

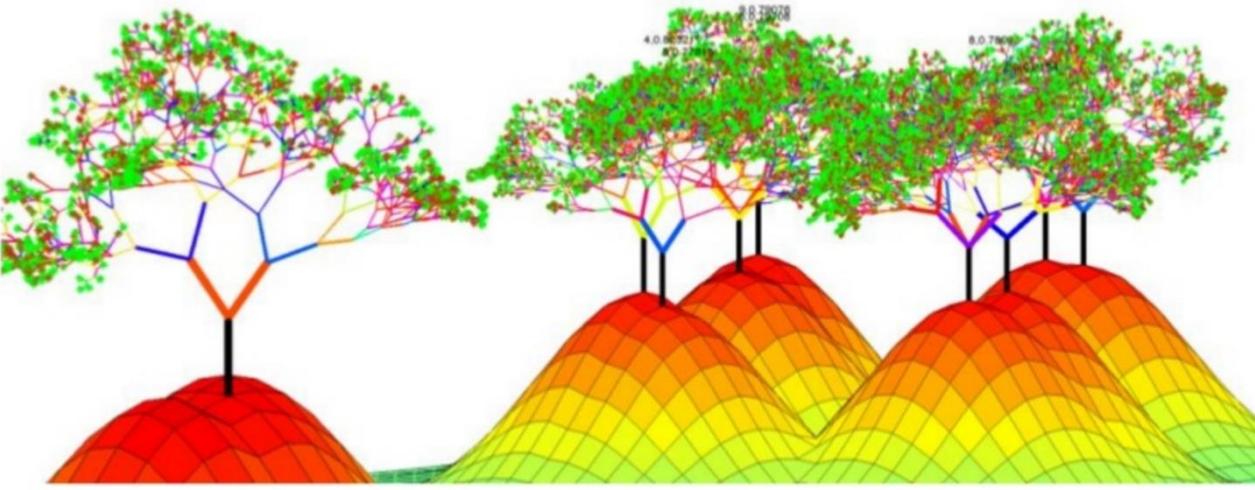
Tree model  
Boosting  
Gradient descent  
XGBoost

