



# Mindre rutinearbeid med maskinlæring

*Automatisk deteksjon av hvitvasking*

Lars Erik Bolstad  
Data Scientist, AML Analyse og Teknologi, DNB

Martin Jullum  
Seniorforsker, Norsk Regnesentral

# AML: Hva og hvorfor

Hvitvasking: Å skjule opprinnelsen til utbytte fra straffbare handlinger

## **Anti**-hvitvasking:

- Risikoklassifisering av kunder
  - Transaksjonsovervåkning
  - Sanksjonsscreening (land, personer)
  - Terrorfinansiering
- 
- Compliance: Hvitvaskingsloven, EU, USA
  - Risk: Bøter, Søksmål, Omdømme, Tillit
  - Ansvar: Rapportere mistenkelig adferd til Økokrim (men også PST, NAV)

# AML i DNB




Definerte  
risikoindikatorer



**Scenarier =  
Regler** som fanger  
opp risiko-  
indikatorer

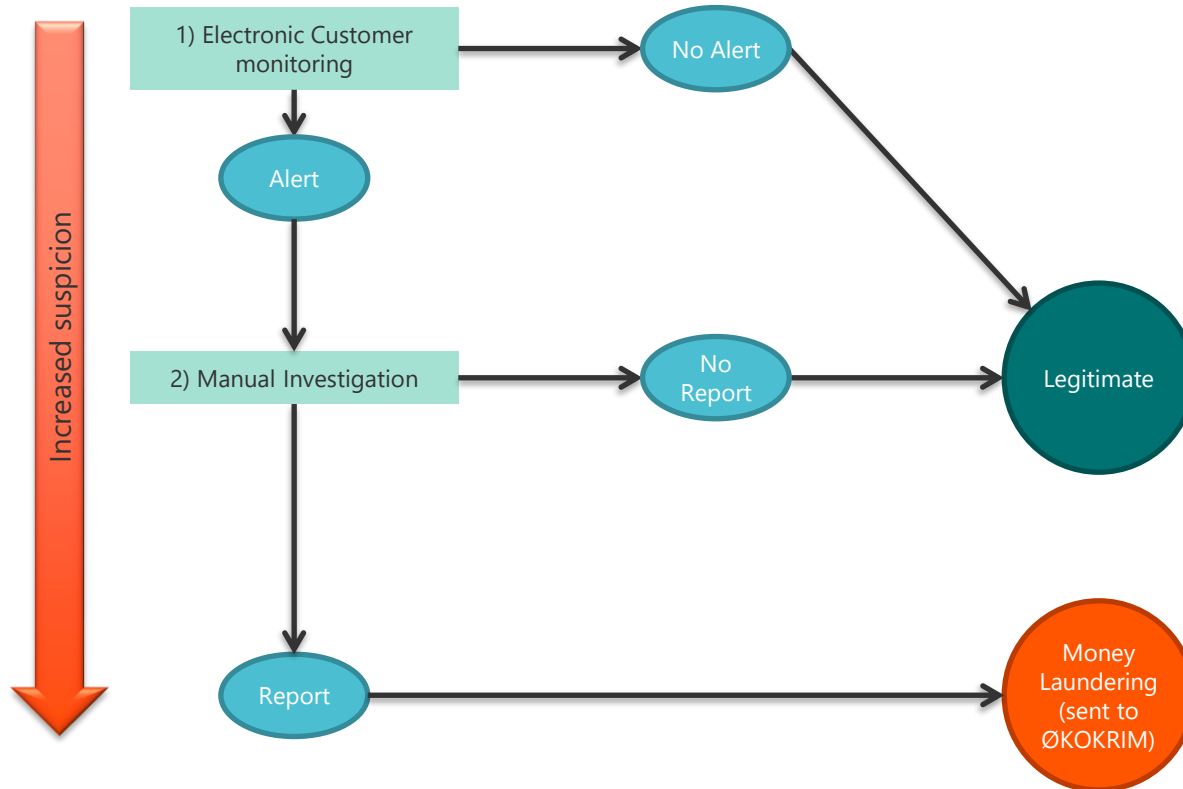


Transaksjons-  
overvåkning =>  
**Alarmer**




Melde mistenkelige  
kunder til Økokrim

# AML: Proses




# Utfordringer med dagens system



- Ikke treffsikkert nok: For mange *false positives* medfører mye manuelt arbeid
- Avdekker ikke mer komplekse adferdsmønstre

