


Projetos finais

Grupo 3


Integrantes



Laez Barbosa da
Fonseca Filho
8586902
laez.filho@usp.br



Caetano Mastroianni
Dieguez
7210164
caetano.dieguez@usp.br



Lais Harumi Fukujima
Aguiar
8587142
lais.aguiar.br@ieee.org



Oscar Vega
Huayanay
9718091
oscar.vegah@usp.br

Reconhecedor de frutas


Um classificador

O problema

- Classificação de frutas é um interessante problema de visão de máquina com aplicações nas áreas de ensino, em indústrias e supermercados, e muitos outros.
- Visão de máquina é uma área de grande interesse e intensa pesquisa (a qual apenas aranhamos a superfície nesse trabalho).
- Grande dimensionalidade envolvida em imagens implica em grande importância para o pré-processamento.

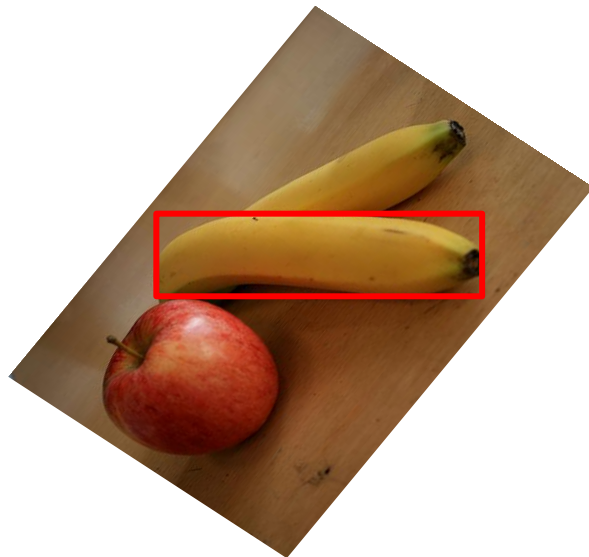
A proposta

- Classificador de frutas, implementado com um MLP, utilizando o Matlab.
- Ênfase no pré-processamento e na extração de características.



A abordagem



- Rotação e extração da região de interesse (ROI) da imagem.
- Imagens obtidas no site www.image-net.org



A abordagem

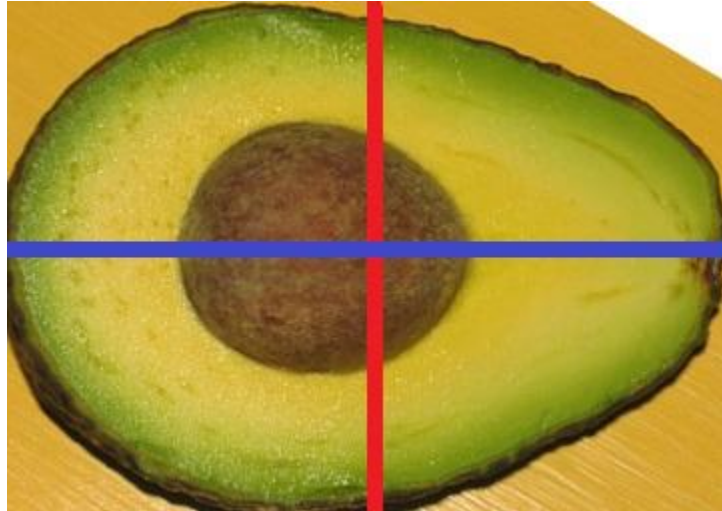
- Trabalhamos no espaço HSI bem como no RGB.
- Extração de características de cor e forma para cada uma das componentes de cada espaço, reduzindo drasticamente a dimensão do problema.

A abordagem



As características

- Média e variância de cada componente RGB e HSI. (características de cor).
- Proporção altura/largura da região de interesse da imagem da fruta.



A implementação

- Como visto em aula:

Iteração em complexidade

Iteração K-Fold

Iteração inicialização dos W_0

... Aspectos de refinamentos nos projetos ...

Diferentes aspectos estudados no treinamento / otimização / caracterização da RNA ...

- Vários Delta W sequenciados (gradiente descendente)
- Re-sorteios de pesos iniciais (fugindo de mínimos locais)
- k-fold cross validation (avaliando sensibilidade aos dados empíricos)
- Diferentes graus de complexidade do modelo neural (evitando sobreaprendizado)
- Ensaios com vários Pré-Processamentos alternativos (aumentando desempenho)
- Descarte de algumas variáveis de menor relevância, p/ melhora do desempenho
- Aumento de $M+M'$ c/ as mesmas variáveis (há custo extra com novas coletas $X; y$)
- Acréscimo de variáveis x incluídas no modelo (há custo extra com novas coletas)
- ... Outros ...

