


# Mobildata og maskinlæring i transportanalyse: En sammenligning av prediktive modeller for estimering av reisemål



Forfattere:

Tarald Ødegård Foss, Konsulent i Capgemini Invent, tidligere masterstudent ved NMBU  
Øyvind Lervik Nilsen, Førsteamanuensis II ved NMBU, sjefsingeniør i Statens vegvesen  
Kristian Hove Liland, Professor ved NMBU.

Hvor vi velger å reise kan i dag estimeres i transportmodeller. Grunnlaget for denne estimeringen kan være et begrenset datagrunnlag fra den nasjonale reisevaneundersøkelsen. Dette kan gi usikre estimater og virkninger av transportprosjekter. Det er derfor behov for å se på nye datakilder og alternative tilnærminger for å kunne gi bedre estimeringen av reisemål. Mobildata sammen med ulike maskinlæringsteknikker sammenlignes for å predikere reisemål og evalueres etter presisjon, robusthet og anvendbarhet. Maskinlæringsteknikken *Dype Nevrale Nettverk* oppnår høyest forklaringsgrad, ( $R^2 = 0.76$ ), men Random Forest presterer best på tvers av modellkriteriene. Analysen viser muligheter for å kombinere mobildata og maskinlæring, og anbefaler videre forskning på usikkerhetsestimater og bruk av større og mer detaljerte datasett.



## INTRODUKSJON

Transportanalyser utgjør en viktig del av beslutningsgrunnlaget i statlige, regionale og kommunale planer. Analysene baserer seg ofte på de regionale og nasjonale persontransportmodellene (RTM og NTM). Disse brukes til å vurdere effekter av ulike tiltak i vegnettet og kollektivtilbudet. Modellene bygger på firetrinnsmetodikken, der antall reiser, reisemål, reisemiddel og rutevalg beregnes. Estimeringen

av reisemiddel- og reisemålvalg hviler i stor grad på data fra den nasjonale reisevaneundersøkelsen. I mange områder er antallet respondenter begrenset, og det er både kostbart og tidkrevende å bedre datagrunnlaget. Derfor er det behov for å vurdere alternative datakilder som kan supplere reisevaneundersøkelsen både som grunnlag inn i transportmodellene, men også for å få en bedre forståelse for reiseaktiviteten i et område.

Fremveksten av stordata, og utviklingen innen kunstig intelligens og maskinlæring, har både nasjonalt og internasjonalt ledet til anbefalinger om å undersøke bruk av KI for prediksjon i transportanalyser (Stigen et al., 2022). Estimeringen av reisemålet er helt sentralt fordi det er avgjørende for hvilket reisemiddel man velger når man skal foreta en reise, og påvirker dermed også utslippene fra transportsektoren.

Et tynt datagrunnlag fra reisevaneundersøkelsen kan påvirke estimeringen av reisemål og føre til en over- eller undervurdering. Dette kan gi feil estimat på distanse, reisetid og valg av reisemiddel (Flügel et al., 2021). I Norge benyttes ofte logitmodeller til estimering av reisevalg (Tørset et al., 2022). Tidligere forskning har imidlertid antydnet at maskinlæringsmodeller kan gi mer presise prediksjoner enn logitmodeller (Rahnasto et al., 2023; X. Zhao et al., 2020). Det å få økt kunnskap om bruk av supplerende datakilder til den nasjonale reisevaneundersøkelsen og teste andre beregningstilnæringer, som maskinlæringsmodeller, er derfor viktig for videreutvikling av dagens transportanalyseverktøy.

## MOBILDATA OG MASKINLÆRINGSMODELLER

Fremveksten av stordata og nye stordatakilder, som mobildata, har åpnet for mer detaljerte og tidsnære analyser av mobilitet (Tolouei et al., 2016; Landmark & Arnesen, 2025). Mobildata baserer seg på mobilmast-triangulering der posisjon beregnes ut fra signalstyrken til nærliggende master, og gir mulighet til å observere faktiske reisestrømmer på aggregert nivå, men mangler ofte informasjon om reisendes demografi, formål og transportmiddelvalg (Anda et al., 2016). Dette gir både nye muligheter og utfordringer for transportmodellering.

