

Identificação de Escritor por Transformada SIFT e SVM-Linear na Língua Portuguesa

João Paulo Lopes Sanchez
Curso de Engenharia Elétrica
Universidade Federal de São Carlos,
Brasil
jplsanchez@estudante.ufscar.br

Celso Ap.de França
Departamento de Engenharia Elétrica
Universidade Federal de São Carlos,
Brasil
celsofr@ufscar.br

Resumo – Este trabalho investiga a viabilidade da Transformada SIFT (*Scale-Invariant Feature Transform*) e do algoritmo SVM-Linear (*Support Vector Machine-Linear*) para a identificação de autores em textos em português. A pesquisa contribui para a área de autoria forense, segurança da informação e análise de estilo, buscando fornecer um método robusto e eficiente para a identificação de autores em diferentes contextos. A metodologia proposta utiliza a Transformada SIFT juntamente com o conceito de *Bag-of-Words* para extrair características relevantes dos textos e a SVM-Linear como classificador para identificar os autores. A pesquisa foi realizada em um conjunto de dados BFL (*Brazilian Forensic Letter Database*), composto por documentos forenses na língua portuguesa, para avaliar a efetividade da metodologia. A metodologia proposta obteve resultados promissores, com uma taxa de acurácia média de até 98,73% na identificação de autores.

Palavras-Chave – Identificação de autor; Transformada SIFT; SVM-Linear; Língua Portuguesa; Autoria forense.

1. INTRODUÇÃO

A análise da autoria de textos tem sido um campo de pesquisa em constante evolução, impulsionado pela crescente necessidade de autenticação, análise e classificação de autoria em um mundo cada vez mais digitalizado. O estudo da identificação e verificação de escritores tem um papel crucial na análise forense, segurança da informação e na compreensão das características individuais da escrita. Tradicionalmente, essa análise dependia de métodos manuais e estilísticos, mas com o avanço da inteligência de máquina, novas abordagens estão emergindo para automatizar e aprimorar o processo de identificação de escritores.

O uso de características globais para identificação de escritor é uma abordagem promissora para superar esse problema. Diferentemente do método de características locais que são usados de forma mais ampla, as texturas são padrões repetitivos que podem ser encontrados em textos, e essa abordagem representa uma promissora fronteira de pesquisa, permitindo uma análise profunda e precisa das características individuais da escrita, enquanto também supera algumas limitações dos métodos tradicionais [1]. Para isso, se busca a compreensão de como essa abordagem pode ser aplicada em através do domínio do maior banco de dados de cartas forenses em língua

portuguesa, o Brazilian forensic letters, dado que este é um domínio de ampla utilização do objeto de pesquisa.

Neste trabalho, é apresentado um método para identificação de escritor com base em características de transformação invariante de escala (SIFT) de forma global e aprendizado de máquina (SVM) popularmente utilizado na língua inglesa.

A justificativa para este estudo é impulsionada pela necessidade de aprimorar a precisão e a eficiência da identificação de escritores, especialmente em um contexto em que a autoria de textos pode ter implicações legais, acadêmicas e de segurança. Abordagens tradicionais frequentemente enfrentam desafios quando se trata de textos curtos, mudanças de estilo proposital, variações contextuais ou tamanho de amostragem [2]. A combinação de características globais e aprendizado de máquina oferece a oportunidade de superar essas limitações, proporcionando uma base mais sólida para a identificação de escritores, o que é fundamental em cenários como a verificação de autoria de documentos legais, a autenticação de obras literárias e a resolução de casos de plágio. Este trabalho visa contribuir para a pesquisa nessa área, explorando uma abordagem que pode ter um impacto em diversos campos de aplicação.

2. REVISÃO BIBLIOGRÁFICA

A análise de autoria pode ser dividida em 2 tarefas identificação e verificação de escritores. A identificação de escritores consiste na tarefa de associar o autor correto a uma certa imagem ao se comparar com imagens do autor em questão, enquanto isso a verificação de escritor consiste em achar todos documentos relevantes de determinado autor [3].

Métodos de identificação de escritores podem ser classificados em duas abordagens principais: aqueles que utilizam características baseadas na estrutura textual local e, alternativamente, algoritmos que se apoiam em características globais textuais [1].

A estatística que se faz o uso da características locais pode ser feita através de inúmeras maneiras e apresenta resultados promissores.[4, 5, 6] Porém ao se basear nos caracteres e suas características, existe o desafio da segmentação da imagem como

primeiro estágio, que ao apresentar erros neste estágio tem todas suas tarefas subsequentes, e por consequência, seu resultado comprometido.

