

Projeto NeuroWood

- Motivação
- Processamento de imagem
- *Deep Learning*
- Redes neurais convolutivas
- Destritores de textura
- Técnicas de classificação
 - Redes neurais
 - Método KNN
 - Árvore de descisão
- Materiais e métodos
- Resultados

Motivação

Inspeção visual automática



Inspeção visual automática

Qualidades da madeira



Quality A




Quality B



Quality C

Processamento de imagem

Sampling




Quantization



8 bits per pixel

$$2^8 = 256$$



4 bits per pixel

$$2^4 = 16$$




2 bits per pixel

$$2^2 = 4$$

RGB Color Image




R




$$2^8 = 256$$

G



B




Aprendizagem profunda

“Deep learning”

Deep Learning

unsupervised supervised




Gostaríamos que a imagem de entrada em fosse gradualmente transformada em alto nível de representação

Para aprender algumas abstrações de alto nível como a visão, linguagem e outras tarefas, é necessária arquitetura profunda

Convolutional Neural Network

CNN

Convolutional Neural Network



- Características da CNN
 - Conectividade local
 - Compartilhamento de pesos
 - Agrupamento

Descritores de textura

Textura

- Representa detalhes numa imagem





Texture with repeated
local patterns




Local pattern

Textura



Repetição




Estocástica




Ambas

Textura

- Comparar texturas e decidir se elas são iguais ou diferentes.



Matriz de co-ocorrência



0 0 1 1 1
0 0 1 1 1
0 2 2 2 2
2 2 3 3 3
2 2 3 3 3

Considerando a configuração da posição relativa $Q = (1, 0)$:

pixel	viz. 0	viz. 1	viz. 2	viz. 3
ref. 0	2	2	1	0
ref. 1	0	4	0	0
ref. 2	0	0	5	2
ref. 3	0	0	0	4

Matriz tende a ser esparsa para mais níveis de intensidade.
É comum usar 8 ou 16 níveis de cinza apenas para diminuir o tamanho da matriz e a complexidade computacional.

$$u_x = \sum_i i \sum_j p_{i,j}, u_y = \sum_j j \sum_i p_{i,j}$$

$$s_x^2 = \sum_i (1 - u_x)^2 \sum_j p_{i,j}, s_y^2 = \sum_j (1 - u_y)^2 \sum_i p_{i,j}$$


$$entropy = - \sum_{i,j} p_{i,j} \log_2 p_{i,j}$$

$$energy = \sum_i \sum_j p_{i,j}^2$$


$$max = Max(p_{i,j})$$

$$correlation = \sum_i \sum_j \frac{(1 - u_x)(1 - u_y)p_{i,j}}{s_x s_y}$$

$$IDM = \sum_i \sum_j \frac{p_{i,j}}{1 + |i - j|}$$



Métodos de classificação



Acquisition Feature extraction Classification

Clustered data

Materiais e métodos

Resultados

Base de dados

Quantização da imagem

Image 27 x 94 pixel

matrix dos pixels

[[194 196 196 ..., 184 146 150]

[185 186 186 ..., 181 173 165]


[179 178 181 ..., 194 192 184]

...,

[187 190 192 ..., 188 187 187]

[176 176 176 ..., 197 196 195]

[193 193 193 ..., 193 193 191]]



Resultados

Descriptores de textura

Table 1: Haralick descriptor for test and training dataset

Class	x ₁	x ₂	x ₃	x ₄	x ₅	x ₁	x ₂	x ₃	x ₄	x ₅
A med	0.51	1.31	0.63	2.30	4.43	0.50	1.38	0.64	2.37	4.98
A stad	0.11	0.27	0.12	0.16	1.37	0.10	0.26	0.11	0.14	2.34
B med	0.48	1.51	0.61	3.19	34.58	0.48	1.52	0.60	3.27	32.88
B stad	0.07	0.23	0.09	0.64	28.96	0.09	0.27	0.11	0.55	22.54
C med	0.38	1.87	0.50	3.22	26.60	0.41	1.81	0.54	3.10	25.60
C stad	0.10	0.38	0.12	0.66	21.08	0.09	0.36	0.11	0.52	23.50

Resultados

Classificadores – rede neural

obt / pred	A	B	C
A	95	4	6
B	4	88	44
C	1	8	50

obt / pred	A	BC
A	90	6
BC	10	94

Resultados

Classificadores – KNN

Table 4: Misclassification matrix: Classes A, B and C - Accuracy 79.7%

obt / pred	A	B	C
A	92	6	3
B	15	81	4
C	9	47	43

Table 5: Misclassification matrix: Classes A and BC - Accuracy 93,4%

obt / pred	A	BC
A	91	9
BC	5	95

Resultados

Classificadores – Geral

Table 6: Average Accuracy(%) by classification process

Regressors	ABC	A-BC
CNN	80.0	88.8
TD/DT	x	x
TD/NN	85.3	92.4
TD/KNN	79.7	93.4

Resultados

Table 14: Dataset: A-B-C average accuracy by classification process

model	Accuracy (%)	κ
CNN	77.69 (± 7.11)	0.611 (± 0.124)
MLP	81.26 (± 4.90)	0.681 (± 0.081)
KNN	82.11 (± 6.17)	0.703 (± 0.102)
SVM	80.73 (± 3.03)	0.660 (± 0.051)
DT	81.28 (± 5.51)	0.688 (± 0.093)

Table 15: Dataset: A-BC average accuracy by classification process

model	κ	accuracy %
CNN	79.07 (± 9.95)	0.549 (± 0.216)
MLP	93.56 (± 3.86)	0.867 (± 0.080)
KNN	92.50 (± 4.15)	0.846 (± 0.085)
SVM	92.49 (± 3.18)	0.845 (± 0.065)
DT	93.31 (± 2.75)	0.860 (± 0.056)

Conclusões

- Para aplicações de classificação de imagens onde a se tem um número restrito de classes, e imagens bem segmentadas as técnicas tradicionais tem melhor resultado.

Obrigado