

AI ser på TikTok

Innsendere: Morten Langfeldt Dahlback og Olav Østrem

Journalister: Kajsa Garmann Lønrusten og Rim Hjelde Elmoft

Utviklere: Ludvig Bergsaker, Fabrizio Palumbo (OsloMet) og Shailendra Bhandari (OsloMet)

Prosjektleder: Morten Langfeldt Dahlback

Prosjektbeskrivelse

TikTok er et av de raskest voksende – og mest omdiskuterte – sosiale mediene i Norge. Viktige deler av offentligheten har flyttet over på plattformen, som også har blitt en karriereplattform for norske influensere. Flere kommentatorer utropte lokalvalget i 2023 til et «TikTok»-valg, etter at ungdomspolitikere som Simen Velle (FpU) og Ola Svenneby (Unge Høyre) brukte plattformen med hell i valgkampen. I tillegg har den kinesiske plattformen vært sentrum i sikkerhetspolitiske debatter, og i sikkerhetsdiskusjoner internt i mediebransjen, hovedsakelig på grunn av uro for at kinesiske myndigheter kan få tilgang til data fra plattformen.

Selv om TikTok har blitt en sentral del av den norske offentligheten, fantes det lite systematisk kunnskap om hva slags innhold som finnes der og hvordan «samtalet» på plattformen har utviklet seg over tid. Mangelen på offisielle tilganger til TikTok-data har også gjort det vanskelig å få et overblikk over aktiviteten der. Konsekvensen er et kunnskapshull om et sosialt medium som har stor gjennomslagskraft, spesielt blant unge.

Vi mener offentligheten har en sterk interesse i å forstå TikTok bedre. Med dette prosjektet ville vi bidra til å bygge opp en slik forståelse gjennom journalistikk, og dermed bidra til å tette samfunnets kunnskapshull om TikTok. Sammen med OsloMet utviklet vi verktøy for å hente ut data fra TikTok og verktøy som bruker AI-modeller til å analysere, transkribere og klassifisere videoinnhold. I arbeidet analyserte vi 37 000 TikTok-videoer fra 64 norske influensere ved hjelp av tre ulike AI-modeller.

I denne metoderapporten forklarer vi hvordan vi har gått frem. I tillegg åpner vi kildekoden vi har brukt for å samle inn og prosessere dataene vi brukte i prosjektet.

Metode

Prosjektet bygger på data vi samlet inn fra TikTok ved hjelp av webscraping og et API som lot oss hente ut videofiler og metadata. Vi analyserte deretter videoene ved hjelp av flere ulike AI-modeller. I tillegg gjennomførte vi analyser av seertall, likerklikk, delinger osv., og benyttet flere ulike muntlige kilder, fra eksperter og influensere til skoleungdom.

Datainnsamling

De 37 000 videoene vi har gått gjennom i dette prosjektet har blitt samlet inn gjennom en kombinasjon av webscraping – å hente ut innhold fra nettsider – og bruk av et betalt API.

Vi har først hentet ut lenker til hver av videoene fra profilene influenserne vi har villet undersøke nærmere ved hjelp av webscraping. Dette arbeidet bød på en god del utfordringer, spesielt fordi TikTok er en dynamisk nettside som veksler mellom ulike oppsett og visninger.

Å hente ut det vi trengte krevde nitid gjennomgang av strukturen til de ulike versjonene av TikTok-nettsiden, men til slutt lyktes utvikler Ludvig Bergsaker med å bygge en scraper som kunne hente ut alt vi trengte av informasjon, både videofiler og metadata om antall visninger, kommentarer og likerklikk den har fått, og opptil 50 av kommentarene under videoen.

Selv om vi hadde en scraper som fungerte, ble vi stoppet av at TikTok med jevne mellomrom krevde at vi løste en *captcha* (en oppgave brukeren må løse for å bevise at de ikke er en robot) for å forbli innlogget. Til tross for flere runder med optimalisering av koden vår, var det vanskelig å hente ut alt innholdet fra store kontoer som Oscar Westerlin, som har publisert flere tusen videoer på plattformen. Det tok rett og slett for lang tid, noe som førte til at prosessen ble avbrutt.

Løsningen ble å bruke scraperen til å hente ut URL-ene til hver enkelt video, noe som gikk langt fortere. Disse URL-ene ble så sendt til den kommersielle API-tjenesten [TikTok-Video-No-Watermark2](#) som lot oss hente ut videoen hver lenke peker til, samt de metadataene vi ville ha, uten at vi trengte å løse en eneste *captcha*. Dermed hadde vi videoer fra alle influenserne vi så på frem til midten av oktober 2023.