Já o uso de características globais como alternativa foi experimentada pela primeira vez ao se utilizar matrizes de coocorrência de níveis (GLCM) e seus descritivos [7]. Porém ao passar dos anos diversas abordagens foram sendo exploradas. Dentre elas há a abordagem do tratamento dos documentos escritos como textura e então a extração de características de transformação invariante de escala (SIFT) juntamente com o uso da estratégias e agrupamento e clusterização dos dados da imagem, já utilizada na língua inglesa [8]. Porém, ao se tratar de bancos de dados exclusivamente na língua portuguesa existem diversos exemplos de modelos de extração de características existentes, apresentados em [1, 9, 10] com resultados de até 99,2% de precisão no BFL.

Por fim, como método classificadores existem diversas ferramentas em utilização para tarefa de identificação de autores. Dentre elas, as CNNs (*Convolutional Neural Networks*) têm começado a se tornar populares [11], porém o uso de SVMs tem sido utilizado de forma abrangente, principalmente devido a seu destaque pela efetividade em espaços de grande dimensão com dados limitados [12, 13].

3. FUNDAMENTAÇÃO TEÓRICA

3.1. Scale Invariant Feature Transform

A Transformação de Característica Invariável de Escala (SIFT) [14] é um método de obtenção de características da imagem que são invariantes à escala, o que significa que eles não mudam de aparência quando a imagem é ampliada ou reduzida. Essas características são extraídas de pontos os quais são locais onde os valores de intensidade da imagem mudam rapidamente através do reescalonamento de nível, este é um processo em que a imagem é redimensionada para diferentes escalas e as características são extraídas em cada escala. As características são então combinadas para formar uma única característica que é invariante à escala. [15]

Os passos de extração das características SIFT podem serem resumidas nos seguintes passos [14]:

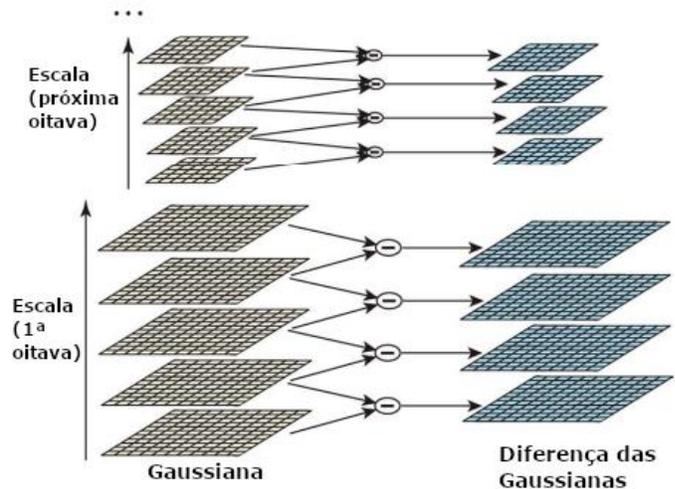
- Detecção dos extremos na escala-espacial;
- Localização de pontos-chave;
- Atribuição de orientação;
- Cálculo do descritor de ponto-chave.

Para detecção dos extremos na escala-espacial, primeiramente se separa a imagem em diversas escalas (denominadas oitavas), e então cada escala é submetida a um filtro gaussiano ao se aplicar uma convolução com a seguinte função:

$$G(x, y, \sigma) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}}$$

O objetivo deste passo é gerar uma Diferença de Gaussianas para cada uma das escalas (σ), e para isso é necessário replicar a convolução diversas vezes na imagem para que posteriormente se possa subtrair as imagens adjacentes, assim como é demonstrado na Figura 1

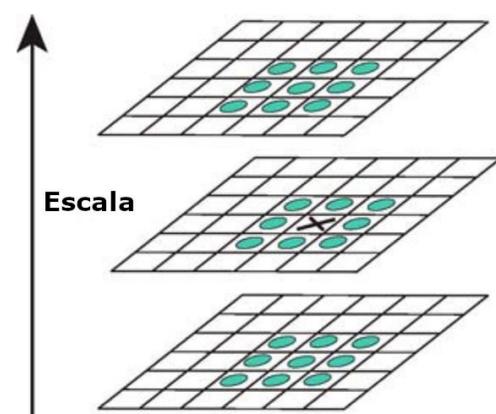
Figura 1 – Diferença das Gaussianas



Fonte: Adaptado de Lowe, D.G [14]

Para que seja encontrado o máximo e mínimo local, cada ponto é comparado aos seus vizinhos tanto no valor local quanto nas camadas adjacentes, ou seja, comparado a 26 valores, como visto na Figura 2

Figura 2 – Comparação da máxima local



Fonte: Adaptado de Lowe, D.G [14]

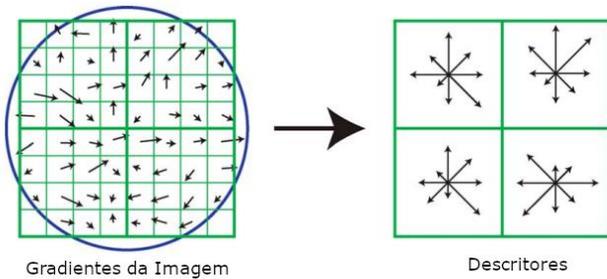
Devido ao alto número de pontos de interesse gerados por este método, os pontos-chave são definidos após uma aplicação de limiares, definindo assim nestes pontos de intensidade, os locais os quais são definidos os descritores SIFT da imagem em questão.