Maskinlæring (ML) har de siste årene fått økt oppmerksomhet som metode for å håndtere store og komplekse datasett, også i transportanalyse (Wang et al., 2024). I denne artikkelen sammenlignes tre ulike ML-modeller:

*Random Forest, XGBoost og Dype Nevrale Nettverk (DNN)*. Random Forest og XGBoost er trebaserte ensemblemetoder som er kjent for robusthet og god generaliseringsevne, også på skjeve og ufullstendige datasett (Fatima et al., 2023). DNN representerer dype modeller som kan fange opp komplekse, ikke-lineære sammenhenger, og er i hovedsak nyttig når datasettet er for stort for tradisjonelle ML-modeller (Janiesch et al., 2021; Marceau et al., 2020).

Modellene evalueres ut fra presisjon, robusthet og praktisk anvendbarhet, med utgangspunkt i et rammeverk for flermålsanalyse (MCDA) (Bouyssou, 1990). Dette gir grunnlag for å vurdere både teknisk ytelse og modellens verdi som beslutningsstøtte i transportplanlegging.

## EVALUERING AV ULIKE TILNÆRMINGER

Formålet med dette kapitlet er å redegjøre for det metodiske rammeverket som ligger til grunn for analysen. CRISP-DM anvendes som metode for å utvikle og evaluere regresjonsmodeller som skal forklare og predikere reisemål basert på mobildata. Det legges vekt på implementeringen av modeller for å demonstrere både verdien og den praktiske anvendelsen av mobildata. Alle seks fasene i CRISP-DM er fulgt for å sikre et solid grunnlag for modellutvikling og implementering (Schröer et al., 2021). De ulike delene er ytterligere beskrevet i punktene under.

### Forretningsmål og suksesskriterier

Forskningsspørsmålene som denne oppgaven bygger på er å identifisere hvilken maskinlæringsmodell som gir best presisjon i prediksjon av destinasjoner basert på mobildata, og å undersøke hvordan slike modeller praktisk kan anvendes som beslutningsstøtte i transportplanlegging. Målet er med det å svare på anbefalinger om bedre utnyttelse av maskinlæring til transportanalyse (Stigen et al., 2022; Nguyen et al., 2018; Wang et al., 2024). Tre sentrale suksesskriterier er lagt til grunn:

1. Modellen skal oppnå en forklaringsgrad ( $R^2$ -verdi) på minst 0,75, som et mål på teknisk prestasjon og bevis av konsept (Sarstedt & Mooi, 2014).
2. Modellen må kunne generalisere på tvers av geografiske soner og tidspunkter, og vise robusthet og praktisk nytte – altså bevis av verdi (Molnar, 2020).
3. Modellens implementerbarhet må vises i praksis, som et bidrag til bevis av bruk (Arnesen et al., 2019).

### Dataforberedelse

Datasettet som benyttes i denne oppgaven er basert på mobildata fra Telia, hentet fra Tønsbergområdet, og tilgjengeliggjort av Rambøll. Det inneholder både rådata og et aggregert og bearbeidet datasett. Rådataene består av alle forflytninger mellom mobil-master i ulike soner fra 2019, og inneholder over 79 millioner reiser. Det bearbeidede datasettet summerer alle reiser mellom unike sonepar, og er aggregert til 369 432 rader. For å beskrive områdene der reiser starter og slutter, er ekstern informasjon om sonene lagt til (Nilsen et al., 2021). Dette inkluderer data om befolkning, arbeidsplasser, handelsmuligheter og avstand mellom sonene. Det er viktig å være bevisst på begrensninger, som fravær av demografiske og sosioøkonomiske variabler, samt usikkerhet knyttet til registrering av reiser (Flügel et al., 2021). I tillegg er datasettet avgrenset til reiser som starter, passerer gjennom eller ender i Tønsberg kommune. Denne avgrensningen gjør at reiser utenfor kommunen ikke tas med, noe som gir mangelfull dekning av viktige reisestrømmer.