Endringer i TikToks brukergrensesnitt gjør at scraperen ikke fungerer per i dag. Antakelig vil det bare kreve mindre justeringer for å gjøre den operativ igjen.

Videoanalyse og dataprosessering


I tillegg ville vi utvikle en *pipeline* for å analysere videomateriale. Vi var inspirert av Svenska Dagbladets serie «[AI lyssnar på poddar](#)», som ble publisert i 2023. Der gikk SvD-journalistene gjennom hele produksjonen til podkasten Alex & Sigge ved hjelp av OpenAIs transkriberingsmodell Whisper og språkmodellen GPT-4. De avdekket blant annet at podkasten hadde blitt sintere over tid.

Vi ville gjøre noe mer ambisiøst, nemlig å få AI til å konsumere og analysere et stort videomateriale. Det innebar at vi måtte kombinere flere ulike modeller for å få et samlet bilde av hver video. I første omgang var vi interesserte i *sentimentet* – det følelsesmessige uttrykket – i videoene vi analyserte.

Oppsettet vårt kombinerte tre forskjellige modeller:

- OpenAIs Whisper for transkribering.
- Facial Expression Recognition (FER) for å analysere følelsesuttrykk i ansiktene som dukket opp i hver video.
- Den Facebook-utviklede modellen [bart-large-nmli](#) for sentimentanalyse av transkripsjoner og beskrivelser (som den som legger ut en video skriver selv).

Vi satte modellene til å identifisere et knippe ulike følelsesuttrykk: sinne, glede, tristhet, frykt, overraskelse og avsky.



FER analyserer ansiktsuttrykket til influenseren Anine Olsen, alias 4nine.

For å finne stemningen i en gitt video, slo vi sammen vurderingene fra hver enkelt modell. Det gjorde vi ved å beregne en samlescore **F** for hver følelse:

$$\mathbf{F} = \sum \left(\frac{2}{5}(\text{Ansiktsuttrykk}) + \frac{2}{5}(\text{Transkribering}) + \frac{1}{5}(\text{Beskrivelse}) \right)$$

Hver video ble kategorisert ut fra følelsen som hadde høyest **F**-verdi. Hvis vi holder oss til følelsene *glad* og *trist* kan en tenkt rangering se slik ut:

$$\mathbf{F}_{glad} = (0.4 \times 0.5) + (0.4 \times 0.3) + (0.2 \times 0.1) = 0.34$$

$$\mathbf{F}_{trist} = (0.4 \times 0.2) + (0.4 \times 0.5) + (0.2 \times 0.6) = 0.4$$

Her er **F**_{trist} høyere enn **F**_{glad}, så denne videoen ville ha blitt kategorisert som trist.

Vektingen av komponentene i **F** ble etablert gjennom gjentatt testing opp mot datamaterialet, hovedsakelig ved å sjekke om kategoriseringen av en video harmonerte med vår egen vurdering. Vi gjorde flere ulike justeringer underveis. For eksempel ble det tidlig klart at beskrivelsene av videoene ikke inneholdt like mye informasjon som ansiktsuttrykk og transkribering, så vi nedjusterte vekten vi la på beskrivelsen i beregningen av **F**.

Unnamed: 0	video_id	created_time	emotion	video_score	transcription	audio_score	title	caption_score	final_score	interaction_type	
0	0	7040329731526429957	2021-12-11 06:35:06	nøytral	NaN	NaN	I don't need a lot of time in the morning at a...	0.051657	0.000000	views	
5	5	7040740157439364357	2021-12-12 09:07:45	trist	0.480000	Oh, let me come home Home is wherever I went	0.135328	Nord-Norge er det fineste :red_heart: Jeg voks...	0.070949	0.260321	views
10	10	7041441821515336965	2021-12-14 06:30:35	sint	0.347048	som skal reklamere for undertøy, hvordan skal ...	0.134810	:) det mener jeg da	0.141889	0.221121	views
15	15	7117711774471818501	2022-07-07 19:16:57	redd	NaN	NaN	Det er chill	0.231236	0.000000	views	
20	20	7118799260946042118	2022-07-10 17:36:56	nøytral	0.383484	Ja, hva finnes i væsken min? En bok. Solbrille...	0.100645	Ksn godt vise flere vesker med enda mer sexy l...	0.077247	0.209101	views
25	25	7124365895303957765	2022-07-25 17:38:20	glad	0.168767	Du må gjennomføre deg, du bare legger ut den h...	0.059400	NaN	NaN	0.000000	views
30	30	7131687760490024198	2022-08-14 11:10:59	trist	NaN	NaN	Housetour!! Første hjemmet hvor jeg ikke bor m...	0.047520	0.000000	views	
35	35	7133129147227966725	2022-08-18 08:24:19	nøytral	0.445864	Jeg er så sykt lei av å bli misforstådd av svo...	0.100069	:Norway: :smiling_face_with_hearts: kommentere...	0.079848	0.234343	views
40	40	7134658024261700870	2022-08-22 11:17:10	glad	NaN	NaN	Enjoying the last bits of Norwegian summer :sp...	0.483006	0.000000	views	
45	45	7135025274638322950	2022-08-23 11:02:13	glad	0.404800	Sofia, er du klar for å begriple litt? 5 spørsm...	0.134063	Hehe :butterfly: Livets harde spørsmål @Joakim...	0.109855	0.237516	views

