,000
0,000	0,028	0,390	0,503	0,038	0,000	0,000	0,002	0,010	0,005	0,000	0,000	0,000	0,004	0,015	0,005	0,000	0,000
0,000	0,028	0,386	0,499	0,041	0,000	0,000	0,001	0,006	0,004	0,000	0,000	0,000	0,004	0,020	0,010	0,000	0,000
0,000	0,035	0,389	0,501	0,019	0,000	0,000	0,003	0,012	0,005	0,000	0,000	0,000	0,005	0,023	0,008	0,000	0,000
0,000	0,035	0,389	0,501	0,019	0,000	0,000	0,003	0,012	0,005	0,000	0,000	0,000	0,005	0,023	0,008	0,000	0,000
0,000	0,017	0,220	0,596	0,125	0,000	0,000	0,002	0,008	0,006	0,001	0,000	0,000	0,003	0,013	0,009	0,001	0,000
0,000	0,014	0,227	0,592	0,118	0,000	0,000	0,002	0,009	0,010	0,001	0,000	0,000	0,002	0,012	0,012	0,001	0,000
0,000	0,018	0,219	0,576	0,128	0,000	0,000	0,001	0,006	0,008	0,001	0,000	0,000	0,004	0,022	0,015	0,002	0,000

E.2.2 Ensembleprediksjoner | Test

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,001	0,072	0,422	0,239	0,022	0,001	0,000	0,019	0,089	0,020	0,003	0,000	0,000	0,019	0,073	0,016	0,001	0,000
0,001	0,069	0,339	0,287	0,046	0,005	0,001	0,024	0,090	0,024	0,005	0,001	0,000	0,017	0,064	0,023	0,004	0,001
0,001	0,068	0,346	0,285	0,044	0,005	0,000	0,024	0,091	0,024	0,004	0,001	0,000	0,017	0,064	0,022	0,004	0,001
0,001	0,070	0,372	0,273	0,036	0,003	0,000	0,022	0,090	0,022	0,004	0,001	0,000	0,017	0,067	0,020	0,003	0,000
0,001	0,067	0,324	0,292	0,053	0,007	0,001	0,025	0,091	0,025	0,005	0,001	0,000	0,016	0,062	0,024	0,005	0,001
0,001	0,063	0,264	0,316	0,081	0,009	0,001	0,024	0,077	0,032	0,008	0,001	0,001	0,018	0,059	0,033	0,010	0,001
0,001	0,063	0,256	0,316	0,086	0,010	0,001	0,024	0,076	0,033	0,009	0,001	0,001	0,019	0,058	0,034	0,011	0,001
0,001	0,062	0,257	0,313	0,086	0,011	0,001	0,025	0,078	0,032	0,009	0,001	0,001	0,018	0,058	0,034	0,011	0,001

E.2.3 Avvik ensembleprediksjoner mot virkelig fordeling | Test

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	-0,003	-0,119	-0,043	0,061	0,002	0,000	0,007	0,022	0,016	0,005	0,000	0,000	0,005	0,021	0,019	0,005	0,000
0,000	-0,001	-0,116	-0,040	0,061	0,004	0,000	0,006	0,018	0,013	0,006	0,000	0,000	0,005	0,018	0,019	0,006	0,000
0,000	0,000	-0,108	-0,037	0,055	0,003	0,000	0,007	0,022	0,014	0,006	0,000	0,000	0,005	0,013	0,014	0,006	0,000
0,000	-0,005	-0,118	-0,033	0,073	0,003	0,000	0,006	0,016	0,015	0,005	0,000	0,000	0,005	0,011	0,016	0,006	0,000
0,000	-0,007	-0,122	-0,034	0,081	0,003	0,000	0,005	0,015	0,013	0,006	0,000	0,000	0,005	0,010	0,016	0,007	0,000
0,000	0,014	0,012	-0,139	-0,008	0,004	0,000	0,009	0,023	0,019	0,007	0,001	0,000	0,008	0,022	0,021	0,008	0,000
0,000	0,016	0,000	-0,135	0,004	0,004	0,000	0,008	0,021	0,015	0,007	0,001	0,000	0,009	0,023	0,018	0,008	0,000
0,000	0,013	0,009	-0,120	-0,008	0,004	0,000	0,009	0,025	0,017	0,007	0,001	0,000	0,007	0,013	0,014	0,007	0,000