# Boostede tre-modeller

Fra en enkel tre-modell til en XGBoost-modell

Martin Jullum  
jullum@nr.no

SSB 9.feb 2021



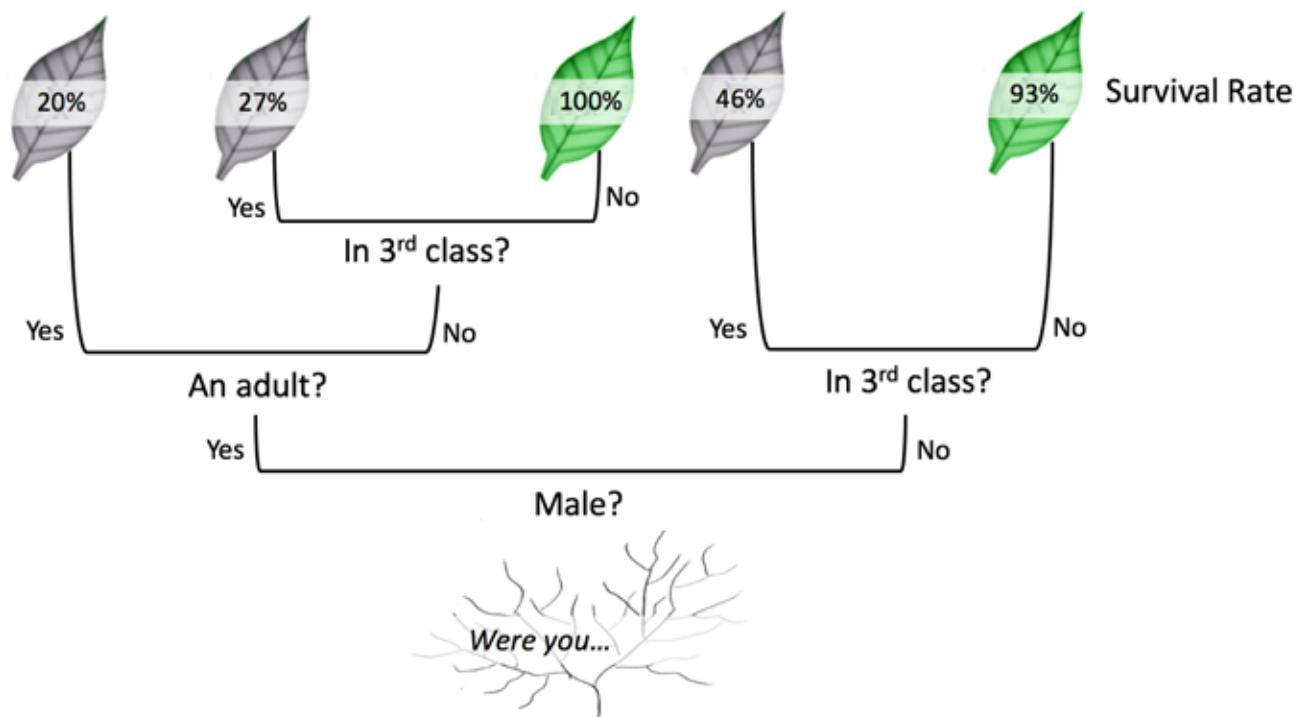
# Problem

- ▶ Anta at vi har et datasett med  $n$  observasjoner
  - Respons:  $y_i$
  - Kovariater:  $x_i = (x_{i1}, \dots, x_{ip})^\top, i = 1, \dots, n$
- ▶ Ønsker å tilpasse en modell  $f$  til disse dataene slik at  $f(x_i)$  approksimerer  $y_i$  så godt som mulig (på et separat datasett) i form av en tapsfunksjon  $L(y_i, f(x_i))$



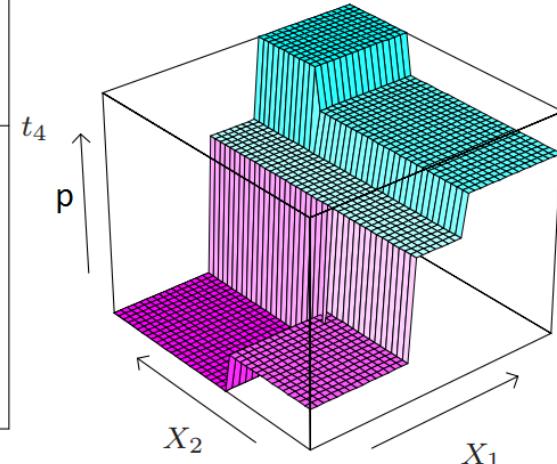
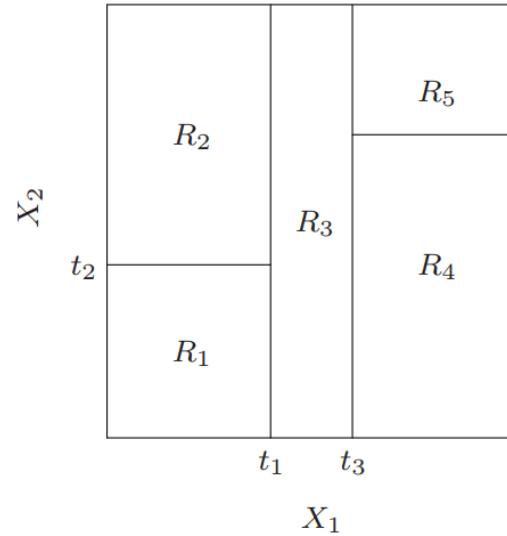
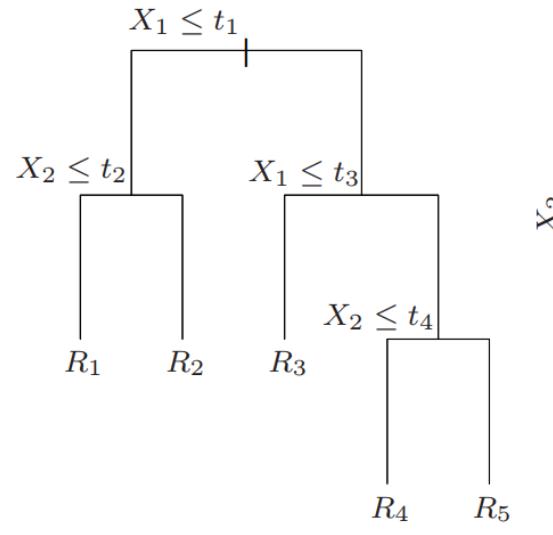
# Tre-modeller (I)