Datasettet er bearbeidet for å gjøre det egnet til modellering. Dette omfatter fjerning av irrelevante variabler, sammenslåing av datasett fra ulike tidspunkter med en kategorisk tidsvariabel, oppdeling i trenings- og testsett, transformasjon av målvariabelen for å håndtere skjevfordeling, samt normalisering av numeriske variabler for DNN-modellen. (Kuhn & Johnson, 2013; Goodfellow et al., 2016).

### Modellering

Tre regresjonsmodeller er utviklet og trent: Random Forest, XGBoost og Dype Nevrale Nettverk (DNN). Modellene er valgt med

utgangspunkt i tidligere forskning som har vist at trebaserte metoder som Random Forest og XGBoost er robuste (Fatima et al., 2023) og gir gode resultater på mobildata (Olsen, 2024), mens DNN er inkludert for å undersøke potensialet i dype modeller på større og mer komplekse datasett (Janiesch et al., 2021; Marceau et al., 2020).

### Evaluering

Modellene er evaluert etter flere kriterier, der prediksjonspresisjon, stabilitet, robusthet, generalisering, prediksjonsusikkerhet, tolkbarhet og overtilpasning er blant de viktigste (Chicco et al., 2021; Molnar, 2020). For å oppsummere evalueringen og identifisere den modellen som er best egnet for videre bruk, er det gjennomført en flermålsanalyse (MCDA) der hver modell er tildelt score på vektete kriterier (Bouyssou, 1990).

### Implementering

Modellene er implementert i et verktøy som kan simulere effekten av endringer i inputvariabler på reisemål mellom soner. Implementeringen er gjort for å demonstrere praktisk nytte og bruk av mobildata og maskinlæring i transportanalyse, i tråd med Arnesen et al. (2019). Verktøyet demonstreres gjennom konkrete caser, der modellen benyttes som et beslutningsverktøy til å estimere effekten av endringer i distanse og arbeidsplasser.



## RESULTATER

Analysens resultater, Tabell 1, viser at alle tre maskinlæringsmodeller oppnår relativt høy forklaringsgrad ( $R^2$ ) på test-data, men med ulike styrker. En høy forklaringsgrad viser at modellene ikke bare klarer å skille mellom høye og lave verdier, men også, basert på tilgjengelige inputvariabler, gir en forklaring på hvorfor disse forskjellene oppstår. DNN-modellen oppnår høyest forklaringsgrad ( $R^2 = 0,76$ ), mens Random Forest har best balanse mellom kvadrert, absolutt og prosentvis feil. En gjennomsnittlig absolutt feil (MAE) på 100 betyr at modellenes prediksjoner i snitt avviker med rundt 100 enheter fra de faktiske verdiene. MAPE og median MAPE viser hvor store avvikene er sammenlignet med de faktiske verdiene. At MAPE er betydelig høyere enn median MAPE, tyder på at noen få prediksjoner

har svært store feil og trekker gjennomsnittet opp. MAPE er gjennomsnittlig prosentfeil, mens median MAPE er medianen og dermed mindre påvirket av ekstreme verdier.

Tabell 1: Resultater fra tre modeller trent på test-data. Modellene er tre

	RF	XGB	DNN
<b>MSE</b>	810 372	987 606	707 983
<b>MAE</b>	104	100	118
<b>R<sup>2</sup></b>	0.73	0.67	0.76
<b>MAPE</b>	200%	252%	171%
<b>MEDIAN MAPE</b>	56%	64%	100%

Datasettet som benyttes i analysen er preget av en høyreskjev fordeling, der de fleste sonepar har et lavt antall reiser, mens et fåtall har svært høye verdier. Dette gir utfordringer for modellene når det gjelder å forklare variasjonen i både store og små reisemengder. Resultatene viser at alle modellene har større utfordringer med å forklare variasjonen når antallet reiser er lavt. Tabell 2 viser resultater fra de tre modellene testet på filtrerte deler av datasettet, og illustrerer hvor godt den klarer å forklare variasjonen for ulike segmenter. Random Forest og XGBoost har negativ forklaringsgrad (R<sup>2</sup>) for sonepar med færre enn 1000 reiser, mens DNN-modellen viser noe høyere forklaringssevne i dette segmentet. Når det gjelder sonepar med høyt reisevolum, presterer alle modellene bedre, med R<sup>2</sup>-verdier rundt 0,5.