3

2015-16 – © Prof. Emilio Del Moral – EPUSP

A implementação

- Matlab

Iteração em complexidade

Iteração K-Fold

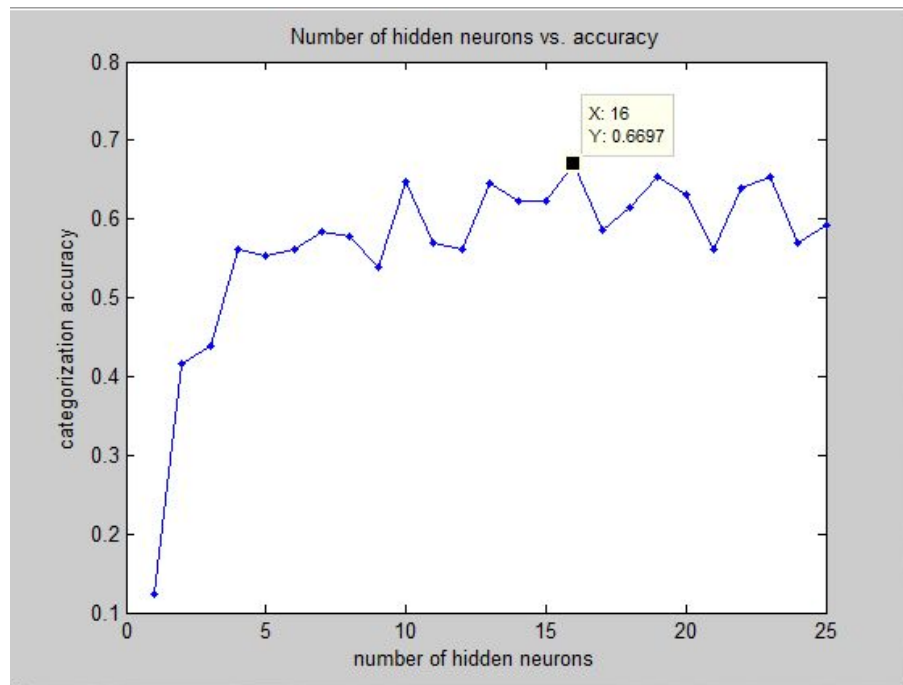
Iteração inicialização dos W_0

```
38
39
40     indices = ones(130);
41     for j = 1:length(indices) ...
44     for i = 1:length(sweep) %Iterar Complexidade
46         for j = 1:3 %Iterar 3-Fold
48
49             cnt = 0;
50             for k = 1:length(indices) ...
55
56                 trainT = ones(130-cnt,1); testT = ones(cnt,1);
57                 cnte = 1; cnta=1;
58                 for k = 1:length(indices) ...
67
68                     for k = 1:3 %Iterar inicialização de W
69                         hiddenLayerSize = sweep(1);
70                         net = patternnet(hiddenLayerSize);
71                         net.divideFcn = 'divideind';
72                         net.divideMode = 'sample';
73                         net.divideParam.trainInd = trainT ;
74                         net.divideParam.valInd= [];
75                         net.divideParam.testind= testT ;
76                         net = train(net, x, t);
77                         models(i,j,k) = net;
78                         outputs = net(inputs);
79                         xt=testT(:,1)';
80                         [c,cm] = confusion(targets(:,xt),outputs(:,xt))
81                         todoScores(i,j,k) = 1-c;
82                     end
83
84                     scoreKFold(i,j) = max( todoScores(i,j,:) );
85                 end
86                 scores(i) = mean( scoreKFold(i,:) );
87     end
```

Os resultados

Estudo da complexidade do modelo

neurônios (16) : 66.97% acurácia



Os resultados

- 1 - Morango
- 2 - Maçã
- 3 - Pêssego
- 4 - Mamão
- 5 - Laranja
- 6 - Tangerina
- 7 - Banana
- 8 - Abacate
- 9 - Maçã verde
- 10 - Uva

Confusion Matrix

	1	2	3	4	5	6	7	8	9	10	
1	12 9.2%	3 2.3%	3 2.3%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	63.2% 36.8%
2	0 0.0%	4 3.1%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	57.1% 42.9%
3	0 0.0%	3 2.3%	5 3.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	55.6% 44.4%
4	0 0.0%	0 0.0%	1 0.8%	11 8.5%	1 0.8%	0 0.0%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	68.8% 31.3%
5	0 0.0%	2 1.5%	0 0.0%	0 0.0%	7 5.4%	5 3.8%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	46.7% 53.3%
6	0 0.0%	1 0.8%	1 0.8%	0 0.0%	4 3.1%	7 5.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	53.8% 46.2%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 7.7%	2 1.5%	0 0.0%	0 0.0%	83.3% 16.7%
8	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	7 5.4%	1 0.8%	0 0.0%	77.8% 22.2%
9	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 2.3%	12 9.2%	1 0.8%	70.6% 29.4%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	11 8.5%	84.6% 15.4%
	92.3% 7.7%	30.8% 69.2%	38.5% 61.5%	84.6% 15.4%	53.8% 46.2%	53.8% 46.2%	76.9% 23.1%	53.8% 46.2%	92.3% 7.7%	84.6% 15.4%	66.2% 33.8%
	1	2	3	4	5	6	7	8	9	10	

