



# Bildegjennkjenning i vurdering av skredfare

Mulighetsstudie av bildeserie fra Slettsvaet i Romsdalen

STATENS VEGVESENS RAPPORTER

Nr. 636



## Tittel

Utprøving av bildeserie fra Slettsvaet i Romsdalen

## Undertittel

Utprøving av bildeserie fra Slettsvaet i Romsdalen

## Forfatter

Torbjørn Smørgrav og Eivind Susort (Geomonitor AS)

## Avdeling

Fagressurser Drift og vedlikehold

## Seksjon

Geofag Drift og vedlikehold

## Prosjektnummer

603423

## Rapportnummer

Nr. 636

## Prosjektleder

Tore Humstad

## Godkjent av

Tore Humstad

## Emneord

bildegjenkjenning, snøskred, maskinlæring

## Sammendrag

I dette prosjektet har Statens vegvesen sammen med Geomonitor AS undersøkt muligheter for å bruke bildegjenkjenning i bilder fra skredutsatte områder til å detektere skred og vesentlige endringer i snødekket. Målet er å etablere en automatikk, der bilder som er interessante for varsling og beredskap automatisk klassifiseres og sendes til rette vedkommende.

Resultatene fra studien viste at det var mulig filtrere ut bilder som ikke er av interesse for manuell analyse. Fortsatt er det behov for å forbedre dataprosessering og behandling for å få vesentlig utbytte av selve analysearbeidet relatert til skred og skredrelaterte observasjoner.

Maskinlæring er avhengig av store datamengder. Bilder fra flere sesonger ville økt forutsetningene for å bruke maskinlæring mer effektivt. En annen måte å øke datamengdene på er å bruke bilder fra flere kamera.

## Title

Image Recognition for Avalanche Danger Assessment

## Subtitle

Feasibility Analysis on Photo Series from Slettsvaet in Romsdalen, Norway

## Author

Torbjørn Smørgrav and Eivind Susort (Geomonitor AS)

## Department

Planning and Engineering Services

## Section

Geoscience Operation and Maintenance

## Project number

603423

## Report number

No. 636

## Project manager

Tore Humstad

## Approved by

Tore Humstad

## Key words

Image Recognition, Snow Avalanche, Machine Learning


## Summary

In this project, we have investigated the possibilities of using image recognition of images from avalanche terrain to detect avalanches and significant changes in the snow cover. The goal is to establish an automatic process, where images that are interesting for avalanche warning services, are automatically classified and sent to the appropriate professionals.

The results of this review showed that it was possible to filter out images that are not of interest for manual analysis. There is still a need to improve data processing and processing in order to gain significant benefit from the actual analysis work related to avalanches and danger sign observations.



# Deteksjon og varsling av skred ved hjelp av bildegjenkjenning



Pilotprosjekt: Veslefjellet, Møre og Romsdal  
Forfattere: Torbjørn Smørgrav og Eivind Susort  
Oppdragsgiver: Statens vegvesen



## Om prosjektet

I dette prosjektet har vi undersøkt muligheter for å bruke bildegjenkjenning i bilder fra skredutsatte områder til å detektere skred og vesentlige endringer i snødekket. I tillegg til bildegjenkjenning inkluderer prosjektet også systemutvikling for integrasjon mellom regObs<sup>1</sup> og GeoMonitor webportal<sup>2</sup> for å automatisere rapportering ved relevante situasjoner og observasjoner. Et kamera lokalisert på Veslefjellet i Rauma i Møre og Romsdal har sendt daglige bilder av løsneområdet på "Slettsvaet" på motsatt side av Romsdalen. Disse bildene har blitt brukt i dette pilotprosjektet og er innsamlet i perioden mars 2018- september 2019. I denne rapporten vil vi gå nærmere inn på metoder og resultater fra utvikling av system og erfaringer med bruk av bildegjenkjenning.