- Verdens enkleste nyttige statistiske modell!
  - Hver forgrening er en IF-THEN regel
  - Fungerer både for kontinuerlig og binær respons, samt klassifisering



Trent tre-modell for overlevelsesrate på Titanic

# Tre-modeller (II)



3 ulike visualiseringer av samme tre-modell

- Kan skrives som en vektet sum av indikatorvariable over regionene:

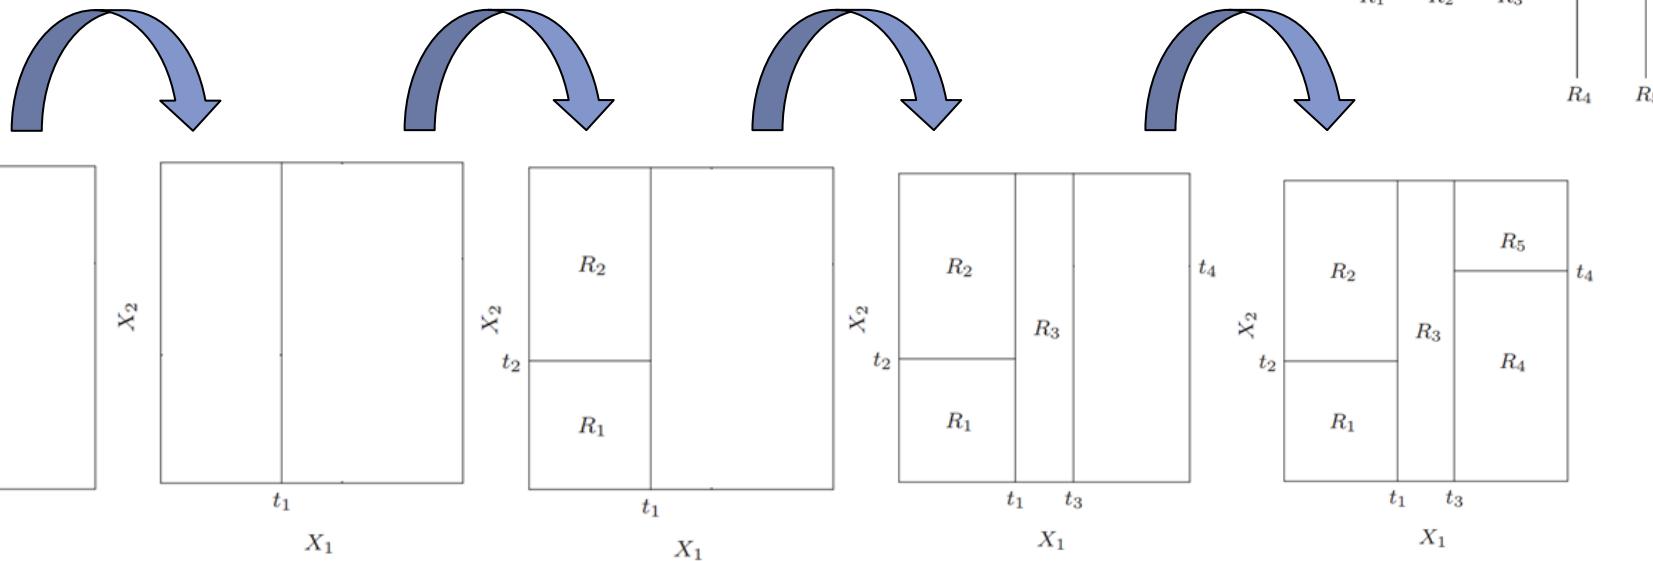
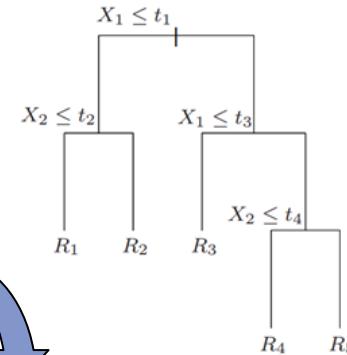
$$f(x) = \sum_{j=1}^T \theta_j \mathbf{1}_{\{x \in R_j\}}$$

