

Handelshøgskolen Innlandet – Fakultet for
økonomi og samfunnsvitenskap

Kamilla Larsen

Masteroppgave

Kapasitetsbasert Revenue Management i alpinbransjen:
en sammenligning av tidsserieregresjon og nevrale nettverk

Digital ledelse og business analytics

2021

Sammendrag

Formålet med denne oppgaven var å vurdere to ulike prognosemodeller til å predikere etterspørselen etter dagskort, og å bruke disse prognosemodellene til å fastsette antall lavprisbilletter et alpinanlegg kan tilby.

Det har blitt brukt en tidsserieregresjonsmodell og en multi-layer perceptron modell til å estimere prognosene i to ulike prognosehorisonter. Både prognosehorisontene og modellen er vurdert etter to ulike nøyaktighetsmål for å vurdere hvilken kombinasjon av modellene og prognosehorisontene som gjorde det best.

Tidsserieregresjonsmodellen gjorde det generelt bedre enn MLP-modellen basert på disse to nøyaktighetsmålene. Likevel gjorde MLP-modellen det bedre basert på et nøyaktighetsmål i en av prognosehorisontene.

Begge modellene med begge prognosehorisontene ble brukt til å fastsette antall lavprisbilletter for tre forskjellige prisscenarioer. Det var tidsserieregresjonsmodellen som best klarte å utnytte seg av inntektsmuligheten, og det er tydelig at et alpinanlegg kan øke fortjenesten ved en implementering av et enkelt topris-system.

Abstract

The objective of this thesis was to evaluate two different forecasting models used in predicting demand for ski resort day tickets, and to use these models to determine the amount of low price tickets a ski resort should offer.

A time series regression model (TSR) and a neural network based multi-layer perceptron model has been used to estimate forecasting in two different forecasting horizons. Both the forecasting horizons and the TSR model was evaluated using two different accuracy measures to evaluate which combination of TSR models and forecasting horizons gives the most correct results.

The TSR model generally performed better than the MLP-model based on these two accuracy measures. In one single instance, the MLP-model did better based on a given accuracy measure in one of the forecasting horizons.

Both models, with both forecasting horizons was used to determine a set amount of low price tickets for three different price scenarios. The TSR model was better at utilizing the income opportunity, and it's clear that a ski resort could increase revenue by implementing a simple two price system.

Forord

Denne masteroppgaven har vært en utrolig spennende og lærerik prosess, og noe jeg ikke kunne vært foruten. Det har vært en ære å være en del av prosjektet Innovative Pricing Approach in Alpine Skiing Industry (iPaaSKi), som har som overordnet mål om å utvikle og implementere nye og innovative prisplaner i alpinbransjen (iPaaSKi, 2021). Denne oppgaven markerer slutten på fem lange, men ikke minst lærerike år ved Høgskolen i Østfold og Høgskolen i Innlandet.

Jeg vil gjerne rette en spesiell takk til min veileder, Erik Haugom, for utrolig god hjelp og godt engasjement under hele prosjektet mitt. I tillegg vil jeg takke min samboer og nærmeste familie for motivasjon og god støtte hele veien. Videre vil jeg takke alle som har bidratt tidligere i prosjektet, og lagt grunnlaget for denne masteroppgaven.

Innholdsfortegnelse

Sammendrag	2
Abstract	3
Forord	4
Figurer og tabeller	6
1. Innledning	7
1.1. Bakgrunn	7
1.2. Problemstilling	9
1.3. Valg av metode og forskningsdesign	9
1.4. Avgrensing	10
2. Teoretisk rammeverk	11
2.1. Etterspørsels- og pristeori	12
2.1.1. Prisresponsfunksjon	14
2.1.2. Tradisjonell og Dynamisk Pristilnærming	15
2.2. Revenue Management	16
2.3. Prognoser	18
2.3.1. Evaluering av prognosemodeller	20
3. Tidligere Forskning	21
3.1. Etterspørsel av dagskort	21
3.2. Dynamisk prising	21
4. Metode	22
4.1. Prognosemodeller	22
4.1.1. Tidsserieregresjon	23
4.1.2. Multi-layer perceptron (MLP)	23
4.2. Evaluering av prognoser	26
4.3. Evaluering av foreslått Revenue Management system	27
5. Data	29
6. Resultater	34
6.1. Tidsserieregresjon	34
6.2. Multi-layer perceptron	37
6.3. Booking limit	40
6.3.1. 2 dagers prognosehorisont	40
6.3.2. 7 dagers prognosehorisont	44
6.3.3. Evaluering av RM	48

7. Diskusjon	52
7.1 Prognosemodeller	52
7.2 Revenue Management	53
8. Konklusjon	56
8.1 Begrensninger og videre forskning.....	56
Litteraturliste	58
Vedlegg 1 - Gjennomsnittlig salg av dagskort fordelt på ukedag	61

Figurer og tabeller

Figur 1 - Prising med kapasitetsbegrensning. Adoptert fra Phillips (2005, s.102)	11
Figur 2 - Markedslikevekt, tilbudsoverskudd og etterspørselsoverskudd.....	12
Figur 3 - Prisresponsfunksjoner	14
Figur 4 – MLP med tre inputs og et skjult lag	24
Figur 5 - Konseptet med ROM. Adoptert fra Temath (2011, s.10).....	27
Figur 6 - Tidsserieplot med alle viktig variabler.....	31
Figur 7 - Observerte verdier VS predikerte verdier basert på tidsserieregresjonsmodellen	36
Figur 8 - Illustrasjon av vår MLP-modell	38
Figur 9 - Observerte verdier VS predikerte verdier basert på MLP-modellen.....	39
Figur 10 - Booking limit med tidsserieregresjonsmodell for 2 dagers prognosehorisont.....	41
Figur 11 - Booking limit med MLP-modell for 2 dagers prognosehorisont	43
Figur 12 - Booking limit med tidsserieregresjonsmodell for 7 dagers prognosehorisont.....	45
Figur 13 - Booking limit med MLP-modell for 7 dagers prognosehorisont	47
Figur 14 - Faktisk ROM for beste system av prisscenario 1 og prisscenario 3.....	54
Tabell 1 – Markedsformer. Adoptert fra Hoff (2000, s.136)	13
Tabell 2 - Ulike pristilnæringer.....	15
Tabell 3 - Prognose typer. Adoptert fra Render et al. (2015, s.168)	19
Tabell 4 - Beskrivelse av variabler.....	29
Tabell 5 - Deskriptiv Statistikk	32
Tabell 6 – Estimer av koeffisienter for tidsserieregresjonsmodellen	35
Tabell 7 - Nøyaktighetsmål for tidsserieregresjonsmodellen.....	37
Tabell 8 - Nøyaktighetsmål for MLP-modellen.....	39
Tabell 9 - Prisscenarioer.....	40
Tabell 10 - Oppsummering av booking limit med en prognosehorisont på 2 dager.....	44
Tabell 11 - Oppsummering av booking limits for en prognosehorisont på 7 dager.....	48
Tabell 12 - RO, ARO og PARO for hver prognosehorisont, modell og prisscenario.....	50

1. Innledning

1.1. Bakgrunn

I Norge er alpinanleggene en stor pådriver og skaper av Norges vinterturisme (Fnugg, 2017), og det finnes over 200 alpinanlegg og mer enn 650 skiheiser (Vanat, 2020). I sesongen 2018/19 var den totale omsetningen på ca. 1,3 milliarder norske kroner, men sett i forhold til sesongen før, var det en nedgang på 3 % (Norske alpinanlegg og fjelldestinasjoner, 2021). Sesongene til alpinanleggene er uforutsigbare, og varierer fra år til år. Sesongen 2017/18 er et godt eksempel på en god sesong, denne endte med en økning på 16% (Norske alpinanlegg og fjelldestinasjoner, 2021). Det finnes flere mulige forklaringer på at alpinanleggenes omsetning varierer, og det er naturlig å tenke seg at vær- og føreforhold kan være faktorer som forklarer en del av variasjonen. Klimautfordringene som alpinanleggene møter er en utfordring, høyere temperaturer og dårlige snøforhold kan føre til kortere sesonger (O'Brien, Aandahl, Orderud & Sæther, 2003). I en rapport gjennomført av Gildestad, Dannevig, Steiger og Aall (2017) vises det til at de neste 10 til 60 årene vil antall dager med nok snø til å stå på alpin uten snøproduksjon reduseres merkbart ved to ulike utslippsscenarioer. For å kunne opprettholde sesonger over 100 dager må alpinanleggene øke kapasiteten for kunstig snøproduksjon, både ved å produsere mer snø i løpet av sesongen og ved å øke fortjenesten til alpinanlegget (Gildestad et al., 2017).

Tidligere har etterspørselen stagnert og til og med hatt litt nedgang, men de siste årene har det vært en økende trend (Vanat, 2020). I følge Steiger, Posch, Tappeiner og Walde (2020) er snøforhold den viktigste grunnen for hvilken destinasjon som blir valgt. Likevel kan pris og god plass i løypene kompensere for dårlige snøforhold. For det meste bruker alpinanleggene i Norge nesten like priser gjennom sesongen, men med noe prisdifferensiering for enkelte kundegrupper og kort-typer (Malasevska, 2018). Blant noen av de største alpinanleggene i Norge differensieres heiskortprisene hovedsakelig på alder, men det finnes også rabattordninger for flere dager og sesongkort (Hafjell, 2020; Norefjell, 2020; SkiGeilo, 2020). Enkelte alpinanlegg differensierer også på ordinær sesong og høysesong, hvor høysesong som regel er juleferien, vinterferien og påskeferien (Hafjell, 2020; SkiGeilo, 2020). Men selv om alpinanleggene i Norge prisdifferensierer noe på heiskort i dag, er det i svært begrenset grad, og det er mye mer å gå på. Selv til noe prisdifferensiering så er prisenivået på heiskort for høyt. Det vises en studie gjennomført av Holmengen (2012) i fem alpinanlegg i innlandet, hvor befolkningen synes at prisenivå på heiskort generelt er for høyt. I Hafjell svarer 99,6% av respondentene at prisenivå ikke er akseptabelt, og 77,4% mener det i stor grad påvirker respondentens valg av reisemål.

Alpinanleggene merker en utfordring med uforutsigbare sesonger og må gjøre tiltak for å kunne håndtere utfordringene. I følge Norske alpinanlegg og fjelldestinasjoner (2021) har det blitt planlagt investeringer til snøproduksjon på 150 millioner kroner, som nesten er det dobbelte av hva som ble brukt sesongen før, 2018/19. Dette endrer kostnadsbildet for alpinanleggene, og kan medføre at enkelte alpinanlegg ser på en prisøkning som eneste mulighet for å overleve. Men, som Holmengen (2012) påpeker; prisene på heiskort er allerede over akseptabelt nivå og en ytterligere prisøkning kan medføre at økte inntekter som følge av høyere priser spises opp av reduserte inntekter som følge av lavere etterspørsel. Alpinanlegg i Norge, og verden for øvrig, bør derfor vurdere nye måter å bruke pris på for å forme etterspørselen etter heiskort. Dette kan gjøres ved å for eksempel sette ned prisen når det er ledig kapasitet og eventuelt øke prisen på dager hvor presset på bakker og heiser blir for stort, såkalt dynamisk prising. Enkelte alpinanlegg i USA og Europa har allerede begynt med en dynamisk pristilnærming (Vanat, 2020). En slik pristilnærming kan gjøre at alpinanleggene får utnyttet kapasiteten bedre, som igjen kan føre til en jevnere etterspørsel og høyere inntekter (Berman, 2005). I flere andre serviceindustrier brukes allerede en mer dynamisk tilnærming til prising (Hinterhuber & Liozu, 2014), og blant noen av dem finner vi selskaper innen turisme (hoteller, flyselskaper) og fritidstjenester (restauranter og sportsklubber). I følge Skugge (2004) kan en vellykket implementering av en slik strategi øke inntektene med 3%-7%.

Fra tidligere forskning vet vi at vær og ukedag er to forhold som har sterk effekt på daglige besøk i alpinanlegg (Haugom & Malasevska, 2019; Malasevska, Haugom & Lien, 2017). En mulig tilnærming til å forme etterspørsel etter heiskort er derfor å lage prognosemodeller for ulike horisonter frem i tid som tar hensyn til disse forholdene. Disse prognosene kan så brukes til å prise heiskortene dynamisk eller fastsette hvor mange billetter som skal selges til rabattert pris. Dette er utgangspunktet for min masteroppgave. Jeg ønsker med andre ord å (1), foreslå en prognosemodell som kan benyttes til å predikere fremtidig etterspørsel etter dagskort i et alpinanlegg, for ulike tidshorisonter og (2), vise hvordan modellen kan benytte en to-pristilnærming (høy/lav) for å fastsette antall lavprisbilletter som skal tilbys under gitte forutsetninger. Rammeverket som utvikles i denne oppgaven vil kunne benyttes av alpinanlegg som er interessert i å implementere en mer dynamisk tilnærming til prising.

1.2 Problemstilling

Basert på denne bakgrunnen ønsker jeg å svare på følgende problemstilling i denne oppgaven:

«Hvordan kan norske alpinanlegg øke inntjening fra salg av dagskort ved bruk av prognoseteknikker i kombinasjon med dynamisk prising?»

De viktigste bidragene jeg kommer med i denne oppgaven er en analyse av:

(1) Hvordan heiskortteterspørselen i et bestemt norsk alpinanlegg kan modelleres og prognostiseres ved hjelp av en rekke kjennetegn ved skidagen. I denne delen av oppgaven vil jeg undersøke i hvilken grad avanserte teknikker bidrar til mer nøyaktige prognoser av heiskortteterspørselen.

(2) Hvordan slike prognoser kan brukes for å fastsette optimalt antall tilgjengelige lavprisbilletter i en sektor hvor dette ikke er gjort tidligere, nemlig alpinsektoren.

Analysene, resultatene, og selve rammeverket som benyttes i oppgaven vil kunne ha store implikasjoner for ledere i alpinanlegg i Norge og verden for øvrig. Jeg vil drøfte disse mot slutten av oppgaven.

1.3 Valg av metode og forskningsdesign

For å besvare problemstilling som er oppgitt i forrige delkapittel skal jeg bruke en kombinasjon av to datasett. Ett datasett fra et alpinanlegg, og ett datasett med værvariabler. Jeg vil utdype mer om datasettene i kapittel 5. Disse datasettene skal brukes til å lage to ulike prognosemodeller; en prognosemodell basert på regresjonsanalyse og en maskinlærings prognosemodell. Begge modellene havner naturligvis i hovedkategorien *kvantitativ metode* (Creswell & Creswell, 2018). Det er også mulig å forme prognoser basert på kvalitative metoder, for eksempel ved intervjuer av eksperter om deres forventninger av fremtidig etterspørsel. Dersom målet er å utvikle et automatisert system som skal foreslå konkrete handlinger (som for eksempel antall lavprisbilletter som bør tilbys neste uke), blir en kvalitativ tilnærming imidlertid lite effektivt.

Jeg har fått tilgang til historiske etterspørselsdata og kombinerer disse med værdata som jeg selv har hentet fra Meteorologisk institutt. Dette datasettet benytter jeg til å estimere prognosemodellene som skal predikere etterspørsel av heiskort.

I kvantitativ metode finnes flere forskjellige typer forskningsdesign, og valg av forskningsdesign gir en spesifikk retning for prosedyrer i forskningsstudiet (Creswell & Creswell, 2018). For kvantitativ metode deles det hovedsakelig inn i to typer forskningsdesign; eksperimentelle og ikke-eksperimentelle. I et eksperimentelt design så prøver en å avgjøre om en spesifikk behandling påvirker resultatet, mens i et ikke-eksperimentelt design er det ingen manipulasjon av den avhengige variabelen (Creswell & Creswell, 2018; Khaldi, 2017). Det gjør at denne oppgaven er av et ikke-eksperimentell forskningsdesign basert på sekundærdata.

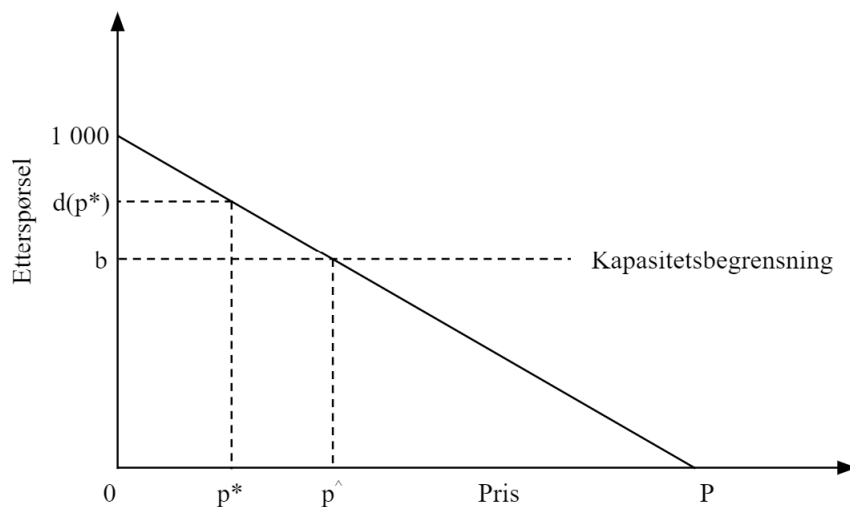
1.4 Avgrensing

Denne oppgaven bygger mye på tidligere forskning som også setter rammer for oppgaven. I denne oppgaven bruker jeg data fra Beitostølen skisenter - et Norsk alpinanlegg lokalisert i Innlandet. Målt i omsetning er Beitostølen skisenter på 15. plass i en oversikt over de største Norske alpinanlegg (Norske alpinanlegg og fjelldestinasjoner, 2021). Analysene som vil gjennomføres vil derfor ikke nødvendigvis kunne generaliseres til å gjelde alle norske alpinanlegg, selv om rammeverket som presenteres vil kunne adopteres av andre.

Videre vil jeg kun analysere etterspørselen etter dagskort for *voksne*. Følgelig vil jeg ikke kunne si noe om hvilke resultater mine analyser har for andre kundegrupper (for eksempel barn- eller honnør) eller andre korttyper (timeskort, flerdagskort eller sesongkort). Disse har selvsagt en betydning for alpinanlegget, men de har igjen ulike karakteristikk som må tas hensyn til i egne analyser. Heretter vil heiskort bli kalt for dagskort.