Søkeord: Bildegjenkjenning, snødekke, kamera, regObs

Publisert av: GeoMonitor AS, Frakkagjerdveien 191, 5563 Førresfjorden, Norge

---

<sup>1</sup> (n.d.). regObs. Retrieved September 6, 2019, from <https://www.regobs.no/>

<sup>2</sup> (n.d.). GeoMonitor | Enkel tilgang til krevende lokasjoner. Retrieved September 6, 2019, from <https://www.geomonitor.no/>



<b>Om prosjektet</b>	<b>2</b>
<b>Innledning</b>	<b>4</b>
<b>Metoder</b>	<b>6</b>
Henting av bilder	6
Bildebehandling	6
Annotering	6
Preprosessering	6
Skalering av dataset	9
Maskinl�ring	9
Andre modeller	10
Til regObs	10
<b>Resultater</b>	<b>11</b>
Systemet	11
Prediksjon	11
V�r- og kvalitetsmodell	11
Sn�kredmodell	13
NIMA modellene	13
Google vision	13
<b>Diskusjon</b>	<b>14</b>
<b>Konklusjon</b>	<b>15</b>
<b>Fremtidig arbeid</b>	<b>15</b>
<b>Vedlegg</b>	<b>16</b>
Kart over omr�de	16



## Innledning

Bruk av kamera og bilder har en stor utstrekning i mange samfunnssektorer. Innen samferdsel kan kameraovervåking bidra til rask tilgang til utvalgte lokasjoner uten å måtte sende ut personell for å gjøre observasjoner. Dette kan være et nyttig verktøy for drift- og tilsyn av veier, rørinntak, bomber, tunneler etc.

I Norge har regional skredvarsling blitt etablert og utviklet i løpet av de siste 10 årene, og observatører kan nå registrere relevante opplysninger om skred- og snøforhold i det nettbaserte systemet regObs<sup>3</sup>. Noen av disse observasjonene blir dokumentert med bilder fra blant annet stasjonære kameraer. I dette prosjektet har vi undersøkt mulighetene for å bruke bilder fra eksisterende kameraer og bildegjenkjenning til å avgjøre om innholdet kan være relevant for skredvarsling.



*Bilde 1: Fra bilde til observasjon med GeoMonitor*

Bildegjenkjenning er brukt til å løse ulike problemstillinger. Informasjon hentet fra bilder kan gi informasjon om strukturer, farger, bildekvalitet, objekter m.m. Dette kan forenkle bildebehandling slik at relevante bilder filtreres ut automatisk for videre behandling. Dette gir grunnlag for å analysere store mengder bilder på kort tid. Dette gir også mulighet til å hente ut relevant informasjon som grunnlag for varsling eller andre handlinger, basert på observasjoner i bilder. Kriterier for hvilke bilder som er relevante, kan hele tiden endres og på den måten muliggjøre kontinuerlig forbedring av treffsikkerhet og filtrering av data. Behandling av data i dette prosjektet har tatt utgangspunkt i bilder fra et bestemt kamera og som deretter har blitt lastet opp for prosessering i GeoMonitor webportal. Ved oppfylte kriterier for videresending, sendes bilder til demoversjonen av regObs. Målet er at relevante bilder skal tilkomme relevant personell, uten at det brukes unødvendig tid til manuelle analyser.

---

<sup>3</sup> (2015, December 8). regObs - NVE. Retrieved September 6, 2019, from <https://www.nve.no/karttjenester/kartverktoy/regobs/>



# Metoder

## Henting av bilder

Bildene fra "Slettsvaet" overført fra kameraet på Veslefjellet blir av Statens vegvesen lagt åpent ut på adressen <http://tsftp.no/tsec003/>. Denne adressen konfigureres i GeoMonitor webportal, og systemet sjekker adressen for nye bilder hver time. Bilder blir betraktet som nye dersom de er binært ulik forrige bilde som er importert fra adressen. Rådataene samt to prosesserte versjoner av bildet blir lagret i systemet for optimalisert visning og videre analyse.

## Bildebehandling

For trening av system for bildegjenkjenning må bildene gjennom en serie med manuelle og maskinelle behandlinger. Gjenkjenning baserer seg på kjente observasjoner, og disse må manuelt registreres da dette ikke kommer med originalbildene. I tillegg er forskjellige teknikker utprøvet for å redusere støy i datasettet.