# Trenings av tre-modeller

$$\sum_{i \in R_j} [L(y_i, \hat{y}_{R_{1j}}) + L(y_i, \hat{y}_{R_{2j}})]$$

where  $\hat{y}_{R_{kj}} = \operatorname{argmin}_c \sum_{i \in R_{kj}} L(y_i, c)$

- Beregningsmessig svært tungt å finne optimal regionsoppdeling
- Bruker en grådig algoritme i stedet (start med roten som den eneste (blad-)noden)
  1. For hver blad-node og kovariate  $x_j$ , finn det splittpunktet som gir lavest tap når man deler regionen i to deler
  2. Velg blad-node, kovariat og splittpunkt med størst tapsreduksjon
  3. Gjennomfør splitt med mindre stoppekriterium inntreffer
  4. Gjenta punkt 1-3



# Egenskaper med tre-modeller

- ▶ Fordeler
  - Enkle å tolke
  - Enkle å trenne
  - Invariant til monotone transformasjoner av kovariatene
  - Håndterer naturlig kontinuerlige og kategoriske data
  - Kan håndtere missing data
  - Modellerer ikke-lineariteter og interaksjoner direkte
  - Skalerer godt til store datamengder
- ▶ Ulemper
  - Fort gjort å overtilpasse
  - Diskrete prediksjoner
  - Begrenset prediksjonskraft

# Boosting: Prinsippet

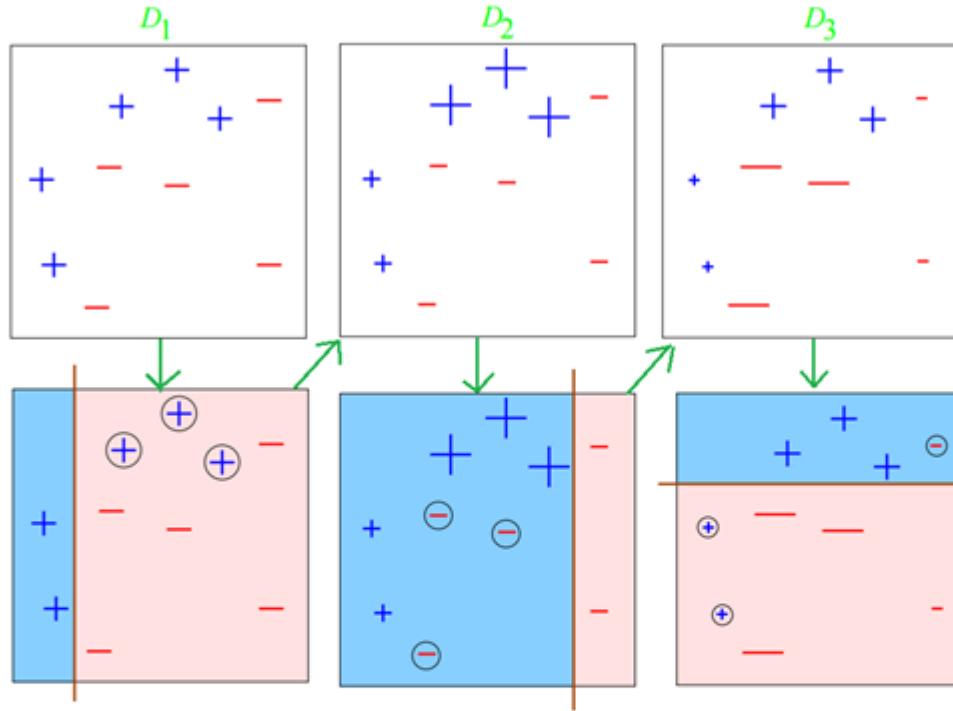
- ▶ Modell-ensamble teknikk som slår sammen mange enkle «basismodeller»  $f_m(x), m = 1, \dots, M$  (weak learners) til en avansert (strong learner)  $f_{final}(x)$
- ▶ Trener iterativt en og en basismodell, hver og en med mål om å reparere feilene til tidligere trente modeller (og minimere empirisk tap)
- ▶ Endelig prediksjon = Sum av prediksjoner fra alle basismodellene

