

С.И. Богучарский¹, С.В. Машталир², М.И. Столбовой²

¹ Харьковский национальный университет им. В.Н. Каразина, Харьков

² Харьковский национальный университет радиоэлектроники, Харьков

БЫСТРОЕ ОБНАРУЖЕНИЕ ИЗМЕНЕНИЯ СВОЙСТВ МНОГОМЕРНЫХ ВРЕМЕННЫХ РЯДОВ НА ОСНОВЕ ИДЕНТИФИКАЦИОННОГО ПОДХОДА К АНСАМБЛЮ МОДЕЛЕЙ

В данной статье рассматривается задача быстрого обнаружения изменений свойств многомерных временных рядов при помощи ансамбля матричных авторегрессионных моделей. Использование предложенного подхода к формированию ансамбля моделей позволяет настраивать каждую адаптивную матричную авторегрессионную модель при помощи собственного критерия идентификации с разной глубиной памяти. Предложенный подход предназначен для использования в задачах кластеризации-сегментации многомерных данных, где в качестве таковых могут служить высокоизбыточные данные, такие как видео. Построенный ансамбль моделей является простым с точки зрения программной реализации и позволяет быстро обрабатывать видеоданные в онлайн режиме.

Ключевые слова: многомерные временные ряды, видеоданные, ансамбль моделей.

Введение

Процесс информационного развития общества привел к неконтролируемому росту объемов различного рода информации, необходимой для жизни человека. Особое место среди подобных данных занимает мультимедиа информация. При этом зачастую возникает необходимость анализа этих данных, что является не такой уж и простой задачей с учетом слабой структурированности и больших объемов мультимедиа и, в частности, видеоданных. В первую очередь интересуют подходы, позволяющие находить необходимую информацию по ее содержанию или контенту в режиме реального времени. Естественно, учитывая объемы обрабатываемых данных, это является трудоемкой задачей. Одним из подходов к упрощению процесса выделения подобных данных является сегментация-кластеризация. В качестве одного из подходов к кластеризации видеоданных вполне может быть использован анализ временных рядов (т.к. любые видеоданные можно представить в виде последовательности кадров) с выявлением в них изменений свойств.

Проблема обнаружения изменения свойств (разладок) временных рядов встречается во множестве практических приложений [1–4], связанных с отказами в работе промышленного оборудования, биомедицинскими приложениями, анализом видеопоследовательностей. Особое место в этой проблеме занимают задачи раннего обнаружения разладок, когда необходимо выявлять эти изменения непосредственно в процессе функционирования контролируемой системы, анализируя последовательности сигналов в online режиме реального времени. И если для анализа одномерных сигналов к настоящему

времени разработаны быстродействующие эффективные алгоритмы, результаты, связанные с анализом многомерных последовательностей и особенно в online режиме, представляются более скромными [5–7].

В связи с этим в качестве цели работы представляется целесообразной разработка адаптивных методов обнаружения изменения свойств многомерных (векторных и матричных) временных рядов, поступающих на обработку в контролируемую систему в режиме реального времени.

Адаптивное обнаружение изменения свойств многомерных последовательностей на основе векторных авторегрессионных моделей

Для обнаружения изменения свойств при сегментации и кластеризации временных рядов перспективным представляется использование model based approach [8], в соответствии с которым анализируются не собственно временной ряд, который может содержать большой объем наблюдений, а некоторая компактная математическая модель, адекватно описывающая свойства моделируемой последовательности. Если же наблюдения поступают на обработку последовательно в online режиме, эффективным представляется использование адаптивных моделей, параметры которых непрерывно уточняются в режиме реального времени.

В качестве таких моделей достаточно удобно использовать так называемые векторные авторегрессионные модели (VAR-models) [9], имеющие относительно небольшое количество настраиваемых

параметров и с точки зрения вычислительной реализации наиболее простые для анализа многомерных временных рядов [10–11]. Особенностью VAR моделей является то, что они связывают с помощью простых соотношений прошлые, текущие и будущие значения векторного сигнала $x(k)$ в форме

$$x(k) = A_0 + \sum_{l=1}^p A_l x(k-l) + \xi(k), \quad (1)$$

где $x(k)$ – $(n \times 1)$ -мерный контролируемый сигнал в текущий момент дискретного времени $k = 1, 2, \dots$; A_l – $(n \times n)$ матрицы коэффициентов, подлежащих оцениванию; $p \geq 1$ – порядок модели; $\xi(k)$ – «белшумное» возмущение, компоненты которого имеют ограниченную дисперсию.

Для нахождения коэффициентов в online режиме введем составную матрицу, образованную этими коэффициентами, вида $A = (A_0 : A_1 : \dots : A_p)$ и расширенный вектор входов $x(k) = (1 : x^T(k-1) : \dots : x^T(k-p))^T$ размерностей $(n \times pn + 1)$ и $(pn + 1 \times n)$ соответственно и перепишем выражение (1) в компактной форме

$$x(k) = AX(k) + \xi(k), \quad (2)$$

где матрица параметров A содержит всю необходимую информацию о контролируемой многомерной последовательности.

В соответствии описанию (2) можно поставить адаптивную модель вида

$$\hat{x}(k) = A(k-1)X(k), \quad (3)$$

где $\hat{x}(k)$ – n -мерный выходной сигнал модели; $A(k-1)$ – матрица настраиваемых коэффициентов, полученная на основании предыдущих $k-1$ наблюдений.

