

# Personlig prediksjonsforklaring

Kort introduksjon

Martin Jullum

med Kjersti Aas, Anders Løland og Nikolai Sellereite

Styremøte Big Insight, 5. desember 2018

# Eksempel: Bank lager boliglånsrobot



## Transaction history

Commercial Card - 456480111111111: 08/04/2004 - 14/04/2004			
Date Processed	Description	Debit	Credit
08/04/2004	CASH ADVANCE FEE		\$5.00-
09/04/2004	SUNSHINE VILLAGE BANFF	\$86.97-	
10/04/2004	PRINCIPAL CREDIT ADJUSTMENT	\$22.00-	
10/04/2004	CARD MEMBERSHIP FEE	\$19.00-	
10/04/2004	PHOTOCARD FEE	\$3.00-	
11/04/2004	PRINCIPAL DEBIT ADJUSTMENT	\$22.00-	
11/04/2004	PRINCIPAL DEBIT ADJUSTMENT	\$22.00-	
12/04/2004	PRINCIPAL CREDIT ADJUSTMENT	\$22.00-	

Age/gender/prev. loans...

&

Misligholdt  
lån?

# Eksempel: Bank lager boliglånsrobot

Transaction history

Commercial Card - 456480111111111: 08/04/2004 - 14/04/2004

Date Processed	Description	Debit	Credit
08/04/2004	CASH ADVANCE FEE		\$5.00-
09/04/2004	SUNSHINE VILLAGE BANFF	\$86.97-	
10/04/2004	PRINCIPAL CREDIT ADJUSTMENT		\$22.00-
10/04/2004	CARD MEMBERSHIP FEE	\$19.00-	
10/04/2004	PHOTOCARD FEE		\$3.00-
11/04/2004	PRINCIPAL DEBIT ADJUSTMENT	\$22.00-	
11/04/2004	PRINCIPAL DEBIT ADJUSTMENT	\$22.00-	
12/04/2004	PRINCIPAL CREDIT ADJUSTMENT		\$22.00-

Age/gender/prev. loans...



$P(\text{misligholde lån})$

Lån  
innvilget?



# Personlig prediksjonsforklaring

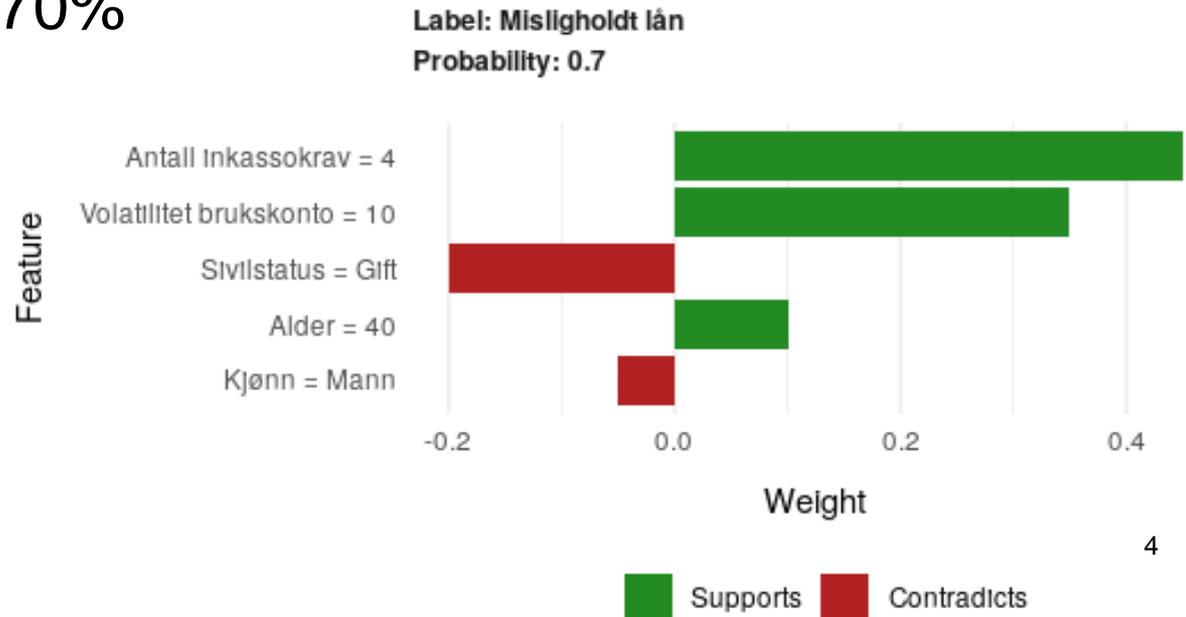
- ▶ IKKE en generell forklaring av black-box modellen

