



Utilização de Classificadores Bayesianos para Predição de Afinidade Entre Personagens Literários

Brenda S. Santana¹, Guilherme F. Gaiardo¹, Luísa P. Lucca¹,
Maurício M. Donato, Thales N. Tavares¹, Vinícius F. Garcia¹

¹Ciência da Computação – Universidade Federal de Santa Maria (UFSM)
Santa Maria – RS – Brasil

{bsantana, ggaiardo, llucca, mdonato, tntavares, vfulber}@inf.ufsm.br

Abstract. *Bayesian Classifiers are classifiers that use statistics to classify an attribute to a given class based on the probability of this object belonging to this class. In this paper, the use of machine learning techniques, aiming at external relations between the entities named in the same literary work. From these classifiers, applied in a test model were able to arrive at a result capable of indicating the potentiality of use of Bayesian classifiers as tools of summarization of texts.*

Resumo. *Classificadores Bayesianos, são classificadores que utilizam meios estatísticos para classificação de um atributo a uma determinada classe baseando-se na probabilidade deste objeto pertencer a esta classe. Neste trabalho, faz-se o uso de tais técnicas de aprendizado de máquina, objetivando extrair relações existentes entre entidades nomeadas de uma mesma obra literária. A partir de tais classificadores, aplicados em um modelo teste consegue-se chegar a um resultado capaz de indicar a potencialidade de uso de classificadores bayesianos como ferramenta de sumarização de textos.*

1. Introdução

Na área de Inteligência Artificial, o aprendizado de máquina é um ramo cujo objetivo é o desenvolvimento de técnicas computacionais sobre o aprendizado bem como a construção de sistemas capazes de adquirir conhecimento de forma autônoma. Um sistema de aprendizado é um programa de computador que toma decisões baseado em experiências acumuladas por meio de solução bem-sucedida de problemas anteriores. Em tal área existem diversos paradigmas de aprendizado, para este trabalho utiliza-se o paradigma estatístico. Dentro de tal modelo, surgem os modelos baseados na Teoria de Bayes. No aprendizado de máquina, tal teoria pode ser utilizada assumindo-se que os eventos são independentes (classificador bayesiano simples) e também assumindo que exista relação entre os eventos (redes bayesianas).

Classificadores Bayesianos, são classificadores estatísticos que classificam um objeto numa determinada classe baseando-se na probabilidade deste objeto pertencer a esta classe, desta forma podem ser considerados uma abordagem interpretativa e analítica para o raciocínio probabilista que descrevem a independência condicional entre subconjuntos de variáveis. Neste trabalho tem-se por objetivo a utilização de tais classificadores como forma de extrair informações a partir de trechos de livros, visando identificar a relação ocorrente entre os personagens envolvidos durante a obra. A construção do modelo de



treinamento se dará a partir de fragmentos retirados de obras literárias. A partir de tais passagens, utilizando-se de um classificador bayesiano, espera-se ser possível estabelecer as relações de proximidade entre as entidades nomeadas envolvidas.

De modo a apresentar os resultados obtidos através do trabalho realizado, as seções deste artigo foram escritas da forma que segue: na segunda seção apresenta-se o estado da arte e trabalhos análogos, ou seja, a fundamentação teórica envolvida no desenvolvimento deste trabalho; na terceira seção é apresentada uma breve explicação a cerca de classificadores bayesianos e fundamentos utilizados; na quarta seção apresenta-se a ferramenta desenvolvida para extrair e processar informações a partir de obras literárias; a quinta seção trás um experimento e os resultados obtidos a partir deste por fim é apresentada uma conclusão a partir dos resultados que foram obtidos juntamente com propostas trabalhos futuros, seguidamente pelas referências utilizadas.