Et utdrag fra .csv-filen som inneholdt alle de kategoriserte videoene.

For å kunne beskrive trender over tid, lagde vi også en mer grovkornet kategorisering av datamaterialet, der glede og overraskelse ble tolket om til positive følelser, mens sinne, frykt osv. ble tolket om til negative følelser.

Vi mente at denne kategoriseringen gjorde risikoen for feil mindre. Grunnen er at det skal mer til for at AI-modellene skal feiltolke en positiv video som negativ enn for at de skal feiltolke en sint video som trist. En mer grovkornet kategorisering gjorde at vi kunne identifisere trender og andre trekk ved videoene vi hadde med større grad av sikkerhet, men siden vi begynte med en mer detaljert klassifisering kunne vi også trekke veksler på denne ved behov.

Utfordringer og løsninger

For å få pålitelige analyseresultater, måtte vi gjennomføre en god del finjustering av de ulike komponentene. For eksempel viste det seg at FER oppfattet tegninger av ansikter som ekte ansikter, noe vi oppdaget da en video om «deffing» (å slanke seg for å få mer definerte muskler) fra en treningsinfluenser ble klassifisert som glad, selv om videoen handlet om hvor kjedelig mat man må spise når man deffer.

Grunnen var at influenseren anbefalte Gastromat for å få slankematen til å smake bedre, og viste et bilde av Gastromat-bøssen. FER trodde den glade Gastromat-munken – som var det eneste «ansiktet» som var synlig i videoen – var en person, og tolket dermed videoen som glad. Løsningen ble å ignorere ansikter som bare var i videoen i noen få frames.



Munker har konsekvenser.


Arbeidet med å prosessere og analysere videoene tok opp en betydelig del av tiden i prosjektet. Rundt januar 2024 hadde vi endelig en full *pipeline* som kunne håndtere alle de 37 000 videoene vi hadde samlet inn, og det egentlige analysearbeidet kunne begynne.

TikTok over tid

Siden vi hadde tilgang til metadata, kunne vi se hvor mange ganger hver enkelt video hadde blitt sett, hvor mange ganger de hadde blitt delt, hvor mange kommentarer de hadde fått og hvor mange likerklipp de hadde mottatt.

Dette ga oss muligheten til å se på utviklingen over tid. Vi brukte Python-biblioteket *pandas* til å analysere datasettet. Deretter lagde vi flere tidsserier, grafer og diagrammer som viste utviklingen over tid og ulike sider ved forholdet mellom positive og negative videoer. I artikkel 1 sammenliknet vi for eksempel hvor mange som hadde sett videoene og hvor engasjerte de var. Vi lagde også en tidsserie som viste at antallet positive videoer hadde økt mest.

Størst økning i positive videoer



Antall videoer publisert per måned, klassifisert etter følelsesmessig stemning ved hjelp av kunstig intelligens.

Tidsserien som viser at positive videoer økte mest.

Kjønnsforskjeller

I artikkel 2 ville vi sammenligne mannlige og kvinnelige influensere. Vi kategoriserte influenserne vi hadde samlet videoer fra etter kjønn, og satt igjen med x menn, y kvinner og én ikke-binær. Dette ga oss et utgangspunkt for å se etter kjønnsforskjeller, for eksempel om menn legger ut sintere innhold enn kvinner. Her kunne vi i stor grad følge samme metodikk som beskrevet over, bortsett fra at vi gjorde større bruk av mer «detaljerte» følelsesklassifiseringer, som sint, glad, trist og redd.