- ▶  $x^*$ : Transaksjonshistorikken/kovariatene til



Forklaring av  $f(x^*) = 70\%$

- ▶ Hvilke kovariater “bidro mest” til å trekke sannsynligheten opp/ned til  $f(x^*) = 70\%$



# Kan kreve forklaring

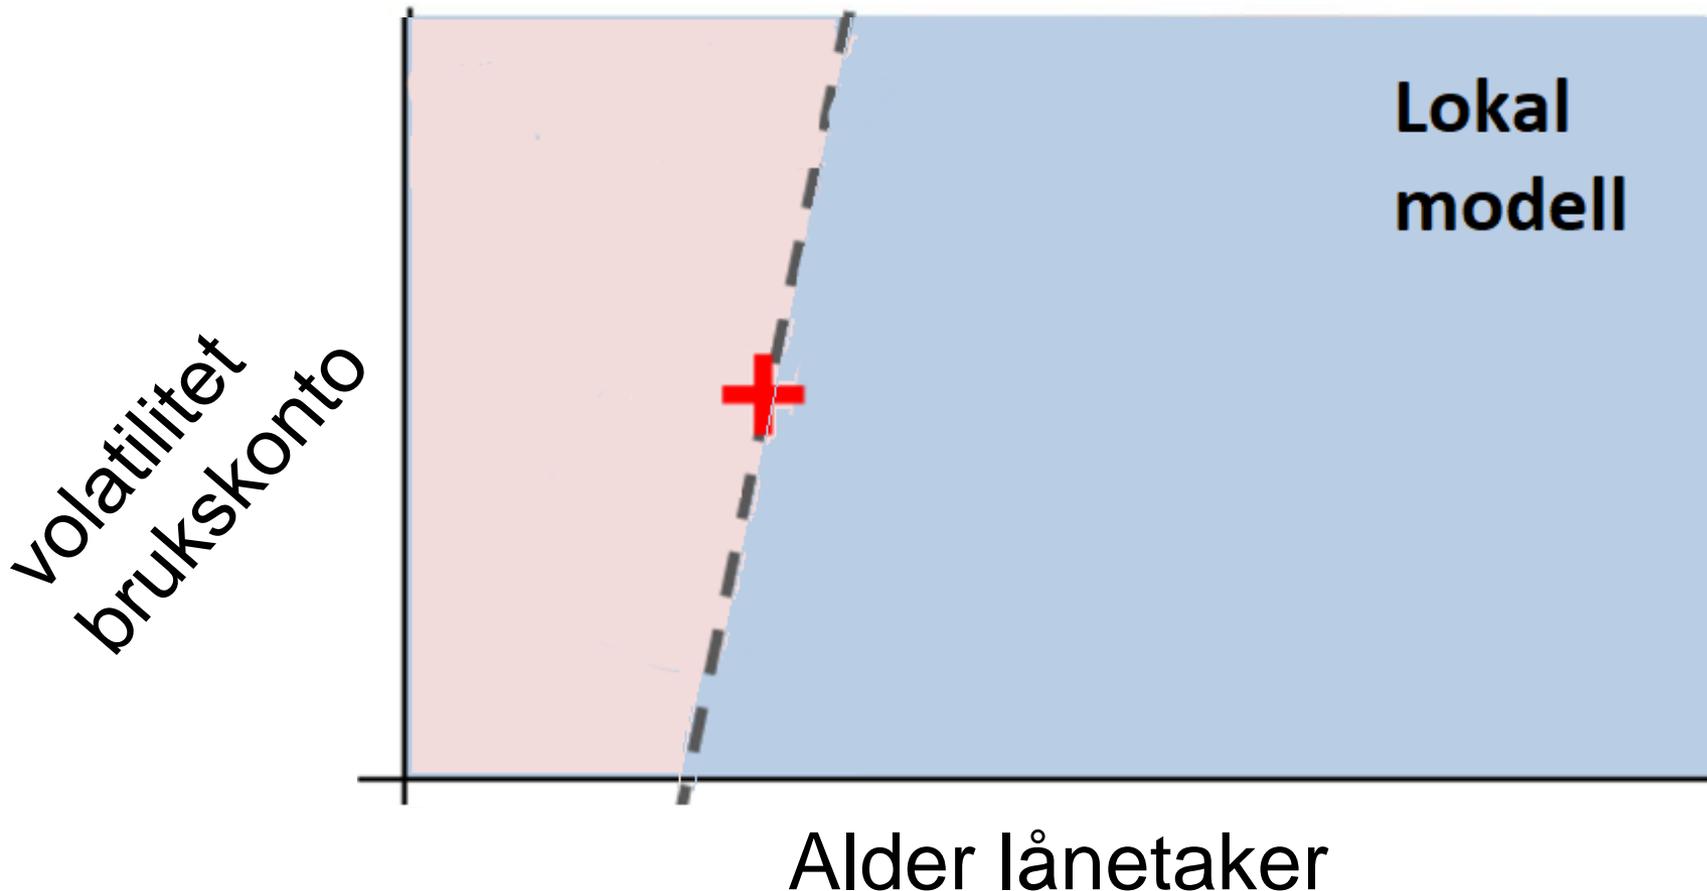


**The General Data Protection Regulation**

# Metode 1: LIME

(Local Interpretable Model-agnostic Explanation)