# Vårt ML-arbeid



- Datasett: 2 år med transaksjoner, kundedata, alarmer og AML-saker
- Rå data => Prosessering => **Feature engineering**
- Mål: En modell som **predikerer sannsynligheten** for at en transaksjon resulterer i en anmeldelse til Økokrim

# Er dette så vanskelig da?

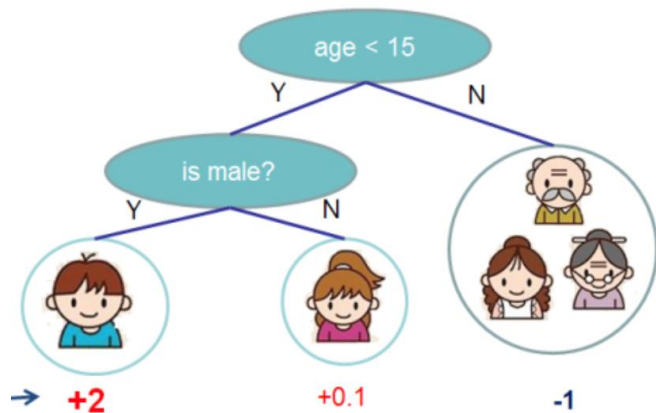
Hvitvaskings-  
transaksjoner



# Modellering

- Binær respons ( $Y$ ): Transaksjon sendt til Økokrim (Ja = 1, nei = 0)
- Vil predikere  $P(Y = 1 | \text{data relatert til aktuell transaksjon})$
- State of the art: **Gradient boosting machines (GBM)**
- **XGBoost** – veldig effektiv og fleksibel implementering av GBM basert på trær
  - **Krever input (features) på tabellform**

dmlc  
**XGBoost**






# Transformering av rådata

## Typer input data

- Spesifikk info om aktuell transaksjon
- Bakgrunnsinfo om sender/mottaker
- Sender/mottakers transaksjonshistorikk
- Tidligere rapporterte transaksjoner fra sender/mottaker

