

CLASSIFICAÇÃO DE SÉRIES TEMPORAIS MULTIVARIADAS POR MEIO DE MODELOS DINÂMICOS BAYESIANOS

Anselmo Ramalho Pitombeira Neto
Diego Silva de França
Lívia Almada Cruz
Ticiane Linhares Coelho da Silva
José Antonio Fernandes de Macedo
Universidade Federal do Ceará
Campus do Pici, Fortaleza, CE, Brasil
anselmo.pitombeira@ufc.br

RESUMO

Considere um conjunto finito de classes de processos estocásticos em tempo discreto, cada um deles com especificações e parâmetros desconhecidos. Dada uma série temporal observada, cuja classe é desconhecida, o problema de classificação de séries temporais trata da identificação de a qual classe a série observada faz parte. Neste artigo, aborda-se a classificação online de séries multivariadas, em que a série observada é classificada a medida que suas observações são obtidas. Propõe-se um modelo composto por um *ensemble* de modelos lineares dinâmicos bayesianos, em que cada modelo é ajustado a uma das classes a partir de amostras. Dada uma série cuja classe é desconhecida, computa-se a probabilidade de cada classe por meio do teorema de Bayes. O modelo é aplicado ao problema de reconhecimento de atividade humana por meio de sensores inerciais, obtendo 96% de acurácia na classificação de atividades.

PALAVRAS CHAVE. Classificação de séries temporais, Modelos bayesianos, Reconhecimento de atividade humana.

Tópicos (EST&MP – Estatística e Modelos Probabilísticos, IC – Inteligência Computacional)

ABSTRACT

Consider a finite set of classes of discrete-time stochastic processes, each of them with unknown specifications and parameters. Given an observed time series, whose class is unknown, the time series classification problem deals with identifying which class the observed series belongs to. In this article, the online classification of multivariate series is addressed, in which the observed series is classified as its observations are obtained. A model composed of an *ensemble* of Bayesian dynamic linear models is proposed, in which each model is adjusted to one of the classes based on samples. Given a series whose class is unknown, the probability of each class is computed using Bayes' theorem. The model is applied to the problem of recognizing human activity using inertial sensors, obtaining 96% accuracy in classifying activities.

KEYWORDS. Time series classification. Bayesian models. Human activity recognition.

Paper topics (EST&MP – Statistics and Probability Models. IC - Computational Intelligence)

1. Introdução

Considere um conjunto finito $\mathcal{K}$ de classes de processos estocásticos em tempo discreto, cada um deles com especificações e parâmetros desconhecidos. Um observador observa uma série temporal multivariada $\mathbf{y}_1, \mathbf{y}_2, \mathbf{y}_3, \dots$ e deseja classificar a série em uma das classes no conjunto $\mathcal{K}$. Neste trabalho considerar-se-á a classificação online, ou seja, a cada tempo t à medida que a série é observada. O objetivo deste trabalho é propor um modelo probabilístico que indique a probabilidade de cada classe $k \in \mathcal{K}$ em um tempo t , dada uma série temporal observada $\mathbf{y}_{1:t} := \{\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_t\}$. Para cada classe $k \in \mathcal{K}$, estimam-se os parâmetros de um modelo linear dinâmico bayesiano a partir de uma amostra de uma série temporal da classe k . Os $|\mathcal{K}|$ modelos são reunidos em um *ensemble* de modelos. Dada uma série temporal observada cuja classe é desconhecida, a probabilidade a posteriori de cada modelo no ensemble é computada após cada observação por meio do teorema de Bayes e indica a probabilidade de cada classe.

2. Modelagem de uma série temporal multivariada como um MLDB

Considere uma série temporal multivariada $\mathbf{y}_1, \mathbf{y}_2, \dots$, em que $\mathbf{y}_t$ é um vetor q -dimensional, observada ao longo do tempo. Modela-se sua evolução como um modelo linear dinâmico bayesiano (MLDB):

$$\mathbf{y}'_t = \mathbf{F}'_t \boldsymbol{\Theta}_t + \boldsymbol{\nu}'_t, \quad \boldsymbol{\nu}_t \sim \mathcal{N}(\mathbf{0}, v_t \boldsymbol{\Sigma}), \quad (1)$$

$$\boldsymbol{\Theta}_t = \mathbf{G}_t \boldsymbol{\Theta}_{t-1} + \boldsymbol{\Omega}_t, \quad \boldsymbol{\Omega}_t \sim \mathcal{N}(\mathbf{0}, \mathbf{W}_t, \boldsymbol{\Sigma}), \quad (2)$$