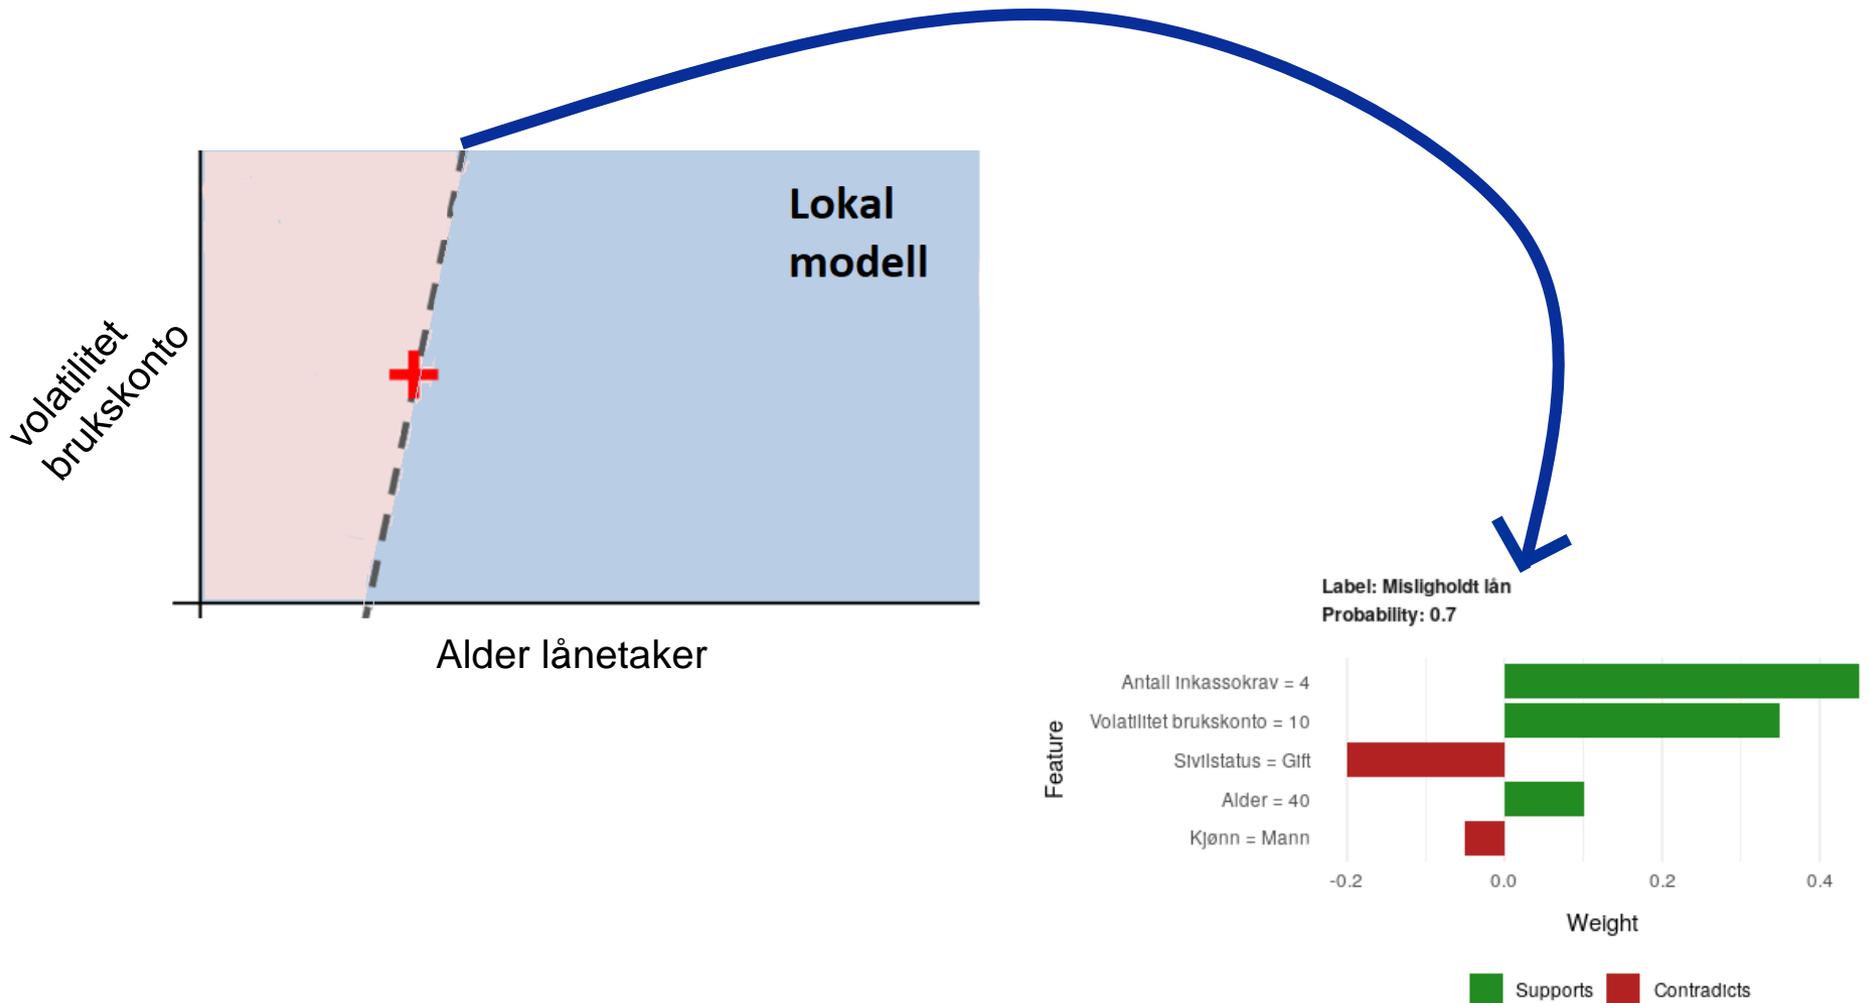
- ▶ Lager en forenklet modell rundt prediksjonen



# Metode 1: LIME

(Local Interpretable Model-agnostic Explanation)