2. Teoretisk rammeverk

Serviceleverandører har stort sett alltid kapasitetsbegrensning de må forholde seg til. Dette gjelder også for alpinanlegg: antall løyper og heiser ligger fast. Riktignok er det slik at man kan velge å kun preparere noen løyper og la enkelte heiser stå stille på rolige dager, men den maksimale kapasiteten ligger helt fast, i alle fall innad i sesongen. I tilfeller hvor serviceleverandøren står overfor en kapasitetsbegrensning, kan pris benyttes som virkemiddel for å øke inntjening. En illustrasjon av et prisingsproblem med en kapasitetsbegrensning er illustrert i Figur 1 under.



Figur 1 - Prising med kapasitetsbegrensning. Adoptert fra Phillips (2005, s.102)


Av figuren er det verdt å merke seg at den optimale prisen avhenger av formen på etterspørselsfunksjonen i tillegg til kapasitetsbegrensningen. Det er med andre ord avgjørende at alpinanlegget har god kjennskap til hvordan etterspørselen varierer over tid når de skal prise dagskort.

Jeg vil derfor i neste del ta for meg hvordan etterspørselen formes generelt og hva som kan skape variasjon i etterspørselen etter dagskort i alpinbakker spesielt. Videre vil jeg presentere et teoretisk rammeverk for hvordan et alpinanlegg kan tilby to prisnivåer for å allokere etterspørselen for å bedre utnytte eksisterende kapasitet. Dette fagområdet heter revenue management (RM) i litteraturen, og i mangel av et godt norsk ord vil jeg videre benytte dette uttrykket.

2.1 Etterspørsels- og pristeori

Etterspørsel og pris er en av markedets grunnleggende egenskaper (Riis & Moen, 2017), og er de første byggesteinene til oppgavens teoretiske rammeverk. Etterspørsel og pris henger tett sammen, og påvirker hverandre i større eller mindre grad.

I Figur 2 ser vi sammenhengen mellom tilbud, etterspørsel og markedets likevekt i et marked med fullkommen konkurranse. Etterspørselen er langs den vertikale aksene, mens pris er langs den horisontale aksene. Den fallende kurven representerer etterspørselen, og illustrerer at etterspørsel synker med en økende pris. Den stigende kurven representerer tilbudet, og er stigende med en økende pris. Krysningspunktet til tilbudskurven og etterspørselskurven kalles markedets likevekt, og det er når etterspørsel og tilbudet er likt til en gitt pris (X^* , P^*). Sannsynligheten er lav for at tilbud og etterspørsel er lik, og hvis prisen enten er høyere eller lavere en markedsliekevt-prisen oppstår det enten etterspørsels- eller tilbudsoverskudd.



Figur 2 - Markedsliekevt, tilbudsoverskudd og etterspørselsoverskudd

I en situasjon hvor prisen er lavere enn markedsliekevt-prisen, fra P^* til P_1 , blir det etterspørselsoverskudd og det vil si at det er flere kjøpere enn tilbydere. I motsatt situasjon hvor prisen øker fra markedsliekevt-prisen, P^* til P_2 , blir et tilbudsoverskudd og det vil si at det er flere tilbydere enn det er kjøpere.

I Figur 2 er det som tidligere skrevet et marked med fullkommen konkurranse, og et slikt marked består av mange små tilbydere, hvor varene er like og ingen av tilbyderne har noen innflytelse over markedsprisen (Winther, Ottesen, Øyen & Hæhre, 2013). Hvis en tilbyder i et slikt marked setter prisen høyere enn markedsprisen vil denne tilbyderen miste alle kundene. Fullkommen konkurranse, sammen med monopol, er ytterpunktene i de ulike markedsfornene

en virksomhet kan ha. Som oftest har virksomheter en markedsform som ligger imellom disse. Tabell 1 viser en oversikt over de vanligste markedsformene.

		Antall virksomheter		
		1	Få store	Mange små
Standardvare	Homogent marked	Monopol	Oligopol	Fullkommen konkurranse
Merkevarer	Heterogent marked		Differensiert oligopol	Monopolistisk konkurranse

Tabell 1 – Markedsformer. Adoptert fra Hoff (2000, s.136)


I oligopol er det noen få store tilbydere som dominerer markedet (Winther et al., 2013), og en prisendring her vil ofte ha liten effekten siden konkurrentene ofte følger tett på. Som nevnt tidligere finnes det over 200 alpinanlegg i Norge (Vanat, 2020), og det er enkelte alpinanlegg som er betydelig større enn de fleste alpinanlegg (Norske alpinanlegg og fjelldestinasjoner, 2021). Likevel vil et alpinanlegg kunne redusere prisen på sine dagskort uten at det fører til at andre alpinanlegg gjør det samme, og det mye på grunn av at det er store avstander mellom alpinanleggene.

Hvis det er et marked med bare er en tilbyder, har denne tilbyderen monopol. I et slikt marked kan tilbyderen bestemme prisen uten å miste alle kundene (Riis & Moen, 2017). Hvordan markedet avgrenses er det store spørsmålet. En tilbyder kan ha monopol i sitt lokale område eller region, mens tilbyderen på landsbasis ikke har monopol. På en måte kan et alpinanlegg ha monopol i sitt område fordi det ofte er langt mellom alpinanleggene, men i et større bilde kan alpinanleggene sin markedsform ligne mer på monopolistisk konkurranse.

I monopolistisk konkurranse er det mange små tilbydere som tilbyr et produkt som dekker omtrent samme behovet hos kjøperen (Winther et al., 2013). Likevel har produktene sine individuelle særpreg. For alpinbransjen kan slike særpreg for eksempel være antall bakker, antall heiser og andre fasiliteter som snowboardpark. Uansett om vi definerer markedsformen til alpinsektoren som monopol, oligopol, eller monopolistisk konkurranse, vil det enkelte alpinanlegg ha mulighet til å bruke pris som virkemiddel for å påvirke fortjenesten. Dette henger sammen med formen på etterspørselsfunksjonen alpinanlegget står ovenfor, noe jeg utdypet nærmere i neste delkapittel.

2.1.1 Prisresponsfunksjon

Et grunnleggende element innen inntekt- og prisoptimering er *prisresponsfunksjon*. Prisresponsfunksjonen spesifiserer etterspørselen etter et produkt for en enkelt selger som en funksjon av prisen denne selgeren tilbyr (Phillips, 2005). En prisresponsfunksjon minner om etterspørselskurven, men det er et viktig skille på disse. En etterspørselskurve tar for seg hvordan et helt marked vil respondere på en endring i pris, men i det samme markedet møter den enkelte virksomhet en egen prisresponsfunksjon og denne varierer fra virksomhet til virksomhet (Phillips, 2005). Det er ulike faktorer som gjør at formen på virksomheters prisresponsfunksjoner kan være forskjellige selv om de opererer i samme marked. Det kan for eksempel være kundens opplevde kvalitet av produktet eller tjenesten, markedsføringskampanjer, reelle forskjeller i produktet eller tjenesten og plassering.



Figur 3 - Prisresponsfunksjoner

Illustrasjonen til venstre i Figur 3 viser en prisresponsfunksjon for en enkelt selger i et marked med fullkommen konkurranse. Her ser vi en vertikal linje på markedsprisen som vil si at hvis selgeren prøver å selge over denne prisen forsvinner alle kundene til andre tilbydere, men hvis selgeren selger til en pris under markedspris vil selgeren få en etterspørsel som er lik hele markedets etterspørsel. I et slikt marked, hvor konkurransen er perfekt, vil det ikke være noe behov for inntekts- og prisoptimering, men de fleste virksomheter møter en prisresponsfunksjon som har fallende etterspørsel med en økning i pris (Figuren til høyre i Figur 3).

Etterspørselen blir påvirket av utallige beslutninger som kunder tar. På et øyeblikk kan kunden bestemme seg for å kjøpe produktet eller tjenesten basert på den prisen de ser. En prisresponsfunksjon spesifiserer hvor mange potensielle kunder virksomheten kan oppnå ved å senke prisen, og hvor mange nåværende kunder de kan miste ved å øke prisen (Phillips, 2005). For et alpinanlegg vil prisresponsfunksjoner kunne variere i form for hver eneste skidag. Det er

ulike faktorer som gjør at disse er forskjellige. Fra tidligere forskning (se kapittel 3.1) er det gjort funn på at vær, ukedag og ferier har en betydelig effekt på formen på prisresponsfunksjonen for dagskort i alpinanlegget. I et tilfelle med dårlig vær og på en ukedag (mandag-torsdag) er alpinister generelt mye mer prissensitive enn ved fint vær og når skikjøringen skjer på en helgedag (fredag-søndag).

Prisresponsfunksjoner er basert på kundeadferd, og kundeadferd i slike modeller baserer seg på kundens betalingsvillighet (Phillips, 2005). Kundens betalingsvillighet beskriver den maksimale prisen kunden er villig til å betale for et produkt eller en tjeneste, og kunden vil kun kjøpe hvis prisen er lavere eller lik sin betalingsvillighet. Et eksempel, er at en kunde skal kjøpe dagskort og har en betalingsvillighet på 390kr. Hvis dagskortet koster 391 kroner vil ikke kunden kjøpe det. Da kan kunden enten gå til konkurrentene eller bestemme seg for å ikke kjøpe i hele tatt. Betalingsvilligheten endrer seg i takt med en endring i kundens preferanser og omgivelsene rundt.

2.1.2 Tradisjonell og Dynamisk Pristilnærming

Tradisjonelt i inntekt- og prisoptimering er enten kostnader, kundeetterspørsel eller konkurrenter utgangspunktet for prissetting som skal maksimere forventet overskudd (Phillips, 2005). I ulike tilnærminger i inntekt- og prisoptimering vektlegges det en av disse forholdene mer enn den andre. Tabell 2 gir en enkel fremstilling av de ulike pristilnærmingerne.

Tilnærming	Basert på	Ignorerer
Kostnadsbasert	Kostnader	Konkurrenter og kunder
Markedsbasert	Konkurrenter	Kostnader og kunder
Verdibasert	Kunder	Kostnader og konkurrenter

Tabell 2 - Ulike pristilnærminger

Kostnadsbasert prissetting er en av de eldste strategiene for prising, og er den dag i dag fortsatt mye brukt. I denne strategien beregnes først kostnadene, før det legges til et prosentvis påslag som utgjør prisen på produktet eller tjenesten. I markedsbasert prissetting priser man seg etter konkurrentene sine priser og hvordan en ønsker å posisjonere seg i forhold til konkurrentene sine priser. En slik strategi er ofte brukt av mindre virksomheter hvor det finnes en tydelig markedsleder. Verdibasert prissetting priser produktet eller tjenesten basert på estimer av hva

kundene verdsetter produktet eller tjenesten til. Det vil si at driveren til denne pristilnærmingen er kundenes verdi, og siden kundene kan verdsette produktet eller tjenesten forskjellig, vil prisen variere fra kunde til kunde. For å finne ut hvordan kundene verdsetter produktet eller tjenesten brukes det blant annet conjoint analyser, spørreundersøkelser og fokusgrupper for å se hvordan kunden foretrekker et alternativ fremfor et annet. Disse tre pristilnærmingene er det man kaller «purist», men i virkeligheten har de fleste virksomheter en eller annen kombinasjon av disse (Phillips, 2005).

I grove trekk kan vi si at i en dynamisk pristilnærming endrer prisingen seg over tid (Bodea & Ferguson, 2014). I en slik tilnærming handler det om å tilpasse seg etter kundens betalingsvillighet, og prising kan baseres på ulike faktorer. I alpinsektoren er det aktuelt å prise basert på vær, ukedag og høytid. En kombinasjon av dårlig vær og ukedag fører til at kundene har lavere betalingsvillighet, og i et slikt tilfelle vil det da være lurt å sette ned prisen for å opprettholde etterspørselen. I motsatt tilfelle, med fint vær og helg kan en prisøkning være det som maksimerer fortjenesten. I neste delkapittel tar jeg for meg en mulig enkel prisstilnærming som kan passe godt for alpinbransjen; et to-pris system hvor det kun er aktuelt å tilby to prisnivåer for hver skidag.

2.2 Revenue Management

Det finnes mange metoder og pristilnærminger en virksomhet kan velge når målet er å maksimere inntektene. Alpinbransjen har i likhet med mange andre service virksomheter noen kjennetegn som gjør at den egner seg spesielt godt til å ta i bruk en mer dynamisk tilnærming til prissetting; en relativt fast kapasitet, lave marginale kostnader (sammenlignet med marginale inntekter og faste kostnader), et marked som kan bli segmentert, samt billetter (her: dagskort) som kan reserveres på forhånd (Berman, 2005). Dette åpner for bruk av såkalt revenue management (RM), som handler om å maksimere inntektene ved å fordele kapasiteten til ulike billettklasser over tid (Phillips, 2005). En slik pristilnærming er designet for å sørge for at riktig antall billetter er solgt til riktige kunder til riktig pris, riktig sted og riktig tid (Kimes & Wirtz, 2003; Queenan, Ferguson & Stratman, 2011).

I alpinbransjen, i likhet med hotell- og flybransjen, går kapasiteten «ut på dato». Det vil si at de dagskortene som ikke blir solgt en dag, ikke kan bli solgt igjen den neste dagen. I stedet for å la de usolgte dagskortene forbli usolgte, kan vi heller selge disse til en lavere pris. Dette gjør at alpinanlegget kan utnytte kapasiteten bedre, som igjen vil medføre økt etterspørsel og høyere

inntekter. Den store utfordringer i en slik tilnærming er hvor mange rabatterte dagskort alpinanlegget skal selge når det er mulighet for at fremtidige kunder er villig til å kjøpe for fullpris (Bodea & Ferguson, 2014). Kunder med lavere betalingsvillighet har en større sannsynlighet for å kjøpe billetter i forkant, siden disse kundene bryr seg mer om pris. Kunder med høyere betalingsvillighet bryr seg sannsynligvis mindre om pris, og har dermed større sannsynlighet for å kjøpe dagskort kortere tid i forkant, eller samme dag som dagskortet skal brukes. Det er her vi kommer inn på begrepene *booking limit* og *protection level*.

Booking limit (BL) bestemmer hvor mange dagskort alpinanlegget vil selge til rabattert pris, mens protection level (PL) er antall dagskort som vi beskytter til kunder som er villig til å betale «fullpris» på den aktuelle dagen (Bodea & Ferguson, 2014). Protection level blir bestemt ut ifra makskapasiteten til alpinanlegget og trekker i fra booking limit: $PL = C - BL$, hvor C er maks kapasitet.

Det er mulig å ha flere billettclasser, men i denne oppgaven ser jeg kun på to billettclasser; en lavprisklasse, og en høyprisklasse. Dagskortene som er til en rabattert pris er lavprisklassen (r_L), mens dagskortene som blir solgt til full pris er høyprisklassen (r_H). Den usikre etterspørsel for kundene med høy betalingsvillighet beskrives som D_H , og det er denne etterspørselen jeg estimerer prognoser på senere i oppgaven.

Hvis et alpinanlegg setter booking limiten for lav og beskytter for mange dagskort ($D_H < PL$), ender alpinanlegget med å ikke få solgt alle dagskortene de har beskyttet. I et slikt tilfelle er det viktig å fange opp marginalkostnaden ved å reservere et dagskort for mye. Dette er beskrevet som overage penalty (C_o) og er lik alternativkostnaden for å ikke selge et dagskort til rabattert pris: r_L . I motsatt tilfelle, hvor alpinanlegget setter booking limiten for høy ($D_H > PL$) får vi underage penalty (C_u) som er lik alternativkostnaden for ikke å få solgt dagskortet til full pris: $r_H - r_L$. Optimal booking limit er gitt ved følgende formel (Phillips, 2005):

$$BL^* = C - \delta_H \Phi^{-1}\left(1 - \frac{r_L}{r_H}\right) - \mu_H$$

Ligning 1

Hvor $\Phi^{-1}\left(1 - \frac{r_L}{r_H}\right)$ er den inverse kumulative normalfordelingsfunksjonen til $1 - \frac{r_L}{r_H}$, videre er μ_H og δ_H forventet fullprissetterspørsel og standardavviket til denne. $\Phi^{-1}\left(1 - \frac{r_L}{r_H}\right)$ er en avtagende funksjon av prisforholdet ($\frac{r_L}{r_H}$), som gjør at den optimale booking limit (BL*) er en økende funksjon av prisforholdet. En viktig faktor er at hvis prisforholdet er $\frac{1}{2}$ er $\Phi^{-1}\left(\frac{1}{2}\right) = 0$,

vil det si at den optimale protection level er lik forventet etterspørsel av kunder med høy betalingsvillighet. Hvis $\frac{r_L}{r_H} < \frac{1}{2}$ er det optimalt å beskytte flere dagskort til etterspørselen av kunder med høy betalingsvillighet enn det vi forventer å få, eller hvis $\frac{r_L}{r_H} > \frac{1}{2}$ er det optimalt å beskytte færre dagskort enn forventet etterspørsel av kunder med høy betalingsvillighet. Det vil si at prisforholdet indikerer om vi beskytter flere eller færre enn hva vi forventer at fullprissetterspørselen vil være.

2.3 Prognoser

For alle virksomheter kan verktøy som prøver å forutsi fremtidige verdier av sentrale variabler hjelpe beslutningstakere med å fatte bedre beslutninger. Prognosemodeller prøver å forutsi fremtiden basert på historiske data. Hvis det ikke finnes noen historiske data, brukes ofte eksperter til å forme prognoser på sine vurderinger av situasjonen (Bodea & Ferguson, 2014). For alpinbransjen er det å forutsi hvor mange dagskort som blir solgt i en fremtidig periode et steg på veien til å sette av riktig antall billetter som skal selges til redusert pris de dagene før aktiviteten skal finne sted. I denne oppgaven er prognosemodellene selve grunnlaget for fastsettelse av booking limiten i et topri-system.