2. Trabalhos Relacionados

Podemos encontrar exemplos na literatura da aplicação de classificadores Bayesianos em textos, como por exemplo, o trabalho realizado por [McCallum et al. 1998]. Neste trabalho, os autores realizaram a comparação entre dois modelos utilizados para a classificação de texto. Para este artigo, foram comparados os modelos Bernoulli multi-variável, na qual consiste em rede Bayesiana sem dependências entre palavras e características de palavras binárias, e o modelo multinomial, na qual consiste em um modelo de linguagem uni-gram com número inteiro de contagens de palavras.

Para a realização dos experimentos, foram utilizados diferentes *datasets*: o Yahoo! Ciência, onde após a realização de um pré processamento, obteve-se um vocabulário com tamanho igual a 44383; A hierarquia do setor industrial, disponibilizada pelo Market Guide Inc., apresentando um vocabulário de tamanho 29964; O conjunto de dados do Newsgroups, onde o vocabulário resultante, após a remoção de palavras que ocorrem apenas uma vez ou em um período, tem 42191 palavras e o conjunto de dados WebKB, contendo 19371 palavras obtidas após um refinamento do *dataset* original.

Segundo os autores, aplicando o método de comparação proposto no artigo, o modelo multinomial é quase uniformemente melhor do que o modelo Bernoulli multi-variável. Em resultados empíricos em cinco *datasets* do mundo real, os autores constataram que o modelo multinomial reduz o erro em uma média de 27% e às vezes em mais de 50%.

Outro exemplo que podemos encontrar é o trabalho realizado por [Larsen 2005]. Neste artigo, os autores propõem um Classificador *Naive Bayes* Generalizado – Generalized Naive Bayes Classifier (GNBC) –, projetado especificamente para problemas de classificação binária, comumente encontradas em aplicações de crédito e de *marketing*. Segundo os autores do trabalho, este método proposto consegue ser uma ferramenta poderosa tanto para análise exploratória como para análise preditiva.

Tal método pode gerar previsões precisas através de um procedimento de montagem flexível e não paramétrico, ao mesmo tempo em que é capaz de descobrir padrões ocultos nos dados. Para isto, o GNBC estende o *Naive Bayes Classifier* (NBC), flexibilizando a suposição de independência condicional entre os preditores. Esta flexibilização é feita ajustando os efeitos do *Naive* através da inclusão de p *functions* $b_1(x_1), b_2(x_2) \dots b_p(x_p)$, onde $b_j(x_j)$ explica o viés atribuído a $g_j(x_j)$.



$$\alpha = \log \frac{P(Y = 1)}{P(Y = 0)} \quad (1)$$

$$\log \frac{f(x_1, \dots, x_p|Y = 1)}{x_1, \dots, x_p|Y = 0} \quad (2)$$

Ressalta-se que $b_1(x_1), b_2(x_2) \dots b_p(x_p)$ são funções suaves não especificadas. Dessa forma, caso os preditores forem condicionalmente independentes, $b_j(x_j) = 0$ para todos os j , o modelo se reduz a um NBC tradicional.

Segundo os autores, após a realização dos experimentos, utilizando um *dataset* público, doado por *George Forman* do *Hewlett-Packard laboratories*, contendo 4601 e-mails onde 1813 são classificados como spam e 2788 são e-mails legítimos, constatou-se que o GNBC é um algoritmo flexível para prever probabilidades de um alvo binário, dado um conjunto de variáveis independentes. Ele pode caber um modelo grande sem qualquer conhecimento prévio sobre as variáveis independentes, o que nos permite descobrir padrões ocultos nos dados e passar mais tempo selecionando variáveis e projetando o modelo.

3. Classificadores Bayesianos

Classificadores Bayesianos são classificadores estatísticos que classificam um objeto numa determinada classe baseando-se na probabilidade deste objeto pertencer a esta classe. Tais classificadores seguem os princípios do Teorema de Bayes, expressado matematicamente na equação 3.

