

CLASSIFICAÇÃO DE AMOSTRAS METALGRÁFICAS DE AÇOS-RÁPIDOS UTILIZANDO MODELOS DE APRENDIZAGEM DE MÁQUINAS

Marcus Patrick Acioli da Silva (acioli@protonmail.com, Engenharia Mecânica - UFPI);
Dr. José Maria Pires de Menezes Júnior (josemenezesjr@ufpi.edu.br, Engenharia Elétrica - UFPI)
Dr. Francisco Ricelly Pereira Feitosa (ricellypfeitosa@gmail.com, Engenharia Mecânica - UFPI)

Introdução

Metalografia é a técnica de estudar as propriedades físicas, químicas e mecânicas dos metais e seus produtos. Essas propriedades estão intrinsecamente relacionadas com a natureza das microestruturas que constituem um material. A observação desses parâmetros permite realizar análises qualitativas e quantitativas de um material. Em posse desses dados, é possível a classificação de um material de acordo com seus microconstituintes.

No presente estudo, propõe-se a classificação de amostras metalográficas de aços-rápidos através de técnicas de Visão Computacional e Aprendizado de Máquinas.

Metodologia

Neste trabalho, será utilizado amostras do dataset proposto por (DECOST et al., 2017), composto por 47 amostras metalográficas (644 x 448 pixels), submetidas ao tratamento térmico de recozimento em faixas de temperaturas de 700 até 1100, com durações de variam de 5 minutos até 85 horas antes da realização da têmpera. As amostras do trabalho são categorizadas por: método de resfriamento, tempo de recozimento e ampliação. Além disso, cada imagem do banco de dados é rotulada devido a sua microestrutura como visto na Fig. 1.




Figura 1 – Amostras presentes no banco de dados.

Então, cada sample do dataset original foi fragmentado em 16 novas amostras de 112 x 166 pixels (18592 posições), totalizando assim 752 samples, estes, constroem o dataset estudado nesse trabalho. Um exemplo da fragmentação pode ser visto na Fig. 2. Após isso, os elementos foram submetidos ao processo de binarização dos níveis de cinza proposto por (OTSU, 1979).

Busca-se então uma redução dimensional e extração das características. As amostras foram submetidas a um algoritmo de redução dimensional e extração de características - Análise de Componentes Principais (PCA, em inglês). Além disso, os dados foram segmentados em conjuntos de treino e teste (Tab 1). As reduções das características originais (18592 pixels por sample) investigadas foram de 200, 400 e 700 componentes.




Figura 2 – Fragmentação e pré-processamento de uma amostra de cementita proeutetóide

Dimensão	Rótulo	Treino	Teste	Quant.
200	Martensita	185 (77.1%)	55 (22.9%)	240
	Cementita proeutetóide	173 (63.7%)	99 (36.3%)	272
	Cementita globulizada	145 (60.5%)	95 (39.5%)	240
400	Martensita	154 (64.2%)	86 (35.8%)	240
	Cementita proeutetóide	183 (67.3%)	89 (32.7%)	272
	Cementita globulizada	166 (69.2%)	74 (30.8%)	240
700	Martensita	168 (70.0%)	72 (30.0%)	240
	Cementita proeutetóide	175 (64.4%)	97 (35.6%)	272
	Cementita globulizada	160 (66.7%)	80 (33.3%)	240

Tabela 1 – Estrutura do banco de dados após fragmentação.

Os classificadores utilizados no presente estudo estão descritos na Tabela 2. Os algoritmos são componentes da biblioteca open source Scikit-Learn (sklearn) (PEDREGOSA et al., 2011). Os parâmetros obtidos através da classe GridSearchCV presente na biblioteca.

Classificador	Acrônimo	Classe sklearn	Parâmetros
Random Forest	RFC	ensemble.RandomForestClassifier	n_estimator=350
Support Vector Machine	SVC	svm.SVC	C=1e3
K-Neighbors	KNN	neighbors.KNeighborsClassifier	n_neighbors=27
Decision Tree	DT	tree.DecisionTreeClassifier	max_depth=500
Gaussian Naive Bayes	GNB	naive_bayes.GaussianNB	var_smooth=1e-9

Tabela 2 – Classificadores e parâmetros.

Resultados




Figura 3 – Desempenho dos classificadores.

Dim.	Métrica	DT	GNB	KNN	RFC	SVC	Média	Desvio
200	ACC (%)	87,4	90,1	77,1	94,6	88,0	87,5	6,5
	MSE (%)	29,0	21,3	57,8	15,5	30,1	30,8	16,3
	TEMP (s)	4,3	4,3	4,1	3,8	3,9	4,1	0,2
400	ACC (%)	86,4	91,6	64,7	92,7	85,1	84,1	11,3
	MSE (%)	36,5	24,1	76,1	23,9	36,5	39,4	21,4
	TEMP (s)	6,1	6,1	5,8	5,1	5,5	5,7	0,4
700	ACC (%)	87,8	89,6	75,5	90,3	86,7	86,0	6,0
	MSE (%)	31,1	26,1	60,6	24,7	41,0	36,7	14,8
	TEMP (s)	7,3	7,3	6,8	5,6	6,2	6,7	0,7
18592	ACC (%)	71,0	85,5	75,5	91,8	86,7	82,1	8,6
	MSE (%)	75,6	42,2	60,6	28,2	41,0	49,5	18,6
	TEMP (s)	41,3	42,5	38,4	6,9	23,0	30,4	15,3

Tabela 3 – Resultados e Métricas.

Conclusões

Em análise da Fig. 3 e Tab. 3, observa-se que dentre os modelos treinados com os datasets com redução dimensional o classificador Random Forest submetido ao dataset reduzido a 200 componentes, obteve uma média de acuracidade de 94,6%, também atingiu o menor tempo médio de processamento 3,8s, além disso o menor Erro Quadrático Médio (MSE) 15,5%. Em contraste, o classificador K-Neighbors obteve a menor taxa de acerto com 64,7% para o conjunto de 400 componentes, logrou também o maior Erro Quadrático Médio 76,1% e um tempo de processamento intermediário entre os classificadores. O maior tempo médio de processamento foi obtido pelo Gaussian Naive Bayes, de 7.3s para o dataset com redução a 700 componentes, mas em contraposição ao desempenho do K-Neighbors, a acurácia nesse ponto foi de 89.6%. O dataset sem redução dimensional apresentou tempo de processamento satisfatoriamente superior aos demais modelos, logrou também de elevado Erro Quadrático Médio e precisões inferiores em alguns classificadores. Além disso, desempenho foi aproximado aos modelos 400 e 700. Assim, devido a tempo de processamento elevado e acurácia as soluções que utilizam a redução dimensional tornam-se mais viáveis.

Referências

- DECOST, B. L. et al. Uhcscdb: UDECOST, B. L. et al. Uhcscdb: Ultrahigh carbon steel micrograph database. Integrating Materials and Manufacturing Innovation, Springer, v. 6, n. 2, p. 197–205, 2017.
OTSU, N. A threshold selection method from gray-level histograms. IEEE transactions on systems, man, and cybernetics, IEEE, v. 9, n. 1, p. 62–66, 1979.
PEDREGOSA, Fabian, et al. "Scikit-learn: Machine learning in Python." *Journal of machine learning research* 12.Oct (2011): 2825-2830.