Det finnes i all hovedsak tre typer hovedkategorier innen prognosemodeller (Render, Stair jr., Hanna & Hale, 2015). Tabell 3 viser en oversikt over type prognosemodeller, og et eksempel på ulike metoder de bruker. I korte trekk baserer *kvalitative* modeller seg på subjektive faktorer og dømmekraft, og bruker blant annet eksperters meninger og individuelle erfaring i modellene sine. Slike modeller brukes blant annet når det skal lanseres nye produkter eller tjenester og det ikke finnes historiske data. I *tidsseriemetoder* predikerer en fremtidige verdier basert på historiske data av akkurat den variabelen. Hvis vi skulle benytte en slik metode til å predikere etterspørsel for dagskort så vil vi kun bruke historiske data på etterspørsel av dagskort, og ikke ta hensyn til andre variabler som kanskje påvirker etterspørselen. *Kausale* metoder er veldig likt tidsseriemetoder. Her predikerer en fremtidige verdier sammen med historiske data på den variabelen og inkluderer variabler som kan påvirke etterspørselen i modellen.

Type prognosemodeller		
Kvalitative modeller	Tidsseriemetoder	Kausale metoder
Delphi metoden	Glidende gjennomsnitt	Regresjonsanalyse
Scenario metoden	Ekspontiell glatting	Multipel regresjon

Tabell 3 - Prognose typer. Adoptert fra Render et al. (2015, s.168)

En tidsserie er en rekke av verdier som er registrert med påfølgende tidsintervaller, og slike tidsintervaller kan eksempelvis være årlig, månedlig eller daglig (Render et al., 2015). Det finnes fire komponenter som en tidsserie kan bestå av: trend, sesong, syklus og tilfeldighet (Render et al., 2015). Trend-komponenten handler at en tidsserie har en generell stigning eller nedstigning over en lang periode, og kan eksempelvis være at antall besøkende hos et alpinanlegg øker fra år til år. Det vil si at det er en positiv trend, men det kan også være det motsatte, altså en negativ trend. Sesong-komponenten viser til tidsserier som har regelmessig gjentagende svingninger av verdier over og under gjennomsnittsverdien. Dette kan for eksempel være når det er få besøkende hos et alpinanlegg i starten av sesongen, med mange besøkende midt i sesongen, og lite besøkende mot slutten av sesongen, og dette gjentar seg sesong etter sesong. Den tredje komponenten er en syklus som viser til om en tidsserie har et årlig mønster som repeterer seg selv over flere år. For eksempel, år 1-3 er det en økende trend med besøkende hos et alpinanlegg, år 4-6 er det en avtagende trend med antall besøkende hos alpinanlegget, og deretter begynner en økende trend de neste tre årene og deretter en avtagende trend igjen. Dette er et eksempel på en tidsserie som har en syklus. Den siste komponenten tar for seg uforutsigbare og uregelmessige variasjoner, og kalles bare for tilfeldighet. Her faller alt som ikke kan klassifiseres under de andre komponentene. Hvilke komponenter tidsserien består av er viktig å ta for seg da dette er viktig for valg av modell.

Tidsseriemodeller og kausale modeller er begge av typen statistiske metoder (Sanders, 2017), men det er ikke de eneste typene metoder som finnes. Det finnes også maskinlæringsmetoder som har mer avanserte prognosemodeller. Både de statistiske metodene og maskinlæringsmetodene har mål om å minimere kostnadsfunksjonen, forskjellen ligger i at maskinlæringsmetoden bruker ikke-lineære algoritmer til å minimere, mens statistiske metoder bruker lineære prosesser (Makridakis, Spiliotis & Assimakopoulos, 2018b). I kapittel 4 utdyper jeg mer om prognosemodellene jeg skal bruke i denne oppgaven.

2.3.1 Evaluering av prognosemodeller

Til å evaluere prognosemodeller bruker vi ulike nøyaktighetsmål. Nøyaktighetsmålene reflekterer hvor god en prognosemodell er til å predikere variabelen vi er interessert i, og brukes både til å velge den modellen som gir best prognosenøyaktighet og til å indikere når en etablert modell trenger å bli omdefinert eller byttet ut (Hyndman & Athanasopoulos, 2018).

Nøyaktighetsmålene kan deles inn to kategorier: standardfeil og relative feil (Sanders, 2017). Standardfeil er avhengig av at prognosemodellene som sammenlignes har samme måleenhet. For eksempel kan vi ikke sammenligne en prognosemodell som predikerer etterspørselen etter dagskort med en prognosemodell som predikerer salg av biler. Relative feil er ikke avhengig av å ha samme måleenhet mellom prognosemodellene. Det er fordi disse typene nøyaktighetsmål er basert på prosent. I denne oppgaven skal jeg bruke et nøyaktighetsmål fra hver kategori, og jeg går nærmere inn på dette i neste kapittel.

3. Tidligere Forskning

3.1 Etterspørsel av dagskort

Det har blitt gjort flere tidligere studier som omhandler modellering av etterspørsel i alpinbransjen og metoder for prising av dagskort. Enkelte studier har funnet at det er en positiv sammenheng mellom etterspørsel og snødybde. Blant annet at lavere snødybde fører til lavere inntekter, og etterspørsel er spesielt sensitiv til lav snødybde i tidlig sesong (Falk & Hagsten, 2016; Falk & Vieru, 2017). Snødybde er ikke det eneste som er funnet som påvirker etterspørselen, men vær, ukedag og høytid har også en signifikant effekt (Malasevska & Haugom, 2019; Malasevska et al., 2017). Det vil si at vær og ukedag er noe som må tas høyde for når etterspørselen modelleres.

3.2 Dynamisk prising

En dynamisk pristilnærming er en måte man kan forme etterspørsel. Falk og Vieru (2017) viser til fleksibel prising som en løsning på å opprettholde etterspørselen ved å gi rabatter på dagskort ved dårlige snøforhold og sette høyere pris på dagskort når etterspørsel er høy. Ved bruk av dynamisk prising i situasjoner som dårlig snødybde kan dette føre til høyere kundetilfredshet og da større mulighet for at besøkende kommer tilbake (Haugom & Malasevska, 2019). Malasevska, Haugom, Hinterhuber, Lien og Mydland (2020) har gjennomført en studie på dynamisk prising av dagskort hvor de finner at det induserer større etterspørsel og kan øke inntektene med 0,5% til 7,5%.

4. Metode

Det finnes utallige ulike prognosemodeller og variasjoner av slike modeller, og det er ikke lett å vite hvilken prognosemodell som er riktig å bruke for sitt mål. Det har blitt gjort flere studier som bruker statistiske modeller, maskinlæringsmodeller og studier som sammenligner disse metodene. Hva som er brukt og forsket på tidligere er viktig å legge til grunn for å kunne velge best mulig prognosemodell. Tidligere har det funnet ut at det ikke nødvendigvis er de mest komplekse modellene som gir mest nøyaktige prognoser, og at de enkle prognosemodellene kan gi vel så nøyaktige prognoser (Makridakis & Hibon, 2000). I senere tid er det gjort et funn som viser at hybride modeller mellom statistiske- og maskinlæringsmetoder gir mer nøyaktige prognoser enn rene statistiske metoder eller maskinlæringsmetoder (Makridakis, Spiliotis & Assimakopoulos, 2018a).

I et studie av Ahmed, Atiya, Gayar og El-Shishiny (2010) sammenlignes åtte ulike maskinlæringsmodeller for tidsserieprognoser, her viser funnene at en nevralt nettverksmodell kalt Multi-Layer Perceptron (MLP) er den maskinlæringsmodellen som gjør det best. I et annet studie med ti ulike maskinlæringsmodeller er MLP også en av de beste, men likevel gjør maskinlæringsmodellene det dårligere enn de beste statistiske modellene (Makridakis et al., 2018b). Makridakis et al. (2018b) mener grunnen til at maskinlæringsmodellene gjør det dårligere enn de statistiske modellene, kan være på grunn av datasettet de brukte.

Jeg vil i denne oppgaven sammenligne prestasjonen til to prognoseteknikker: (1), en tidsserieregresjon og (2), en såkalt Multi-layer perceptron (MLP). I dette kapitlet vil jeg beskrive nærmere hvordan disse to metodene fungerer og samtidig presentere ulike mål som vil bli benyttet for evaluering av prognosens nøyaktighet.

4.1 Prognosemodeller

Det har vært viktig å ha to modeller som kan sammenlignes på relativt likt grunnlag, og da spesielt kunne ha et likt sett med variabler i prognosemodellene. Regresjonsanalyse er en av de mest brukte teknikkene, og kan både brukes til å predikere utfall og forklare sammenheng mellom den avhengige variabelen og de uavhengige variablene (Hair Jr., Black, Babin & Anderson, 2019). En slik modell (hvertfall i denne oppgaven) kan inneholde like mange variabler som en nevralt nettverksmodell, og gjør grunnlaget relativt likt når modellene skal

sammenlignes. Den modellen regresjonsanalysen skal sammenlignes opp mot er en maskinlæringsmodell, og her av typen nevrale nettverk. Det finnes mange forskjellige typer av nevrale nettverk, men til tidsserieprognoser var det MLP som gjør det best av maskinlæringsmodellene (Ahmed et al., 2010; Makridakis et al., 2018b).

4.1.1 Tidsserieregresjon

En tidsserieregresjon kan benyttes når dataene som brukes i analysen er samlet over tid, som i datasettet jeg skal bruke hvor jeg har observasjoner for hver dag alpinanlegget er åpent. Når det er en tidsserieregresjon med to eller flere uavhengige variabler kalles det en multippel regresjonsmodell, og er gitt ved følgende formel (Hyndman & Athanasopoulos, 2018):

$$y_t = \beta_0 + \beta_1 x_{1,t} + \beta_2 x_{2,t} + \dots + \beta_k x_{k,t} + \varepsilon_t$$

Ligning 2

Hvor y er den avhengige variabelen og er den variabelen som skal predikeres. x_1, \dots, x_k er de uavhengige variablene, og β_0, \dots, β_k måler den marginale effekten til de uavhengige variablene. ε_t er et feilledd som beskriver avviket mellom observasjonene og «den rette linjen», og fanger opp andre ting som kan påvirke den avhengige variabelen utenom de uavhengige variablene.

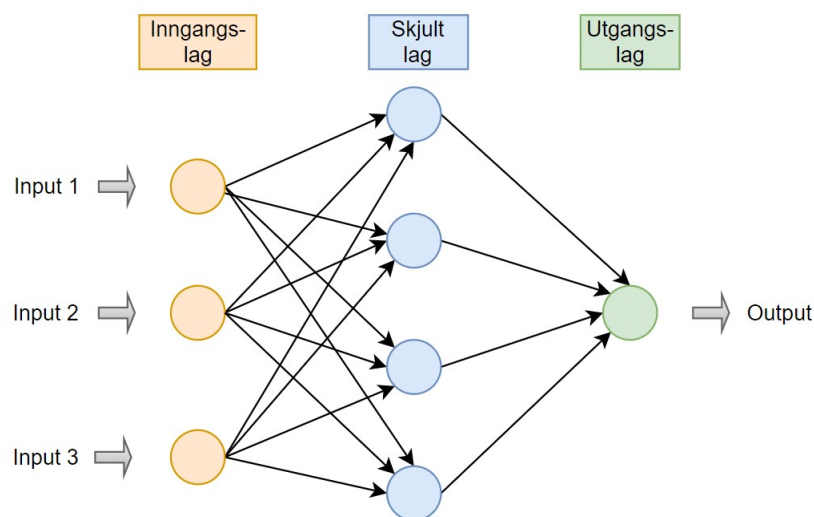
I en slik regresjonsanalyse er det visse forutsetninger som må være oppfylt for at resultatene fra modellen skal være gyldige (1), det antas at modellen er en rimelig tilnærming til virkeligheten, og (2), videre antas det at feilleddet ($\varepsilon_1, \dots, \varepsilon_t$) har et gjennomsnitt lik null, at de er ikke autokorrelerte og at de ikke er relatert til de uavhengige variablene og (3), til slutt antas det at hver uavhengig variabel ikke er en tilfeldig variabel (Hyndman & Athanasopoulos, 2018).

4.1.2 Multi-layer perceptron (MLP)

MLP er en av de mest normale nevrale nettverksmodellene, og er også ofte bare kalt for nevrale nettverk (NN) (Ahmed et al., 2010). NN har to type læringsmetoder: veiledet (Engelsk: supervised) og ikke-veiledet (Engelsk: unsupervised) (Claveria & Torra, 2014). Enkelt forklart prøver en veiledet NN-modell å predikere utfall, mens en ikke-veiledet NN-modell prøver å

oppdage mønstre. I denne oppgaven skal jeg predikere etterspørsel, og da blir det naturlig at jeg bruker en veiledet modell.

NN består av et sett med dataelementer kalt nevroner, som er organisert i tre type lag; et inngangslag, utgangslag og en eller flere skjulte lag (Hyndman & Athanasopoulos, 2018). Det er også mulig ha en NN-modell med bare inngangslag og utgangslag, men da blir omtrent som en lineær regresjon. Det finnes forskjellige måter nevronene knyttes sammen, men den som er mest relevant for tidsserieprognoser er forovermatet NN-modell og denne typen NN gjør at hvert lag får input fra forrige lag (Hyndman & Athanasopoulos, 2018). MLP er en forovermatet NN-modell med minst et skjult lag, og Figur 4 viser et eksempel på en MLP-modell med et skjult lag.



Figur 4 – MLP med tre inputs og et skjult lag

Enkelt forklart er nevronene i et lag knyttet med en vektforbindelse til nevronene i neste lag. En vekt ($w_{i,j}$) beskriver forbindelsen med en tallverdi mellom et nevron, og vekten påvirker i hvor stor grad det nevronet påvirker i neste lag. En skjult nevron i en NN-modell med 3 inputs kan forklares slik:

$$z_j = b_j + \sum_{i=1}^3 w_{i,j} x_i$$

Ligning 3

Hvor x_i er inngangsnevronet, $w_{i,j}$ er vekten mellom i inngangsnevron og j skjulte nevron, og b_j er skjevheten (Engelsk: bias).

I de skjulte lagene har hvert nevron en aktiveringsfunksjon. Aktiveringsfunksjonen finnes i ulike typer, men det mest vanlige er sigmoidfunksjonen(s_i), også kalt logistisk funksjon. Denne funksjonen presser verdiene til et sted mellom 0 og 1, og er også kjent som en «squashing function». Grunnen til at vi bruker en slik funksjon er at den reduserer effekten til ekstreme verdier og gjør nettverket mer robust for avvikere (Engelsk: outliers) (Hyndman & Athanasopoulos, 2018). Sigmoid funksjonen er gitt ved følgende formel:

$$s(z) = \frac{1}{1 + e^{-z}}$$

Ligning 4

Sigmoid funksjonen er en ikke-lineær funksjon, og for utgangslaget brukes som oftest enten denne funksjonen eller en lineær funksjon (Lorrenz, 2015).

For at modellen skal lære bruker vi en læringsalgoritme, og det er den som estimerer vektene ($w_{i,j}$) og skjevhetene (b_j). Det finnes flere typer læringsalgoritmer, men det mest normale er å legge til en standard tilbake-forplantingsalgoritme. En slik algoritme estimerer vektene og minimerer en kostnadsfunksjon som f.eks. MSE (Hyndman & Athanasopoulos, 2018). I denne oppgaven vil kostnadsfunksjonen være av MSE, og vi skal se nærmere på den i neste delkapittel 4.2.

Det som er spesielt for NN er at vi her ikke velger manuelt hvordan modellen skal bli, men vi bruker en teknikk for å velge modell. I maskinlæring er K-fold kryssvalidering den dominante tilnærmingen for å velge modell (Ahmed et al., 2010). Den brukes til å velge ut antall variabler som skal brukes i inngangslaget og hvor kompleks modellen skal være. I K-fold kryssvalidering deler man et sett med observasjoner inn i k grupper i omtrent lik størrelse, og er gitt ved følgende formel (James, Witten, Hastie & Tibshirani, 2013)

$$CV_{(k)} = \frac{1}{k} \sum_{i=1}^k MSE_i$$

Ligning 5

I denne oppgaven følger jeg metoden en ser brukt i Makridakis et al. (2018b) når jeg bygger opp MLP modellen. Først konstruer jeg en MLP-modell med bare et skjult lag, som skal brukes til å velge antall laggede verdier (Skriver mer om dette i kap. 5). For å velge antall laggede verdier kjører jeg en K-fold kryssvalidering med 10 grupper. Da finner jeg den optimale mengden av de laggede variabelene som legges til i modellen, før vi så kjører en ny 10fold

kryssvalidering for å finne optimal mengde av skjulte nevroner. Utvalget av skjulte nevroner er $2N+1$, som vil si et utvalg er på 43 skjulte nevroner. Antall skjulte lag er av sekundær betydning. I den ferdige modellen bruker jeg Scaled Conjugate Gradient (SCG) metoden i stedet for standard tilbakeforplantingsalgoritme for å estimere optimale vektorer. SCG er et alternativ til Levenberg-Marquardt algoritmen som er brukt i annen tidligere forskning (Ahmed et al., 2010), og hvor SCG er funnet til å prestere bedre enn begge disse algoritmene (Makridakis et al., 2018b). For utgangsnevronene så er den en lineær funksjon som brukes i stedet for sigmoid funksjonen. Før modellen blir estimert skalerer vi dataene mellom 0 og 1 for å unngå beregningsproblem, og etter at prediksjonene er gjort skalerer jeg dataene tilbake til original skala (Makridakis et al., 2018a). Skalering skjer basert på min-max verdier, og er en av de mest normale metodene å bruke (Abbott, 2014).

4.2 Evaluering av prognoser

For å evaluere prognosemodellenes nøyaktighet må de predikerte verdiene sammenlignes med de virkelige verdiene der de er kjent. Det finnes ulike nøyaktighetsmål for å evaluere hvor store *feilene* fra en prognosemodell er. Det første nøyaktighetsmålet er Mean Squared Error (MSE), som er kategorisert som standardfeil og tar gjennomsnittlig kvadrert avvik mellom faktiske observasjoner og predikerte verdier (Sanders, 2017). Det er dette nøyaktighetsmålet som blir brukt til å bygge modellene. MSE er gitt ved følgende formel:

$$MSE = \frac{1}{n} * \sum_{t=1}^n e_t^2$$

Ligning 6

Hvor $e_t = Y_t - \hat{Y}_t$ er prognosefeilen, e_t^2 er den kvadrerte feilen og n er antall predikerte observasjoner.

