

Máquinas de Aprendizado Extremo para a Extração de Descritores em Imagens de Textura

Acacio Neckel¹, João B. Florindo²
UNICAMP, Campinas, SP

Nos dias atuais a inteligência artificial é uma das áreas com grande aplicação no desenvolvimento de novas tecnologias. Entre suas subáreas, destaca-se a visão computacional, abordada no presente trabalho, mais especificamente na tarefa de classificação de imagens de textura com diferentes algoritmos e algumas variações.

O ponto de partida de nosso algoritmo é baseado em máquinas de aprendizagem extrema (ELM da sigla em inglês) [1]. Este modelo pode ser modificado para extrair descritores de imagens [2]. Para tanto, um conjunto de submatrizes, com dimensões $(3 \times 3, 5 \times 5, \dots)$ percorre a imagem, recolhendo duas informações: o pixel correspondente ao centro de cada submatriz e seus respectivos vizinhos. Cada vetor coluna correspondente a uma vizinhança é armazenado em uma matriz X e o pixel central na matriz Y . Uma matriz W de pesos aleatórios é gerada e $Z = \phi(WX)$, sendo ϕ uma função de ativação. Ao final temos um sistema linear $MZ = Y$, no qual os valores de M correspondem ao vetor de descritores da imagem. Outra ferramenta aqui utilizada como auxiliar ao ELM foi a transformada de padrões locais binários (LBP) [3]. Nesta também se percorre a imagem com uma submatriz (3×3) , gerando um número binário, onde cada bit é uma comparação entre um pixel da submatriz com seu central. Ao final, o número binário é transformado em decimal e uma nova imagem é construída com esses valores.

O primeiro teste foi a aplicação do ELM em imagens após a transformada LBP (notação ELM_{LBP} na Tabela 1). Também foi feito o caminho inverso, usar o ELM como transformada e o LBP para extrair descritores (LBP_{ELM}). Além disso, foi trabalhado com a junção do ELM com LBP ($ELM + LBP$), quando na entrada dos dados é usado o vetor do ELM e na saída é usada a transformação LBP deste vetor, conforme a Figura 1. Outra abordagem foi a utilização do ELM morfológico (ELM_{morf}) [4], porém aqui utilizado para extrair descritores de imagens.

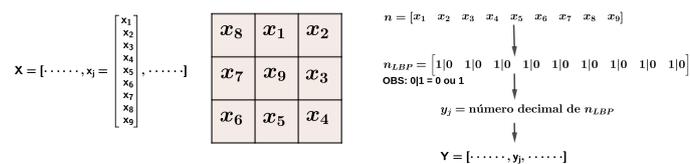


Figura 1: Junção dos algoritmos ELM e LBP. Fonte: [5].

Os algoritmos computacionais foram testados nas seguintes bases de imagens de texturas: UMD [6] composta por 25 classes com 40 imagens cada, UIUC [7], mesmo número de imagens e classes que a anterior, e KTHTIPS-2b [8], que tem 11 classes com 432 imagens em cada. Para os testes, foram utilizados três classificadores: Análise Discriminante Linear, Máquinas de Vetores de Suporte e Florestas Aleatórias. Na Tabela 1 são apresentados os melhores resultados.

¹acacio.neckel@gmail.com

²florindo@unicamp.br

Tabela 1: Porcentagem de acertos em bases de *Benchmark*.

Método	UMD	UIUC	KTHTIPS-2b
<i>ELM</i>	97.4	95.8	58.2
<i>ELM_{LBP}</i>	93.4	70.6	50.3
<i>ELM + LBP</i>	98.2	95.7	61.1
<i>LBP_{ELM}</i>	96.1	75.6	54.5
<i>ELM_{morf}</i>	97.7	93.3	59.2
Combinações <i>ELM</i>	99.0	96.8	65.4

Analisando-se a Tabela 1, temos o destaque para o aumento da acurácia na junção do algoritmo ELM com LBP. Percebe-se que a combinação de todos os valores da submatriz como dados de entrada no sistema ($MZ = Y$) contribui para uma maior riqueza e robustez dos descritores e que Y tem o valor ajustado por um processo envolvendo todos os pixels da imagem original. A linha com os resultados de combinações *ELM* apresenta diferentes tipos de concatenações entre os métodos explorados. As implementações computacionais com mais detalhes e os resultados aqui destacados podem ser observados em [5], ficando uma análise matemática para trabalhos futuros.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Referências

- [1] G. B. Huang, Q. Y. Zhu e C. K. Siew. “Extreme learning machine: Theory and applications”. Em: **Neurocomputing** 70.1 (2006), pp. 489–501. ISSN: 0925-2312. DOI: <https://doi.org/10.1016/j.neucom.2005.12.126>.
- [2] J. J. M. Sa Junior e A. R. Backes. “ELM based signature for texture classification”. Em: **Pattern Recognition** (2016), pp. 395–401. DOI: <https://doi.org/10.1016/j.patcog.2015.09.014>.
- [3] T. Ojala, M. Pietikainen e T. Maenpaa. “Multiresolution gray-scale and rotation invariant texture classification with local binary patterns”. Em: **IEEE Transactions on Pattern Analysis and Machine Intelligence** 7 (2002), pp. 971–987. DOI: 10.1109/TPAMI.2002.1017623.
- [4] P. Sussner e I. Campiotti. “Extreme learning machine for a new hybrid morphological/linear perceptron”. Em: **Neural Networks** 123 (2020), pp. 288–298. DOI: <https://doi.org/10.1016/j.neunet.2019.12.003>.
- [5] A. Neckel. “Máquinas de aprendizado extremo aplicadas ao reconhecimento de imagens de texturas: uma aplicação em imagens médicas”. Dissertação de mestrado. Unicamp, 2020.
- [6] Database UMD. **Viewpoint invariant texture description**. 0. URL: <http://users.umiacs.umd.edu/~fer/website-texture/texture.htm>.
- [7] S. Lazebnik, C. Schmid e J. Ponce. “A sparse texture representation using local affine regions”. Em: **IEEE Transactions on Pattern Analysis and Machine Intelligence** 27.8 (2005), pp. 1265–1278.
- [8] P. Mallikarjuna et al. “THE KTH-TIPS 2 database”. Em: 2006.