em que $\boldsymbol{\Theta}_t$ é uma matriz de estado $p \times q$, cujas colunas são os vetores de estado $\boldsymbol{\theta}_{jt}$ para cada componente $j = 1, \dots, q$. Os termos de erro observacional $\boldsymbol{\nu}_t$ seguem uma distribuição normal multivariada com média $\mathbf{0}$ e matriz de covariância $v_t \boldsymbol{\Sigma}$. Os termos de erro $\boldsymbol{\Omega}_t$ seguem uma distribuição normal *matricial* com média $\mathbf{0}$, matriz de covariância esquerda $\mathbf{W}_t$ e matriz de covariância direita $\boldsymbol{\Sigma}$. Ao se fixar uma estrutura para $\mathbf{F}_t$ e $\mathbf{G}_t$ e valores para v_t , $\mathbf{W}_t$ e $\boldsymbol{\Sigma}$, é possível derivar em cada tempo t a distribuição preditiva $p(\mathbf{y}_t | \mathbf{y}_{1:t-1}, \boldsymbol{\alpha})$ por meio de uma versão modificada do filtro de Kalman [West e Harrison, 2006; Särkkä e Svensson, 2023], em que $\boldsymbol{\alpha}$ reúne os parâmetros do MLDB.

Dada uma série temporal observada $\mathbf{y}_{1:T}^{(k)}$ correspondente à classe k , a função de log-verossimilhança de $\boldsymbol{\alpha}_k$ é

$$\ell(\boldsymbol{\alpha}_k) = \prod_{t=1}^T p(\mathbf{y}_t^{(k)} | \mathbf{y}_{1:t-1}^{(k)}, \boldsymbol{\alpha}_k). \quad (3)$$

Cada termo em (3) corresponde a uma função densidade t de Student multivariada. Obtém-se um estimador de máxima verossimilhança para $\boldsymbol{\alpha}_k$ ao se maximizar (3).

3. Classificação de séries temporais multivariadas por meio de um *ensemble* de MLDBs

Seja $\mathcal{K}$ um conjunto finito de classes. Para cada classe $k \in \mathcal{K}$, estimam-se os parâmetros $\boldsymbol{\alpha}_k$ de um MLDB $M_k = M(\boldsymbol{\alpha}_k)$ a partir de dados em uma amostra de uma série temporal da classe k por meio da maximização de (3). O ensemble é então formado pela coleção finita de MLDBs $M_k, k \in \mathcal{K}$. Note que cada MLDB é indexado por seu vetor de parâmetros $\boldsymbol{\alpha}_k$. Dada uma série temporal que está sendo observada de forma online, para se inferir sua classe, aplica-se recursivamente o ensemble de MLDBs.

Considere que no tempo t dispõem-se de observações da série temporal até o tempo imediatamente anterior, ou seja, $\mathbf{y}_{1:t-1}$. Seja $p(k | \mathbf{y}_{1:t-1})$ a probabilidade a priori da classe $k \in \mathcal{K}$ no tempo t . Após se observar $\mathbf{y}_t$, atualiza-se o conhecimento via teorema de Bayes e obtém-se a distribuição a posteriori:

$$p(k | \mathbf{y}_{1:t}) = \frac{p(\mathbf{y}_t | \mathbf{y}_{1:t-1}, k) p(k | \mathbf{y}_{1:t-1})}{\sum_{k' \in \mathcal{K}} p(\mathbf{y}_t | \mathbf{y}_{1:t-1}, k') p(k' | \mathbf{y}_{1:t-1})}, \quad \forall k \in \mathcal{K}. \quad (4)$$

Atividade	Precisão	Recall
caminhada	0,83	1,00
corrida	0,97	0,95
ciclismo	1,00	0,92
caminhada nórdica	1,00	0,87
subir escadas	0,99	1,00
descer escadas	0,99	1,00
pular corda	0,98	1,00

Tabela 1: Métricas de classificação para as classes testadas (acurácia de 96% no conjunto de teste)

Note que $p(\mathbf{y}_t | \mathbf{y}_{1:t-1}, k) = p(\mathbf{y}_t | \mathbf{y}_{1:t-1}, \alpha_k)$. Ademais, no tempo $t = 1$ define-se uma priori não informativa $p(k | \mathbf{y}_{1:0}) = p(k) = 1/|\mathcal{K}|$. Logo, pode-se usar a distribuição a posteriori (4) para classificar a série temporal no tempo t por meio do argumento que maximiza a probabilidade a posteriori:

$$\hat{k}_t = \arg \max_{k' \in \mathcal{K}} p(k' | \mathbf{y}_{1:t}). \quad (5)$$

A aplicação recursiva de (5) produz uma sequência de previsões $\hat{k}_1, \hat{k}_2, \dots$ à medida que se observa a série temporal.