Output Class

Target Class

Os resultados

Matriz de Confusão

Melhores categorias:
(>75% de sensibilidade)

- Morango (1)
- Mamão (4)
- Banana (7)
- Maçã verde (9)
- Uva (10)

Confusion Matrix

	1	2	3	4	5	6	7	8	9	10	
1	12 9.2%	3 2.3%	3 2.3%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	63.2% 36.8%
2	0 0.0%	4 3.1%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	57.1% 42.9%
3	0 0.0%	3 2.3%	5 3.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	55.6% 44.4%
4	0 0.0%	0 0.0%	1 0.8%	11 8.5%	1 0.8%	0 0.0%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	68.8% 31.3%
5	0 0.0%	2 1.5%	0 0.0%	0 0.0%	7 5.4%	5 3.8%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	46.7% 53.3%
6	0 0.0%	1 0.8%	1 0.8%	0 0.0%	4 3.1%	7 5.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	53.8% 46.2%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 7.7%	2 1.5%	0 0.0%	0 0.0%	83.3% 16.7%
8	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	7 5.4%	1 0.8%	0 0.0%	77.8% 22.2%
9	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 2.3%	12 9.2%	1 0.8%	70.6% 29.4%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	11 8.5%	84.6% 15.4%
	92.3% 7.7%	30.8% 69.2%	38.5% 61.5%	84.6% 15.4%	53.8% 46.2%	53.8% 46.2%	76.9% 23.1%	53.8% 46.2%	92.3% 7.7%	84.6% 15.4%	66.2% 33.8%
	1	2	3	4	5	6	7	8	9	10	

Output Class

Target Class

Os resultados

Piores categorias:
(<40% de sensibilidade)

- Maçã (2)
- Pêssego (3)

	1	2	3	4	5	6	7	8	9	10	
1	12 9.2%	3 2.3%	3 2.3%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	63.2% 36.8%
2	0 0.0%	4 3.1%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	57.1% 42.9%
3	0 0.0%	3 2.3%	5 3.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	55.6% 44.4%
4	0 0.0%	0 0.0%	1 0.8%	11 8.5%	1 0.8%	0 0.0%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	68.8% 31.3%
5	0 0.0%	2 1.5%	0 0.0%	0 0.0%	7 5.4%	5 3.8%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	46.7% 53.3%
6	0 0.0%	1 0.8%	1 0.8%	0 0.0%	4 3.1%	7 5.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	53.8% 46.2%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 7.7%	2 1.5%	0 0.0%	0 0.0%	83.3% 16.7%
8	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	7 5.4%	1 0.8%	0 0.0%	77.8% 22.2%
9	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 2.3%	12 9.2%	1 0.8%	70.6% 29.4%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	11 8.5%	84.6% 15.4%
	92.3% 7.7%	30.8% 69.2%	38.5% 61.5%	84.6% 15.4%	53.8% 46.2%	53.8% 46.2%	76.9% 23.1%	53.8% 46.2%	92.3% 7.7%	84.6% 15.4%	66.2% 33.8%
	1	2	3	4	5	6	7	8	9	10	

Os resultados

- Grande confusão entre laranjas e tangerinas.
- Muitos falsos positivos em morangos.
- Alguma confusão entre frutas compridas.
- Baixa acurácia em frutas redondas e avermelhadas.

Confusion Matrix

	1	2	3	4	5	6	7	8	9	10	
1	12 9.2%	3 2.3%	3 2.3%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	63.2% 36.8%
2	0 0.0%	4 3.1%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	57.1% 42.9%
3	0 0.0%	3 2.3%	5 3.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	55.6% 44.4%
4	0 0.0%	0 0.0%	1 0.8%	11 8.5%	1 0.8%	0 0.0%	3 2.3%	0 0.0%	0 0.0%	0 0.0%	68.8% 31.3%
5	0 0.0%	2 1.5%	0 0.0%	0 0.0%	7 5.4%	5 3.8%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	46.7% 53.3%
6	0 0.0%	1 0.8%	1 0.8%	0 0.0%	4 3.1%	7 5.4%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	53.8% 46.2%
7	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	10 7.7%	2 1.5%	0 0.0%	0 0.0%	83.3% 16.7%
8	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	0 0.0%	7 5.4%	1 0.8%	0 0.0%	77.8% 22.2%
9	1 0.8%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	0 0.0%	3 2.3%	12 9.2%	1 0.8%	70.6% 29.4%
10	0 0.0%	0 0.0%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	0 0.0%	1 0.8%	0 0.0%	11 8.5%	84.6% 15.4%
	92.3% 7.7%	30.8% 69.2%	38.5% 61.5%	84.6% 15.4%	53.8% 46.2%	53.8% 46.2%	76.9% 23.1%	53.8% 46.2%	92.3% 7.7%	84.6% 15.4%	66.2% 33.8%
	1	2	3	4	5	6	7	8	9	10	