## Annotering

I GeoMonitor webportal har vi annotert ca. 250 av bildene med kategorier som vi ønsket å detektere. Kategoriene vi har testet er:

- Snødekt terreng
- Tåke
- Bildekvalitet
- Skredaktivitet i bildet
- Tegn på vindpåvirket snø


## Preprosessering

For å redusere støy i bildene, og på den måten maksimere informasjonstettheten, ble to kantdetektorer testet for å preprosessere bildene: *Sobel*<sup>4</sup> og *Canny*<sup>5</sup>. Disse detekterer kanter eller diskontinuiteter som oppstår, utvikler seg eller forsvinner i bildet. Bakgrunnen for utprøving av disse, var at bruddkanter og omriss rundt snø i bevegelse var signifikante mhp. skredgjenkjenning. Bilde 2 viser originale bildeutsnitt fra "Slettsvaet", 4 dager i februar 2019 med bevegelse i snøen (glideskred).

---

<sup>4</sup> "Sobel operator - Wikipedia." [https://en.wikipedia.org/wiki/Sobel\\_operator](https://en.wikipedia.org/wiki/Sobel_operator).


<sup>5</sup> "Canny edge detector - Wikipedia." [https://en.wikipedia.org/wiki/Canny\\_edge\\_detector](https://en.wikipedia.org/wiki/Canny_edge_detector).



*Bilde 2: Utvikling av glideskred på "Slettsvaet" februar 2019*

### **Sobel**

Sobel er en utbredt kantdetektor for klassisk bildebehandling. I bildet 3, som dekker de samme utsnittene som bilde 2, ser vi tendenser til at metoden plukker opp detaljer i og rundt området med bevegelse. Men i hovedsak ser man at det er kontrast mellom snø og berg som blir markert.




*Bilde 3: Sobel kantdeteksjon av bilde 2*

### **Canny**


Canny er en relativt ny kantdetektor som i motsetning til Sobel har en større terskel for å markere en kant. Særlig tidlig bevegelse og bruddkant kommer tydeligere frem med Canny enn med Sobel.





*Bilde 4: Canny kantdeteksjon av bilde 2*

Som preprosessering ble differansen mellom bildene fra dag til dag utprøvd. Til dette brukte vi sammenligningsfunksjonen til *Imagemagick*<sup>6</sup>. Bildet under viser en slik differanse på utvalget som vi brukte på kant detektorer.



*Bilde 5: Differansen mellom kvadrantene i bilde 2*

For skredrelaterte endringer i snødekket var noen avgrensede områder i bildeutsnittet spesielt interessante. Derfor ble alle forsøk gjort med både originalt bildeutsnitt fra kameraet (hele bildet) og et tilpasset bildeutsnitt fokusert på området i midten av originalt bildeutsnitt.

---

<sup>6</sup> "ImageMagick." <https://www.imagemagick.org/>.



## Skalering av dataset

Den manuelle annotering av bildene resulterte i en klar ubalanse mellom bilder med mye og lite av en kategori. Dette var en naturlig konsekvens av at bilder med tåke ikke kan annoteres for snødekke. En slik ubalanse vil gjøre maskinlæringen predisponert til å velge kategorien med flest innslag da dette statistisk vil gi en høy treffrate. Det finnes flere måter å motvirke dette. Vekting av feil av en kategori som er underrepresentert er en mulighet. Vi valgte å duplisere bilder som var annotert med en underrepresentert kategori på en slik måte at de ikke påvirket balansen mellom kategoriene på en negativ måte. Tabellen under viser antall bilder som hadde annotering under og over på 0.5 for hver kategori, før og etter skalering.

	<b>Original annotering</b> lite   mye	<b>Etter skalering</b> lite   mye
<b>Tåke</b>	196   39	308   243
<b>Snødekke</b>	125   68	152   152
<b>Kvalitet</b>	43   195	277   277

## Maskinlæring

Innfallsvinklingen til prosjektet var å se på forskjellige modeller av typen *nevrale nettverk* (CNN<sup>7</sup>). I dette prosjektet har vi brukt plattformen *Tensorflow*<sup>8</sup> som overfører metoder brukt på ett problemområde til ett annet som ligner (såkalt *transfer learning*<sup>9</sup>). Til dette brukes offentlig tilgjengelige modeller distribuert med API-et *Keras*<sup>10</sup> med slik som *Inception 3*<sup>11</sup>, *MobileNet*<sup>12</sup>, og *VGG16*<sup>13</sup>. Med utgangspunkt i disse modellene, ble det satt opp en modell med et skjult lag pr. klasse slik at klassene kunne trenes med en viss uavhengighet.