Til de ferdige prognosemodellene vil jeg rapportere to nøyaktighetsmål. Det ene er MSE, og det andre er Symmetric Mean Absolute Error (sMAPE). sMAPE er kategorisert som relativ feil, og er en utvidelse av Mean Absolute Percentage Error (MAPE). Grunnen til at jeg bruke SMAPE i stedet for MAPE er for å kunne sammenligne med tidligere studier (Ahmed et al., 2010; Makridakis & Hibon, 2000; Makridakis et al., 2018a, b), og fordi SMAPE unngår MAPE sin ulempe med at den setter tyngre straff på negative feil enn positive feil (Hyndman & Athanasopoulos, 2018). SMAPE er gitt ved følgende ligning:

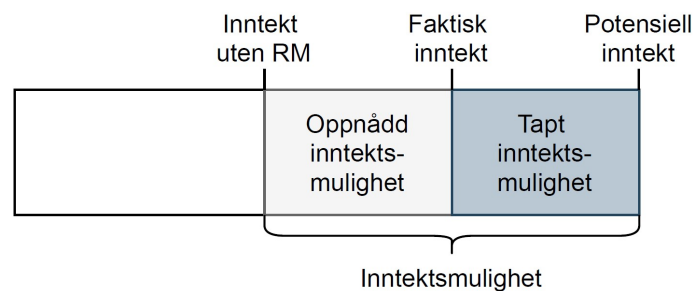
$$SMAPE = \text{gjennomsnitt} \left(200 \frac{|Y_t - \hat{Y}_t|}{|Y_t + \hat{Y}_t|} \right)$$

Ligning 7

Hvor Y_t er de faktiske observerte verdiene og \hat{Y}_t er de predikerte verdiene. SMAPE tar to ganger gjennomsnittet av absolutte avvik mellom faktiske observasjoner og predikerte verdier delt på absolutte summen av faktiske observasjoner og predikerte verdier.

4.3 Evaluering av foreslått Revenue Management system

En mye brukt teknikk for å evaluere et RM-system er *revenue opportunity model* (ROM). For å beregne ROM bruker vi tre variabler: inntekten selskapet ville hatt uten RM, maksimal potensiell inntekt og faktisk inntekt med RM (Temath, 2011). Potensiell inntekt viser hvor mye vi kan oppnå med perfekt RM. Dette betyr i praksis at vi selger akkurat så mange fullpris billetter som etterspørselen tilsier og resten av kapasiteten til rabatterte pris. Faktisk inntekt er den inntekten vi faktisk oppnår med det foreslåtte (eller implementerte) RM-systemet. Inntekt uten RM er inntekten som ville blitt oppnådd dersom det ikke er noe RM-system som kontrollerer hvor mange som skal få lov til å kjøpe rabatterte billetter. Inntektene fra denne «strategien» følger prisen *first come, first serve* prinsippet som betyr at selskapet vil selge rabatterte billetter (på forhånd) så lenge man har kapasitet til det. Figur 5 viser en illustrasjon med ROM konseptet.



Figur 5 - Konseptet med ROM. Adoptert fra Temath (2011, s.10)

All inntekt mellom inntekt uten RM og potensiell inntekt er inntektsmuligheten, og alt som er mellom faktisk inntekt og inntekt uten RM er inntektsmuligheten som faktisk er oppnådd med det foreslåtte RM-systemet. Det skraverte området mellom faktisk inntekt og potensiell inntekt er tapt inntektsmulighet. Når vi skal evaluere et RM-system beregner vi inntektsmuligheten (RO), oppnådd inntektsmulighet (ARO) og prosentvis oppnådd inntektsmulighet (PARO) (Temath, 2011):

$$RO = \text{Potensiell inntekt} - \text{Inntekt uten RM}$$

$$ARO = \text{Faktisk inntekt} - \text{Inntekt uten RM}$$

$$PARO = \frac{ARO}{RO}$$

Ligning 8

Hvor RO beskriver hvor mye inntekt vi potensielt kan oppnå med RM, ARO beskriver hvor mye vi faktisk har oppnådd, og PARO beskriver den relative suksessen med RM sammenlignet med potensialet.

5. Data

I denne oppgaven bruker jeg et datasett fra Beitostølen Skisenter i kombinasjon med ulike værvariabler hentet fra Meteorologisk institutt (Meteorologisk Institutt, 2021b). Datasettet består av 6 alpinsesonger fra 2014 til 2020, og utgjør 826 observasjoner. Da er det kun dagskort for voksne som er inkludert. Tabell 4 viser oversikt over alle variablene i datasettet, og en beskrivelse av dem. Alle værvariablene utenom lufttrykk og følt temperatur er hentet fra en værstasjon i underkant av en 1km i luftlinje fra Beitostølen skisenter, og ligger på 965 moh. Denne værstasjonen hadde ikke tilgjengelig lufttrykksdata, og dermed ble dette innhentet fra nærmeste værstasjon som hadde tilgjengelig. Fagernes lufthavn er lokalisert nesten 3,5 mil i luftlinje unna Beitostølen skisenter og ligger på 822 moh., og denne værstasjonen hadde lufttrykksdata tilgjengelig.

Variabler	Beskrivelse
Antall dagskort	Antall solgte dagskort per dag
Snø	Målt snødybde i cm per døgn
Vind	Gjennomsnitt av vindstyrke målt ved hovedobservasjonene: kl. 6, 12 og 18
Temperatur	Gjennomsnittlig temperatur per døgn
Kvadrert temperatur	Gjennomsnittlig temperatur per døgn kvadrert
Nedbør	Total nedbør per døgn
Lufttrykk	Gjennomsnittlig lufttrykk per døgn på stasjonsnivå
Følt temperatur	Gjennomsnittlig vindavkjølingsindeks per døgn
Kvadrert følt temperatur	Gjennomsnittlig vindavkjølingsindeks per døgn kvadrert
Ukedag	Dummy variabel for hver ukedag (man-søn)
Måned	Dummy variabel for hver måned (nov-mai)
Trend	En variabel som teller for hver observasjon (1-826)
Juleferie	Dummy variabel for perioden mellom julaften og nyttårsaften
Vinterferie	Dummy variabel for vinterferie (for uke 8 og 9)
Påskeferie	Dummy variabel for påskeferie

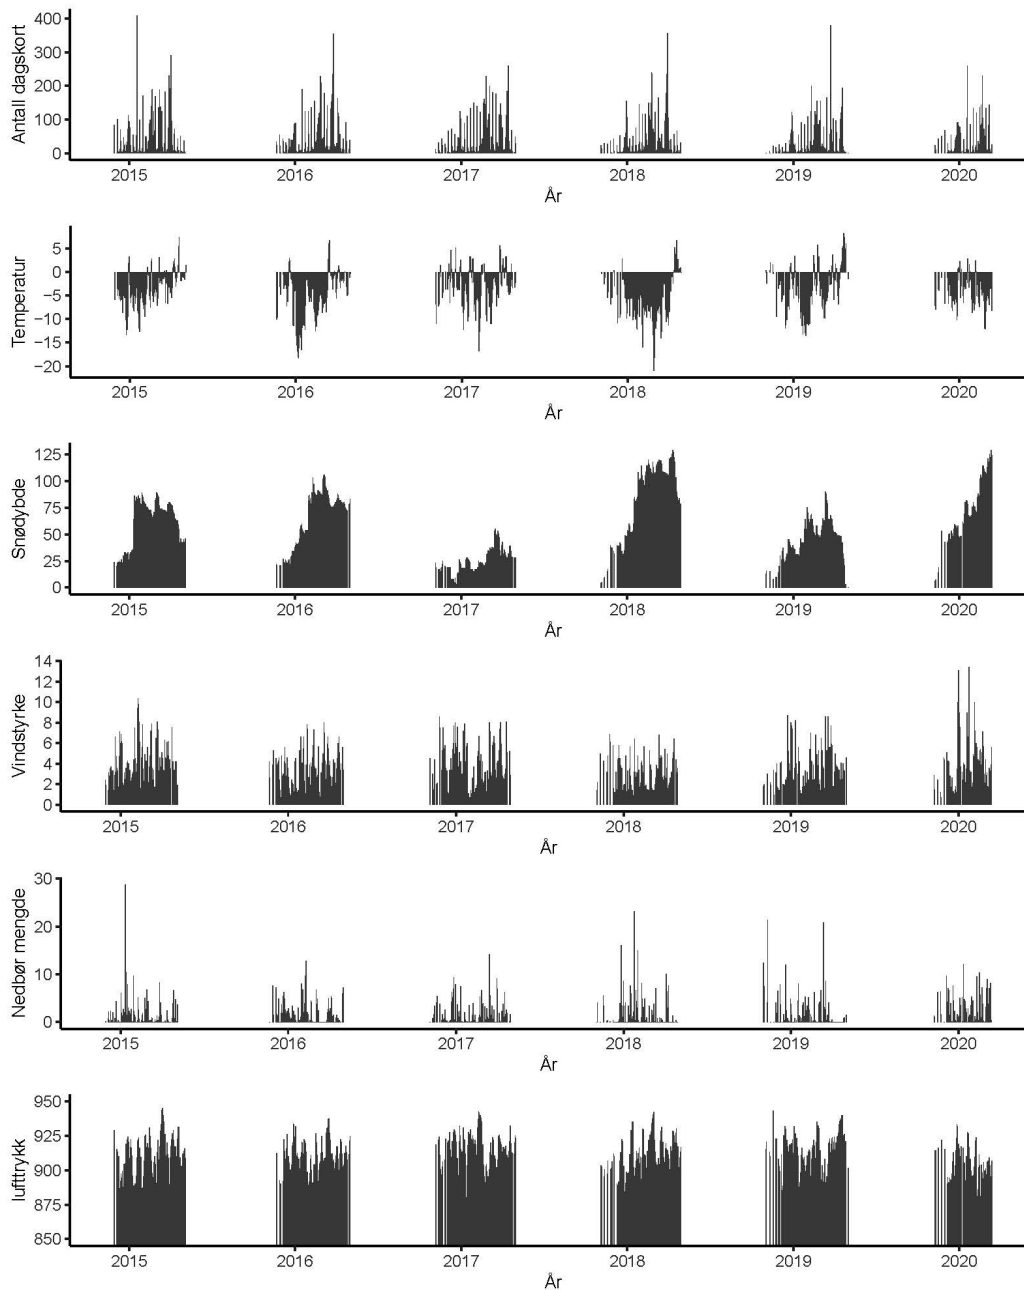
Tabell 4 - Beskrivelse av variabler

Følt temperatur (W) beskriver den temperaturen vi opplever når vind og temperatur blir sett i forhold til hverandre (Meteorologisk Institutt, 2021a). Formelen er gitt ved:

$$W = 13,12 + 0,6215T - 11,37V^{0,16} + 0,3965T * V^{0,16}$$

Variabelen 'trend' er det beste måten jeg kan sjekke hvordan trenden er i datasettet. Grunnen til at jeg ikke kan bruke dato er fordi alpinanlegget er ikke åpent hver dag hele sesongen, og det gjør at det blir store hull mellom datoene. I tillegg til temperatur og følt temperatur har jeg også inkludert kvadrerte variabler av disse. Kvadrerte variabler har jeg med siden tidligere forskning viser at dette har sterk påvirkning på etterspørselen etter dagskort, og disse variablene gir en ikke-lineær effekt på temperatur og følt temperatur (Malasevska et al., 2017).

Figur 6 viser et tidsserieplot for antall solgte dagskort og alle vær variablene. Her kan vi se variasjonen for de forskjellige variablene over sesongene. Det er tydelig at det i starten av sesongene er lavere salg av dagskort enn utover i sesongene, og det stemmer godt overens med tidligere forskning (Malasevska et al., 2017). I tillegg er det tydelig at det er gjennomsnittlig lavere salg av dagskort mandag til torsdag, mens det er betydelig høyere i helgene, spesielt lørdag (se vedlegg 1). Det er tydelig at det er sesongvariasjon både ukentlig og månedlig. Derfor bruker jeg dummy variabler for å fange opp disse variasjonene.



Figur 6 - Tidsserieplot med alle viktig variabler

Luftrykket gir oss et inntrykk av hvordan været er, og er målt i hPa (hektopascal). Det er viktig å ta høyde for at luftrykket avtar med høyden, og i de nederste lag avtar den raskest med cirka 1 hPa/8 m (Harstveit, Sivle & Evans, 2020). Ettersom datasettets luftrykk er målt på 822 moh må vi trekke 102,75 ($822/8=102,75$) når jeg presenterer hva spennet er for høytrykk og lavtrykk. Et høytrykk gir ofte et rolig og godt vær med svake vinder, men forbindes også med tåke (Velle, 2020). Et vanlig høytrykk ligger mellom 922,5 - 947,25 hPa. I motsetning til et høytrykk, så følger lavtrykk ofte med skyer og nedbør (Harstveit & Velle, 2019) . Et vanlig lavtrykk ligger mellom 867,25 – 877,25 hPa.

Tidsserieplotet i Figur 6 gir oss ikke bare muligheter til å se variasjoner, men også sammenhenger. For eksempel i sesongen 2017/18 kan vi se at denne sesongen hadde mest snø, sammen med at den samme sesongen hadde de kaldeste temperaturene og en større mengde med nedbør. Det gjør at vi kan anta at på grunn av større mengde nedbør og kaldere temperaturer har dette ført til mer snø gjennom sesongen.

Tabell 5 viser den deskriptive statistikken over de viktigste variablene, og denne informasjonen kan vise hvordan variablene fordeler seg. For tidsseriedata er det viktig å sjekke om datasettet er stasjonær, for hvis datasettet ikke er stasjonær så kan hele resultatet være fabrikkert (Mushtaq, 2011). En stasjonærhetstest sjekker om gjennomsnittet er konstant, og her har jeg brukt en Augmented Dickey-Fuller test (ADF).

Variabel	n	Gjennomsnitt	Standardavvik	Median	Minimum	Maksimum	Skjevhet	Kurtose	Stasjonærhet
Antall dagskort	826	43,27	57,84	18,5	0	408	2,22	6,32	-8,6218
Snø	819	58,27	31,28	54	0	129	0,27	-0,91	-2,682
Vind	819	3,43	1,96	3,1	0,5	13,4	1,08	1,6	-8,3484
Temperatur	819	-4,17	4,44	-3,9	-20,9	8,3	-0,23	0,31	-5,3756
Nedbør	826	1,63	2,89	0,3	0	28,8	3,54	19,59	-8,4354
Luftrykk	826	911,1	13,59	911,6	866,5	945,2	-0,14	-0,29	-6,981
Følt temperatur	819	-4,91	4,45	-4,91	-24,21	9,11	-0,13	0,71	-5,5995

Tabell 5 - Deskriptiv Statistikk

I antall dagskort er det stor forskjell mellom gjennomsnittlig antall solgte dagskort (43,27) og medianen (18,5). Dette kan være fordi det er noen høye verdier som drar opp gjennomsnittet betraktelig. Skjevhet måler symmetrien til distribusjonen, og sammenlignes med en normal distribusjon (Hair Jr. et al., 2019). En negativ skjev distribusjon har relativt få lave verdier og halen til venstre, mens en positiv skjev distribusjon har relativt få høye verdier og halen til høyre. Hvis skjevhetsverdien er utenfor -1 til +1 så indikerer det at variabelen har en vesentlig skjev distribusjon, og det kan vi se at antall dagskort og nedbørvariablene har. Kurtose måler hvor spiss eller hvor flat distribusjonen er i forhold til en normal distribusjon (Hair Jr. et al., 2019). En positiv verdi indikerer en relativ spiss distribusjon, som vi kan se at antall dagskort og nedbør har. En negativ verdi indikerer en relativ flat distribusjon, som det så vidt indikeres på snø og luftrykk.

Som vi kan se i Tabell 5 så mangler det 7 observasjoner for enkelte variabler, og som i datasettet står som NA-verdier (not available). Dette er problem en ofte kan møte på med datasettet, og det er da viktig å ta en vurdering på hvordan en skal håndtere det. I følge Kuhn og Johnson (2013) så er det ikke noe problem å fjerne verdiene fra store datasett så lenge ikke mangelen er informativ. For oss utgjør disse 7 radene med manglende verdier bare 0,7% av alle radene, og bør ikke utgjøre en stor forskjell. Dette gjør at det ferdige datasettet, før vi ser på de laggede verdiene, består av 811 observasjoner.

I denne oppgaven vurderer jeg et antall laggede variabler av antall solgte dagskort mellom 2 og 10, og det noteres som $Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{t-8}, Y_{t-9}, Y_{t-10}$. Hvis jeg hadde inkludert alle laggede verdier fra 2 til 10, kunne jeg hatt en prognosehorisont fra 1 dag og opptil 9 dager. For denne oppgaven skal vi se på en prognosehorisont på 2 dager og 7 dager.

6. Resultater

I multippel regresjonsanalysen ble det brukt mye tid på å finne riktig modell, og det ble prøvd ut mange modeller før den endelige modellen ble valgt. I MLP har det vært krevende å bygge opp modellen, blant annet med å anvende tidligere forskning til dette datasettet.

For å kunne evaluere hvor godt modellene predikerer etterspørselen etter dagskort, blir datasettet delt inn i et treningssett og et testsett. Det vil si at vi estimerer modellene basert på treningssettet, og evaluerer hvordan modellen gjør det basert på testsettet. Det finnes ulik fordeling av treningssett og testsett, hvor det i denne oppgaven er delt slik at 2/3 av datasettet er treningssettet og 1/3 av datasettet er testsettet (Abbott, 2014). Det vil si at de fire første sesongene er treningssettet og de to siste sesongene er testsettet. Alle resultatene som blir vist i dette delkapittelet er basert på testsettet.

Til å gjennomføre analysene har jeg kodet i språket R med verktøyet RStudio IDE.

6.1 Tidsserieregresjon

For å finne den optimale tidsserieregresjonsmodellen for dette datasettet har det blitt testet ut mange kombinasjoner av uavhengige variabler, og de ulike modellene ble vurdert etter MSE, hvor den med lavest MSE ble valgt. Tidsserieregresjonsmodellen endte med å bestå av følgende laggede variabler: $Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-9}$, og består av 810 observasjoner og 19 uavhengig variabler etter å ha fjernet NA verdier. De har blitt sjekket for autokorrelasjon og delvis autokorrelasjon mellom den avhengige variabelen og laggede dager, opptil 10 dager. Etter at tidsserieregresjonsmodellen var estimert, viste en residualanalyse noe autokorrelasjon i feilledet. Dette gjaldt imidlertid først og fremst for perioden for siste tilgjengelig observasjon (lag 1) som ikke kan tas inn i noen av modellene siden vi benytter en prognosehorisont på 2 og 7 dager.