Output Class

Target Class

Análise

- Muitas confusões entre frutas da mesma cor ou forma.
- Tangerinas e laranjas foram muito confundidas, mas os próprios membros do grupo tiveram dificuldade em diferenciá-las. Talvez seja uma tarefa muito difícil para esse tipo de classificador.

Comentários

- O modelo sofreu com a falta de variáveis de textura, que poderia diferenciar frutas com cores e/ou formas parecidas, como maçãs e pêssegos.
- A utilização de uma medida de forma mais sofisticada poderia, também, ajudar na performance do modelo.
- Acreditamos que a própria escolha das categorias apresentou influência no resultado: eram poucas categorias, e algumas eram similares entre si, enquanto outras se destacavam facilmente pela cor apenas (ex. maçã verde)
- Para um próximo ensaio, além das coisas notadas acima, pode-se coletar mais exemplares, que sejam representativos da fruta em formas diferentes (ex. aberta, fechada, com caroço etc).

Estimador de notas

Um regressor

O problema

- Estimar o desempenho de aluno em redação, com base no histórico de notas do mesmo.
- Útil para acompanhamento do aluno, prevendo com antecedência resultados ruins para possíveis medidas de prevenção.
- Possibilita a auto-avaliação do curso, para melhora do serviço com antecedência.

A proposta

- Estimador simples, MLP implementado no MBP.
- Enfoque no aprendizado e validação.

A abordagem

- Uso de dados brutos, com pouco pré-processamento.
- Dados obtidos diretamente com um cursinho famoso de São Paulo.
- Possibilita maior foco na otimização dos pesos, teste, validação, e outras questões que não são específicas do problema.

Definições


- A imputação dos dados faltantes foi feita utilizando a seguinte fórmula, para substituir cada redação que não foi feita:

$$\text{Nota_faltante} = (1/10) * \Sigma(\text{notas})$$

- Para esse projeto consideramos um bom resultado uma previsão com erro menor que 1 ponto, isso nos ajuda a mensurar a qualidade da rede.

A implementação



- Foram feitos ensaios em diferentes topologias, comparando-se os resultados obtidos.
- A partir de alguns testes foi definida uma topologia que se enquadra melhor ao nosso problema (10-1-1).



Topologia 10-5-1

- Ensaio 10-5-1

Histograma de Erro




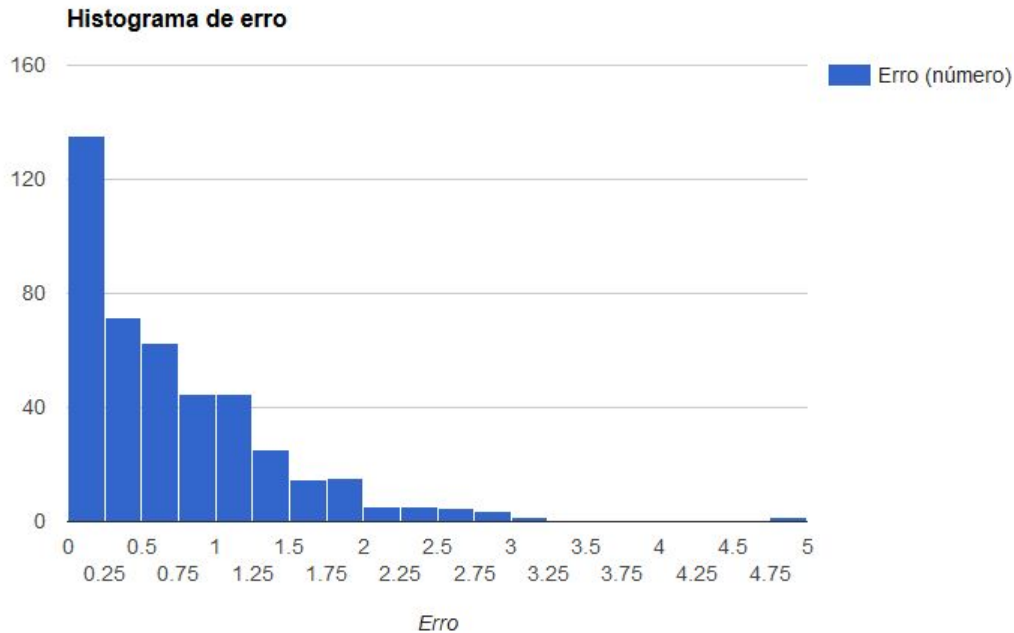
Topologia 10-5-1

- 95.34% dos módulos dos erros foram abaixo de 2 pontos, e 71.33% abaixo de 1.