---

<sup>7</sup> "Convolutional neural network - Wikipedia."

[https://en.wikipedia.org/wiki/Convolutional\\_neural\\_network](https://en.wikipedia.org/wiki/Convolutional_neural_network).

<sup>8</sup> "TensorFlow." <https://www.tensorflow.org/>.

<sup>9</sup> "Transfer learning - Wikipedia." [https://en.wikipedia.org/wiki/Transfer\\_learning](https://en.wikipedia.org/wiki/Transfer_learning).

<sup>10</sup> "Home - Keras Documentation." <http://keras.io/>.

<sup>11</sup> "Inception V3 Deep Convolutional Architecture For Classifying ...."

<https://software.intel.com/en-us/articles/inception-v3-deep-convolutional-architecture-for-classifying-a-cute-myeloidlymphoblastic>.

<sup>12</sup> "MobileNets: Open-Source Models for Efficient ... - Google AI Blog."

<http://ai.googleblog.com/2017/06/mobilenets-open-source-models-for.html>.

<sup>13</sup> "VGG16 - Convolutional Network for Classification and Detection."

<https://neurohive.io/en/popular-networks/vgg16/>.



Bildet under viser implementasjonen med VGG modellen som forklart over.

```
def vgg16model(tensor_names):
    global _INIT_WEIGHT
    base = applications.VGG16(weights='imagenet' if _INIT_WEIGHT else None, include_top=False,
                               input_shape=(IMAGE_SIZE, IMAGE_SIZE, 3))

    # Prep base layers
    for layer in base.layers:
        layer.trainable = False

    # Model constituents
    outputs = []
    inputs = base.inputs

    # Custom common layers
    flatten = layers.Flatten()(base.outputs[0])

    # One hidden and one output layer pr output class
    for name in tensor_names:
        hidden = layers.Dense(128, activation='relu', trainable=True)(flatten)
        outputs.append(layers.Dense(1, kernel_initializer=initializers.constant(0.5), activation='relu', trainable=True,
                                    name=name)(hidden))

    mod = Model(inputs=inputs, outputs=outputs)
    print(mod.summary())
    return mod
```

Bilde 6: Implementasjon av en av CNN modellene i prosjektet

## Andre modeller

Tre offentlig tilgjengelig modeller ble også testet for å se om vi kunne bruke resultatet av disse som tilleggsmåling i vår prosessering. Disse var to varianter av *NIMA* modellen<sup>14</sup> og *Google Vision*<sup>15</sup>. Særlig Google Vision så interessant ut da dette er en modell som er trent opp med et enormt datagrunnlag. Det var derimot lite informasjon om hvilke kategorier som denne modellen kunne kategorisere.

## Til regObs

Etter at systemet har blitt lært opp, blir alle bilder løpende annotert med en prediksjon pr. kategori gitt av modellene beskrevet over.

RegObs bruker et offentlig API kalt RegObs-WebAPI<sup>16</sup>. GeoMonitor har en integrasjon mot dette APIet og kan dermed sende og hente informasjon om observasjoner. GeoMonitor lagrer på sin side RegObs observasjons-ID for alle observasjoner den sender fra seg. Dette brukes til å synliggjøre observasjonen i GeoMonitor Webportal samt gir mulighet til oppdatering og sletting av observasjonen på et senere tidspunkt.

<sup>14</sup> "Introducing NIMA: Neural Image Assessment - Google AI Blog."  
<http://ai.googleblog.com/2017/12/introducing-nima-neural-image-assessment.html>.

<sup>15</sup> "Vision - Google Cloud." <https://cloud.google.com/vision/>.

<sup>16</sup> <http://api.nve.no/doc/regobs-webapi/>



# Resultater

## Systemet

System for henting av bilder, bildebehandling, løpende prediksjoner og sending til RegObs<sup>17</sup> har vært operativt i 4 måneder og har vært stabilt i hele den perioden.

Hele prosessen for importering av bilde, bildeprosessering og evt. videresending tar ca. 30 sekunder fra bildet er hentet til GeoMonitor Webportal og det er ferdig prosessert og kan sendes videre til RegObs. Tregheten i systemet er dermed i hovedsak knyttet til hvor ofte bilder hentes og ikke til selve prosesseringen, som anses som veldig rask for de fleste praktiske formål med bruk av bilder som kilde.