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

Tal proposição permite calcular o termo $P(B|A)$ em termos de: $P(A|B)$, $P(B)$ e $P(A)$. Para [Russell and Norvig 2004] a regra de Bayes se torna útil pela existência de diversos casos em que faz-se boas estimativas de probabilidade para três termos e necessita-se do quarto, produzindo resultados rapidamente, de grande correção quando aplicados a grandes volumes de dados, comparáveis aos resultados produzidos por árvores de decisão e redes neurais. Ou seja, quando o efeito é percebido como evidência de alguma causa desconhecida e busca-se determinar essa causa. Nesse caso, a regra de Bayes torna-se equivalente ao exposto na equação 4.

$$P(causa|efeito) = \frac{P(efeito|causa)P(causa)}{P(efeito)} \quad (4)$$

Desta forma a utilização de classificadores bayesianos pode ser definida como a busca pela relação de causa e efeitos.

3.1. Classificadores Bayesianos Simples

O Classificar Bayesiano Simples é um classificador estatístico, baseado no Teorema de Bayes, onde pressupõem-se que os atributos possuem forte independência entre si. Isto



significa que um atributo não influencia os demais, de modo que a presença ou ausência de uma característica em um atributo não determina ou influencia a presença ou ausência dessa mesma característica em outros atributos.

Dessa maneira, a classificação de uma tupla X em uma classe C_i considera a maior probabilidade condicional $P[X|C]$ possível, dentre todas as classes possíveis. Isto significa que, a tupla X pertence a classe C_i sempre que a comparação abaixo é satisfeita.

$$P[C_i|X] > P[C_j|X] \quad (5)$$

para todas as outras classes $C_j | C_j \neq C_i$.

3.2. Naïve Bayes

O algoritmo utiliza um conjunto inicial de dados os quais são classificados em classes (*clusters*) e, a partir de um dado de entrada, busca classificar este novo dado.

Este algoritmo é dividido em duas etapas principais, sendo estas as etapas de aprendizado e classificação. No estágio de aprendizado do algoritmo, são calculadas as probabilidades iniciais de classificação para cada classe existente, ou seja, as chances de um atributo ser classificado em cada classe. Após, o modelo é construído calculando as probabilidades de pertencimento a classe de acordo com a base de treinamento classificada previamente. Neste processo, ocorre também uma suavização das probabilidades de forma a evitar cálculos errôneos. Já na etapa de classificação realiza-se o cálculo das probabilidades de pertencimento a cada classe, aplicando-se o modelo estimado previamente. Após o cálculo de tais exequibilidades a entrada de dados é classificada dentro das possibilidades existentes.

4. Descoberta de afinidade entre personagens literários utilizando classificadores bayesianos

A ferramenta de extração de afinidade entre personagens de obras literárias utilizando classificadores bayesianos foi desenvolvida com um intuito exploratório do processo de leitura.

A ferramenta foi desenvolvida utilizando a linguagem de programação Python 3.6, tendo como bases de treinamentos arquivos CSV contendo trechos de livros e suas respectivas classes. As obras escolhidas para treinamento do algoritmo, atendem ao gênero juvenil por apresentarem padrões de escrita semelhantes, tais como linguagem utilizada e expressão de sentimentos.

A ferramenta proposta, apresenta 5 estágios para sua execução, tal como exposto no fluxograma da Figura 1 sendo estes extração dos dados, construção do modelo de treinamento, aplicação do algoritmo, classificação e análise dos dados.

1. **Extração** A fase de extração dos dados é realizada de forma a capturar trechos existentes entre duas entidades nomeadas previamente identificadas;
2. **Construção do modelo de treinamento** Para construção de tal modelo, os trechos extraídos são armazenados em arquivos CSV, juntamente com a classificação previamente informada (afinidade/inimizade). Tais classificações são conhecidas preliminarmente pois tratam-se de livros populares no meio juvenil;



Figura 1. Fluxograma

3. **Algoritmo** Neste estágio realiza-se a aplicação do algoritmo Naïve Bayes, para o cálculo probabilístico de pertencimento as classes informadas;
4. **Classificação** Nesta etapa, utiliza-se o resultado obtido através da aplicação do algoritmo Naïve Bayes, para classificação do trecho de entrada. A classe de tal passagem é determinada a partir da verificação da maior probabilidade indicada;
5. **Análise** No período de análise dos dados, verifica-se a corretude das classificações obtidas.