Para que os descritores sejam invariantes a rotação, assim como são invariantes a escala, é calculado um histograma contendo a magnitude do gradiente para 36 direções (cobrindo 360°). A partir deste histograma é definida a orientação principal do ponto chave, no ponto de maior valor. Isto é feito para que no caso de o mesmo descritor ser encontrado com uma diferente rotação em outra imagem, ele possa ser comparado tendo sua orientação principal como comparativo.

O último passo da extração das características SIFT consiste na definição de um descritor que resume todas as características de cada ponto-chave. Este descritor é extraído ao se computar a orientação e magnitude de cada ponto em uma região ao redor do ponto-chave, tendo seu valor acumulado em histogramas em grupos de 4 regiões ao redor do ponto, como demonstrado na Figura 3

No exemplo da Figura 3 é demonstrado um histograma 2x2 extraído de uma região 8x8 de amostragem. Porém, na proposta do artigo da transformada SIFT [14] o descritor final é relativo a um histograma de 4x4 gerado a partir de uma amostra de 16x16. Deste modo o descritor SIFT padrão utilizado é representado usualmente por um vetor normalizado de 128 valores (4x4 * 8 magnitudes por orientação).

Figura 3 – Extração do descritor de ponto-chave



Fonte: Adaptado de Lowe, D.G [14]

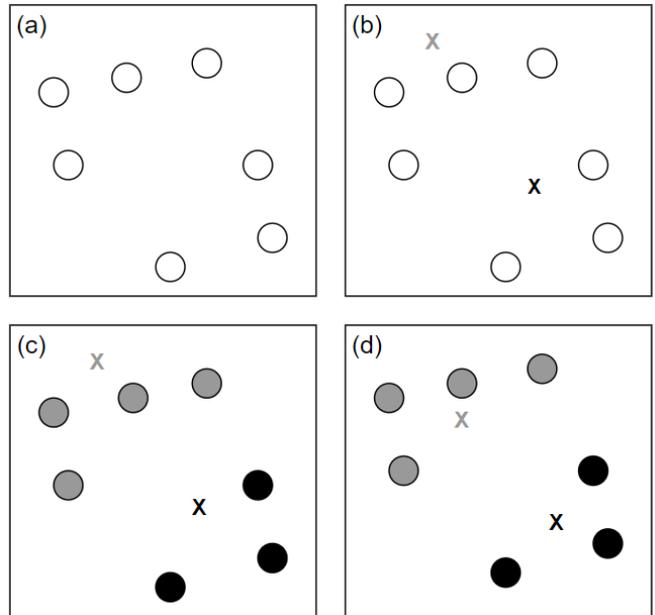
3.2. K-Means e Clusterização

K-means é um algoritmo de clusterização e agrupamento não supervisionado que agrupa dados em k grupos, o qual tem como objetivo minimizar a soma das distâncias entre cada ponto dos dados ao centroide do seu agrupamento.

O algoritmo funciona da seguinte forma:

- Inicialmente, k centroides são escolhidos aleatoriamente no espaço de dados.
- Cada ponto de dados é então atribuído ao cluster cujo centroide é o mais próximo dele.
- Os centroides dos clusters são então atualizados para serem a média dos pontos de dados que pertencem a cada cluster.
- Os passos 2 e 3 são repetidos até que os centroides não mudem mais

Figura 4 – Exemplo visual do algoritmo de *k-means*



Fonte: Autor

Na Figura 4 é possível observar um exemplo do passo a passo do algoritmo, onde em (a) existe um grupo de dados, em (b) dois k centroides são definidos aleatoriamente, em (c) todos os pontos são atribuídos ao cluster do centroide mais próximo e por fim em (d) os centroides são recalculados. Os passos mostrados em (c) e (d) são repetidos até que os centroides não se alterem mais.

Este algoritmo pode ser repetido várias vezes para que se encontre o melhor resultado dentre diversos k centroides aleatórios iniciais, evitando mínimos locais.

Uma abordagem comumente utilizada é usar *K-Means* como pré-processamento, geração de características ou pré-agrupamento de características presentes nos conjuntos de dados como facilitador de outros algoritmos de aprendizado de máquina, fazendo assim com que resultados mais precisos sejam alcançados, isso num processo chamado de *Bag-of-Words*. [16]

Bag-of-Words, também chamado de *Bag-of-Visual-Words* é um processo de geração de um vetor de características a partir de descritores locais mais complexos, como no caso dos próprios descritores da transformada SIFT. O processo consiste em clusterizar descritores semelhantes (chamados de “palavras”), via processos estatísticos ou de aprendizado de máquina, nos resultando em um vocabulário (também chamado de “codebook”) de palavras possíveis na imagem e a definição de cada um dos descritores como uma destas palavras [16].