Sending til demoversjonen til RegObs ble etter hvert deaktivert da system sendte bilder som ble reprosessert på grunn av utvidet testing. Dette førte til at mange duplikate bilder ble videresendt.

## Prediksjon

For *binære variabler* er målet på presisjon relativt intuitivt hvor presisjonen er enten 0% eller 100%. Eksempler på binære variable er skred/ikke skred eller snø/ikke snø i bildet. For *kontinuerlige variabler* er dette naturlig nok annerledes. Kontinuerlige variabler beskriver f.eks. hvor mye snø det er i bildet, eller hvor stort et skred er. Vi normaliserte alle kontinuerlige variabler til en verdi mellom 0 og 1. Presisjonsmål kan da være den absolutte differansen mellom målt og predikert verdi. Av tekniske grunner valgte vi å lage 3 akkumulerte bøtter der differansen var innenfor 0.1, 0.2 og 0.3. Eksempelvis vil en målt verdi på 0.5 og en predikert verdi på mellom 0.4 og 0.6 komme innenfor 0.1 i presisjon, mens en verdi på 0.9 og predikert verdi på 0.5 kommer utenfor disse bøttene og dermed bli betraktet som en feil prediksjon.

## Vær- og kvalitetsmodel

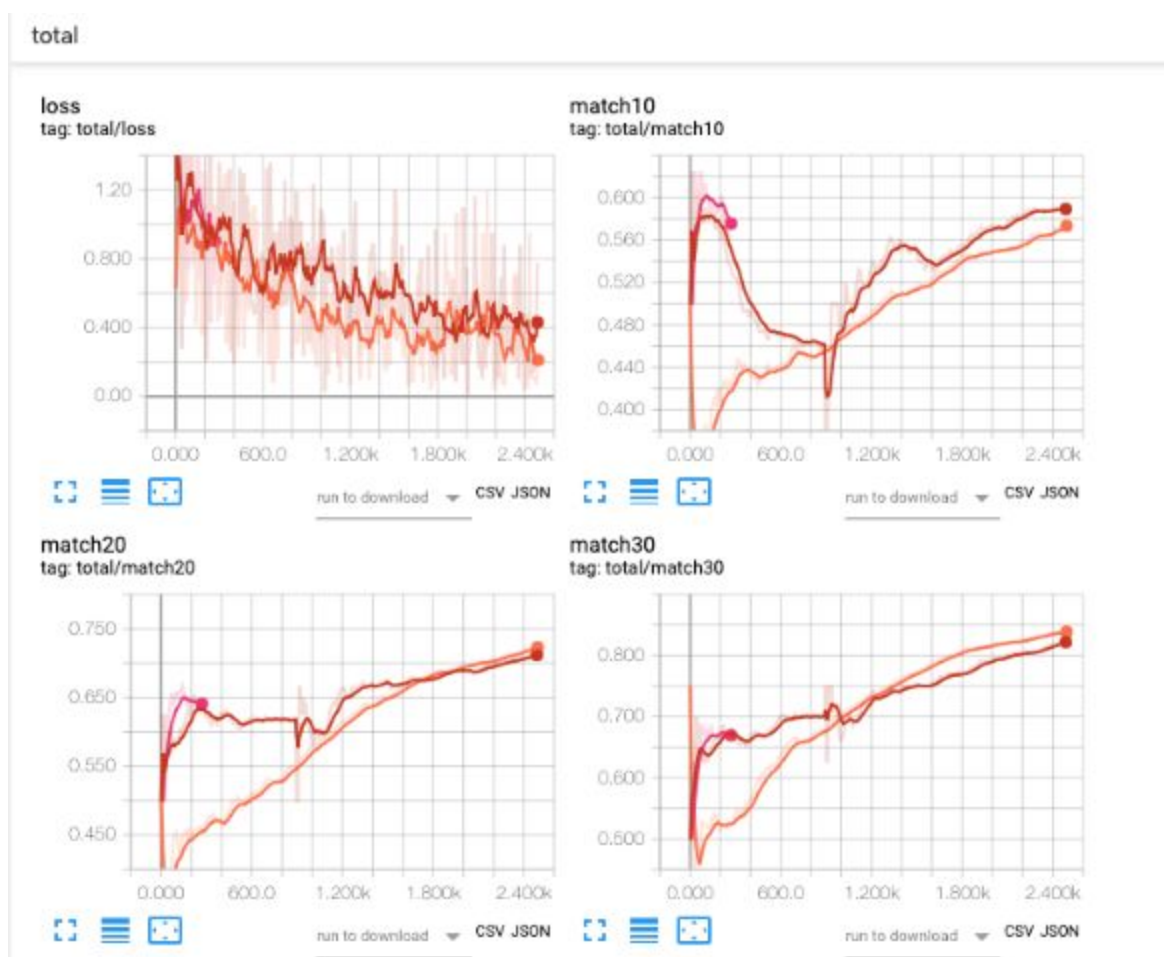
I en av modellene ble det vurdert bilde kvalitet, tåke i bildet og hvor mye snødekt terreng i bildeutsnitt. Med kvalitet menes hvor lett eller vanskelig det er for det menneskelige øye å oppdage hva som finnes av informasjon i bilder pga. f.eks. tåke, whiteout, tett snø eller dårlig lys. Kvalitet og tåke har dermed en sterk korrelasjon.