4. Resultados numéricos

Ilustra-se a aplicação do ensemble de MLDBs proposto à tarefa de reconhecimento de atividade humana a partir de sensores de medição inerciais (IMUs). Foi utilizado o conjunto de dados PAMAP2 [Reiss, 2012]. Este conjunto de dados contém uma variedade de atividades físicas e sedentárias realizadas por nove indivíduos, com frequência de amostragem de aproximadamente 100 Hz.

O acelerômetro, o giroscópio e o magnetômetro fornecem um sinal tridimensional correspondente aos eixos x, y e z. O vetor $\mathbf{y}_t$ é formado pela norma euclidiana dos sinais de cada sensor. Treinou-se o ensemble de MLDBs para 7 atividades físicas do indivíduo 101 do PAMAP2, de forma que há 7 classes possíveis: caminhar, correr, andar de bicicleta, caminhada nórdica, subir escadas, descer escadas e pular corda. Utilizaram-se os dados do IMU posicionado no pulso do indivíduo. Para cada atividade, a série temporal disponível foi dividida ao meio. A primeira metade, correspondente aos primeiros 50% das observações da série temporal, foi utilizada para treinamento, e os 50% restantes foram reservados para testes. Para cada atividade, maximizou-se a verossimilhança (3) nos dados de treinamento usando o algoritmo L-BFGS-B [Byrd et al., 1995]. Todo o processo de treinamento para as 7 atividades levou menos de 2 minutos em um PC de uso geral.

O ensemble de MLDBs foi testado aplicando-o aos dados da série temporal de teste de cada atividade. A cada tempo t , após observar o valor $\mathbf{y}_t$, o ensemble de MLDBs calcula a probabilidade posterior de cada atividade k de acordo com (4). A maior probabilidade é usada para classificar a observação $\mathbf{y}_t$ seguindo (5). A Figura 1 mostra a classificação online de cada observação $\mathbf{y}_t$ na série temporal de teste da atividade “caminhada nórdica”. Pode-se observar que o ensemble de MLDBs atribui probabilidade 1 à atividade de caminhada nórdica para a maior parte do sinal observado. Também pode ser observado que classifica incorretamente a atividade como corrida durante os poucos segundos iniciais e como caminhada nos últimos segundos, correspondendo a mudanças perceptíveis no padrão do sinal do acelerômetro. A Tabela 1 exibe as métricas de classificação para as 7 atividades.




Figura 1: Predição online obtida pelo ensemble de MLDBs quando aplicado a dados de teste de uma série temporal multivariada da atividade “caminhada nórdica” (o sinal de giroscópio e magnetômetro foram omitidos na visualização)

5. Conclusão

Neste artigo, foi proposto o uso de um ensemble MLDBs para a classificação de séries temporais multivariadas. A aplicação do ensemble de modelos foi ilustrada por meio de sua aplicação à tarefa de reconhecimento de atividade humana a partir de séries temporais geradas por sensores inerciais. Os resultados numéricos indicaram que o ensemble de modelos foi capaz de obter uma acurácia de classificação de 96% nos dados de teste. Como trabalhos futuros, recomenda-se a incorporação de arquiteturas profundas aos MLDBs, seguindo a abordagem proposta recentemente por Titsias et al. [2023].

Agradecimentos

Parte dos resultados apresentados neste trabalho foram obtidos por meio do projeto “Centro de Excelência em Inteligência Artificial - AI4Wellness”, financiado pela Samsung Eletrônica da Amazônia Ltda., de acordo com a Lei No. 8.248/91.

Referências

- Byrd, R. H., Lu, P., Nocedal, J., e Zhu, C. (1995). A limited memory algorithm for bound constrained optimization. *SIAM J Sci Comput*, 16(5):1190–1208.
- Reiss, A. (2012). PAMAP2 Physical Activity Monitoring. UCI Machine Learning Repository.
- Särkkä, S. e Svensson, L. (2023). *Bayesian filtering and smoothing*. Cambridge University Press.
- Titsias, M. K., Galashov, A., Rannen-Triki, A., Pascanu, R., Teh, Y. W., e Bornschein, J. (2023). Kalman filter for online classification of non-stationary data. *Arxiv Prepr*.
- West, M. e Harrison, J. (2006). *Bayesian forecasting and dynamic models*. Springer Science & Business Media.