Valores de limiar	Quantidade de acertos	% de acertos
0.25	134	31.24%
0.5	194	45.22%
0.75	248	57.81%
1	306	71.33%

Topologia 10-8-1

- Ensaio 10-8-1



Topologia 10-8-1



- 95.57% dos módulos dos erros foram abaixo de 2 pontos, e 72.73% abaixo de 1.

Valores de limiar	Quantidade de acertos	% de acertos
0.25	135	31.47%
0.5	206	48.02%
0.75	268	62.47%
1	312	72.73%

Topologia 10-3-1

- Ensaio 10-3-1

Histograma de Erro




Topologia 10-3-1

- 93.71% dos módulos dos erros foram abaixo de 2 pontos, e 69.00% abaixo de 1.

Limiar	Quantidade de acertos	% de acertos
0.25	116	27.04%
0.5	194	45.22%
0.75	252	58.74%
1	296	69.00%

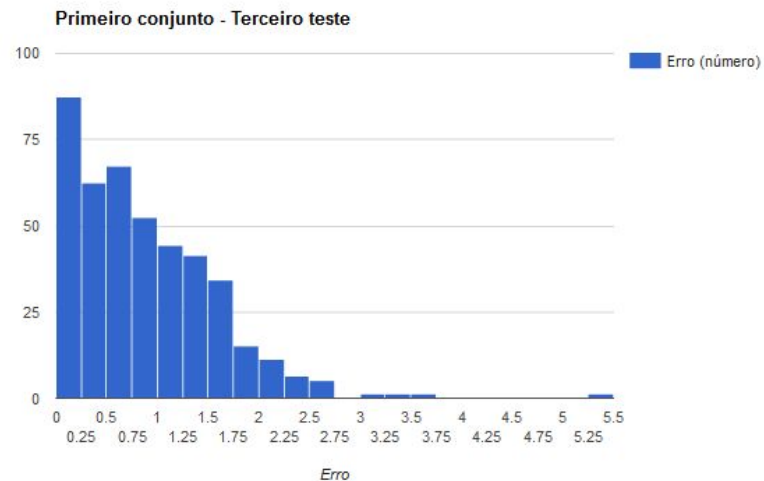
Topologia 10-1-1 (escolhida)

- Para essa topologia foi realizada validação cruzada K-fold, utilizando $k = 5$.
- Dessa forma, fazemos uma iteração para sortear novos pesos iniciais para cada treino, de forma a obter a melhor rede neural para cada conjunto.




Primeiro Conjunto

Limiar	Quantidade de acertos	% de acertos
0.25	87	20,33%
0,5	149	34,81%
0,75	216	50,47%
1	268	62,62%



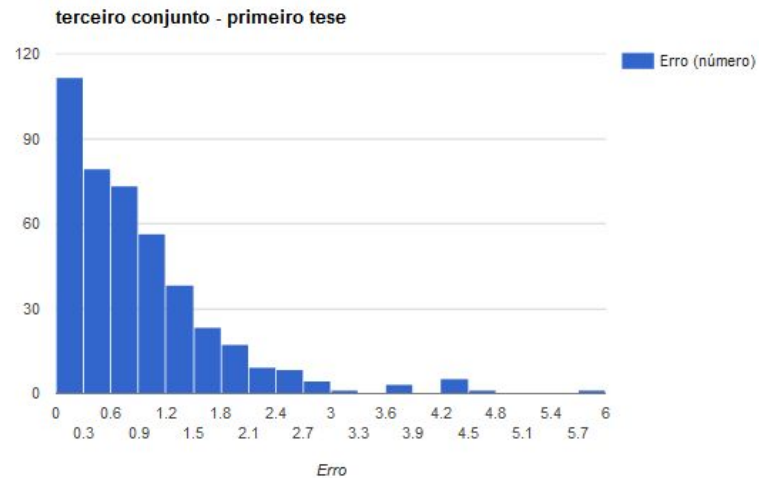
Segundo Conjunto

Limiar	Quantidade de acertos	% de acertos
0.25	86	20,05%
0,5	157	36,60%
0,75	226	52,68%
1	277	64,57%