3.3. Support Vector Machine

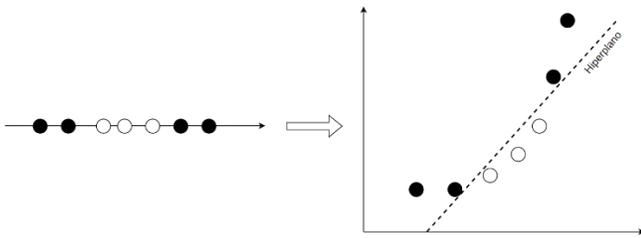
SVM [17] é um algoritmo de aprendizado de máquina supervisionado que usa um hiperplano para separar as classes de dados, que pode ser usado para regressão, classificação e detecção de outliers. O objetivo é encontrar um hiperplano que maximize a margem entre as classes, ou seja, a distância entre o hiperplano e os pontos de dados mais próximos de cada classe.

Para problemas os quais não são linearmente separáveis uma SVM se usa de um kernel. O kernel da SVM é uma função que mapeia os dados de entrada para um espaço de características de dimensão superior. Isso permite que a SVM encontre um hiperplano linear nesse espaço de características de dimensão superior. Sejam x_1 e x_2 dois pontos de dados, φ é um mapeamento e K denota Kernel que é dado por [13]:

$$K(x_1, x_2) = \varphi(x_1)^T \varphi(x_2)$$

. Na Figura 5 é possível ver um exemplo de um conjunto de dados de uma dimensão não linearmente separável, que através de um mapeamento para a segunda dimensão por uma função exponencial, permite que exista uma separação de classes definida de forma a qual seria impossível de se obter na dimensão real dos dados.

Figura 5 – Exemplo de hiperplano utilizado por SVM



Fonte: Autor

A escolha do kernel depende da natureza dos dados e da tarefa de aprendizado de máquina. Existem diferentes tipos de kernels, como o kernel linear, o kernel polinomial e o kernel RBF (*Radial Basis Function*). Dentre eles o kernel linear pode ser expresso por [13]:

$$K(x_1, x_2) = x_1^T x_2 \rightarrow \varphi(x) = x$$

Um kernel linear pode não ser eficaz para conjuntos de dados não-linearmente separáveis. Porém tem se mostrado uma boa escolha para conjuntos de dados de alta dimensão [13], como no caso da das múltiplas características geradas em um documento escrito a mão.

Como SVM é um algoritmo de classificação binário existem diversas técnicas utilizadas para a classificação de múltiplas

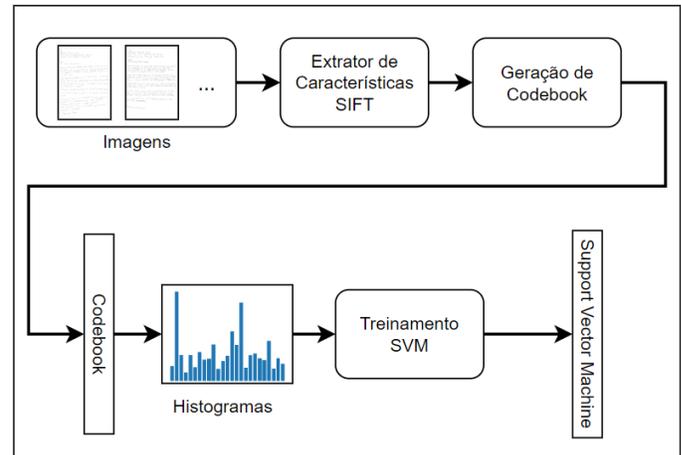
classes ($n > 2$), dentre elas, uma das mais populares é a um-versus-um.

Na técnica de classificação um-versus-um [18] uma SVM binária é treinada para cada par de classes, onde para um número n de classes, $n(n-1)/2$ SVMs binárias devem ser treinadas. Sendo assim, o método de um-versus-um é muito eficaz e robusto para múltiplas classes, porém tendo como desvantagem sua complexidade e tempo de treinamento [18].