Tabell 2: Viser resultater fra globale modeller testet på test-data, filtrert på ulike verdier. Viser hvordan modellene generaliserer på ulike datatyper.

INTERVALL	R <sup>2</sup> (LOG)	R <sup>2</sup> (UTEN LOG)
<b>REISER &lt; 1000</b>	0.86	-10.64
<b>REISER &gt; 1000, OG REISER &lt; 10 000</b>	0.43	-0.61
<b>REISER &gt; 10 000</b>	0.36	0.55

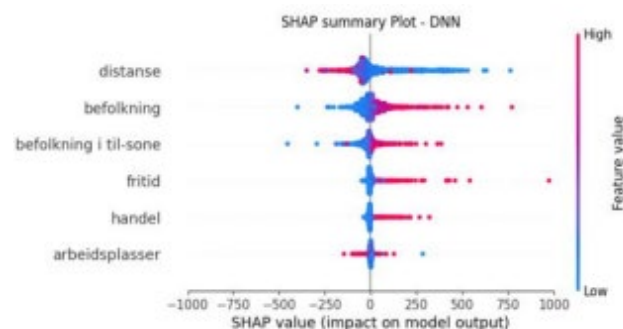
Transformasjon av målvariabelen, for eksempel log-transformasjon, kan redusere påvirkningen av ekstremverdier og bedre modellens evne til å håndtere ubalansert data. Samtidig reduseres forklaringsgraden for sonepar med mange reiser når transformasjon benyttes, se Tabell 3. Dette viser at valg av tapsfunksjon og transformasjon bør tilpasses analysens formål.

Tabell 3: XGBoost-modellen trent med log-transformert målvariabel. Testet på filtrert test-data, og viser hvordan modellen presterer på datapunkter med ulike reisemengder.

	RF	XGB	DNN
<b>REISER &lt; 1000</b>	-2.22	-10.64	0.52
<b>REISER &gt;1000 OG REISER &lt; 10000</b>	-0.15	-0.61	-1.27
<b>REISER &gt; 10000</b>	0.50	0.55	0.59

### Tolkbarhet og anvendelighet

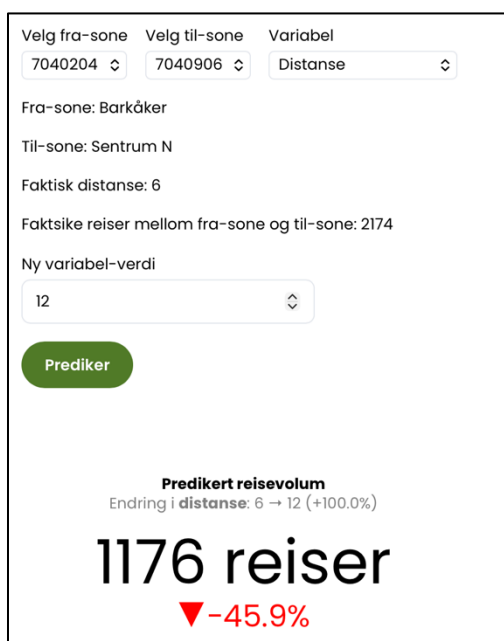
Tolkbarhetsanalysene viser at Random Forest og XGBoost gir tydelige og forventede mønstre for variabelbetydning, mens DNN-modellen er vanskeligere å tolke, men identifiserer likevel gjenkjennbare sammenhenger, se Figur 1. Når det gjelder beregningstid, bruker DNN betydelig lengre tid på trening enn de trebaserte modellene, men forskjellen har begrenset praktisk betydning siden modellene hovedsakelig trenes i forkant av bruk.



Figur 1: SHAP-analyse for DNN-modellen. Analysen viser hvordan høye og lave verdier for de ulike inputvariablene driver prediksjonene (Feature value).

### Implementering

For å demonstrere implementeringen av modellen er det laget et verktøy som viser konsekvensene av endringer i ulike inputvariabler, vist i Figur 2.