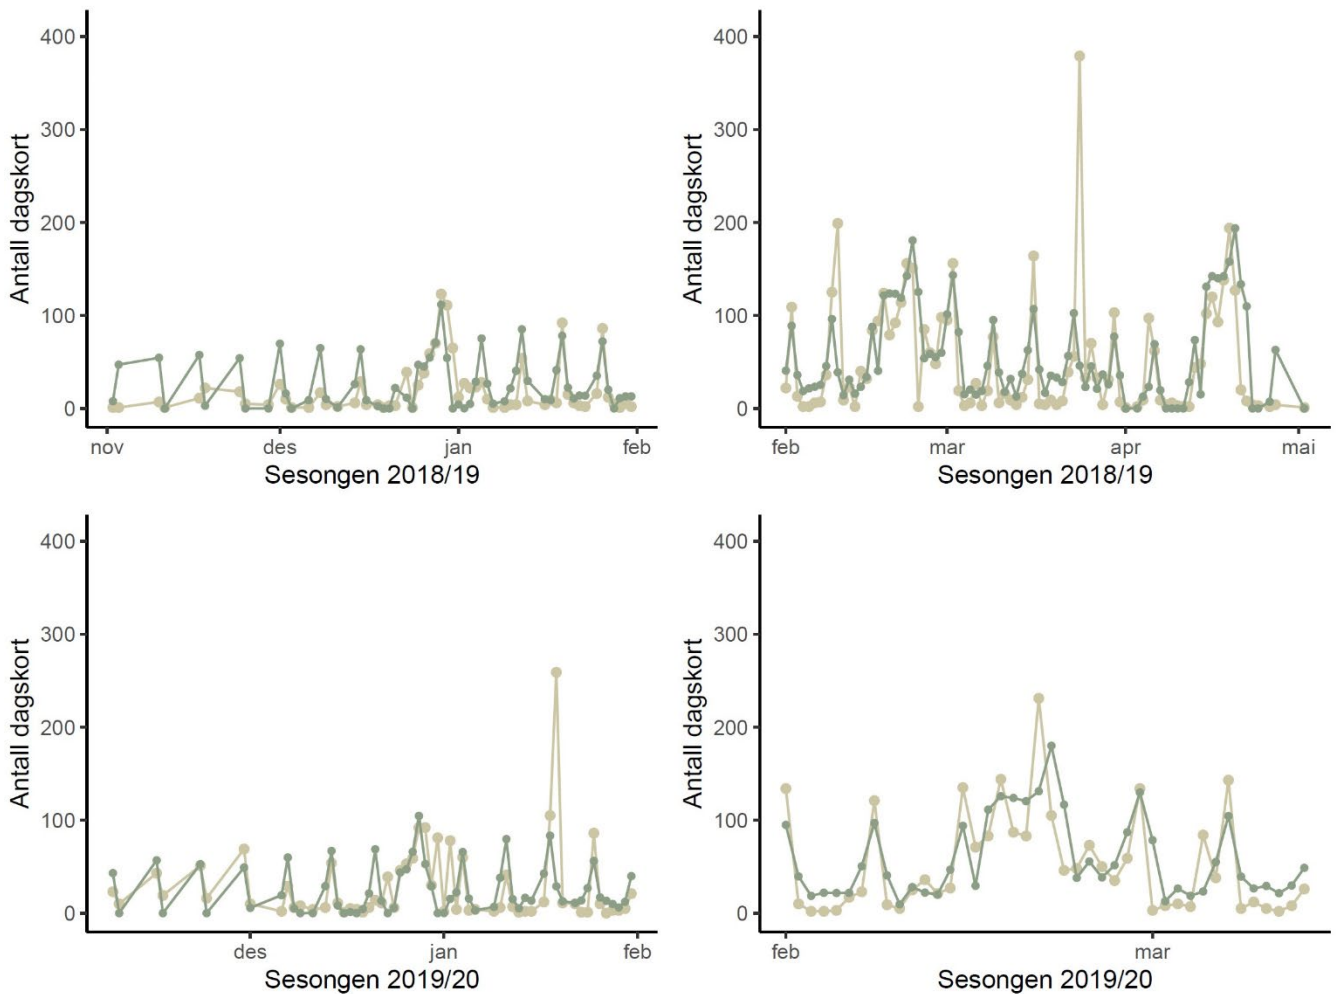
Tabell 6 viser estimatene av koeffisientene fra multippel regresjonsanalysen. Dummy variablene 'Mandag' og 'November' blir holdt utenfor analysen og er referansedagen/måneden.

Variabel	Koeffisient	Standardavvik	t-verdi	
Skjæringspunkt	51,57	147,6	0,35	
Lag 2	0,02	0,04	0,39	
Lag 3	-0,04	0,04	-0,87	
Lag 4	-0,01	0,04	-0,23	
Lag 5	-0,1	0,04	-2,29	*
Lag 6	-0,06	0,04	-1,71	.
Lag 9	-0,04	0,03	-1,15	
Snø	0,01	0,07	0,14	
Vind	-0,4	0,98	-0,41	
Nedbør	-1,05	0,71	-1,48	
Lufttrykk	-0,06	0,16	-0,39	
Følt temperatur	0,41	0,81	0,51	
Kvadrert følt temperatur	-0,04	0,06	-0,67	
Tirsdag	10,28	7,79	1,32	
Onsdag	6,66	8,18	0,81	
Torsdag	14,38	7,98	1,8	.
Fredag	34,86	7,95	4,38	***
Lørdag	74,99	7,48	10,03	***
Søndag	19,49	7,12	2,74	**
Desember	13,89	9,79	1,42	
Januar	30,85	9,56	3,23	**
Februar	41,21	10,39	3,97	***
Mars	50,21	10,62	4,73	***
April	18,18	10,82	1,68	.
Mai	-1,41	20,67	-0,07	
Juleferie	42,16	10,09	4,18	***
Vinterferie uke 8	101,53	10,21	9,95	***
Vinterferie uke 9	50,84	9,92	5,05	***
Påskeferie	132,05	9,92	13,31	***
Trend	-0,01	0,01	-1,02	

Tabell 6 – Estimer av koeffisienter for tidsserieregresjonsmodellen

Merk: Signifikansnivå på 0,1%, 1%, 5% og 10% er betegnet som ***, **, * og .

Skjæringspunktet er antall dagskort vi tror vi at etterspørselen er hvis alle de uavhengige verdiene er lik 0, og det vil si ca. 52 dagskort. Hvis det er en onsdag vil etterspørselen være ca. 7 dagskort mer enn hvis det hadde vært mandag, og tillegg hvis denne onsdagen hadde vært i januar, ville etterspørselen øke med ytterligere 31 dagskort mer enn hvis det hadde vært november. Det vil si at hvis vi holder alle de andre variablene lik null hadde vi endt med en etterspørsel på ca. 90 dagskort. Likevel har vi også negative koeffisienter som vil dra ned salget, som noen av værvariablene. Hvis vi har en nedbør på 10 mm den aktuelle dagen vil det redusere etterspørselen av dagskort med ca. 11. Utenom dette kan vi se at høytid har en stor påvirkning på dagskort, og trendvariablene indikerer at vi har en svak avtagende trend i etterspørsel av dagskort. I Figur 7 ser vi hvordan prognosene av dagskort har gjort det i forhold til det som faktisk var solgt.



Figur 7 - Observerte verdier VS predikerte verdier basert på tidsserieregresjonsmodellen

● Observerte verdier ● Predikerte verdier

Vi kan se at prognose nok så godt følger de observerte verdiene, med noen unntak selvfølgelig. De dagene hvor etterspørselen plutselig blir spesielt høy, er verdier vanskelig å predikere, og de kan være påvirket av andre variabler som jeg ikke har med i min modell.

I Tabell 7 ser en hvor god tidsserieregresjonsmodellen er til å estimere prognosene basert på disse nøyaktighetsmålene. I en prognosehorisont på 2 dager må vi minst ha 3 laggede verdier for å kunne predikere 2 dager frem. Det er fordi vi ikke vet verdien for dagen «i dag» før denne dagen er over, og vi må ha minst to historiske verdier for å estimere to fremtidige verdier. Det vil si at ved en prognosehorisont på 2 dager så fjerner vi laggede verdi Y_{t-2} , men beholder alle andre variabler like. Det samme gjelder for en prognosehorisont på 7 dager, og vil si at vi fjerner alle laggede verdiene utenom Y_{t-9} .

	2 dager prognosehorisont	7 dager prognose horisont
MSE	1654,35	1676,71
SMAPE	9,32%	9,17%


Tabell 7 - Nøyaktighetsmål for tidsserieregresjonsmodellen

Modellen med en prognosehorisont på 7 dager gjør det dårligere i forhold til en 2 dagers prognosehorisont basert på MSE, men basert på SMAPE gjør den det bedre.

6.2 Multi-layer perceptron

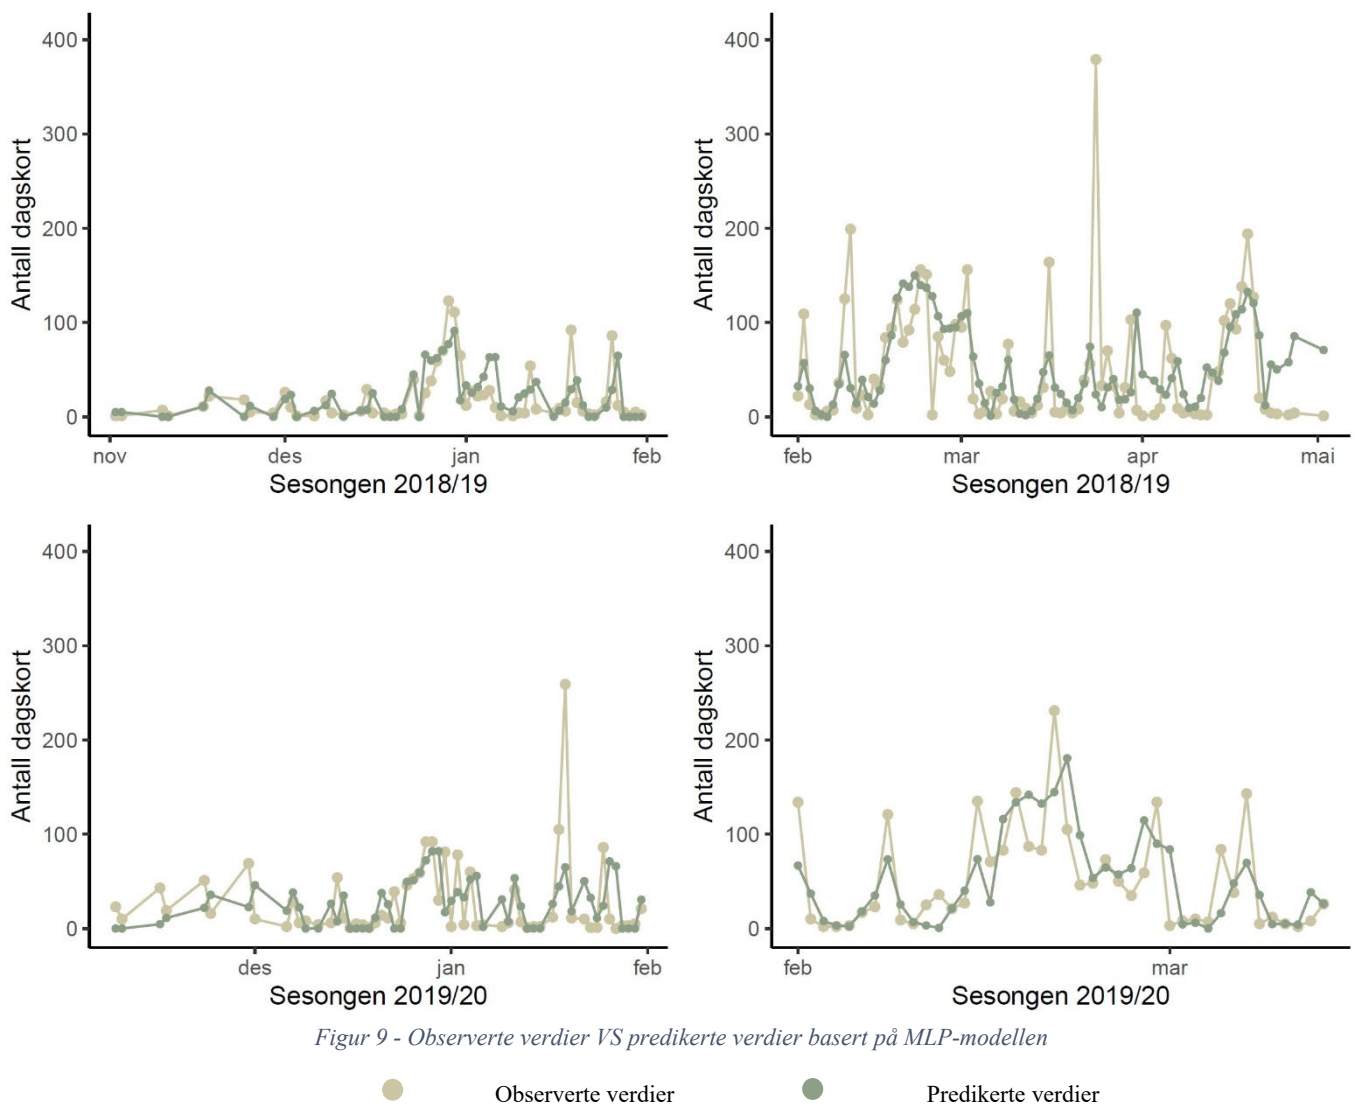
For å finne den optimale MLP-modellen brukte jeg metoden til Makridakis et al. (2018b) beskrevet i kapittel 4.1.2, hvor K-fold kryssvalidering var essensiell for valg av modell. I deling av 10 like store grupper gikk det ikke opp, og de 4 første verdiene fra gruppe 1 ble brukt igjen i slutten av gruppe 10. Etter jeg har undersøkt optimal mengde av laggede verdier og skjulte nevroner, så endte jeg med en MLP-modell bestående av: $Y_{t-2}, Y_{t-3}, Y_{t-4}, Y_{t-5}, Y_{t-6}, Y_{t-7}, Y_{t-8}$ og 10 skjulte nevroner før prognosehorisontene. Etter alle NA-verdier var fjernet ble datasettet bestående av 811 observasjoner og 20 uavhengig variabler.

I Figur 8 vises en illustrasjon av MLP-modellen.



Figur 8 - Illustrasjon av vår MLP-modell

I MLP-modellen har over 200 forbindelser, og blir litt som en svart boks. Det er ikke lett å beskrive hva som skjer steg for steg, men dette er en av de store utfordringene med nevralt nettverksmodeller. F.eks. i en regresjonsmodell kan vi bruke de estimerte koeffisientene til å beregne manuelt. Det er mye vanskeligere å kunne beregnet manuelt basert på en MLP-modell. I Figur 9 ser en hvordan prognose gjør det i forhold til de faktiske verdiene.



Figur 9 - Observerte verdier VS predikerte verdier basert på MLP-modellen

Vi kan se at prognosene følger ganske godt de observerte verdiene, men klarer ikke å følge de plutselige store økningene i observerte verdier.

Tabell 8 viser hvor god MLP-modellen er til å estimere prognoser basert på disse nøyaktighetsmålene. I en prognosehorisont på 2 dager må vi minst ha 3 laggede verdier for å kunne predikere 2 dager frem. Det er fordi vi ikke vet verdien for dagen «i dag» før denne dagen er over og vi må minst ha to historiske verdier for å estimere to fremtidige verdier. Det vil si at ved en prognosehorisont på 2 dager så fjerner vi laggede verdi Y_{t-2} , men beholder alle andre variabler like. Det samme gjelder for en prognosehorisont på 7 dager, og vil si at vi fjerner alle laggede verdiene utenom Y_{t-8} .

	2 dagers prognosehorisont	7 dagers prognosehorisont
MSE	1887,59	1776,49
SMAPE	9,1%	9,4%

Tabell 8 - Nøyaktighetsmål for MLP-modellen

Vi kan se at i forhold til MSE så gjør modellen med 7 dagers prognosehorisont det best, men i forhold til SMAPE gjør 2 dagers prognosehorisont det best.

6.3 Booking limit

Vi skal nå ta for oss booking limit for begge prognosehorisontene og modellene, og vurdere 3 ulike prisscenarioer (se Tabell 9). I tillegg har vi satt en maks kapasitet til $C = 200$, og det er på grunn av at 98% av de observerte verdiene er under 200 og omtrent det samme gjelder for prognose også. Denne kapasitetsbegrensningen er lik for alle prisscenarioene.