4. METODOLOGIA

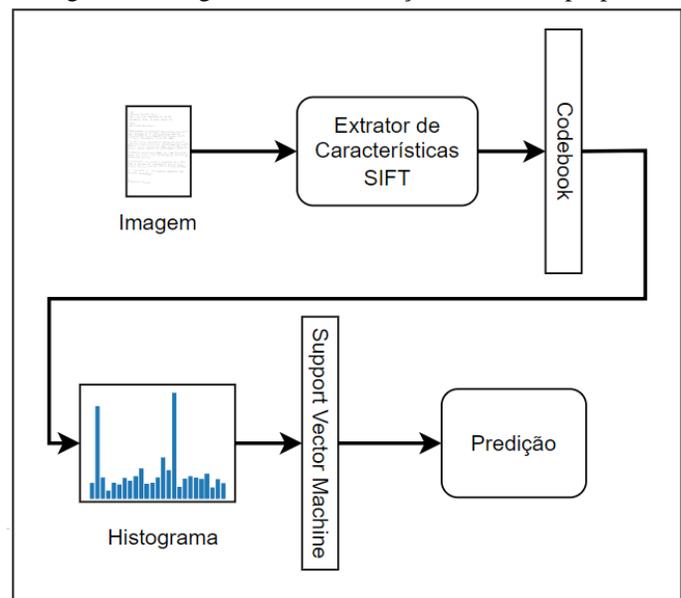
Na Figura 6 é possível ver o diagrama de blocos do treinamento do sistema de identificação de autores proposto, assim como, na Figura 7 é mostrado o diagrama do sistema no processo de classificação.

Figura 6 – Diagrama do treinamento do sistema proposto.



Fonte: Autor

Figura 7 – Diagrama da classificação do sistema proposto.



Fonte: Autor

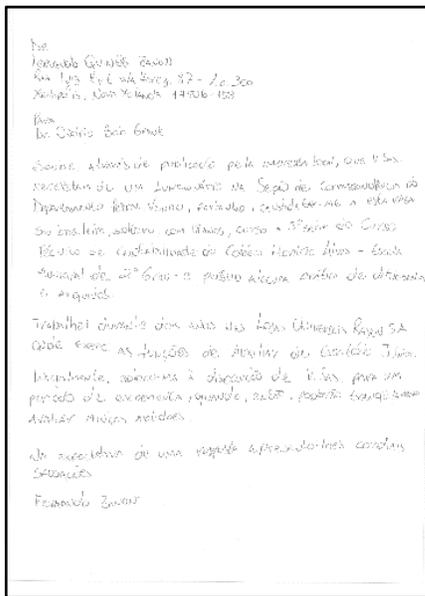
4.1. Banco de Imagens

O banco de imagens utilizado é o Brazilian Forensic Letter Database (BFL) [19], sendo este um banco de imagens de manuscritos em português, composto por 945 imagens, sendo estas escritas por 315 autores, com 3 amostras por cada. Sendo todos textos coletados de uma folha de papel A4 branca e digitalizados em tons de cinza com 300 dpi.

Sendo este um banco de imagens com dados reduzidos por autor, se torna uma ótima ferramenta para simulação de contexto reais, onde o número de dados de manuscritos produzidos pelo autor é reduzido. A Figura 8 apresenta um exemplo de documento do BFL

Deste modo, é proposto o uso de somente duas imagens por autor para a geração de características e treinamento de máquina. De forma que, a terceira imagem possa ser utilizada para classificação e verificação da precisão do modelo.

Figura 8 – Amostra de documento do BFL

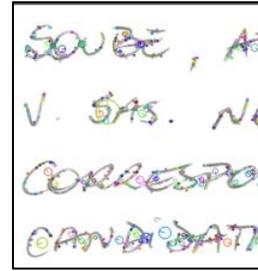


Fonte: Brazilian Forensic Letter Database [19]

4.2. Aprendizagem não-supervisionado

A extração das características SIFT consiste em extrair todos os descritores de cada uma das imagens no conjunto de treinamento. Seguindo o padrão proposto por [14] cada um destes descritores representam a textura em pontos de interesses locais. São representados por vetores normalizados compostos por 128 valores calculados a partir dos gradientes por volta de cada ponto-chave da imagem, e portanto, cada imagem é composta por milhares destes descritores. Na Figura 9 é demonstrado um recorte de um dos documentos do BFL com marcação em seus respectivos pontos-chave.

Figura 9 – Seção da imagem com os descritores SIFT



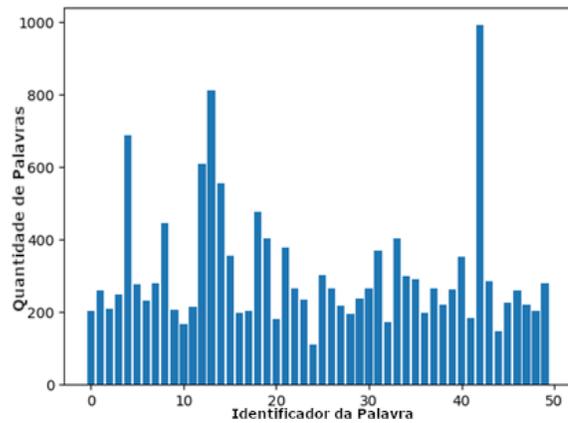
Fonte: Autor

Para que a análise possa ser feita de forma global, é utilizado então o conceito de vocabulário de códigos (também chamado de *Bag-of-Words* ou *Codebook*) [16]. A definição do vocabulário é feita a partir da clusterização de todos os descritores das imagens no grupo de teste, independente da imagem de origem. A quantidade de clusters é escolhida previamente, de acordo com o tamanho da amostra e também o número de amostras, normalmente obtido empiricamente.