Figur 2: Resultater fra case, som viser effekten redusert distanse har på reiseomfang. Omfordelingen fører til en reduksjon fra 2174 til 1176 reiser på et år.

Figur 2 viser hvordan en distanseendring fra 6 til 12 km mellom to soner reduserer antallet reiser med 46% mellom disse to sonene.

### Stabilitet

For å undersøke modellusikkerheten ble det trent flere instanser av hver modelltype med ulike initialiseringsverdier (random seeds). Resultatene, vist i Tabell 4, viser at Random Forest-modellen har lavest standardavvik og relativt standardavvik. Standardavviket viser hvor mye prediksjonene varierer mellom de ulike modellinstansene, og det relative standardavviket viser variasjonen i forhold til snittprediksjonen.

Tabell 1: Viser stabiliteten til de tre modellene trent uten transformert-målvariabel.

MODELL	STD	RELATIV STD
RF	15.9	8%
XGB	56.6	105%
DNN	94.5	137%

## DISKUSJON

Resultatene viser at dype nevralt nettverk (DNN) ikke gir vesentlig bedre prediksjoner av reisevolum enn trebaserte modeller, til tross for lengre treningstid. DNN oppnår riktignok best forklaringsgrad og gjennomsnittlig kvadrert feil, noe som indikerer potensial for bruk ved analyse av store og komplekse datasett. Likevel forklares den begrensede merverdien av at datasettet i denne studien er aggregert og dermed mindre komplekst (Janiesch et al., 2021). Dette samsvarer med tidligere funn som viser at beslutningstrær ofte presterer like godt som dype modeller når datamengden og kompleksiteten er begrenset (Marceau et al., 2020).

Blant de tre modellene presterer Random Forest best samlet sett, med høy presisjon og relativt lav absolutt feil, som kan forklares med modellens evne til å ikke la seg påvirke av uteliggere (Fatima et al., 2023). XGBoost, på sin side, er mer sensitiv for ekstreme verdier og presterer best på delsett med høyt reisevolum, spesielt etter log-transformasjon av målvariabelen. Samtidig kan denne transformasjonen redusere ytelsen på de viktigste soneparene i byområder.

Samlet viser analysen at valg av modell bør tilpasses datasettets størrelse og kompleksitet, samt hvilke deler av reisefordelingen som er viktigst å predikere.

### Bevis av konsept

Når en regresjonsmodell skal vurderes, finnes det flere evalueringsmål. Chicco et al. (2021) påpeker at mål som kvadrert, absolutt og prosentvis feil (MSE, MAE og MAPE) kan variere fra 0 til uendelig, og er derfor vanskelige å bruke alene for å evaluere modellkvalitet. Chicco et al. (2021) fremhever derfor forklaringsgrad ( $R^2$ ) som et mer relevant mål, ettersom det beskriver inputvariablenes evne til å forklare målvariabelen og er uavhengig av målvariabelens absolutte verdier. Ifølge Ozili (2022) regnes  $R^2$  under 0,6 som svakt, mens Sarstedt og Mooi (2014) viser til en tommelfingerregel der 0,75, 0,5 og 0,25 tilsvarer henholdsvis sterk, moderat og svak forklaringsgrad. Slike regler må likevel tilpasses konteksten.  $R^2$ -verdiene i denne studien vurderes som akseptable gitt formålet, og det er rimelig høy

sammenheng mellom inputvariabler og målvariabel. Samtidig ville flere forklarende variabler, som bompenger og reisetid, trolig økt forklaringsgraden ytterligere. Ozili (2022) påpeker også at det er vanskelig for en modell å forklare alle faktorer bak menneskelige valg, som reisemål er.

Gjennomsnittlig absolutt feil (MAE) på 95 er vanskelig å tolke isolert, men gir mer mening i lys av variasjonen i datasettet. For sonepar med under 100 reiser er dette en høy feil, mens det er akseptabelt for relasjoner med flere tusen reiser. Det viktigste er at modellen predikerer i riktig størrelsesorden, slik at effekten av tiltak kan vurderes.