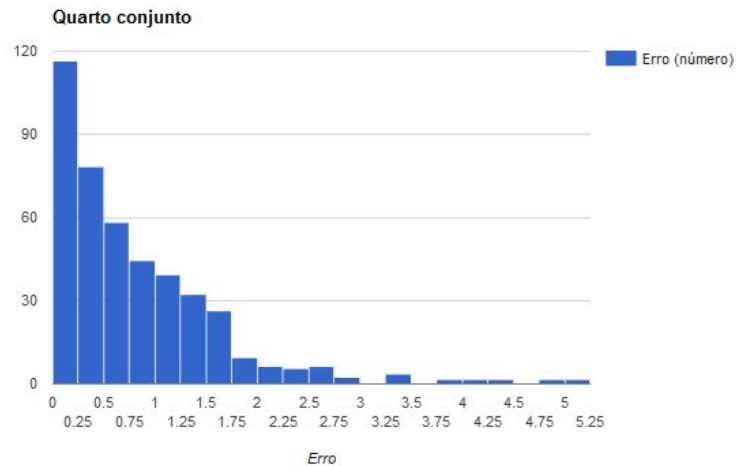
Terceiro Conjunto

Limiar	Quantidade de acertos	% de acertos
0.25	101	23,54%
0,5	173	40,33%
0,75	224	52,21%
1	284	66,20%



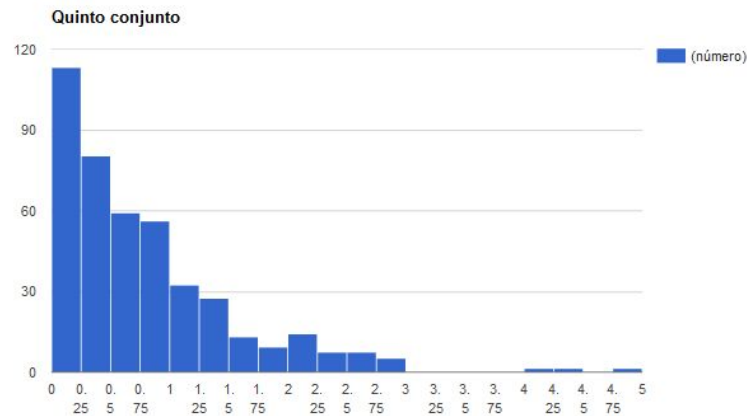
Quarto Conjunto

Limiar	Quantidade de acertos	% de acertos
0.25	116	27,04%
0,5	194	45,22%
0,75	252	58,74%
1	296	69,00%