Com o *codebook* calculado via algoritmo *K-Means* por todos os descritores no grupo de treinamento, é definida uma atribuição de cada descritor SIFT a uma palavra. E então, com cada descritor associado um determinado código, se calcula um histograma com a frequência de aparição dos códigos para cada documento. O histograma calculado representa o conjunto de descritores semelhantes por cada imagem.

Na Figura 10 é possível observar um exemplo de histograma gerado para um vocabulário de 50 palavras.

Figura 10 – Exemplo de histograma de imagem



Fonte: Autor

4.3. Support Vector Machine

A última parte do processo de preparação do sistema é constituída pelo treinamento da SVM a partir dos dados dos histogramas de cada imagem. Devido as características do sistema serem formados por vetores de alta dimensão, é possível que seja usada uma SVM com um kernel linear. De modo que se ganhe alta velocidade no treinamento com uma pequena desvantagem no resultado final [13].

Para múltiplas classes se faz necessário o treinamento das SVMs em pares de classe-a-classe (um-a-um), de forma que

posteriormente a validação de um novo documento possa ser classificado de acordo a classe mais presente nos confrontos um-versus-um definidos pelas SVMs.

4.4. Processo de Classificação

Por fim, para classificação de uma nova imagem, ou seja, definição de um texto de um autor desconhecido para dentre os autores no treinamento, é necessário que se percorra por um caminho similar ao que ocorre no processo de treinamento.

Primeiramente a imagem passa pelo processo de extração das características SIFT, gerando assim um vetor com todas os descritores da imagem, sendo cada vetor formado por 128 valores, assim como no processo de treinamento. Tais descritores passam então pela categorização de acordo com as palavras definidas no vocabulário de palavras estabelecido anteriormente. E então, um histograma com a frequência de cada palavra na imagem a ser classificada deve ser definido.

Para finalização da identificação, o histograma definido deve passar pelo classificador SVM, num processo de um-a-um, assim como no treinamento, para que então seja feita a identificação e classificação do autor do texto em questão.

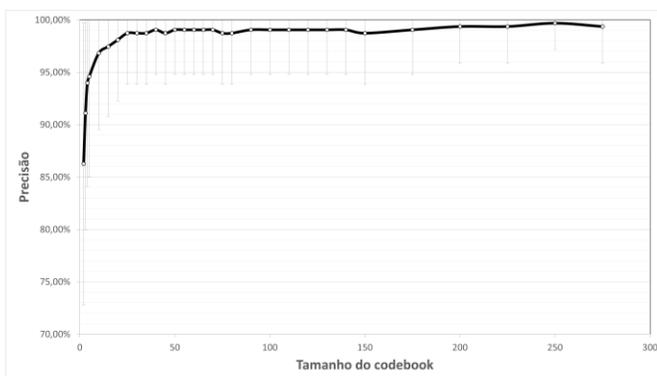
5. RESULTADOS E DISCUSSÕES

Devido a presença de somente 315 escritores e 3 documentos por escritor no banco de dados, se optou que a metodologia fosse validada utilizando-se de amostras de pequenos grupos de escritores. Deste modo é possível replicar os testes repetidas vezes para diferentes grupos de escritores gerando resultados para variadas amostras de documentos.

5.1 Tamanho dos grupos e do codebook

Na proposta inicial da validação foram utilizadas amostras de 5 escritores, de forma que o teste pudesse ser replicado 63 vezes (grupos de 5 a 5 pelos 315 escritores do BFL), de modo que o comportamento do tamanho de *codebook* pudesse ser analisado com mais assertividade. O teste do sistema foi feito pela geração de *codebooks* de 2 códigos até de 275 códigos como demonstrado na Figura 11 abaixo.

Figura 11 – Precisão x Tamanho do Vocabulário - 5 autores

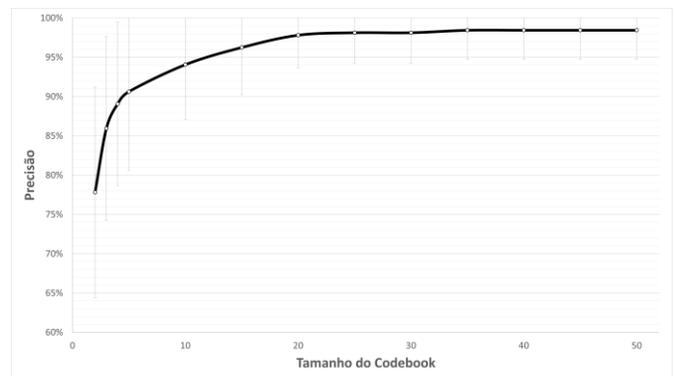


Fonte: Autor

Pelos dados amostrados é possível analisar que para um grupo de 5 autores conhecidos, a precisão na identificação de autores já entra em estabilidade para um *codebook* de cerca de 25 códigos (98,73%). Porém, neste ponto de estabilidade, há um erro padrão de 4,88%, isso se dá devido ao fato que para amostras de 5 autores, quando ocorre uma imprecisão nos 1,27% dos casos, a amostra ficaria com 80% de acerto, aumentando de forma intensa a margem de erro padrão global.