Den laveste relative feilen fra de trente modellene hadde DNN med 171%, noe som tilsvarer at prediksjonene i snitt avviker nesten tre ganger fra de faktiske verdiene. Dette er høyt, men median prosentvis feil på rundt 50% tyder på at enkelte ekstremverdier trekker snittet opp. Selv om flere evalueringsmål peker på muligheter, viser resultatene at modellene fortsatt er under utvikling og langt fra perfekte. Når dette vurderes i lys av datasettets begrensninger, er det likevel rimelig å konkludere med at modellene har konseptuell nytteverdi og potensial for videre utvikling.

Landmark og Arnesen (2025) har blant annet trukket frem tolkbarheten til mobildata som en av faktorene som skaper usikkerhet rundt integreringen i transportmodeller. Selv om det naturligvis ikke er like enkelt for en transportanalytiker å forstå sammenhengene i en maskinlæringsmodell sammenlignet med mer tradisjonelle metoder, viser tolkbarhetsanalysene i denne studien at modellenes resultater i stor grad er i tråd med eksisterende faglige antakelser. Et annet viktig diskusjonspunkt er at turer som foregår internt innenfor én sone ikke inkluderes i datasettet. Eksisterende datakilder har derimot vist at en andel av hverdagsreisene ikke krysser grunnkretsgrenser. Dette antyder at modellene trent på mobildata i praksis kun er egnet for å predikere lengre reiser mellom soner, og ikke lokale turer innenfor én sone – noe som utgjør en betydelig begrensning.

### Bevis av verdi

Tradisjonelle datakilder som reisevaneundersøkelser gir detaljert informasjon om formål, transportmiddel og reisemiddelvalg, men mangler kvantitativ bredde. Dette utløser behovet for nye datakilder som enten kan supplere eller erstatte dagens verktøy. Resultatene viser at det er mulig å hente ut verdifull innsikt fra mobildata brukt alene – uten støtte fra reisevaneundersøkelser.

Deterministiske modeller har i begrenset grad evne til å håndtere usikkerhet i prediksjonene – noe det både er økende behov for og etterspørsel etter (Stigen et al., 2022). Willumsen (2021) har pekt på usikkerhetsanalyser som en av forskningsmulighetene ved stordata. Usikkerhets- og stabilitets-analysene i denne studien viser at stokastiske og dynamiske modeller, slik som maskinlæringsmodeller, gir muligheter for å kvantifisere variasjon og prediksjonsusikkerhet.

Et viktig aspekt ved bruk av mobildata i transportanalyse er å dokumentere den praktiske verdien og anvendbarheten (Arnesen et al., 2019). Resultatene fra modellimplementeringen viser hvordan analysene kan benyttes direkte til å simulere effekten av ulike trafikale tiltak. Dette støtter også ønsket om mer datadrevet beslutningsstøtte (Stigen et al., 2022). Steinsland et al. (2022) påpeker at dagens transportmodeller forutsetter at historisk atferd danner grunnlag for fremtidige prediksjoner – en forutsetning som også gjelder denne oppgavens modeller. Til forskjell har modellene i denne studien fordelen av å kunne oppdateres kontinuerlig og trenes på ny data, noe som åpner for raskere tilpasning til endrede mønstre og trender i transportsystemet.



## KONKLUSJON

Studien viser at mobildata kombinert med maskinlæring kan benyttes til å predikere reisemål i transportanalyse. Dette gjelder ikke de aller korteste reisene som ikke rapporteres i mobildataene, og dermed ikke inngår i estimeringsgrunnlaget til maskinlæringsmodellene. Videre inneholder ikke mobildata informasjon om sosioøkonomiske aspekter og reisehensikt som ofte er sentrale i beregning av

transporttetter spørsmål. Disse begrensningene bør tas i betraktning ved videre analyser og anvendelse av mobildata.

Resultatene dokumenterer at maksinlærings-modeller kan gi verdifull innsikt om reisemønstre, og at mobildata har forklaringskraft også uten støtte fra tradisjonelle reisevane-undersøkelser. Random Forest fremstår som den mest robuste modellen med dagens data-grunnlag, mens dype nevralt nettverk har potensial ved større og mer detaljerte datasett. Studien gir et første bevis på at mobildata og maskinlæring kan brukes som beslutningsstøtte i transportplanlegging for å predikere fordelingen av reiser, og peker på behovet for videre forskning på usikkerhetsestimater og utvidet datagrunnlag for å realisere det fulle potensialet i avanserte modeller.

