




SCIENCE AND
EDUCATION **FOR**
SUSTAINABLE
LIFE


KARTERING AV LINJÄRA STRUKTURER OCH VEGETATION I DE SVENSKA FJÄLLEN VIA NEURALA NÄTVERK

*Anna Allard, Sven Adler, Ann-Helen Granholm, Helena Forsman,
Åsa Hagner, Hans Gardfjell*
Landskapsanalys, SLU, Umeå

Deep Learning - image classification



Detektion av körspår och andra linjära objekt i fjällmiljö med hjälp av flygbilstolkning och maskininlärning (ML), Deep Learning




Classification



Malamute

Semantic Segmentation




Hund, gräs, skog, hundstuga (bara pixel)

Classification + Location



Malamute

Object detection



Undulat

Undulat

Instance segmentation



Undulat

Undulat

single object

multiple objects


Classification



Malamute



Dela upp i små bilder – var finns det vi söker efter?



Allokera i bilden var det finns stig/led, körspår, vattendrag samt det geografiska och ekologiska läget

Classification +
Location



Malamute
Gräsmatta

Utmaningar och fördelar med fjällen



Källa: Skolvision.se

Vegetationen befinner sig på sin naturgivna gräns:

- Ekologiskt läge
- Berggrund och näringsinnehåll i jord
- Klimatmässigt läge (altitud och latitud)
- m.m.

Det gör också att naturtyperna följer naturens lagar – och kan beräknas. Underlättar modelleringen.

Hela fjällkedjan delas upp i rutor om 30 x 30 m

Linjära element i fjällen via neurala nätverk och modeller

- *insamling av träningsdata,
2023*

Anna Allard, Helena Forsman, Ann-Helen Granberg, Sven
Adler


Sveriges lantbruksuniversitet, SLU
Institutionen för skoglig resurshushållning, Landskapsanalys
Nationell Inventeringar av Landskapet i Sverige - NILS
2024-02-11

Linjeelement	Antal 2023
Vattendrag/dike	8638
Stig/led Torr	1685
Stig/led Fukt	1145
Körspår 4-hjuling Torr	2213
Körspår 4-hjuling Fukt	1200
Kraftledning/Skidlift	145
Renstig Torr	584
Renstig fukt	327
Väg	175
Pipeline	8
övrigt linjärt element	14
Vegetationstyp	Antal 2023
Fjällbjörkskog	1006
Videbuskmark	854
Myr (graminidrik typ)	938
Myr (rismyr, buskmyr, fuktig rished)	853
Rished torr/frisk	1295
Lavrik rished	831
Gräshed/skarp rished	885
Gräsmark (hög- och lågörtäng)	874
Substratmark	1897



Oerhört stora mängder data
behövs till Deep Learning.
Detta är första insamlingen.

Blandning mellan
Vegetationskartans
vegetationstyper och
Annex-1-naturtyper.



Insamling av linjära objekt i torr eller frisk/fuktig/blöt mark.
Vi arbetar i IR-färg, inte normal färgbild.





Många objekt är
lätta att förstå för
en hjärna, men det
är svårt att lära en
maskin att förstå
skillnaden.




Myr eller gräsmark – klassisk mixup i fjällen



Ingen led syns tydligt, trots karta. Alltså får den inte vara med i träningsdata




Fjällbjörkskog: Moss- risrik, lavrik fjällbjörkskog
och ängsbjörkskog



Moss/risrik
fjällbjörkskog




Ängsbjörkskog



Lavrik
fjällbjörkskog

Laserdata är viktigt

Videbuskmarker Annex-1-naturtyper




Deep Learning

Körspår och vandringsled i fjällen

Lager

- pict_id_149
Band 1: 637_42_55 (Gray)
154
- test20
 - 0
 - 1.0000000000000000
 - 2.0000000000000000
 - 3.0000000000000000
 - 4.0000000000000000
 - 5.0000000000000000
- 637_42_55
Band 1 (Gray)
243
- tIndex_ortoHist60Pan050_cumulat
- test20_v02
 - 0
 - 1.0000000000000000
 - 3.0000000000000000
- test20_v02_3klasser
 - 0
 - 1.0000000000000000
 - 2.0000000000000000
 - 3.0000000000000000
- test10
 - 0
 - 1.0000000000000000
- 757_64_55