Prisscenario 1	Prisscenario 2	Prisscenario 3
Kr 299	Kr 199	Kr 99

Tabell 9 - Prisscenarioer

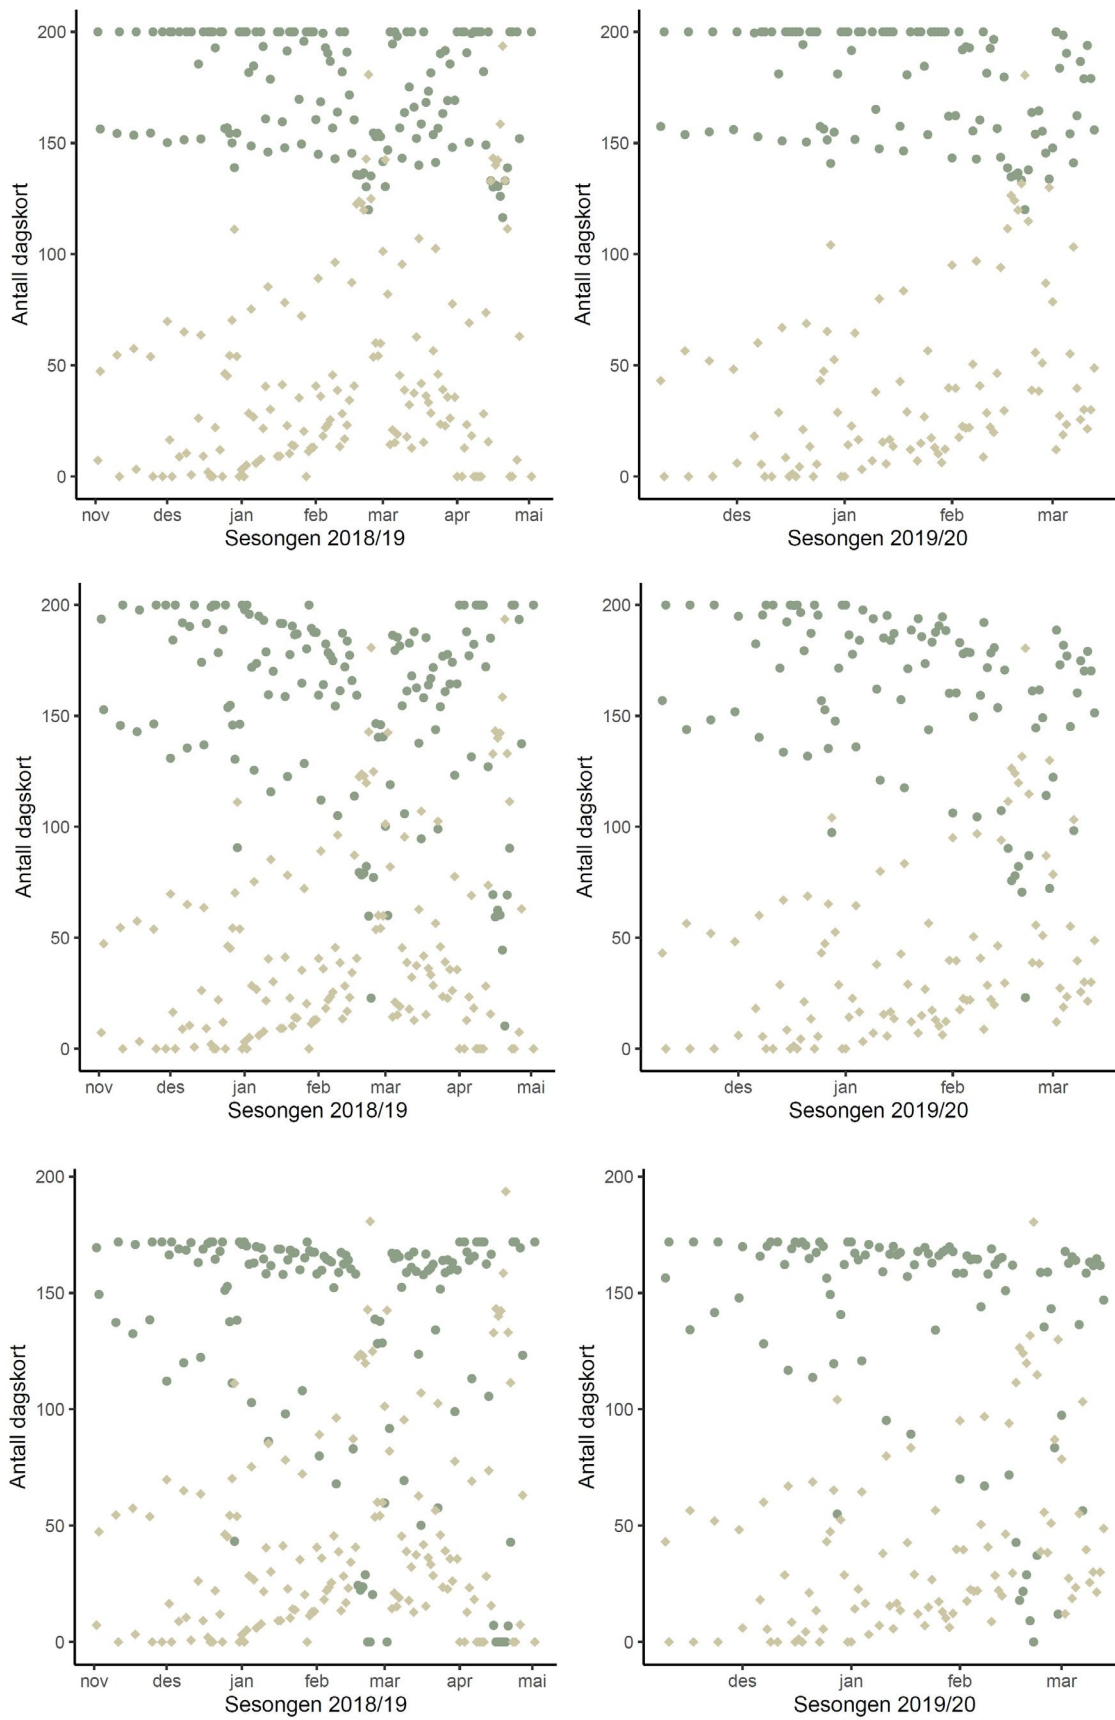
Fullpris-dagskortene holdes lik over alle prisscenarioer, og er det Beitostølen Skisenter har i dag, $r_H = 390$ (Fnugg, 2021). Siden prisscenarioene har en god spredning i prisnivå, gir det gode muligheter til å se hvordan dette påvirker booking limitene. Booking limitene er beregnet for hver dag, og standardavviket er beregnet ut ifra prognosene til de ulike prognosehorisontene og modellene. Som en liten oppfriskning, så beregnes booking limiten etter følgende formel:

$$BL^* = C - \delta_H \Phi^{-1}\left(1 - \frac{r_L}{r_H}\right) - \mu_H$$

Vi starter med å ta for oss en prognosehorisont på 2 dager og beregner booking limit basert på begge modellene for hvert prisscenario. Videre gjør vi det samme for en prognosehorisont på 7 dager og til slutt skal vi evaluere hver kombinasjon av modell, prognosehorisont og prisscenario med RO, ARO og PARO.

6.3.1 2 dagers prognosehorisont

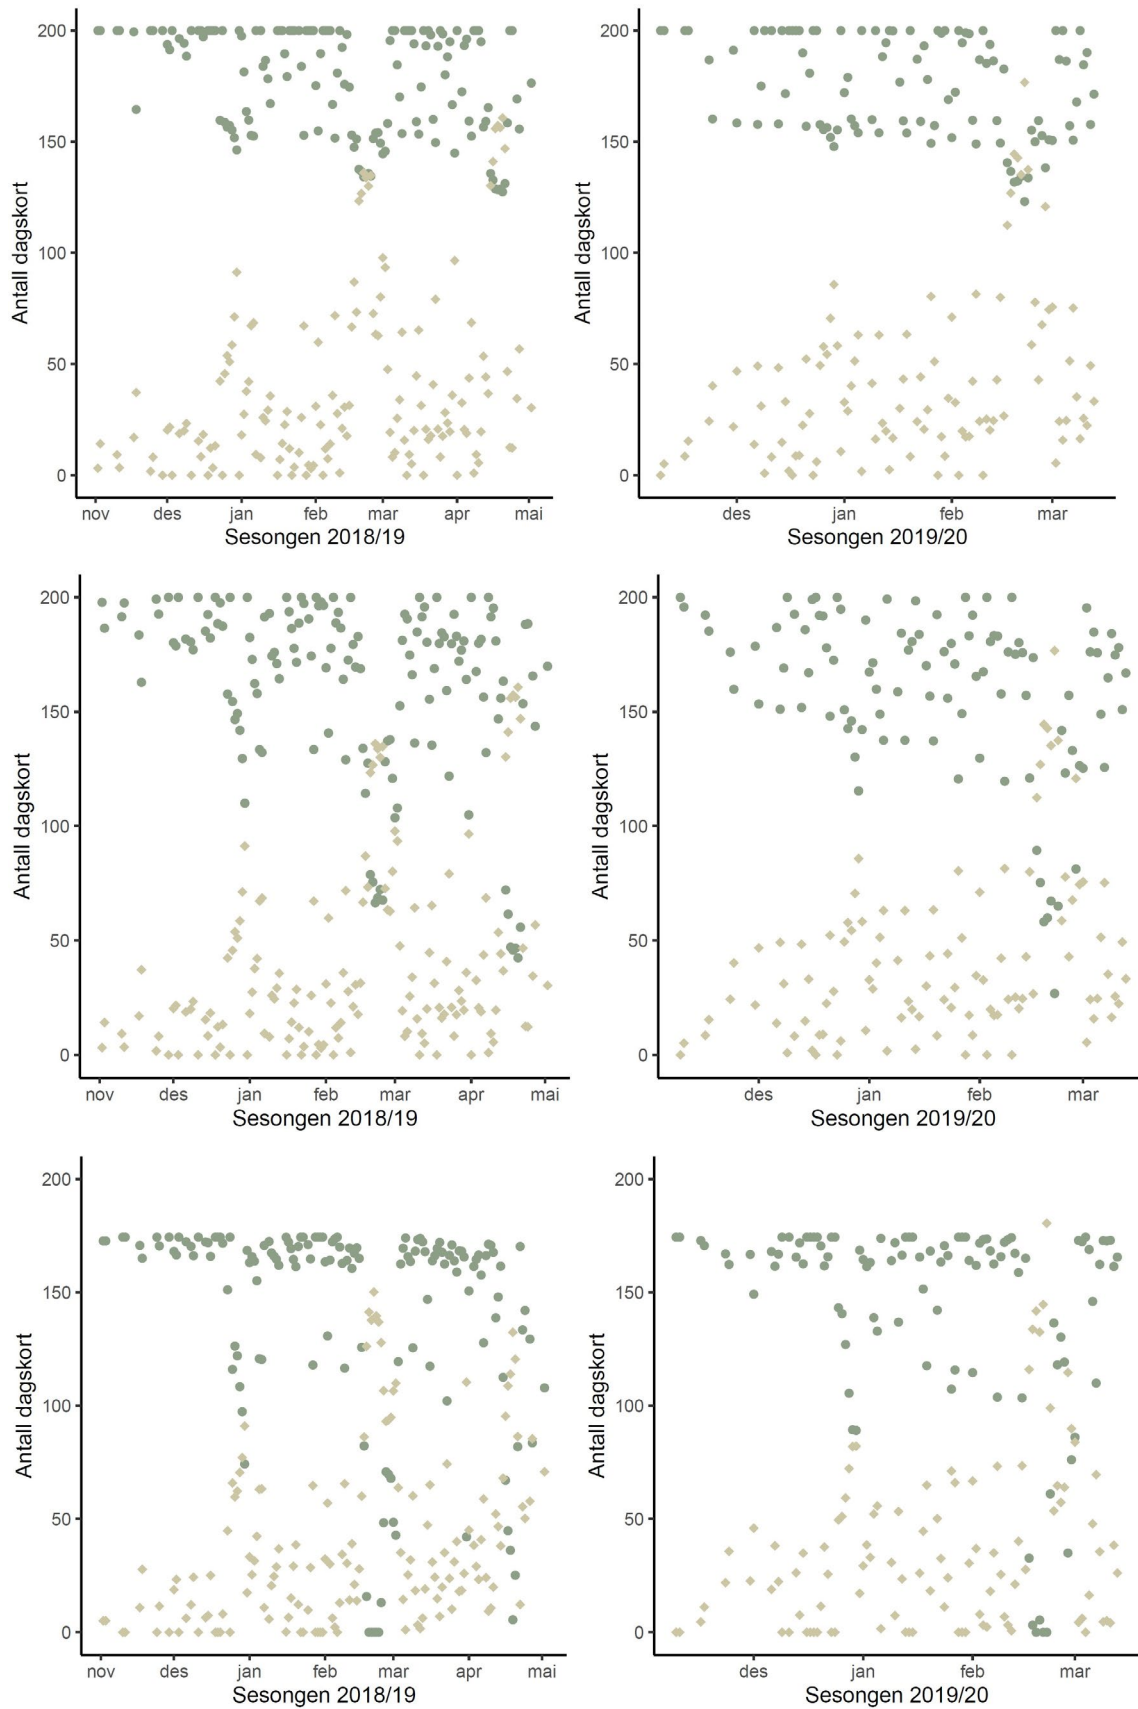
Først ser vi på booking limit estimert basert på tidsserieregresjonsmodellen og tar for oss alle tre prisscenarioene. Figur 10 viser booking limit og prognosene i samme figurer over tre panel, hvor det er ett panel for hvert prisscenario.



Figur 10 - Booking limit med tidsserieregresjonsmodell for 2 dagers prognosehorisont
 Øvre panel: Prisscenario 1, midterste panel: Prisscenario 2, og nedre panel: Prisscenario 3

● Booking limit ◆ Predikerte verdier

I øvre panel i Figur 10 ser vi at det er flest booking limiter som er satt til 200, altså lik kapasiteten, i forhold til midtre og nederste panel. Når booking limiten er satt lik kapasiteten, vil det si at vi kan selge alle dagskort til rabattert pris. For hver gang vi reduserer prisen, $r_D = 299$ til $r_D = 199$, og videre til $r_D = 99$, blir det flere og flere lavere verdier av foreslåtte booking limits. I nederst panel i Figur 10, hvor prisnivået er $r_D = 99$, så foreslår modellen aldri at vi skal selge hele kapasiteten til rabattert pris. I neste figur ser vi en lik analyse for MLP-modellen.



Figur 11 - Booking limit med MLP-modell for 2 dagers prognosehorisont
 Øvre panel: Prisscenario 1, midterste panel: Prisscenario 2, og nedre panel: Prisscenario 3

● Booking limit ◆ Predikerte verdier

Vi kan se at MLP-modellen foreslår mye av det samme som tidsserieregresjonsmodellen og fastsetter naturligvis lavere booking limits med lavere pris. I nederste panel i Figur 11 foreslår modellen i enkelte tilfeller at booking limit settes til 0, som vil si at vi skal beskytte hele kapasiteten for fullprisetterspørsel. En tydelig forskjell mellom MLP-modellen og tidsserieregresjonsmodellen er at tidsserieregresjonsmodellen setter flere lavere booking limits i tidlig sesong i alle tre prisscenarioene. Dette henger sammen med forskjeller i prognosene; Tidsserieregresjonsmodellen har høyere prognoser i tidlig sesong enn hva MLP-modellen har.

Tabell 10 viser en oversikt over booking limit basert på de to modellene og prisscenarioene. Hvor minimum viser hva den laveste booking limiten, og maksimum viser den høyeste booking limiten, medianen viser den midterste booking limiten og gjennomsnittet er gjennomsnittet av alle booking limitene.

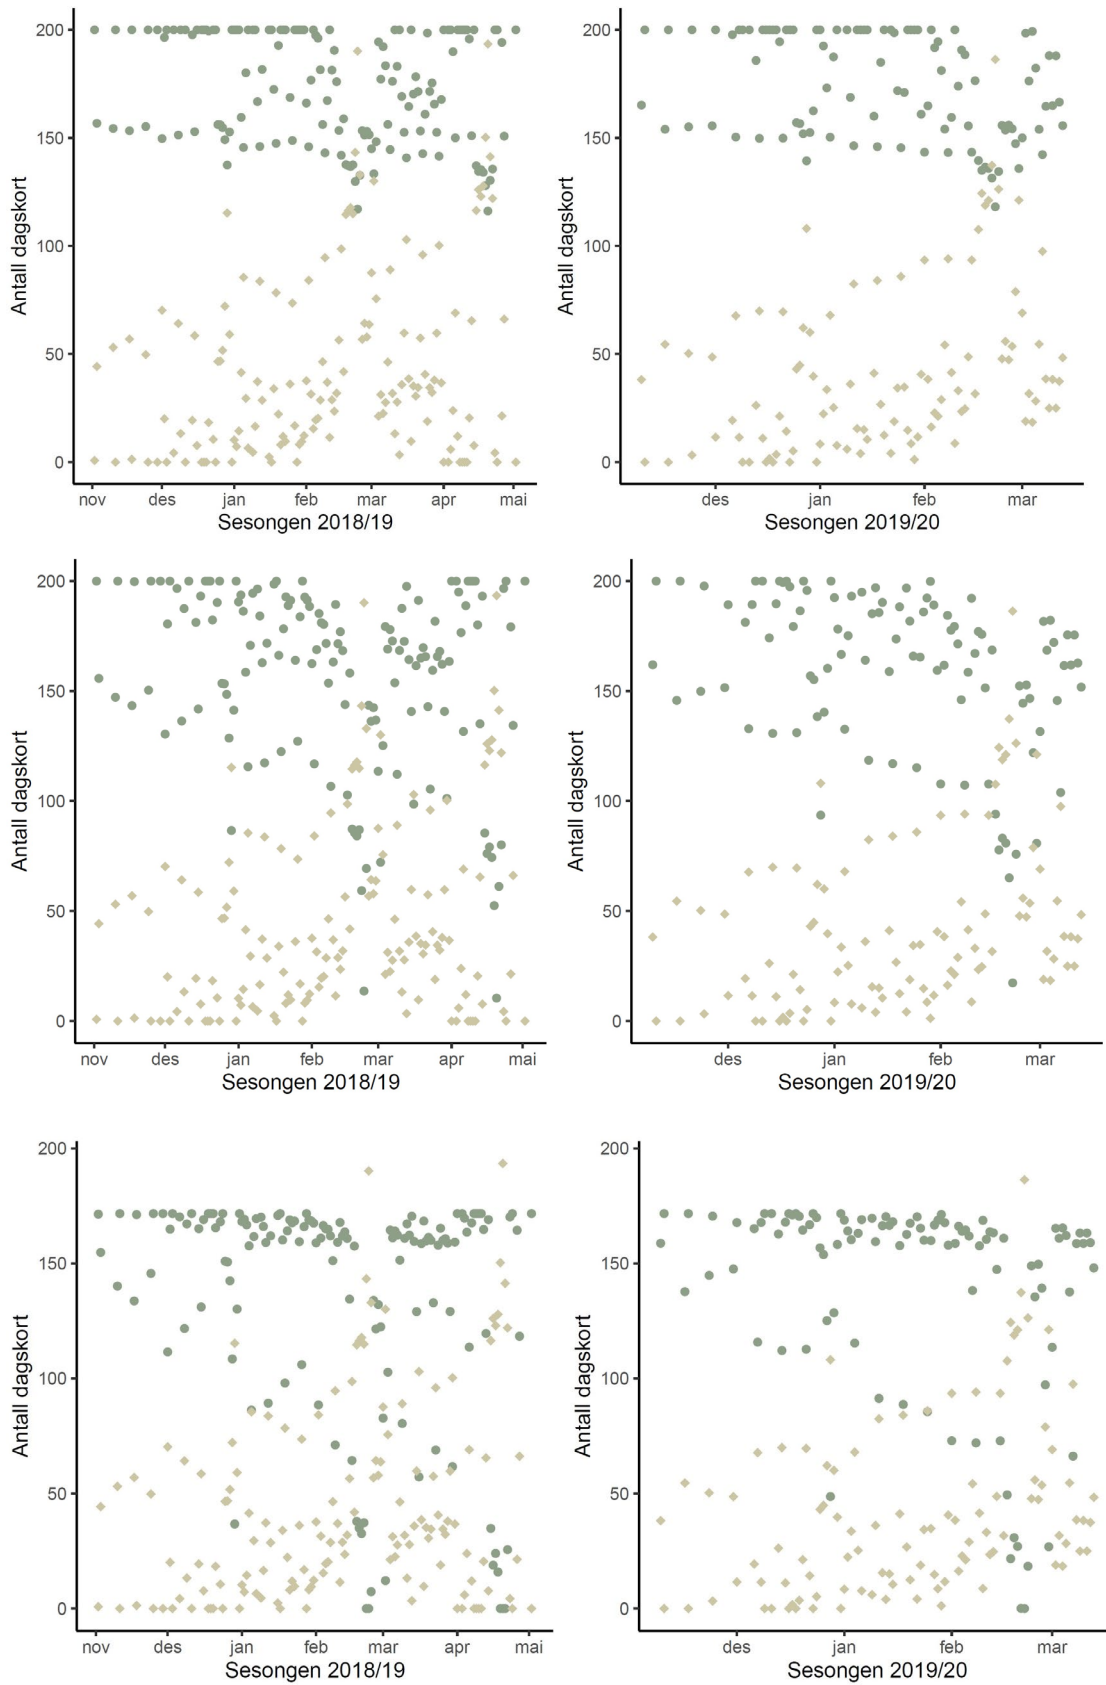
	Minimum	Median	Gjennomsnitt	Maksimum
Tidsserieregresjonsmodell				
Prisscenario 1	116,5	181,4	174,5	200
Prisscenario 2	10,3	171,7	158,3	200
Prisscenario 3	0	162,3	137,6	171,9
MLP-modell				
Prisscenario 1	122,8	180,2	176,2	200
Prisscenario 2	23,1	172,5	162	200
Prisscenario 3	0	165,1	142,1	174,4