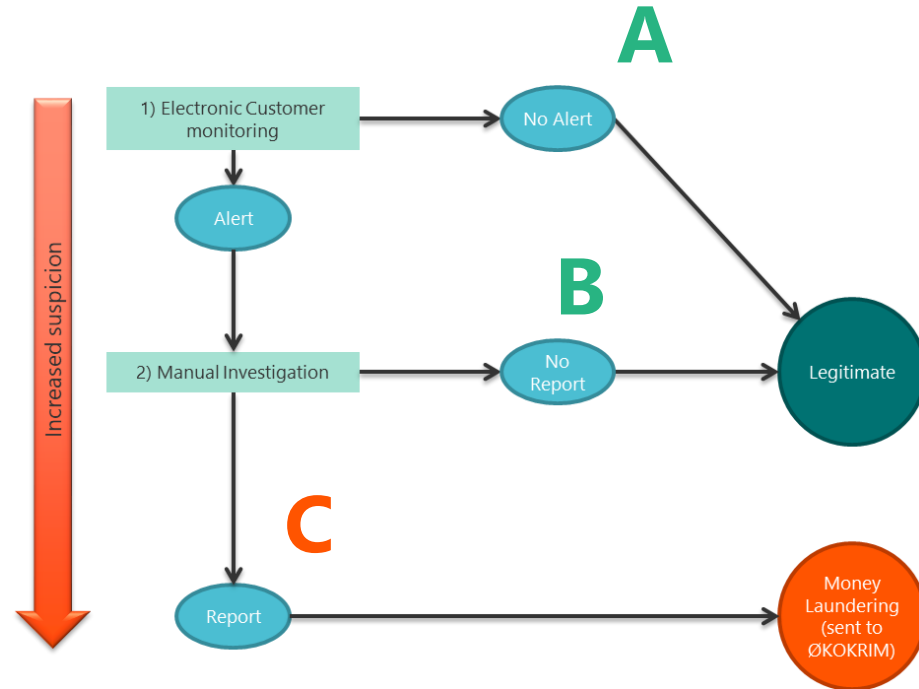



Y	X1	X2	X3	X4	X5	X6
1	0,453406	0,992838	0,734389	0,159918	0,397515	0,949952
0	0,274	0,654207	0,169886	0,493841	0,407112	0,939789
0	0,741897	0,855005	0,585788	0,366456	0,365123	0,57955
1	0,488119	0,465754	0,716517	0,493048	0,855049	0,632114
0	0,134458	0,762057	0,848194	0,098779	0,872603	0,063026
0	0,531914	0,998817	0,808215	0,060721	0,716595	0,35374
0	0,341509	0,8398	0,637808	0,48304	0,279987	0,730286
0	0,530306	0,463271	0,338713	0,986781	0,925251	0,272484
1	0,864123	0,652763	0,689599	0,080937	0,990294	0,364736
0	0,106812	0,900351	0,450224	0,143815	0,593244	0,020764

**1716 kolonner (features)**


# Trening og testing

- “Ubegrenset” med normaltransaksjoner (A)
  - Har valgt  $\#A = \#B$
- Håndtering av overtilpasning
  - 10-fold kryssvalidering
  - Stoppekriterium (# iterasjoner): AUC
- Tuning: Random + iterativt grid-søk
- Trening på GPU




# 2 treningsscenarier

Alle datatyper



Uten urapporterte transaksjoner



# Evaluering av scenariene

Rangering:

AUC

Sannsynligheter:


Brier score

# Sammenligning av scenarier

	Alle datatyper	Uten urapporterte transaksjoner
AUC	0.907	0.852
Brier	0.025	0.340

**MYE bedre!**

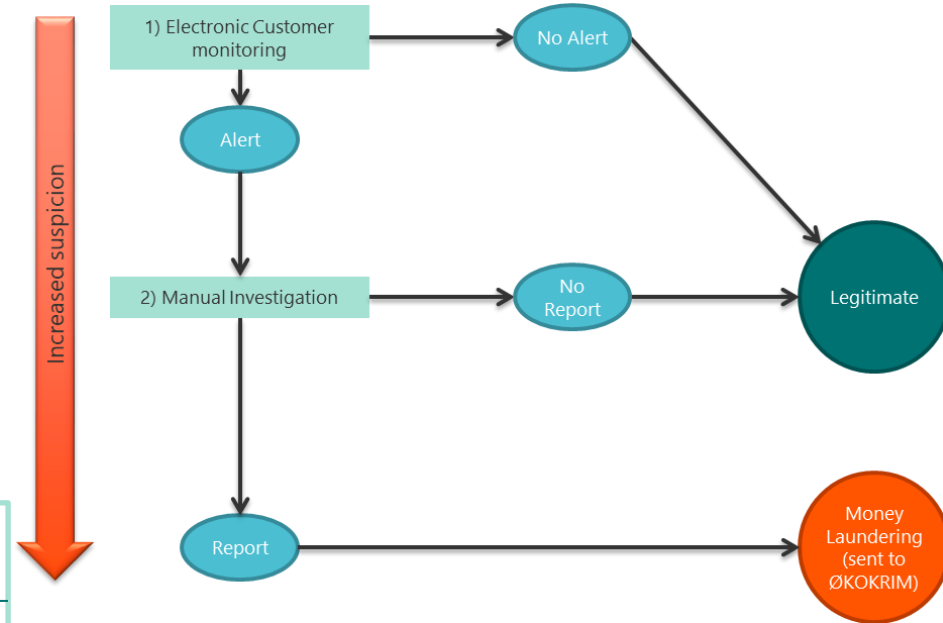
Hvitvaskings-  
transaksjoner



# ML vs dagens AML system

- Vanskelig å sammenligne
- **PPP = Proportion of Positive Predictions:**  
Andel transaksjoner som må kontrolleres for å finne 95% av de rapporterte transaksjonene

	ML (alle datatyper)	Dagens system
PPP	31.5 %	48.9 %



# Videre arbeid

- Utvidelse av datasett
- Evaluering av antagelser i feature engineering
- NR: Auto-encoding av features vha Deep Learning
  
- Anvendelser:
  - Automatisk prosessering/kategorisering av alarmer
  - Bruke output for bedre, mer treffsikre scenarier
  - Avdekke adferd som ikke fanges opp i dag