Denne artikkelen er basert på hovedforfatterens masteroppgave i Industriell økonomi ved NMBU, våren 2025. Masteroppgaven omfatter 30 studiepoeng, og er utarbeidet ved Fakultetet for realfag og teknologi.



## KILDER

Anda, C., Fourie, P., & Erath, A. (2016). *Transport Modelling in the Age of Big Data*. FCL. <https://ethz.ch/content/dam/ethz/special-interest/baug/ivt/ivtdam/vpl/reports/1101-1200/ab1164.pdf>

Arnesen, P., Landmark, A. D., Hjelkrem, O. A., & Södersten, C. (2019). *Mobility Analytics*. Sintef. <https://sintef.brage.unit.no/sintef-xmlui/handle/11250/2653972>

Bouyssou, D. (1990). BUILDING CRITERIA: A PREREQUISITE FOR MCDA. Springer. <https://citeseerx.ist.psu.edu/document?repid=rep1&type=pdf&doi=f0d92b325a2a68edccdc2a378d929e1b2d896>

Chicco, D., Warrens, M. J., & Jurman, G. (2021). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*. <https://peerj.com/articles/cs-623.pdf>

Fatima, S., Hussain, A., Amir, S. B., Ahmed, S. H., & Aslam, S. M. H. (2023). XGBoost and Random Forest Algorithms: An In-Depth Analysis. *Pakistan Journal of Scientific Research*, 3(1). <https://pdfs.semanticscholar.org/8abb/99db16d6ccc080e3c2a2bb207c9ea20cd5e6.pdf>

Flügel, S., Madslie, A., Hulleberg, N., Steinsland, C., & Johansen, B. G. (2021). *Transportmodeller mot fremtiden* (No. 1819). TØI. [https://www.toi.no/getfile.php/1355996-1619079239/Publikasjoner/TØI%20rapporter/2021/1819-2021/1819-2021\\_elektronisk.pdf](https://www.toi.no/getfile.php/1355996-1619079239/Publikasjoner/TØI%20rapporter/2021/1819-2021/1819-2021_elektronisk.pdf)

Goodfellow, I., Benigo, Y., & Courville, A. (2016). *DEEP LEARNING*. MIT Press.

Janiesch, C., Zschech, P., & Heinrich, K. (2021). Machine learning and deep learning. *Electronic Markets*. <https://link.springer.com/content/pdf/10.1007/s12525-021-00475-2.pdf>

Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. Springer. <https://link.springer.com/book/10.1007/978-1-4614-6849-3>

Landmark, A. D., & Arnesen, P. (2025). Hvor nyttig er mobildata for å undersøke folks reisevaner? *SINTEFblogg*. <https://blogg.sintef.no/digital/hvor-nyttig-er-mobildata-fora-undersoke-folks-reisevaner/>

Marceau, L., Lingling Qiu, Nick Vandewiele, & Eric Charton. (2020). *A COMPARISON OF DEEP LEARNING PERFORMANCES WITH OTHER MACHINE LEARNING ALGORITHMS ON CREDIT SCORING UNBALANCED DATA*. National Bank Of Canada. <https://arxiv.org/pdf/1907.12363>

Molnar, C. (2020). *Interpretable Machine Learning: A Guide For Making Black Box Models Explainable* (3. utg.). github. <https://christophm.github.io/interpretable-ml-book/>

Nguyen, H., Kieu, L.-M., Wen, T., & Cai, C. (2018). Deep learning methods in transportation domain: A review. *IET Journals*. [https://www.researchgate.net/publication/326741678\\_Deep\\_learning\\_methods\\_in\\_transportation\\_domain\\_A\\_review](https://www.researchgate.net/publication/326741678_Deep_learning_methods_in_transportation_domain_A_review)