E.2.4 Avvik gjennomsnittsfordeling Svanøy mot virkelig fordeling | Test

Sup01	Sup12	Sup23	Sup34	Sup45	Sup56	Ord01	Ord12	Ord23	Ord34	Ord45	Ord56	Prod01	Prod12	Prod23	Prod34	Prod45	Prod56
0,000	0,016	0,142	-0,011	-0,077	-0,002	0,000	-0,002	-0,015	-0,017	-0,002	0,000	0,000	0,000	-0,010	-0,017	-0,005	0,000
0,000	0,012	0,113	-0,002	-0,056	-0,002	0,000	-0,002	-0,013	-0,014	-0,002	0,000	0,000	-0,002	-0,010	-0,017	-0,005	0,000
0,000	0,012	0,109	-0,006	-0,053	-0,002	0,000	-0,003	-0,017	-0,015	-0,002	0,000	0,000	-0,001	-0,005	-0,012	-0,005	0,000
0,000	0,019	0,112	-0,004	-0,075	-0,002	0,000	-0,001	-0,011	-0,014	-0,002	0,000	0,000	-0,001	-0,002	-0,014	-0,005	0,000
0,000	0,019	0,112	-0,005	-0,075	-0,002	0,000	-0,001	-0,011	-0,014	-0,002	0,000	0,000	-0,001	-0,002	-0,014	-0,005	0,000
0,000	0,001	-0,057	0,091	0,031	-0,002	0,000	-0,002	-0,016	-0,013	-0,001	0,000	0,000	-0,002	-0,012	-0,013	-0,005	0,000
0,000	-0,002	-0,050	0,086	0,024	-0,002	0,000	-0,001	-0,014	-0,009	-0,001	0,000	0,000	-0,003	-0,013	-0,010	-0,004	0,000
0,000	0,002	-0,058	0,070	0,034	-0,002	0,000	-0,002	-0,018	-0,011	-0,001	0,000	0,000	-0,001	-0,003	-0,007	-0,003	0,000

Appendiks F Potensielle gevinster

F.1 Potensiell gevinst salgsledd | Svanøy

$$0,05 * 3\ 000\ 000\ kg * 4\ kr/kg = 600\ 000\ kroner$$

*Antar 5 prosent feilestimering, årlig produksjon på 3 000 tonn og potensiell gevinst på 4 kr/kg.

F.2 Potensiell gevinst salgsledd | Ocean Quality

$$0,05 * 125\ 530\ 000\ kg * 4\ kr/kg = 25\ 106\ 000\ kr \approx 25,1\ millioner\ kroner$$

*Antar 5 prosent feilestimering, årlig salgsvolum på 125 530 tonn og potensiell gevinst på 4 kr/kg.

F.3 Gevinst i produksjonsledd | Svanøy | Overestimering

F.3.1 Lavere produksjonsverdi enn forventet

$$\frac{3\ 000\ 000\ kg}{1\ 300\ 000\ kg} * 135\ 000\ kg * 0,8 * 50,25\ kr/kg = 12\ 523\ 846\ kr \approx 12,5\ millioner\ kroner$$

*Antar 135 tonn mindre fisk per konsesjon, 20 prosent sløyvesvinn og salgspris 50,25 kr.

F.3.2 Kostnad for overfôring

$$\frac{3\ 000\ 000\ kg}{1\ 300\ 000\ kg} * 142\ 000\ kg * 14,15\ kr/kg = 4\ 636\ 846\ kr \approx 4,6\ millioner\ kroner$$

*Antar 142 tonn overfôring per konsesjon og fôrpris 14,15 kr/kg.

F.4 Gevinst i produksjonsledd | Svanøy | Underestimering

$$\frac{3\,000\,000\text{ kg}}{1\,300\,000\text{ kg}} * \left((137\,000\text{ kg} * 0,8 * 50,25\text{ kr/kg}) \right. \\ \left. - \left((145\,000\text{ kg} * 14,15\text{ kr/kg}) + (137\,000\text{ kg} * 3,79\text{ kr/kg}) \right) \right) \\ = 6\,776\,354\text{ kr} \approx 6,78\text{ millioner kroner}$$

*Antar 137 tonn vekstpotensial per konsesjon, 20 prosent sløyvesvinn, salgspris 50,25 kr/kg, fôrpris 14,15 kr/kg, ytterligere 145 tonn fôr per konsesjon og slaktekostnad 3,79 kr/kg.