Também foram feitos testes com grupos de autores 10 a 10 para comparação relativa. Porém para este grupo o teste foi feito até um número menor de *codebooks*, tendo em vistas que a estabilização para pequenos grupos de autores ocorre em tamanhos relativamente pequenos de *codebook*.

Figura 12 – Precisão x Tamanho do Vocabulário - 10 autores

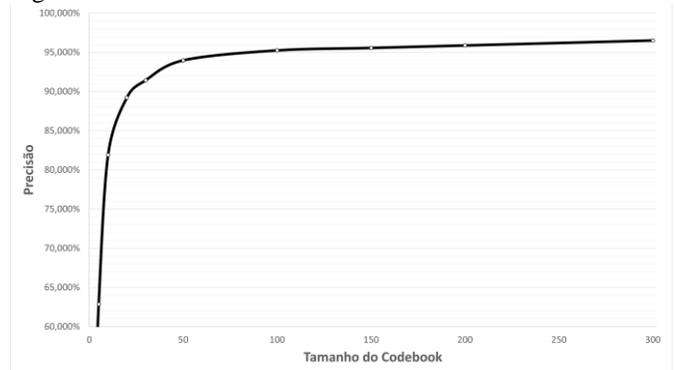


Fonte: Autor

Para este grupo de teste também é possível analisar o mesmo comportamento na curva ocorrido no grupo de 5 autores. Com até seu ponto de estabilidade sendo bem próximo dos valores encontrados para 5 escritores.

Por fim se realizou um teste de tamanho de *codebook* se utilizando de todos autores presentes no BFL, onde foi apresentado uma curva semelhante às existentes até então. Utilizando 2 textos de cada um dos 315 autores, foi realizada a geração do *codebook* e do classificador SVM, demonstrada na Figura 13.

Figura 13 – Precisão x Tamanho do Vocabulário - 315 autores



Fonte: Autor

Para toda base de dados BFL, é possível analisar que o comportamento de estabilidade é similar a grupos amostrais menores. Se tem então um valor de pico de cerca 96,51% de precisão em um tamanho de *codebook* de 300 palavras e será a partir dele que será possível comparar com resultados de outras metodologias aplicadas no BFL.

5.2. Resultados Comparativos

Para fins de comparação serão utilizados outros artigos os quais se utilizaram de sistemas aplicados em amostras similares ao proposto, tendo em vista que o modelo é independente do texto, mas que para todo o BFL os textos são o mesmo por todos os documentos, a comparação de dados é feita somente com outros artigos feitos a partir do próprio BFL.

Tabela 1 - Comparação de resultados obtidos no BFL

Autor	Método	Precisão (%)
Kessentini et al. [9]	Polygon [20]	97.78
Kessentini et al. [9]	Chain Code [20]	93.02
Bertolini et al. [1]	LPQ + Texture [1]	99.20
Kessentini et al. [9]	Edge-Hinge + RL[9]	98.41
Amaral et al. [10]	Graphometry [10]	76
Modelo proposto	SIFT + Linear-SVM	96,51

O resultado de precisão do modelo proposto se encontra relativamente próximo aos modelos de outros autores que performaram melhor no banco de dados de língua portuguesa. Principalmente tendo em vista que é utilizado um processo global, sem etapa de segmentação e com aplicação de modelos lineares de aprendizado de máquina.

Além disso é possível observar que para amostras de dados menores, para menores classes, como o caso do treinamento de amostras de 5 a 5 escritores, o modelo proposto ainda apresenta uma precisão ainda mais competitiva, com os valores de 98,73% de precisão mostrados anteriormente.

6. CONCLUSÕES

O modelo utilizando de características SIFT com *Bag-of-Words* e SVM-Linear se demonstrou efetivo, apresentando uma precisão de 96,51% para um conjunto de 315 escritores, ou seja, toda amostra do BFL. Além disso, houve uma precisão ainda maior para reconhecimento de autor pequenas amostras de 5 e 10 autores, chegando a 98,73%. Mesmo que na literatura existam modelos com maior eficácia, como o LPQ + Textura, este modelo aqui proposto ainda apresenta bastante eficiência e abre margem para diversos outros estudos e aprimoramentos no modelo. Dentre as possibilidades, são possíveis alterações no modelo de extração das características, assim como no próprio modelo de classificação final, até para uma análise mais profunda sobre a influência do tamanho de amostra e de *codebook*. Desta forma, o modelo proposto tem potencial para que seja uma solução tão eficaz quanto as outras presentes na literatura para identificação de autores na língua portuguesa.