---

<sup>17</sup> "demo regObs Forside." <https://demo.regobs.no/Registration/172018>. Accessed 12 Nov. 2019.



Kategori/Bøtte	0.1	0.2	0.3
Snødekt terreng	35%	53%	78%
Tåke	59%	66%	83%
Kvalitet	64%	70%	89%



Bilde 7: Treningslogg for to tester av Vær- og kvalitetsmodellen

Bilde 7 viser to ulike tester (rød og oransje linje) for treningen av "vær- og kvalitetsmodellen". Match10 tilsvarer andel prediksjoner som er innenfor 0.1 bøtten der x-aksen er antall prediksjoner. Match20 og Match30 er henholdsvis 0.2 og 0.3 bøtten. Loss beskriver i absolutt verdi hvor langt snittet av prediksjonene er fra en perfekt prediksjon (som er 0). Hvert datapunkt i grafene er gjennomsnittet av prediksjonene for alle kategorier: tåke, snø og kvalitet.



Presisjonen her lider av at modellen tolker snødekt terreng feil når det med sikkerhet er mye tåke i bildet. Vi kan likevel si at modellen gir tilstrekkelig indikasjon på om det er snø i bildet. Det er derimot ikke tilstrekkelig presisjon til å detektere mindre endringer i utbredelsen av snødekket.

## Snøskredmodell

For snøskred klarte vi ikke å få bedre presisjon enn 60% innenfor 0.3 intervallet. Noe som i praksis betyr at maskinlæringen ikke klarte å plukke opp de riktige egenskapene i bildene.

## NIMA modellene

NIMA-modellen ble brukt som et første forsøk på å bruke offentlig tilgjengelige modeller som en automatisk annotering av bildene som vi igjen kunne bruke som input til maskinlæringen. Vi så at vår egen kvalitetsmodell gjorde det bedre enn NIMA for dette datagrunnlaget. Vi valgte derfor å ikke bruke denne modellen videre i prosjektet.

## Google vision

Google vision fant generelle kategorier, men ingen som vi fant nyttige i dette prosjektet. Under er et eksempel på resultat fra Google Vision på et bilde fra Veslefjellet:

<b>Klassifisering</b>	<b>Prosentvis sannsynlighet for bestemt innhold</b>
Mountainous landforms	0.92
Mountain	0.84
Geological phenomenon	0.80
Hill	0.71
Ridge	0.70
Fell	0.68
Geology	0.65
Intrusion	0.60
Batholith	0.58
Mountain range	0.57



## Diskusjon

Kamera som ble valgt for dette prosjektet var prioritert som et pilot område med bakgrunn i årlige snøskred i området. Spesielt med tanke på glideskred var dette et område hvor vi kunne få data med hendelsesforløp over flere dager. Avstand fra kamera til skredutsatt fjellside var stor og bildeutsnitt har derfor inneholdt mye bildeinformasjon som ikke har vært relevant for selve skredeteksjonen i dette prosjektet.

Ved jobbing med disse modellen ble det etterhvert klart at maskinlæringen ikke klarte med det begrensede datagrunnlaget og den korte tidsserien å plukke de riktige signalene i bildene på en tilfredsstillende måte for å detektere skred og skredrelaterte observasjoner som endringer i snødekket.