Underveis i arbeidet fikk vi en mistanke om at AI-modellen vi brukte til ansiktsgjenkjenning tolket menns og kvinners ansiktsuttrykk ulikt, og spesielt om den var mer tilbøyelig til å oppfatte mannlige ansikter som sinte. Hvis det stemte, var det fare for at vi kom til å fremstille en slagside i analysemodellen som reelle funn.

Vi undersøkte derfor hvilken effekt det hadde på kategoriseringen av videoene om vi fjernet ansiktsanalysen fra regnestykket. Vi satt da igjen med en ny **F**-score:

$$\mathbf{F}^* = \sum \left(\frac{2}{3}(\text{Transkribering}) + \frac{1}{3}(\text{Beskrivelse}) \right)$$

Vi var spesielt opptatt av om videoer laget av menn ble tolket som mindre sinte og av om effekten av å fjerne ansiktsanalysen fra regnestykket var ulik for kvinner og menn. Derfor brøt vi ned forskjellen mellom **F** og **F*** på kjønn.

	gender	final_score	adjusted_final_score	difference
0	IB	0.244204	0.182435	-0.061769
1	K	0.219128	0.211615	-0.007513
2	M	0.208842	0.196979	-0.011862

*Forskjellen mellom **F** og **F*** for kvinner, menn og ikke-binære.*

Som det fremgår av tabellen over var forskjellen mellom **F** og **F*** på -0.007513 for kvinner og -0.011862 for menn. Selv om endringen var noe større for menn, var forskjellen mellom de to kjønnene på bare 0.004349. Vi var derfor trygge på at FER-modellen ikke tolket menns og kvinners ansiktsuttrykk nevneverdig forskjellig.

I tillegg gjennomførte vi en [Mann-Whitney U-test](#) for å sjekke om kjønnsforskjellene vi hadde funnet var signifikante.

```
test for redd:
Statistic: 2166.5
p-value: 0.1240052855655443
There is no significant difference between the distributions.

test for sint:
Statistic: 801.5
p-value: 8.101660517076814e-08
There is a significant difference between the distributions.

test for trist:
Statistic: 2720.5
p-value: 1.4172213049358175e-05
There is a significant difference between the distributions.
```

Resultatet av Mann-Whitney U-testen.

Testen viste at det var en signifikant forskjell mellom hvor mange sinte og triste videoer menn og kvinner la ut, men ingen signifikant kjønnsforskjell mellom hvor mange videoer som uttrykte frykt influenserne i vårt datasett la ut.

Muntlige kilder

I artikkel 1 brukte vi to forskere som kilder. Forskerne vi kontaktet har forsket på hvordan unge bruker sosiale medier og hvordan dette påvirker dem. De ga både viktig kontekst til resultatene våre, i tillegg til at de kom med sine reaksjoner og synspunkter på analyseresultatene.

I artikkel 2 vendte vi oss til influenserne. Vi kontaktet opptil flere av TikTok-influenserne som var en del av datasettet og endte opp med å snakke med to forskjellige, Anine Olsen og Gard Øksendal. Begge influenserne ga sine reaksjoner på resultatene fra analysen og fortalte om deres egne erfaringer og inntrykk av norske TikTok-ere og innholdet de lager.

Fordi TikTok er en plattform som blir brukt mye av barn og ungdom, ønsket vi å høre hvordan TikTok oppleves for dem. I forbindelse med arbeidet med artikkel 1 dro derfor til Frydenberg ungdomsskole i Oslo og snakket med fem elever ved 8. trinn, både gutter og jenter, om hva de ser mest på TikTok, hvordan de opplever plattformen og innholdet de ser, og hvor mye tid de bruker på dette. Inntrykket vi fikk fra samtalene med elevene var at resultatene av analysene våre harmonerte godt med opplevelsene ungdommene hadde.

Funn

Hovedfunnene våre var:

- Norske TikTok-brukere har blitt «sløvere» over tid. Etterhvert som plattformen har blitt allemannseie, har bruken endret seg fra aktivt engasjement gjennom likerklipp og deling til mer passivt konsum av innhold.
- Positivt ladet innhold blir sett mer og skaper mer engasjement (deling, kommentering, likerklipp) enn negativt ladet innhold. Her skiller TikTok seg fra plattformer som Facebook, der aktiviteten i større grad er drevet av sint innhold.
- Mannlige influensere er betydelig mer negative enn kvinnelige. Vi ser også at mannlige influensere som lager negativt ladet innhold, oftest lager *sint* innhold, mens kvinnelige influensere oftest lager *trist* innhold.