Tabell 10 - Oppsummering av booking limit med en prognosehorisont på 2 dager

Det er tydelig at en prisendring fra $r_D = 299$ til $r_D = 199$ gjør stor forskjell i laveste booking limit for begge modellene, men selv om det blir mye lavere booking limits justerer ikke gjennomsnittet seg i stor grad. Det vil si at det fortsatt er flest høye booking limits. I tillegg kan vi se at i de fleste tilfeller har MLP-modellen høyere booking limits enn tidsserieregresjonsmodellen.

6.3.2 7 dagers prognosehorisont

Vi starter med å se på tidsserieregresjonsmodellen her og, men denne gangen med en prognosehorisont på 7 dager. Figur 12 viser et panel for hvert prisscenario.

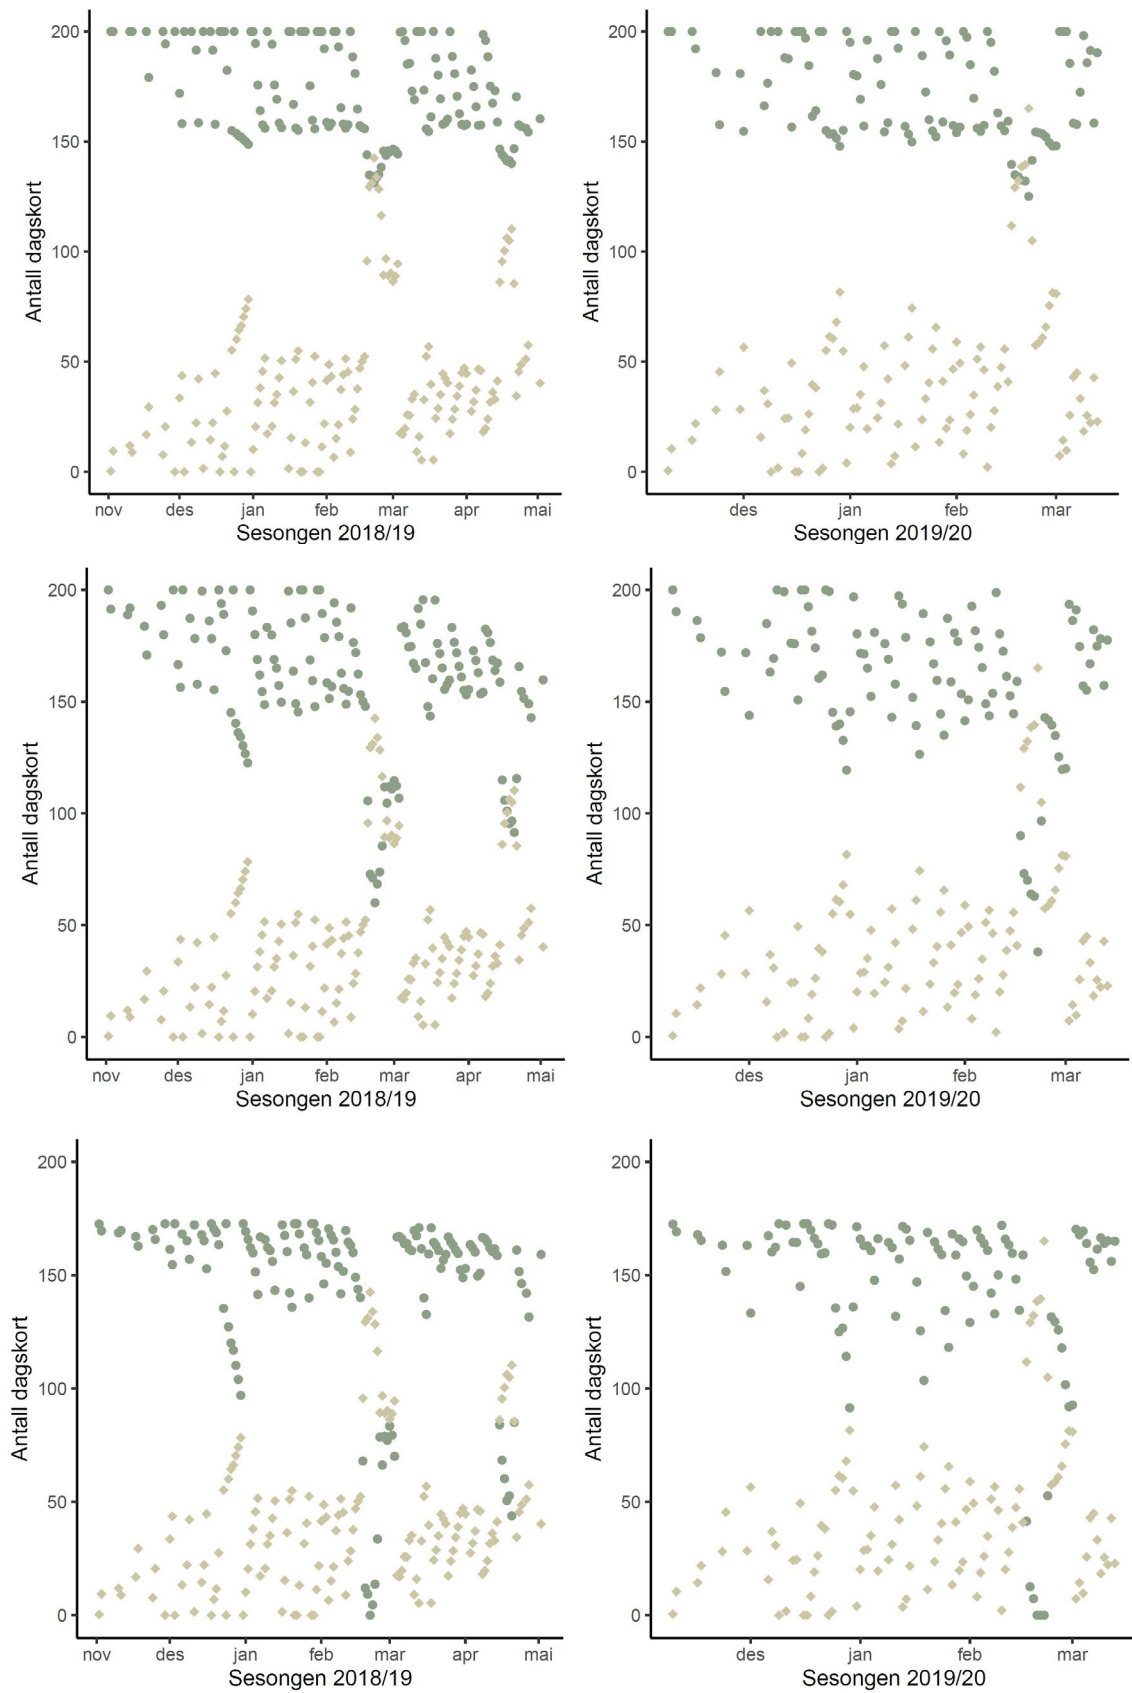


Figur 12 - Booking limit med tidsserieregresjonsmodell for 7 dagers prognosehorisont
 Øvre panel: Prisscenario 1, midterste panel: Prisscenario 2, og nedre panel: Prisscenario 3

● Booking limit ◆ Predikerte verdier

Vi kan se at for hver gang prisen reduseres med 100 kroner settes det lavere booking limits, og gjør det ganske likt som samme modell med en 2 dagers prognosehorisont. Tidsserie-regresjonsmodellen setter fortsatt flere lavere booking limits i tidlig sesong enn MLP-modellen (Se Figur 13) gjør i en 7 dagers prognosehorisont.

I neste figur ser vi på booking limits basert på MLP-modellen.



Figur 13 - Booking limit med MLP-modell for 7 dagers prognosehorisont
 Øvre panel: Prisscenario 1, midterste panel: Prisscenario 2, og nedre panel: Prisscenario 3

● Booking limit ◆ Predikerte verdier

I øvre panel i Figur 13 ser det ut som det er færre antall av booking limits som blir satt lik hele kapasitet i forhold til hva det var for en 2 dagers prognosehorisont (øvre panel i Figur 11). Igjen så settes det lavere booking limits i takt med at prisen blir satt ned.

I Tabell 11 viser en oversikt av booking limits for de to modellene og prisscenarioene.

	Minimum	Median	Gjennomsnitt	Maksimum
Tidsserieregresjonsmodell				
Prisscenario 1	116,2	176	173,5	200
Prisscenario 2	10,44	168,35	157,87	200
Prisscenario 3	0	160,9	137,3	171,6
MLP-modell				
Prisscenario 1	125,1	169,2	172,4	200
Prisscenario 2	38,11	165,02	159,42	200
Prisscenario 3	0	160,9	143,2	172,8

Tabell 11 - Oppsummering av booking limits for en prognosehorisont på 7 dager

Den store forskjellen mellom en 2 dagers prognosehorisont og en 7 dagers prognosehorisont for begge modellene er at det satt flere lavere booking limits i alle prisscenarioene, og det er spesielt synlig ved å se på medianen. Men gjennomsnittet har i nesten alle tilfeller blitt lavere, og dette har en sammenheng med at med en lengre prognosehorisont følger det større usikkerhet og dermed bør booking limiten settes lavere.

6.3.3 Evaluering av RM

Etter å ha sett hvordan booking limiten blir satt basert på prisscenarioene og prognosehorisontene er vi klare for å se hvordan booking limit kan øke inntjeningen. Da skal vi som sagt bruke RO, ARO og PARO som ble presentert i kapittel 2.2, og som en oppfriskning er de gitt ved:

$$RO = \text{Potensiell inntekt} - \text{Inntekt uten RM}$$

$$ARO = \text{Faktisk inntekt} - \text{Inntekt uten RM}$$

$$PARO = \frac{ARO}{RO}$$

For å kunne gjøre disse beregning måtte jeg ha etterspørselen etter rabatterte billetter, noe som mitt datasett ikke inneholdt. Mitt datasett inneholder kun salg av fullprisbilletter. Dermed har jeg støttet meg til tidligere forskning som har estimert prisresponsfunksjoner for ulike perioder og situasjoner (for eksempel ukedager vs. helgedager), og brukt rapporterte estimater av parameter til slike prisresponsfunksjoner til å beregne hvor mye etterspørselen vil kunne øke ved hvert prisscenario (Malasevska & Haugom, 2018). Fra Malasevska og Haugom (2018) brukte jeg resultatene fra skisenter 2, da dette skisenteret ligner mest på Beitostølen. Videre tok jeg høyde for at det er ulik økning i etterspørsel av rabatterte billetter på ukedager (mandag til torsdag) og helgedager (fredag til søndag). En antagelse jeg tar er at etterspørselen etter fullpris billetter og rabatterte billetter er uavhengig av hverandre, og vi vil diskutere dette nærmere i kapittel 7.2.

I Tabell 12 kan vi se en oversikt over beregning for hver prognosehorisont, modell og prisscenario. RO og ARO er beregnet for hver dag i testsett-perioden. Jeg har så beregnet gjennomsnittet og så beregnet PARO av disse aggregerte tallene.

		RO	ARO	PARO
2 dagers prognosehorisont				
Tidsserieregresjonsmodell				
	Prisscenario 1	10 332	9 455	91,51%
	Prisscenario 2	10 541	9 068	86,03%
	Prisscenario 3	12 434	10 705	86,09%
MLP-modell				
	Prisscenario 1	10 332	9 389	90,87%
	Prisscenario 2	10 541	8 693	82,47%
	Prisscenario 3	12 434	10 286	82,72%
7 dagers prognosehorisont				
Tidsserieregresjonsmodell				
	Prisscenario 1	10 332	9 447	91,43%
	Prisscenario 2	10 541	9 107	86,4%
	Prisscenario 3	12 434	10 800	86,86%
MLP-modell				
	Prisscenario 1	10 332	9 390	90,88%
	Prisscenario 2	10 541	8 704	82,57%
	Prisscenario 3	12 434	10 229	82,27%

Tabell 12 - RO, ARO og PARO for hver prognosehorisont, modell og prisscenario

Inntektsmuligheten (RO) for hvert prisscenario er lik, uavhengig av modell og prognosehorisont. Dette er gitt direkte av definisjonen for RO. Forskjellen ligger i hvor godt hver modell klarer å utnytte seg av inntektsmuligheten, og det er dette PARO sier noe om. Blant prisscenarioene er det prisscenario 3 som har størst inntektsmulighet, og det er også dette prisscenarioet hvor hver modell har oppnådd høyest inntektsmulighet (ARO). Men det er ikke nødvendigvis prisscenario 3 som prosentvis har oppnådd høyest inntektsmulighet av det som potensielt er mulig. For begge modellene oppnår de størst prosent av inntektsmuligheten (PARO) ved prisscenario 1 for begge prognosehorisontene.

Det finnes flere forklaringer på at PARO gjør det dårligere ved en lavere pris. Det som kan skje ved redusering i pris, er at det kan bli en økende etterspørsel, men i tilfelle med PARO, så øker ikke etterspørselen for lavprisbilletter til lavere pris like mye som etterspørselen til lavprisbilletter som har litt høyere pris, totalt sett.

Mellom prognosehorisontene for hver modell er det marginale forskjeller, men det er tydelig at tidsserieregresjonsmodellen gjør det bedre enn MLP-modellen. En av grunnene til at MLP-modellen gjør det dårligere enn tidsserieregresjonsmodellen kan være på grunn av at MLP-modellen ikke predikerer like høy etterspørsel som tidsserieregresjonsmodellen gjør, og dette reflekteres direkte i hvordan booking limitene blir fastsatt. Når vi ser på Figur 11 og Figur 13, ser vi at prognose generelt er lavere enn i tidsserieregresjonsmodellen (Figur 10 og Figur 12), og sett sammen med Tabell 10 og Tabell 11 ser vi at booking limitene generelt er høyere for MLP-modellen enn tidsserieregresjonsmodellen. Det vil si at med MLP-modellen selger vi generelt flere dagskort til rabattert pris enn med tidsserieregresjonsmodellen, som dermed gjør at den vil ha lavere inntjening enn tidsserieregresjonsmodellen.

7. Diskusjon

I dette kapitlet skal vi se på resultatene av analysene, og se de i sammenheng med tidligere forskning, metode- og med teorikapitlet. Formålet er å best mulig komme frem til en konklusjon.

7.1 Prognosemodeller

I denne oppgaven har jeg lagd prognoser basert på en tidsserieregresjon og en MLP for to ulike prognosehorisonter. Tidsserieregresjonsmodellen gjorde det generelt best basert på MSE for begge prognosehorisontene, og ved første øyekast kan det virke som tidsserieregresjonsmodellen gjør det best av modellene. Likevel må vi også vurdere hvordan prognosene gjør det i forhold til sMAPE. Basert på sMAPE viste resultatene at MLP modellen var noe mer nøyaktig for en prognosehorisont på 2 dager.

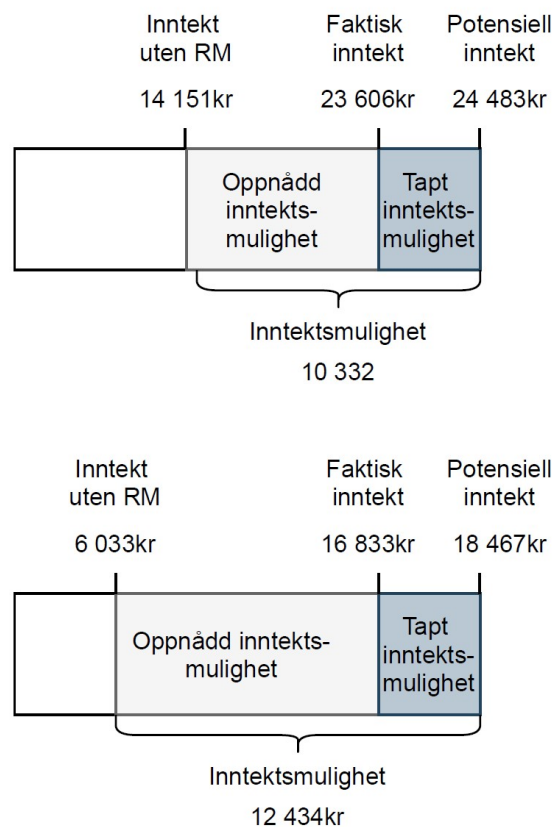
Nøyaktighetsmålene venter forskjellige faktorer, og det må vi ta høyde for når vi velger hvilket nøyaktighetsmål som bli lagt til grunn. For eksempel vil MSE forsterke store prognosefeil (Sanders, 2017), og her tyder det på at MLP-modellen har flere større prognosefeil enn tidsserieregresjonsmodellen har. Funnene i mitt studie tyder på at det ikke er den mest komplekse prognosemodellen som gir mest nøyaktige prediksjoner. Dette resultatet er i samsvar med funn fra større sammenligninger av prognosemodeller på mange ulike datasett (Makridakis & Hibon, 2000).