$$f_{final}(x) = f^{(M)}(x) = \sum_{m=1}^M f_m(x)$$

$$f_m = \underset{h \in \Phi}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, f^{(m-1)}(x_i) + h(x_i))$$

For modellklasse  $\Phi$

# Eksempel boosting



$$\text{Pred} = \text{sign} \left( \frac{\text{Region 1}}{\text{Region 2}} + \frac{\text{Region 3}}{\text{Region 4}} \right) = \begin{array}{|c|c|c|c|} \hline & & & \\ \hline \text{+} & \text{-} & \text{+} & \text{-} \\ \hline \text{+} & \text{-} & \text{+} & \text{-} \\ \hline \end{array}$$

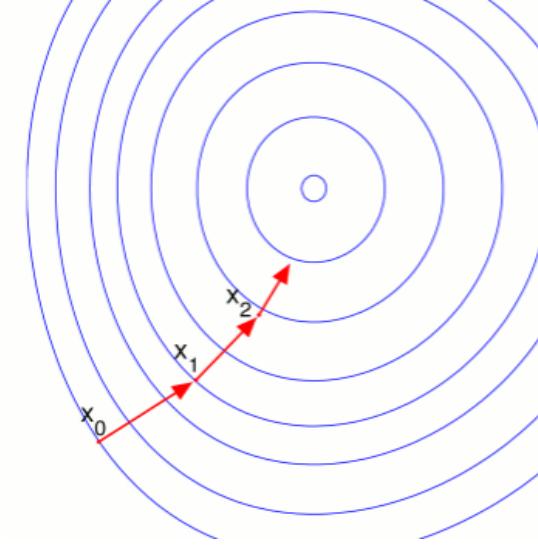
# Egenskaper med boosting

- ▶ Fordeler
  - Arver typisk alle egenskapene til basismodellene, men gir en vilkårlig god prediksjonskraft i tillegg
- ▶ Utfordringer
  - Svært viktig å kontrollere overtilpasning for å få en god modell
  - Boosting kan i seg selv ikke paralleliseres
  - Generelt vanskelig å oppdatere med nye modeller via

$$f_m = \underset{h \in \Phi}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, f^{(m-1)}(x_i) + h(x_i))$$

# Gradient boosting

- ▶ Gradient descent
  - Iterativ metode for å finne minimum av multivariat funksjon  $s(z)$
  - Tar steg langs den negative gradienten:  $z_m = z_{m-1} - \rho_m s'(z_{m-1})$
- ▶ Vi vil minimere
$$f_m = \underset{h \in \Phi}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, f^{(m-1)}(x_i) + h(x_i))$$
- ▶ Gradient boosting = Gradient descent for funksjoner/modeller
  - La  $s_i(z) = L(y_i, f^{(m-1)}(x_i))$ ,  $i = 1, \dots, n$
  - Bruk gradient descent for hver  $s_i$ , kall disse for  $y_i^*$
  - Tilpass modell av klasse  $\Phi$  med tapsfunksjon  $(y_i^* - f(x_i))^2$
  - + diverse detaljer om steglengde
  - Dette er den “vanlige” boosting-metoden.  
Brukes f.eks. i gbm-pakka i R
  - For steglengde =  $\frac{1}{2}$  og original kvadratisk tap er  $y_i^*$  = residualene



# 2. ordens approksimasjon

- Vil fortsatt minimere

$$f_m = \underset{h \in \Phi}{\operatorname{argmin}} \sum_{i=1}^n L(y_i, f^{(m-1)}(x_i) + h(x_i))$$