- ▶ Lager en forenklet modell rundt prediksjonen



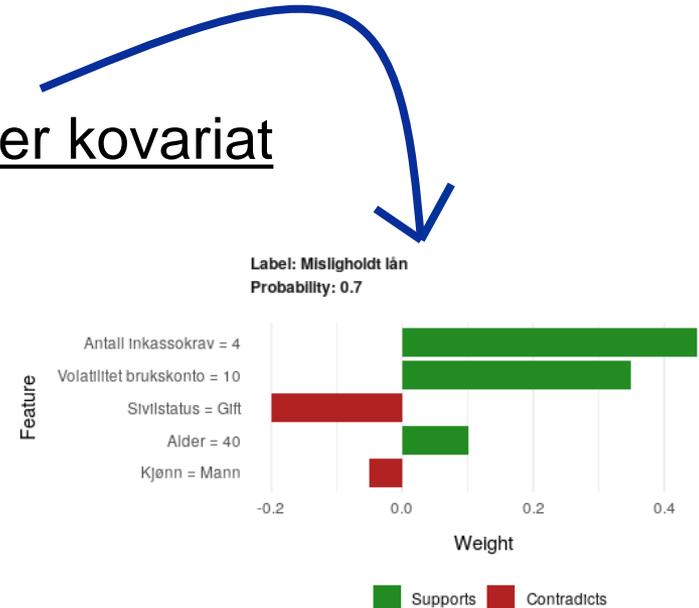
# Metode 2: SHAP

(SHapley Additive exPlanations)

- ▶ Shapley verdier
  - Konseptet stammer fra (lag-)spillteori



- ▶ SHAP
  - Spillerne = kovariatene ( $x_1, \dots, x_p$ )
  - Utbetaling = prediksjonen  $f(\mathbf{x})$
  - Eksplisitt formel for bidrag fra hver kovariat



# Forklaring med LIME vs SHAP

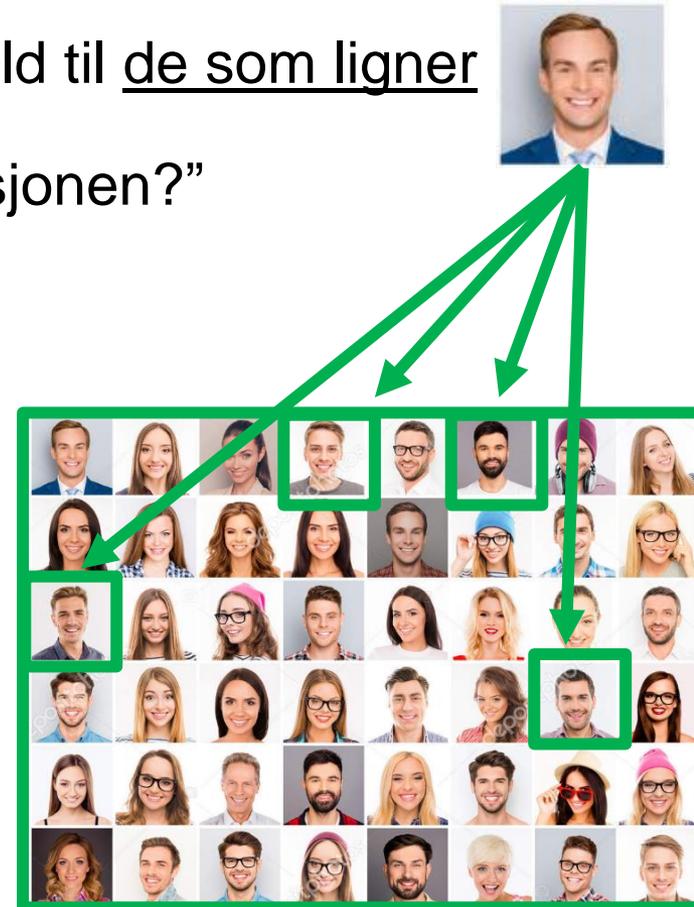
- ▶ Svarer på ulike spørsmål

- ▶ LIME

- Forklarer prediksjon for  i forhold til de som ligner 
- Spm: “Hvordan enklest endre prediksjonen?”

- ▶ SHAP

- Forklarer prediksjon for  i forhold til hele populasjonen
- Spm: “Hvilke variable er viktigst å observere for prediksjonen?”



# Vårt bidrag

- ▶ LIME og SHAP ignorerer avhengighet mellom kovariater
  - Kan gi helt feil forklaring hvis sterk avhengighet



# Vårt bidrag

- ▶ LIME og SHAP ignorerer avhengighet mellom kovariater
  - Kan gi helt feil forklaring hvis sterk avhengighet
- ▶ Vårt arbeid: **Reparere SHAP**
  - SHAP antar  $p(\mathbf{x}_A|\mathbf{x}_B) \approx p(\mathbf{x}_A)$  som en del av algoritmen
  - Vi forsøker å estimere  $p(\mathbf{x}_A|\mathbf{x}_B)$  skikkelig
- ▶ Arbeider med både artikkel og programvare for dette
- ▶ Flere interessante relaterte problemstillinger