Et bedre datagrunnlag kunne bestått av lengre tidsserier, flere bilder pr. dag, gjerne fra flere lokaliteter og helst med flere kjente skredhendelser eller endringer i bildene.

Maskinlæring virket til å være disponert til å se på tekstur i bildet og ikke system av kanter. Dette førte til at kantdeteksjon ikke hadde ønsket effekt. Dette kan peke i retning av at annotering av bildet må inkludere utsnittet der annoteringen er observert.

I tillegg til maskinlæringsmetoder vil andre metoder kunne bidra til bedre prediksjon, f.eks *Local Binary Patterns*<sup>18</sup> som en ren teksturmetode.

GeoMonitor har arbeidet med lignende prosjekter med bruk av bildegjenkjenning innen vannkraft i Norge<sup>19</sup>. Erfaringer fra disse prosjektene har vist bedre treffsikkerhet på deteksjon av hendelser som for eksempel "overløp" som er en situasjon hvor vann renner over terskel/risten på dam/inntak. Bakgrunn for større treffsikkerhet i deteksjon av disse hendelsene kan være knyttet til kompleksitet og variasjon i bilder.

Kontinuerlige variabler er krevende når man skal annotere bildene manuelt. Vurderingene vil da være svært subjektive, f.eks. er det ikke rett fram å bestemme seg for om en egenskap skal få verdien 0.8 eller 0.9. Sensordata fra ulike sensorer som f.eks snødybde ville vært en nyttig datakilde for mer korrekt annotering.

De offentlig tilgjengelige modeller vi testet i dette prosjektet var for generelle og lite spesifikke og tilførte ikke prosjektet relevant informasjon.

---

<sup>18</sup> "Local binary patterns - Wikipedia." [https://en.wikipedia.org/wiki/Local\\_binary\\_patterns](https://en.wikipedia.org/wiki/Local_binary_patterns).

<sup>19</sup> "Bildegjenkjenning skal gjøre vannkraftverkene mer effektive ...." 8 Mar. 2019, <https://energiogklima.no/spirprisen/bildegjenkjenning-skal-gjore-vannkraftverkene-mer-effektive/>. Accessed 12 Nov. 2019.



## Konklusjon

GeoMonitor og Statens vegvesen har delt erfaringer og utfordringer. Bildegjenkjenning er et verktøy som kan anvendes til noen applikasjoner som f.eks. prosent snødekt terreng i bildene, tåkedeteksjon og problemer med tildekket linse. Resultatene viser at vi kan filtrere ut bilder som ikke er av interesse for manuell analyse, men at det er fortsatt behov for å forbedre dataprosessering og behandling for å få vesentlig utbytte av selve analysearbeidet relatert til skred og skredrelaterte observasjoner.

## Fremtidig arbeid

Maskinlæring er avhengig av store datamengder. Ettersom vi får samlet data fra en eller flere kommende sesonger vil forutsetningene for å bruke maskinlæring bli bedre. En annen måte å øke datamengdene på er å bruke bilder fra flere kamera.

Å bruke rene tekstur baserte metoder er en alternativ vei å gå. En forutsetning for dette er at annoteringsmodulen i GeoMonitor Webportal støtter denne type annotering.

Støtte for mer detaljert annotering vil også forbedre maskinlæringen som anvendt i dette prosjektet.






## Vedlegg

### Kart over område



Bilde 8: Kartutsnitt er hentet fra regObs<sup>20</sup>

<sup>20</sup> (2019, February 27). ons 13:51 torehum@svv - regObs. Retrieved September 6, 2019, from <https://www.regobs.no/Registration/183282>



Bilde 9: Kart hentet fra regObs<sup>21</sup>

<sup>21</sup> "man 11:05 torehum@svv - regObs." 28 jan.. 2019,  
<https://www.regobs.no/Registration/178092>. Åpnet 12 nov.. 2019.



Førresfjorden, 14.11.19

---

Torbjørn Smørgrav  
Systemutvikler

---

Eivind Susort  
Prosjektleder



Statens vegvesen  
Pb. 1010 Nordre Ål  
2605 Lillehammer

Tlf: (+47)22073000  
firmapost@vegvesen.no

ISSN: 1893-1162

vegvesen.no

**Trygt fram sammen**