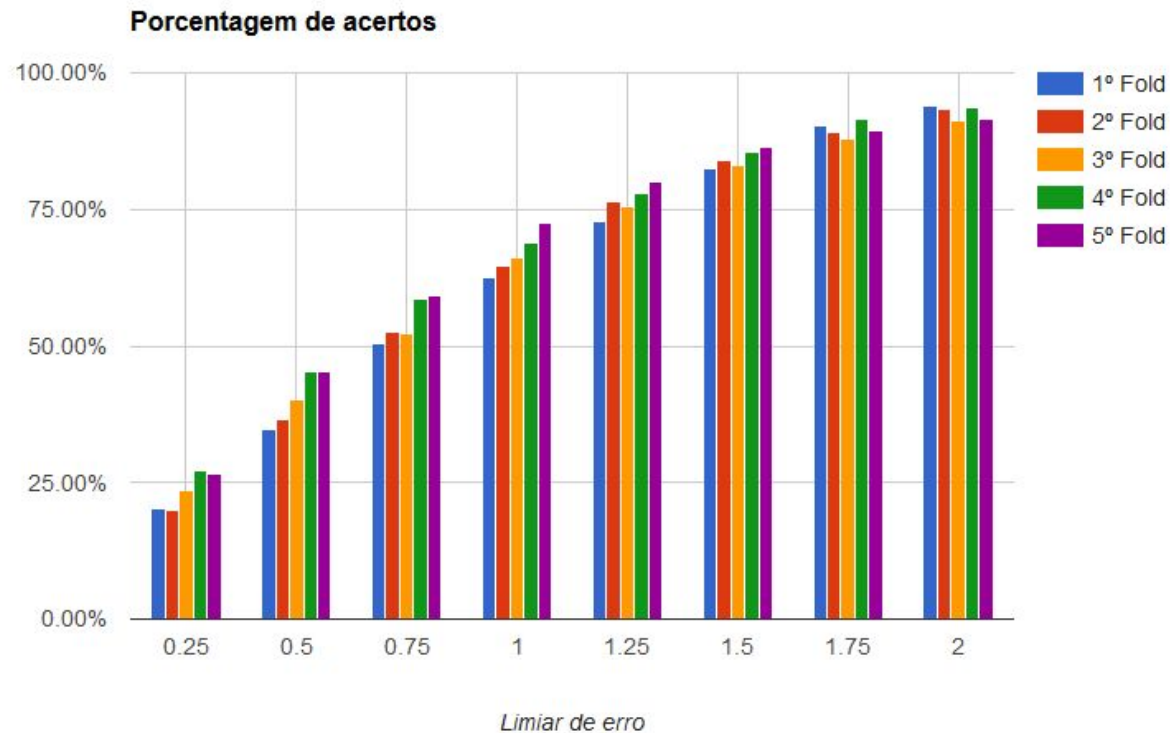


Quinto conjunto

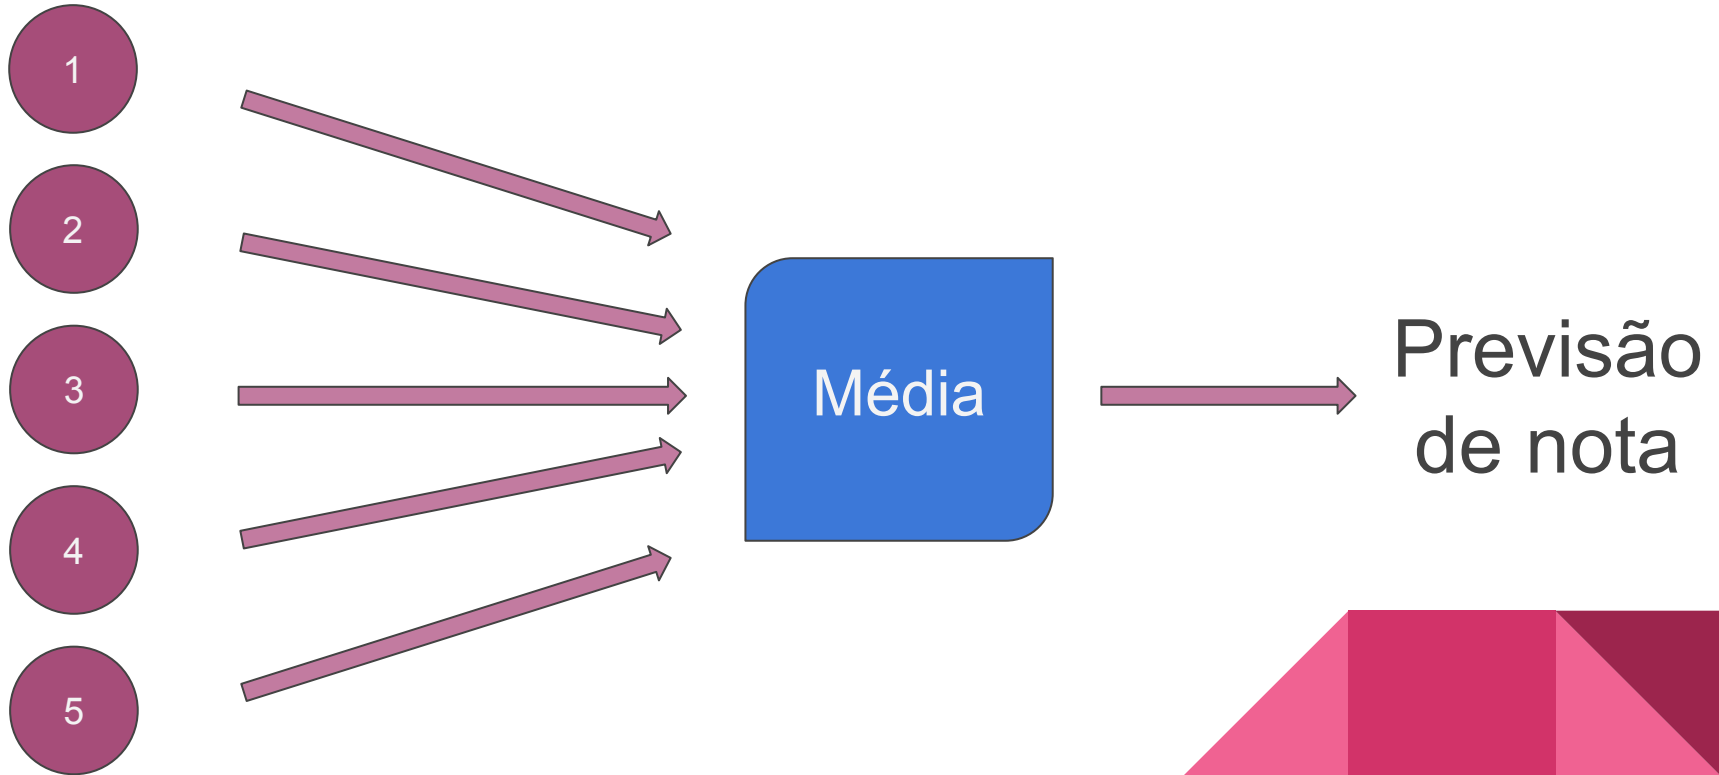
Limiar	Quantidade de acertos	% de acertos
0.25	113	26,59%
0,5	193	45,41%
0,75	252	59,29%
1	308	72,47%