I tidligere forskning er sMAPE en av nøyaktighetsmålene som er brukt til å vurdere de ulike modellene, og for MLP har den blitt henholdsvis målt til 8,34% og 8,39% (Ahmed et al., 2010; Makridakis et al., 2018b). I min MLP-modell med begge prognosehorisontene gjør det dårlige enn disse, til og med dårligere enn benchmark-modellen til Makridakis et al. (2018b) med en SMAPE på 8,58%.

7.2 Revenue Management

Basert på modellene og prognosehorisontene som er beskrevet over har jeg også predikert booking limit for tre ulike prisscenarioer. For lavere rabatterte priser blir foreslått booking limit satt lavere. Dette henger direkte sammen med formelen for fastsettelse av optimal booking limit.

Tidligere forskning viser tydelig at en dynamisk pristilnærming kan være fremtiden for alpinanlegg (Falk & Vieru, 2017; Malasevska & Haugom, 2019; Malasevska et al., 2020), og resultatene i denne oppgaven er med på å bekrefte dette. Et topris system med fullprisbillett til 390 kroner og rabattert billett til 299 kroner, er det systemet basert på en tidsserie-regresjonsmodell med 2 dagers prognosehorisont, som utnytter inntektsmulighet best av alle systemene. Dette systemet har en PARO på 91,51%, og en inntektsmulighet på 10 332 kroner og av denne inntektsmuligheten er 9 455 kroner faktisk oppnådd. Selv om dette systemet utnytter inntektsmulighet best, så kan vi stille spørsmål ved om prisscenario 3 med større inntektsmulighet er et bedre valg av system. Dette topris systemet er med en fullprisbillett til 390 kroner og rabattert billett til 99kr, og det er tidsserieregresjonsmodellen med 7 dagers prognosehorisont som gjør det best på dette systemet. Dette systemet har en PARO på 86,86%, og en inntektsmulighet på 12 434 kroner og av dem faktisk oppnådd 10 286 kr. Vi kan se at denne gjør det betraktelig dårligere til å utnytte seg av inntektsmulighet, men igjen så virker det som dette systemet faktisk har oppnådd mer i kr.



Figur 14 - Faktisk ROM for beste system av prisscenario 1 og prisscenario 3
 Øvre panel: ROM for prisscenario 1 basert på tidsserieregresjonsmodellen med 2 dagers prognosehorisont
 Nedre panel: ROM for prisscenario 3 basert på tidsserieregresjonsmodellen med 7 dagers prognosehorisont

Figur 14 viser hvordan disse to systemene gjør det når vi visualiserer de basert på ROM. Fra nå av kaller jeg øvre panel i Figur 14 kun for prisscenario 1, og nedre panel i Figur 14 kun for prisscenario 3. Det er tydelig i figuren at det er stor forskjell mellom systemene, og i prisscenario 1 er inntekt uten RM nesten 2,5 ganger større enn hva den er i prisscenario 3. Inntekt uten RM er den inntekten alpinanlegget har ved et to-prissystem uten begrensninger for rabatterte billetter, og ved å innføre booking limits øker inntekten betraktelig fra en inntekt uten RM. I prisscenario 1 har en faktisk inntekt i gjennomsnitt på 23 606 kroner per åpne skidag, og utnytter seg av nesten hele potensielle inntekt som i gjennomsnitt på 24 483 kroner per åpne skidag. Prisscenario 3 gjør det mye dårligere og har en faktisk inntekt på i gjennomsnitt 16 833 kroner per åpne skidag, og utnytter ikke like godt den potensielle inntekten i gjennomsnitt som prisscenario 1. Det er tydelig at prisscenario 1 er best, både med tanke på PARO og med tanke på faktiske inntekter.

Når vi sammenligner faktiske inntekter med inntekter uten RM så blir det urealistisk i forhold til dagens situasjon. Siden Beitostølen skisenter har en fast pris på dagskort gjennom hele sesongen, så kan ikke det sammenlignes med hvordan inntekt uten RM er beregnet. I gjennomsnitt per åpne skidag er den faktiske inntekten Beitostølen har hatt beregnet til 13 637 kr, gitt en kapasitetsrestriksjon på 200 dagskort per dag. Det vil si at med et RM-system som jeg foreslår i denne oppgaven, kan Beitostølen skisenter øke sine inntekter med 9 969 kroner i gjennomsnitt per åpne skidag, det er en økning på ca. 73%.

Mine resultater viser videre at det ikke er noe å hente på å benytte veldig avanserte prognoseteknikker når et skisenter skal utvikle sitt eget RM-system. Faktisk er det slik at en enklere tidsserieregresjon viser seg å være bedre enn den mer avanserte MLP-modellen også når det kommer til å utløse inntekspotensialet fra det foreslåtte to-pris RM-systemet. Ledere av alpinanlegg kan derfor, både i Norge og internasjonalt, trygt starte med enklere modeller i utviklingsfasen av sin egen RM strategi.

8. Konklusjon

Målet med denne oppgaven har vært todelt; Ett av målene har vært å sammenligne prediksjonsevnen til to ulike prognosemodeller; en «enkel» og en «avansert». Det andre målet har vært å bruke begge prognosemodellene til å fastsette booking limit for hvor mange lavpris billetter Beitostølen skisenter bør tilby i et enkelt to-pris system.

Jeg har brukt to nøyaktighetsmål til å måle prediksjonsevnen til prognosemodellene, hvor den ene er MSE og den andre er SMAPE. Tidsserieregresjonsmodellen gjorde det merkbart bedre enn MLP-modellen basert på MSE, men MLP-modellen gjør det marginalt bedre enn tidsserieregresjonsmodellen for 2 dagers prognosehorisont basert på SMAPE. Hvilken modell som gjør det best avhenger altså noe av hvilket nøyaktighetsmål som benyttes, men vi kan konkludere med, i likhet med tidligere forskning at det er ikke nødvendigvis er de mer komplekse modellene som gir mest nøyaktige prognoser (Makridakis & Hibon, 2000).

Uavhengig av hvordan modellene gjorde det basert på nøyaktighetsmålene, har jeg også brukt prognosemodellene til å fastsette booking limits for tre ulike prisscenarioer. Det var tydelig at tidsserieregresjonen gjorde det generelt bedre enn MLP-modellen i alle tre prisscenarioene for begge horisonter. Systemet som gjorde det best var basert på en tidsserieregresjonsmodell med 2 dagers prognosehorisont, og rabattert pris lik 299 kroner. Beitostølen skisenter kan i gjennomsnitt øke inntjening på deres dagskort med en slik dynamisk pristilnærming i med 9 969 kroner per åpne skidag, og det tilsvarer en økning på ca. 73%.

Det er tydelig at en dynamisk tilnærming vil kunne forme etterspørsel og øke inntjeningen til alpinanlegget. Et slikt RM-system er absolutt noe et alpinanlegg bør vurdere å implementere. Da vil jeg anbefale å bruke en enkel prognoseteknikk fremfor en mer avansert, siden resultatene viser at dette også gir best resultat i praksis.

8.1 Begrensninger og videre forskning

I denne studien er det noen begrensninger som jeg nå kort vil bemerke. Disse begrensningene kan imidlertid også være et fint utgangspunkt for videre forskning på området. Den første begrensning som kan nevnes er at mine analyser kun omhandler ett alpinanlegg i Norge. Fremtidig forskning kan derfor med fordel utvides til å omfatte flere alpinanlegg både i Norge og internasjonalt for å se om de generelle resultatene fra mitt studie viser seg å være gjeldende også i analyser av andre anlegg.

Videre har jeg begrenset meg til å se på kun to prognosemodeller, to prognosehorisonter, et to-pris system, og tre ulike nivåer for rabatterte priser. En sammenligning av flere prognoseteknikker og horisonter, samt et system med tre eller flere prisklasser vil kunne være av stor verdi for alpinanlegg som tenker å implementere et RM-system. Til slutt bør det nevnes at jeg har valgt å begrense meg til analyser hvor jeg antar at fullpris- og lavprissetterspørselen er uavhengige av hverandre. Det er ikke slik det er i praksis, så videre forskning bør forsøke å utvide mine analyser til å ta hensyn til at lavprissetterspørselen i større eller mindre grad går på bekostning av fullprissetterspørselen.

Litteraturliste

- Abbott, D. (2014). *Applied predictive analytics: Principles and techniques for the professional data analyst* John Wiley & Sons.
- Ahmed, N. K., Atiya, A. F., Gayar, N. E. & El-Shishiny, H. (2010). An empirical comparison of machine learning models for time series forecasting. *Econometric Reviews*, 29(5-6), 594-621.
- Berman, B. (2005). Applying yield management pricing to your service business. *Business horizons*, 48(2), 169-179. <https://doi.org/10.1016/j.bushor.2004.10.015>
- Bodea, T. & Ferguson, M. (2014). *Segmentation, revenue management and pricing analytics* Routledge.
- Claveria, O. & Torra, S. (2014). Forecasting tourism demand to Catalonia: Neural networks vs. time series models. *Economic modelling*, 36, 220-228. <https://doi.org/10.1016/j.econmod.2013.09.024>
- Creswell, J. W. & Creswell, J. D. (2018). *Research design : qualitative, quantitative & mixed methods approaches* (5th edition. utg.). Los Angeles, California: Sage.
- Falk, M. & Hagsten, E. (2016). Importance of early snowfall for Swedish ski resorts: Evidence based on monthly data. *Tourism management (1982)*, 53, 61-73. <https://doi.org/10.1016/j.tourman.2015.09.002>
- Falk, M. & Vieru, M. (2017). Demand for downhill skiing in subarctic climates. *Scandinavian journal of hospitality and tourism*, 17(4), 388-405. <https://doi.org/10.1080/15022250.2016.1238780>
- Fnugg. (2017). Statsbudsjettet 2018 varsler momsøkning. Hentet fra <https://fnugg.no/artikler/pressemelding-alpinanleggenes-landsforening-alf-norske-fjell-as-momssjokk-reiselivet-okning-rammer-alpinnaeringen-hotell-ovrig-reiseliv-hardt/>
- Fnugg. (2021). Beitostølen Skisenter. Hentet 20.04.2021 fra <https://fnugg.no/beitostolen/>
- Gildestad, I. M., Dannevig, H., Steiger, R. & Aall, C. (2017). Konsekvensar av klimaendringar for norske skianlegg. *Vestlandsforskning, Sogndal*.
- Hafjell. (2020). Lift Pass Prices. Hentet 13.11.2020 fra <https://www.hafjell.no/en/heiskortpriser>
- Hair Jr., J. F., Black, W. C., Babin, B. J. & Anderson, R. E. (2019). *Multivariate Data Analysis* (Eighth. utg.).
- Harstveit, K., Sivle, A. D. & Evans, A. K. D. (2020). Luftrykk. Hentet fra <https://snl.no/luftrykk>
- Harstveit, K. & Velle, M. (2019). Lavtrykk. Hentet fra <https://snl.no/lavtrykk>
- Haugom, E. & Malasevska, I. (2019). The relative importance of ski resort- and weather-related characteristics when going alpine skiing. <https://doi.org/https://doi.org/10.1080/23311886.2019.1681246>
- Hinterhuber, A. & Liozu, S. M. (2014). Is innovation in pricing your next source of competitive advantage? *Business horizons*, 57(3), 413-423. <https://doi.org/10.1016/j.bushor.2014.01.002>
- Holmengen, H. (2012). Lillehammer ski resort: en imageundersøkelse.
- Hyndman, R. J. & Athanasopoulos, G. (2018). *Forecasting: principles and practice* OTexts.
- iPaaSki. (2021). About. Hentet 05.02.2021 fra <https://www.ipaaski.com/about/>
- James, G., Witten, D., Hastie, T. & Tibshirani, R. (2013). *An introduction to statistical learning* Springer.
- Khalidi, K. (2017). Quantitative, Qualitative or Mixed Research: Which Research Paradigm to Use? *Journal of Educational and Social Research*, 7(2), 15.

- Kimes, S. E. & Wirtz, J. (2003). Has revenue management become acceptable? Findings from an international study on the perceived fairness of rate fences. *Journal of service research*, 6(2), 125-135.
- Kuhn, M. & Johnson, K. (2013). *Applied predictive modeling* (Corrected at 5th printing 2016. utg.). New York, NY: Springer.
- Lorrenz, P. (2015). *Artificial Neural Systems: Principle and Practice* Bentham Science Publishers.
- Makridakis, S. & Hibon, M. (2000). The M3-Competition: results, conclusions and implications. *International journal of forecasting*, 16(4), 451-476. [https://doi.org/10.1016/S0169-2070\(00\)00057-1](https://doi.org/10.1016/S0169-2070(00)00057-1)
- Makridakis, S., Spiliotis, E. & Assimakopoulos, V. (2018a). The M4 Competition: Results, findings, conclusion and way forward. *International journal of forecasting*, 34(4), 802-808. <https://doi.org/10.1016/j.ijforecast.2018.06.001>
- Makridakis, S., Spiliotis, E. & Assimakopoulos, V. (2018b). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS One*, 13(3), e0194889-e0194889. <https://doi.org/10.1371/journal.pone.0194889>
- Malasevska, I. (2018). A hedonic price analysis of ski lift tickets in Norway. *Scandinavian journal of hospitality and tourism*, 18(2), 132-148. <https://doi.org/10.1080/15022250.2017.1322531>
- Malasevska, I. & Haugom, E. (2018). Optimal prices for alpine ski passes. *Tourism management* (1982), 64, 291-302. <https://doi.org/10.1016/j.tourman.2017.09.006>
- Malasevska, I. & Haugom, E. (2019). Alpine skiing demand patterns. *Scandinavian journal of hospitality and tourism*, 19(4-5), 390-403. <https://doi.org/10.1080/15022250.2018.1539924>
- Malasevska, I., Haugom, E., Hinterhuber, A., Lien, G. & Mydland, Ø. (2020). Dynamic pricing assuming demand shifting: the alpine skiing industry. *Journal of travel & tourism marketing*, 37(7), 785-803. <https://doi.org/10.1080/10548408.2020.1835787>
- Malasevska, I., Haugom, E. & Lien, G. (2017). Modelling and forecasting alpine skier visits. *Tourism economics : the business and finance of tourism and recreation*, 23(3), 669-679. <https://doi.org/10.5367/te.2015.0524>
- Meteorologisk Institutt. (2021a). Effektiv temperatur og «føles som». Hentet 18.03.21 fra <https://hjelp.yr.no/hc/no/articles/360001695513-Effektiv-temperatur-og-f%C3%B8les-som->
- Meteorologisk Institutt. (2021b). Observasjoner og værstatistikk. Hentet 26.02.2021 fra <https://seklima.met.no/observations/>
- Mushtaq, R. (2011). Augmented dickey fuller test. Hentet fra https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1911068
- Norefjell. (2020). Skipass. Hentet 13.11.2020 fra <https://www.norefjell.com/skipass>
- Norske alpinanlegg og fjelldestinasjoner. (2021). Bransjerapport 2018/19. Hentet 28.03.2021 fra <https://indd.adobe.com/view/cc2b0cf0-73a2-4ccc-bd99-b7bd3b9ffe8f>
- O'Brien, K., Aandahl, G., Orderud, G. & Sæther, B. (2003). Sårbarhetskartlegging - et utgangspunkt for klimadialog. *Plan*, (5), 12-17.
- Phillips, R. L. (2005). *Pricing and revenue optimization*. Stanford, Calif: Stanford Business Books.
- Queenan, C. C., Ferguson, M. E. & Stratman, J. K. (2011). Revenue management performance drivers: An exploratory analysis within the hotel industry. *Journal of revenue and pricing management*, 10(2), 172-188.
- Render, B., Stair jr., R. M., Hanna, M. E. & Hale, T. S. (2015). *Quantitative Analysis for Management*. Harlow: Pearson Education Limited.

- Riis, C. & Moen, E. R. (2017). *Moderne mikroøkonomi* (4. utg. utg.). Oslo: Gyldendal akademisk.
- Sanders, N. R. (2017). *Forecasting fundamentals*. New York, New York (222 East 46th Street, New York, NY 10017): Business Expert Press.
- SkiGeilo. (2020). Skipass & Pris. Hentet 13.11.2020 fra <https://www.skigeilo.no/skipass-og-priser>
- Skugge, G. (2004). Growing effective revenue managers. *Journal of revenue and pricing management*, 3(1), 49-61. <https://doi.org/10.1057/palgrave.rpm.5170093>
- Steiger, R., Posch, E., Tappeiner, G. & Walde, J. (2020). Effects of climate change on tourism demand considering individual seasonal preferences. *Working Paper in Economics and Statistics*.
- Temath, C. (2011). *Performance measurement in airline revenue management: A simulation-based assessment of the network-based revenue opportunity model* Universitätsbibliothek.
- Vanat, L. (2020). *2020 International Report on Snow & Mountain Tourism*. Hentet fra <https://www.vanat.ch/RM-world-report-2020.pdf>
- Velle, M. (2020). Høytrykk. Hentet fra <https://snl.no/h%C3%B8ytrykk>
- Winther, T., Ottesen, L., Øyen, A. H. & Hæhre, R. (2013). *Grunnleggende bedriftsøkonomi* (3. utg. utg.). Oslo: Gyldendal akademisk.

Vedlegg 1 - Gjennomsnittlig salg av dagskort fordelt på ukedag