7. REFERÊNCIAS

- [1] Bertolini, D., Oliveira, L. S., Justino, E., & Sabourin, R. "Texture-based descriptors for writer identification and verification." 2013. Expert Systems with Applications, 2069–2080. doi:10.1016/j.eswa.2012.10.016
- [2] R. Morris, Forensic handwriting identification : fundamentals, concepts and principals. Amsterdam: Academic Press, 2020.
- [3] V. Christlein, M. Gropp, S. Fiel and A. Maier, "Unsupervised Feature Learning for Writer Identification and Writer Retrieval," 2017 14th IAPR International Conference on Document Analysis and Recognition (ICDAR), Kyoto, Japan, 2017, pp. 991-997, doi: 10.1109/ICDAR.2017.165.
- [4] U.-V. Marti, R. Messerli, and H. Bunke, "Writer identification using text line based features," in Proceedings. Sixth International Conference on Document Analysis and Recognition, 2001, pp. 101–105.
- [5] C. Hertel and H. Bunke, "A set of novel features for writer identification," in Audio- and Video-Based Biometric Person Authentication, ser. Lecture Notes in Computer Science, J. Kittler and M. Nixon, Eds. Springer Berlin / Heidelberg, 2003, vol. 2688, pp. 1058–1058
- [6] A. Schlapbach and H. Bunke, "A writer identification and verification system using HMM based recognizers," Pattern Analysis and Applications, vol. 10, pp. 33–43, 2007.
- [7] Said, H. E. S., Tan, T. N., & Baker, K. D. (2000). "Personal identification based on handwriting." Pattern Recognition, 33, 149–160
- [8] Fiel, S., & Sablatnig, R. (2012). Writer Retrieval and Writer Identification Using Local Features. 2012 10th IAPR International Workshop on Document Analysis Systems. doi:10.1109/das.2012.99
- [9] Kessentini, Y., BenAbderrahim, S., & Djeddi, C. (2018). Evidential combination of SVM classifiers for writer recognition. Neurocomputing. doi:10.1016/j.neucom.2018.05.096
- [10] Amaral, A.M.M.M., de Almendra Freitas, C.O., Bortolozzi, F., Maldonado e Gomes da Costa, Y. (2018). Forensic Document Examination: Who Is the Writer?. In: Mendoza, M., Velastín, S. (eds) Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. CIARP 2017. Lecture Notes in Computer Science(), vol 10657. Springer, Cham. https://doi.org/10.1007/978-3-319-75193-1_7
- [11] Christlein, V., Bernecker, D., Maier, A., Angelopoulou, E. (2015). Offline Writer Identification Using Convolutional Neural Network Activation Features. In: Gall, J., Gehler, P., Leibe, B. (eds) Pattern Recognition. DAGM 2015. Lecture Notes in Computer Science(), vol 9358. Springer, Cham. https://doi.org/10.1007/978-3-319-24947-6_45
- [12] Christlein, Vincent; Bernecker, David; Hönl, Florian; Maier, Andreas; Angelopoulou, Elli (2016). Writer Identification Using GMM Supervectors and Exemplar-SVMs. Pattern Recognition, (), S0031320316303211-. doi:10.1016/j.patcog.2016.10.005
- [13] Chauhan, V. K., Dahiya, K., & Sharma, A. (2018). Problem formulations and solvers in linear SVM: a review. Artificial Intelligence Review. doi:10.1007/s10462-018-9614-6
- [14] Lowe, D. G. (2004). . International Journal of Computer Vision, 60(2), 91–110. doi:10.1023/b:visi.0000029664.99615.94
- [15] Wang, Y., Lu, J., & Zhang, L. (2009). Authorship authentication of artworks based on texture analysis. Pattern recognition letters, 30(12), 1439-1446.
- [16] G. Csurka, C. R. Dance, L. Fan, J. Willamowski, and C. Bray, "Visual categorization with bags of keypoints," In Workshop on Statistical Learning in Computer Vision, ECCV, pp. 1–22, 2004
- [17] Boser, B. E., Guyon, I. M., & Vapnik, V. N. (1992). A training algorithm for optimal margin classifiers. Proceedings of the Fifth Annual Workshop on Computational Learning Theory - COLT '92. doi:10.1145/130385.130401
- [18] Kressel, U. 1999Pairwise classification and support vector machines. Advances in Kernel Methods: Support Vector Learning , Cambridge, MA, USA (Chapter 15.) MIT Press
- [19] Freitas, Cinthia & Soares de Oliveira, Luiz & Bortolozzi, Flavio. (2008). Brazilian forensic letter database.
- [20] Siddiqi, I., & Vincent, N. (2010). Text independent writer recognition using redundant writing patterns with contour-based orientation and curvature features. Pattern Recognition, 43(11), 3853–3865. doi:10.1016/j.patcog.2010.05.019