- Over tid har mannlige influensere blitt mer *negative*, mens kvinnelige influensere har blitt mer *positive*.
- Både mannlige og kvinnelige influensere skaper mest engasjement når de lager positive videoer. Når mannlige influensere lager negative videoer, og spesielt videoer som uttrykker sinne, «straffes» de imidlertid mindre enn sine kvinnelige motstykker.

Resultater

De to artiklene våre ble lest til sammen 142 100 ganger, med en gjennomsnittlig lesetid på like under fem og et halvt minutt. Gjennom disse artiklene har vi gitt det første systematiske overblikket over TikTok i Norge. Vi har også utviklet verktøy for analyse av videoinnhold som kan brukes i en rekke ulike sammenhenger. Disse kommer vi til å benytte i journalistikken vår fremover.

Artikler

«Stor Faktisk-analyse: TikTok-funn overrasker»

<https://www.faktisk.no/artikler/j1d3d/stor-faktisk-analyse-tiktok-funn-overrasker>

«Faktisk-analyse av TikTok: Menn mest negative»

<https://www.faktisk.no/artikler/zkxey/faktisk-analyse-av-tiktok-menn-mest-negative>

«Slik brukte vi AI til å forstå TikTok»

<https://www.faktisk.no/artikler/0gpdg/slik-brukte-vi-ki-til-a-forsta-tiktok>

Kode (Github)

Dataprosessering: <https://github.com/fabrizio-palumbo/Tik-Tok-Analyse>

TikTok-scraper (NB: må oppdateres): <https://github.com/ludvig03/Tiktok-scraper>

Appendiks: Influenserne

Listen under viser hvilke influensere som var med i vårt datamateriale:

Fullt navn	Brukernavn på TikTok
Oscar Westerlin	oskarwesterlin
Snorre	snorrepus
Ola Svenneby	olasvenneby
Simen Velle	simen.velle
Oliver Bergset	oliverbergset
Mankegard	mankegard
Kasper Kvello	styrketreneren
Adib Waezz (Mr.dubai)	adibwaezz
Sebastian Brevik	barisbrevik3
David Mokel	davidmokel16
Espen Berg (muskelbunten)	muskelbunt1
Morten Marius Skau	mort1rulle
Norway Rob	norwayrob
Even Sjamel	sjamlifts
Olly Bowman	mrmelk_
Martin Hansen	manylandy777
Kim Danial	danian92
Leviyo	jegerleviyo
Jacob Gudim Karlsen	jacob_karlsen
Henrik Viken	henki_viken
Wolfgang Wee	wolfgangwee
Danby Choi	danbychoi
Benni Bravo	bennibravo
Brilleslangen	brilleslangen2
Ramon	ramonandresen
Tappelino	.tappelino
Tim Kristian	timkristian
Henrik Schatvet	henrikschatvet
Melchisparby	melchisparby

Sikkerhetsproffen	sikkerhetsproffen
Kevin Lauren	lurkiofra2etasje
Christian Brennhovd	christianbrennhovd
Eivind Trædal?	eivindtr
Kevin Haugan	kevinhauganofficial
Anine (4 anine)	4nine
Sonja Iren	sonja.iren
Jenny Gehrken	jennygehrken
Fetisha Williams	fetishawilliams
Camilla Lorentzen	camillalor
Julie Lorentzen	julieevlorentzen
Jenny Huse	jenny.huse
Kristjana Vera	kristijanavera
Emma Ellingsen	emmathevampireslayer
Cecilia Teigen	ceciliateigen
Sofie Karlstad	sofiekarlstad
Linn Woyenlenes	linnwoyenlenes
Anny Isabella Øvrehus	anny.isabella
Linnea Løtvedt	linnealotvedt
Erika Norwich	enorwich
Johanne Massey	johannemasseyy
Emilie Paus	emiliepaus
Ellen Aabol	ellenaabol
Amalie Olsen	amalieolsengjerse
Naomi Seki	naomiseki
Delshad	delshad01
Lasse	lassesaeelvik2
Podcasten til Oskar Westerlin og Snorre	kontoretpodcast
Selene Lie	seleneliie
Sophie Elise Isaksen	sophieeliseisachsen
Mads Hansen	mads_hansen1
Elias Omberg	eliasomberg
Synnøve Dørum	synnovedorum
McMarti	mcmartii