Nilsen, Ø. L., Uteng, A., & Myrberg, G. (2021). *MOBILITETSKARTLEGGING TØNSBERG*. Rambøll. [https://www.tonsberg.kommune.no/\\_f/p1/i83e37574-5ed0-4d30-b5f2-e9529c2a6312/kartlegging-av-mobilitet-i-ny-kommune.pdf](https://www.tonsberg.kommune.no/_f/p1/i83e37574-5ed0-4d30-b5f2-e9529c2a6312/kartlegging-av-mobilitet-i-ny-kommune.pdf)

Olsen, K. (2024). *Prediction of destination choice in transport modelling with mobile phone data and machine learning models: Experiences from Tønsberg* [NMBU].

<https://nmbu.brage.unit.no/nmbuxmlui/bitstream/handle/11250/3148031/no.nmbu:wiseflow:7110333:59110574.pdf?sequence=1>

Ozili, P. K. (2022). *The Acceptable R-square in Empirical Modelling for Social Science Research*. SSRN Electronic Journal.  
[https://mpr.ub.unimuenchen.de/116496/1/MPRA\\_paper\\_116496.pdf](https://mpr.ub.unimuenchen.de/116496/1/MPRA_paper_116496.pdf)

Rahnasto, I., Hollestelle, M., & Ramboll Finland. (2023). *INCREASING DESTINATION CHOICE MODEL ACCURACY OF ACTIVITY- BASED MODELS WITH MACHINE LEARNING*. EUROPEAN TRANSPORT CONFERENCE.

Samferdselsdepartementet. (2024). *Nasjonal transportplan 2025-2036*. Regjeringen.no.  
<https://www.regjeringen.no/no/dokumenter/meld.-st.-14-20232024/id3017436/>

Sarstedt, M., & Mooi, E. (2014). *Regression Analysis*. ResearchGate.

Schröer, C., Kruse, F., & Gómez, J. M. (2021). Applying CRISP-DM Process Model on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181, 526–534.

Steinsland, C., Madslie, A., Johansen, K. W., & Wangsness, P. B. (2022). *Transportmodellberegninger*. TØI.  
<https://www.toi.no/publikasjoner/konseptvalgutredning-veibruksavgift-og-bompengervedlegg-6-3-transportmodellberegninger>

Stigen, T., Nilsen, Ø. L., & Andersen, S. N. (2022). *VURDERING AV FRAMTIDIG TRANSPORTMODELLEBEHOV I OG UTENFOR BYOMRÅDER*. Rambøll.  
<https://vegvesen.brage.unit.no/vegvesenxmlui/bitstream/handle/11250/3154774/270924%20VURDERING%20AV%20FRAMTIDIG%20TRANSPORTMODELLEBEHOV%20I%20OG%20UTENFOR%20BYOMRÅDER.pdf?sequence=1&isAllowed=y>

Tolouei, R., Psarras, S., & Prince, R. (2016). Origin-Destination Trip Matrix Development: Conventional Methods versus Mobile Phone Data. *Transport Research Procedia*, 26, 39–52.

Tørset, T., Malmin, O. K., Flaata, E. H., & Hjelkrem, O. A. (2022). *Cube – Regional persontransportmodell versjon 4.4 (Rapport 2021:01297)*. SINTEF Community.  
<https://hdl.handle.net/11250/3042790>

Wang, H., Tian, H., Chen, J., Wan, X., Xia, J., Gaoxiong Zeng, Bai, W., Jiang, J., Wang, Y., & Chen, K. (2024). Towards Domain-Specific Network Transport for Distributed DNN Training. *Usenix*.  
<https://www.usenix.org/system/files/nsdi24-wang-hao.pdf>

Willumsen, L. G. (2021). Use of big data in transport modelling. *International Transport Forum Discussion Paper*. <https://doi.org/10.1787/86a128c7-en>

Willumsen, L. G., & Ortúzar, J. de D. (1994). *Modelling Transport* (2. utg.). WILEY.

Zhao, X., Xiang, Y., Yu, A., & Van Hentenryck, P. (2020). Prediction and behavioral analysis of travel mode choice: A comparison of machine learning and logit models. *Travel behaviour and society*, 20, 22–35.