4.1. Experimentos e Resultados Preliminares

Afim de testar a ferramenta desenvolvida, foi realizado um teste com uma base de treinamento possuindo 127 trechos classificados em 'afinidade' e 127 classificados em 'inimizade'. Foram estas duas classes, pois as mesmas de mostraram mais pertinentes as pesquisas envolvidas. Foram selecionadas 50 passagens de livros que não haviam sido categorizadas previamente, como atributos de entrada. Os resultados obtidos podem ser observados na Figura 2.

A partir da análise a da matriz de confusão gerada, é possível extrair as seguintes métricas:

- **Acurácia** indica a proporção de predições corretas, sem levar em consideração o que é positivo e o que é negativo.
▷ $Acurácia = (16 + 8) / (50) = 0.48 = 48\%$
- **Sensibilidade** indica a capacidade do sistema em prever corretamente a condição para casos que realmente as têm.



Predição de saída

	V	F
V	18	10
F	16	6

Figura 2. Matriz de Confusão

- ▷ Sensibilidade = $18 / (18+6) = 0.75 = 75\%$
- **Especificidade** indica a capacidade do sistema em prever corretamente a ausência da condição para casos que realmente não a têm.
 - ▷ Especificidade = $6 / (10+6) = 0.25 = 25\%$
- **Eficiência** balanço entre sensibilidade e especificidade.
 - ▷ Eficiência = $(75+25) / (2) = 50\%$

5. Considerações Finais

A partir de uma análise dos resultados obtidos é possível perceber que o uso de classificadores bayesianos para identificação da relação existente entre personagens envolvidos na prosa literária, possui potencial de uso. Entretanto, o método utilizado apresenta-se ainda não tão acurado, necessitando-se assim de aprimoramentos, afim de melhorar os resultados atingidos. Deste modo a criação de algoritmos que identifiquem a relação ocorrente entre os personagens envolvidos durante a obra, podem fazer parte de um conjunto de ferramentas voltadas à sumarização de textos.

De forma a melhorar a eficiência dos resultados obtidos, como trabalhos futuros propõe-se a remoção de *stop words*, dos trechos capturados para treinamento e análise. Tais palavras podem ser consideradas irrelevantes para o conjunto de resultados a ser exibido. Também em um momento futuro, almeja-se implementar o uso de classificadores multilabel de forma a recuperar e combinar demais características apresentadas no decorrer de cada obra.

Referências

- Kibriya, A. M., Frank, E., Pfahringer, B., and Holmes, G. (2004). Multinomial naive bayes for text categorization revisited. In *Australian Conference on Artificial Intelligence*, volume 3339, pages 488–499. Springer.
- Kim, S.-B., Seo, H.-C., and Rim, H.-C. (2003). Poisson naive bayes for text classification with feature weighting. In *Proceedings of the Sixth International Workshop on Information Retrieval with Asian Languages - Volume 11*, AsianIR '03, pages 33–40, Stroudsburg, PA, USA. Association for Computational Linguistics.



Larsen, K. (2005). Generalized naive bayes classifiers. *ACM SIGKDD Explorations Newsletter*, 7(1):76–81.

McCallum, A., Nigam, K., et al. (1998). A comparison of event models for naive bayes text classification. In *AAAI-98 workshop on learning for text categorization*, volume 752, pages 41–48. Madison, WI.

Russell, S. and Norvig, P. (2004). *Inteligência artificial*. CAMPUS - RJ.