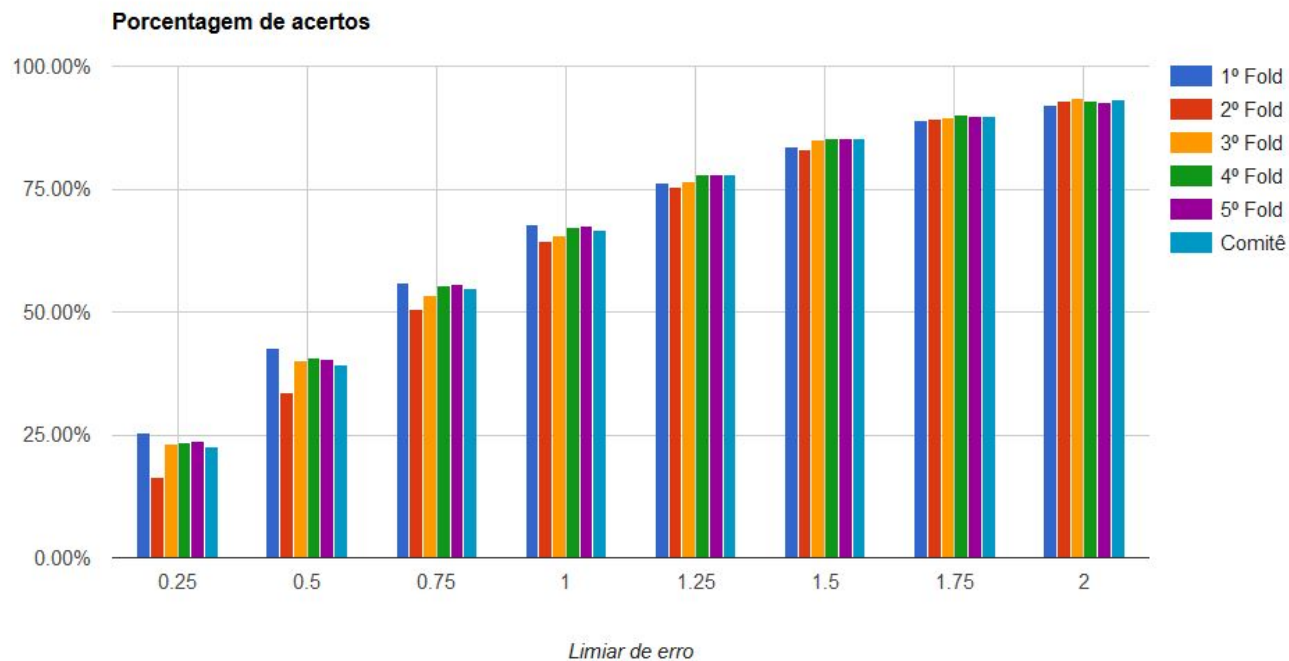
Resultados da validação



Comitê de Máquinas



Comitê de Máquinas



Comentários

- Modelos com mais de um neurônio na camada escondida não apresentaram ganho considerável de performance que justificasse usar rede mais complexa.
- Era esperado que o Comitê de máquinas apresentasse performance ligeiramente menor que as redes individuais para o conjunto de exemplos usado, por tender a ser menos enviesado em relação ao treino. Na prática, porém, não se observou perda significativa.
- Provavelmente modelos muito mais simples consigam performances equiparáveis.

Bibliografia

- Deng, Jia, et al. "Imagenet: A large-scale hierarchical image database." *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*. IEEE, 2009.
- Savakar, Dayanand G., and Basavaraj S. Anami. "Recognition and classification of food grains, fruits and flowers using machine vision." *International Journal of Food Engineering* 5.4 (2009).
- Zhang, Yudong, et al. "Fruit classification using computer vision and feedforward neural network." *Journal of Food Engineering* 143 (2014): 167-177.
- Arivazhagan, S., et al. "Fruit recognition using color and texture features." *Journal of Emerging Trends in Computing and Information Sciences* 1.2 (2010): 90-94.
- Material de aula de Élia Matsumoto.
- Material da disciplina PSI2672

Fim

Perguntas?