Datakällor Lager




Deep Learning


Körspår och vattendrag i fjällen

Lager

- pict_id_149
Band 1: 637_42_55 (Gray)
154
- test20
 - 0
 - 1.0000000000000000
 - 2.0000000000000000
 - 3.0000000000000000
 - 4.0000000000000000
 - 5.0000000000000000
- 637_42_55
Band 1 (Gray)
243
- tindex_ortoHist60Pan050_cumulat
- test20_v02
 - 0
 - 1.0000000000000000
 - 3.0000000000000000
- test20_v02_3klasser
 - 0
 - 1.0000000000000000
 - 2.0000000000000000
 - 3.0000000000000000
- test10
 - 0
 - 1.0000000000000000
- 757_64_55

Datakällor Lager





Två befintliga Python/R paket:
Keras / PyTorch

Parameters	Keras	PyTorch
Developed In	March 2015	October 2016
API	High-level	Low-level
Speed	Comparatively slower	Fast
Architecture Complexity	Simple	Complex
Community support	Limited	Strong
Dataset	Small datasets	Large datasets
Debugging	Challenging	Fast and easy
Computation Graphs	Static	Dynamic
Backend Implementation	TensorFlow, Theano and Microsoft CNTK	No
Ease of Use	Easy to use for beginners	Easy to use for scientifically-minded people

In R: Torch fungerar utan att man installerar Python






Grundläggande idé:

Vi människor förstår att detta är två olika vägar. Inte datorn. Då behöver man vrida och vända och se till att det går att förstå för en datoralgoritm






$$\begin{pmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{pmatrix} * x = W * x = x'$$

Här har vi vänt, själva stegen kan man förstå, men när det blir många tusentals bilder behöver man en dator






$$x' = x + v$$


Förflyttar





Större spår






$$x' = k * x$$






$$x' = W_1 * x + v_1$$



$$x' = W_2 * x + v_2$$



- Rotation
- Förstoring
- Flyttning
- Standardiserade pixelvärden (0-1 i varje bild, med samma kontrast)



Varje "lager" (layer) i ett neuralt nätverk är en datatransformation:

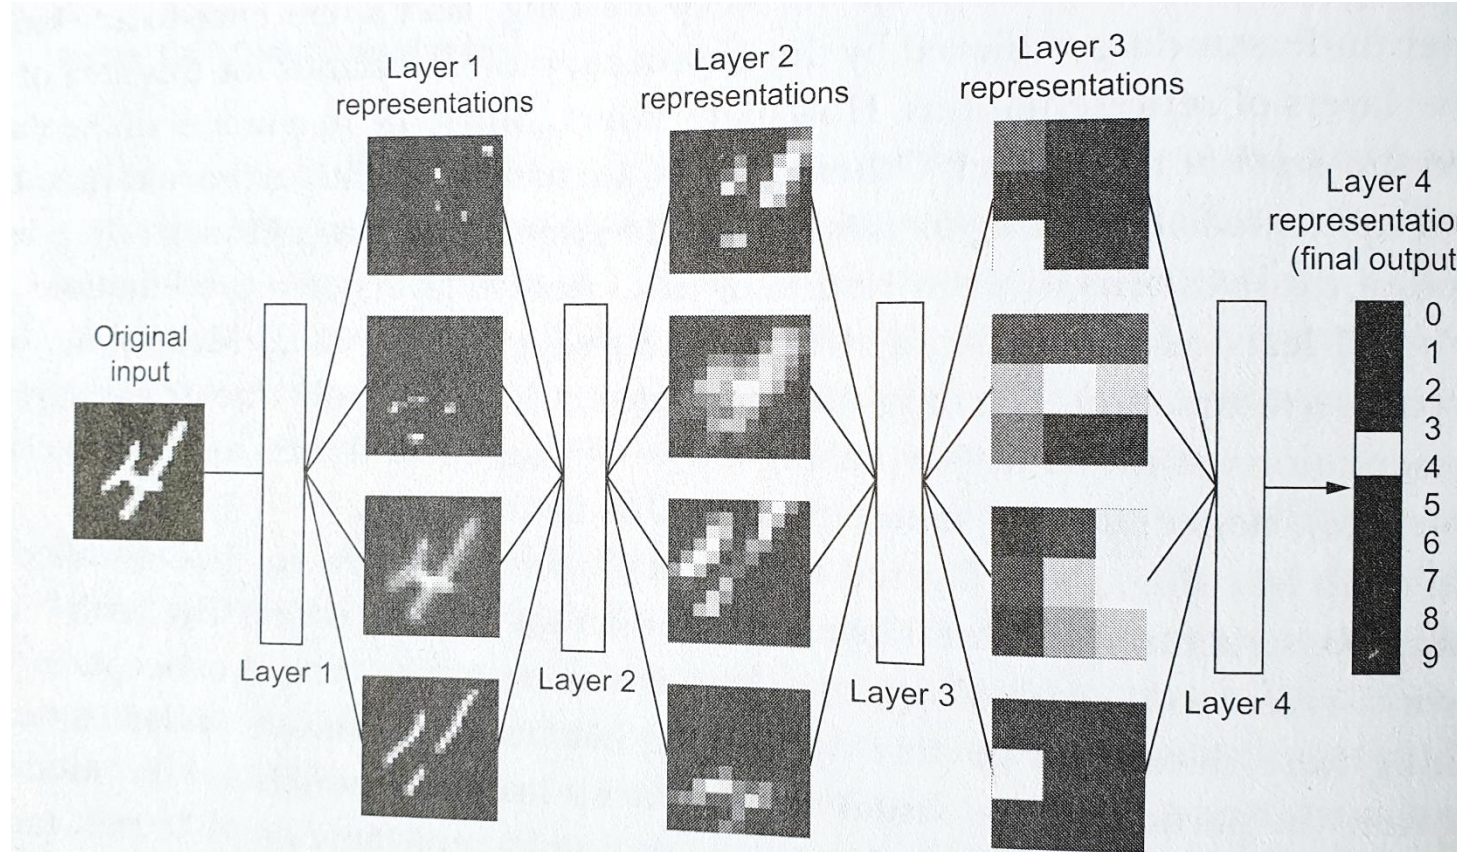



Figure 1.6 data representations learned by a digit-classification model

Första output – oftast helt fel. En mängd iterationer och nya vägar baserat på föregående resultat gör att man närmar sig målet.