- Approksimer  $s_i(z) = L(y_i, z)$ , ved en 2. ordens Taylor ekspansjon:  
$$\begin{aligned} & L(y_i, f^{(m-1)}(x_i) + h(x_i)) \\ & \approx s_i(f^{(m-1)}(x_i)) + s_i'(f^{(m-1)}(x_i))h(x_i) + \frac{1}{2}s_i''(f^{(m-1)}(x_i))h(x_i)^2 \\ & = \frac{1}{2}s''(f^{(m-1)}(x_i))[-\frac{s'(f^{(m-1)}(x_i))}{s''(f^{(m-1)}(x_i))} - h(x_i)]^2 \end{aligned}$$
- Bytt ut original tapsfunksjon med kvadratisk approksimasjon og tilpass modell
- Brukes av XGBoost og andre moderne boosting-rammeverk, med tre-modeller som modellklasse  $\Phi$
- Ekvivalent med gradient boosting for kvadratisk tap

# XGBoost = eXtreme Gradient Boosting

- ▶ Et open source bibliotek bygget rundt en effektiv implementering av gradient boosting med tre-modeller som basismodeller
  - Utviklet av Tianqi Chen (Uni. Washington) i 2014
- ▶ Implementasjon
  - Grensesnitt for mange språk/plattformer: C++, Python, R, Julia, Java, Apache Spark etc.
  - Paralleliserbar trening av trærne, minnegjerrig og skalerbar
  - Kjører både på CPU og GPU
- ▶ Metodiske nyvinninger
  - 2.ordens approksimasjon av tapsfunksjonen – mer presis/effektiv enn ordinær gradient boosting
  - Legger til regularisering på toppen av original tapsfunksjon
- ▶ Praktisk bruk
  - Veldig mange parametere som kan skrus på, må gjøres manuelt
  - Kan ta lang tid å optimalisere/tune, men brukbare defaultparametere
  - «The Kaggle game killer»

# Funksjonalitet i XGBoost

- ▶ Håndterer både kryssvalidering og ferdigoppdelt trening/validering/testsett
- ▶ Kan definere egne tapsfunksjoner og valideringsmål (mange allerede implementert).
- ▶ Kan følge valideringsresultater mens modellen kjører (f.eks. AUC på trening, validering og testsett)
- ▶ «Early stopping» (stopper å legge til nye trær når valideringsresultater ikke forbedres lenger)
- ▶ Mange tilgjengelige måter å håndtere overtilpasning på
- ▶ Ingen pre-prosessering/skalering/standardisering nødvendig
- ▶ Håndterer manglende data automatisk (lærer default retning i hver splitt)
- ▶ Effektiviserer trening av trær ved å forhåndsdefinere en begrenset mengde splittpunkter (histogram-metoden)

# XGBoost – diverse

- ▶ Konkurrenter
  - LightGBM (Microsoft)
    - Har drevet/motivert mye av utviklingen av XGBoost
    - Mye likt, men ikke like modent og mangler noe funksjonalitet
    - Fortsatt noe raskere enn XGBoost?
  - CatBoost (Yandex)
    - Lignende, men håndtere også kategoriske variable direkte
    - Var langt treigere, men har blitt vesentlig bedre
    - Begrenset dokumentasjon
- ▶ Jeg har enda til gode å se et eksempel der Random Forest gjør det bedre enn en tunet XGBoost model!
- ▶ Hovedutfordringer:
  - Vanskelig/tidkrevende å finne optimal modell
  - Takler kun numerisk input: Ikke så god når det er mange kategoriske variable med mange klasser.

# Ressurser

- ▶ Didrik Nielsen, Masteroppgave NTNU, 2016:  
<https://brage.bibsys.no/xmlui/handle/11250/2433761>
- ▶ Chen & Guestrin (2016), XGBoost: A Scalable Tree Boosting System: <https://arxiv.org/abs/1603.02754>
- ▶ Hastie et al. (2009), Elements of Statistical Learning, Ch 9.2 + 10
- ▶ XGBoost GitHub: <https://github.com/dmlc/xgboost>
- ▶ XGBoost dokumentasjon: <http://xgboost.readthedocs.io>
- ▶ Slides fra foredrag med Tianqi Chen:  
<http://datascience.la/xgboost-workshop-and-meetup-talk-with-tianqi-chen/>