Därför behovet av enorma mängder indata



R (keras + tensorflow)

```

model1 = keras_model_sequential()
model1 %>% layer_flatten() %>%
  layer_dense(units = 480, activation = 'relu') %>%
  layer_dense(units = 240, activation = 'relu') %>%
  layer_dense(units = 125, activation = 'relu') %>%
  layer_dense(units = 4, activation = 'softmax')

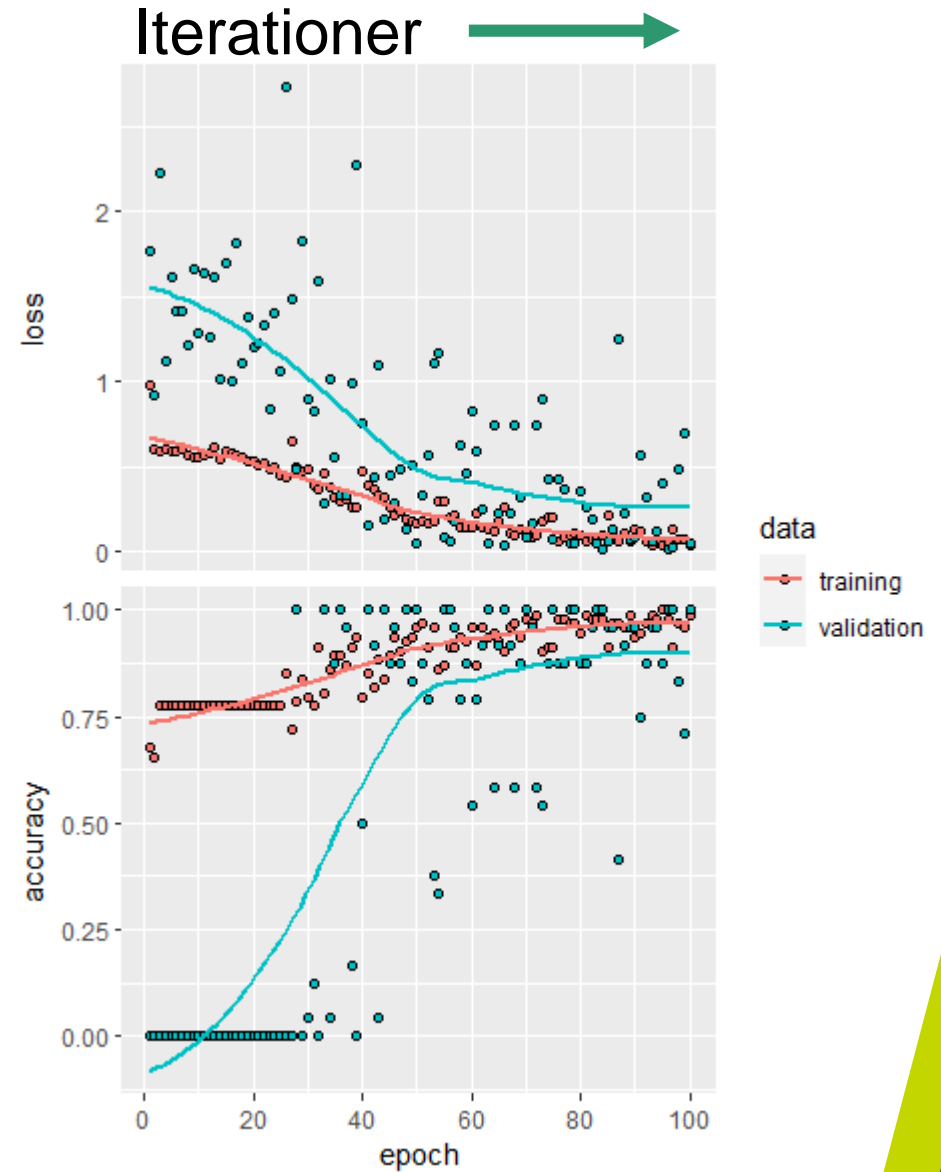
model1 %>% compile(optimizer = 'adam', loss = 'categorical_crossentropy',
  metrics = c('accuracy'))


fit1 = model1 %>% fit(x = trainx, y = trainlabel, epochs = 100, batch_size=30,
  validation_split = .2, callbacks = callback_tensorboard("logs/run_a"))

model1 %>% evaluate(testx, testlabel) [116 bilder]

```

loss	accuracy
0.06046977	0.9310345





En klassiker:
**Variation mellan grupperna
måste vara större än
variationen inom varje
grupp!**

→ Rätt klassad

→ Fel klassad

Nu börjar det roliga!



Framtiden

Mer indata, finindelad indata! Flygbilder, drönare, fältinventering, innovationer och utveckling av fältmetodik.

Struktur, textur, konfiguration

Arbeta in data i fler algoritmer

Utveckla karteringen av vegetation som bakgrund till de linjära objekten. Draghjälp av NMD-kartering hos Naturvårdsverket.

Doktorand och/eller Master som arbetar med data och utvecklingsarbete.