Для уточнения матрицы оценок $A(k)$ нестационарного сигнала $x(k)$ в принципе может быть использован традиционный экспоненциально взвешенный рекуррентный метод наименьших квадратов, который, однако, может быть неустойчив при больших размерностях матрицы настраиваемых параметров $A(k)$. В связи с этим была использована многомерная модификация [12] алгоритма взвешенной стохастической аппроксимации [13] вида

$$\begin{cases} A(k) = A(k-1) + \frac{e(k)x^T(k)}{\alpha r(k-1) + \|x(k)\|^2}, \\ e(k) = x(k) - \hat{x}(k) = x(k) - A(k-1)x(k), \\ r(k) = \alpha r(k-1) + \|x(k)\|^2, \end{cases} \quad (4)$$

где $0 \leq \alpha \leq 1$ – параметр забывания (forgetting factor).

Следует отметить, что при $\alpha = 0$, алгоритм (4) совпадает с одношаговым алгоритмом прогнозирования многомерных случайных последовательностей [14]. Данная процедура обеспечивает максимальное быстродействие процессу настройки параметров модели, однако крайне чувствительна к появлению резких выбросов в сигнале возмущения $\xi(k)$ и скачкам параметров, входящих в матрицу A в [2]. При $\alpha = 1$ (4) приобретает свойства стохастической аппроксимации и обладает выраженными сглаживающими свойствами. В задаче обработки стационарных сигналов $\alpha = 1$ обеспечивает построение оптимального прогноза.

Для обнаружения изменения свойств векторного сигнала $x(k)$ в [12] было предложено использовать концепцию следящего сигнала и настраиваемого с его помощью параметра α . Данный подход обеспечивает надежное обнаружение изменения свойств контролируемой последовательности, однако он достаточно инерционен, т.е. сигнал разладки генерируется с некоторым запаздыванием. В ситуациях, когда на первый план выходит повышенное быстродействие процесса обнаружения разладок, использование следящего сигнала может оказаться неэффективным.

В связи с этим, нами предлагается использовать концепцию ансамбля прогнозирующих моделей, когда обучение структуры (3) производится с помощью набора алгоритмов (4) с разными значениями параметра забывания $0 = \alpha_1 < \alpha_2 < \dots < \alpha_r < \dots < \alpha_s = 1$. Таким образом, генерируется набор прогнозов $\hat{x}_1(k), \hat{x}_2(k), \dots, \hat{x}_r(k), \dots, \hat{x}_s(k)$, при этом $\hat{x}_1(k)$ практически мгновенно реагирует на все возможные возмущения и изменения в сигнале $x(k)$, а $\hat{x}_s(k)$ по сути является отфильтрованной на всем интервале наблюдений последовательностью.

В процессе настройки ансамбля моделей контролируется либо сигнал расхождения между прогнозами

$$T_{qr}(k) = \|\hat{x}_q(k) - \hat{x}_r(k)\|, \quad \forall q, r = 1, 2, \dots, S, \quad (5)$$

либо сигнал расхождения между матрицами настраиваемых параметров

$$T_{qr}^A(k) = (\text{Sp}(A_q(k) - A_r(k)) \cdot (A_q(k) - A_r(k))^T)^{1/2}, \quad \forall q, r = 1, 2, \dots, S \quad (6)$$

При превышении сигналом разладки некоторого априори заданного условия Δ или Δ^A

$$T_{qr}(k) > \Delta, \quad T_{qr}^A(k) > \Delta^A, \quad (7)$$

принимается решение о том, что многомерный сигнал $x(k)$ претерпел изменение свойств.

Адаптивное обнаружение изменения свойств многомерных последовательностей на основе матричных авторегрессионных моделей

В задачах обработки потоков видео, когда каждый отдельный кадр $x(k) = \{x_{i_1, i_2}(k)\}$, $i_1 = 1, 2, \dots, n$; $i_2 = 1, 2, \dots, v$ представляет собой, по сути, $(n \times v)$ матрицу, использование модели (1) представляется неэффективным, поскольку ведет к резкому увеличению числа оцениваемых параметров, а, следовательно, к снижению быстродействия процесса обнаружения разладок. В этой ситуации целесообразно ввести в рассмотрение матричную авторегрессионную модель (MAR-model) вида

$$x(k) = \sum_{l=1}^p A_l x(k-l) B_1 + \xi(k), \quad (8)$$

где $A_l, B_1 - (n \times n), (v \times v)$ – матрицы параметров, подлежащих оцениванию; $p \geq 1$ – порядок модели; $\xi(k)$ – «белое шумное» матричное возмущение. Вводя далее составные матрицы $A = (A_1 : A_2 : \dots : A_p)$, $B = (B_1 : B_2 : \dots : B_p)^T$ размерности $(n \times np), (vp \times v)$ соответственно и расширенную матрицу входов

$$x(k) = \begin{pmatrix} x(k-1) & & & & 0 \\ & \ddots & & & \\ & & x(k-1) & & \\ & & & \ddots & \\ 0 & & & & x(k-p) \end{pmatrix}$$

размерности $(np \times vp)$, перепишем выражение (8) в компактной форме

$$x(k) = AX(k)B + \xi(k), \quad (9)$$

являющейся матричным аналогом описания (2). Заметим также, что (9) содержит $(n^2 + v^2)p$ параметров, подлежащих оцениванию.

В соответствии описанию (9) можно поставить адаптивную модель вида

$$\hat{x}(k) = A(k-1)X(k)B(k-1), \quad (10)$$

где $\hat{x}(k) - (n \times v)$ -мерный выходной сигнал модели; $A(k-1), B(k-1) -$ матрицы настраиваемых коэффициентов, полученные на основании предыдущих $k-1$ наблюдений.

Для уточнения параметров модели (10) в [12] был введен градиентный адаптивный алгоритм идентификации вида

$$\begin{cases} A(k) = A(k-1) + \eta_A(k)e_A(k)B^T(k-1)x^T(k), \\ e_A(k) = x(k) - A(k-1)x(k)B(k-1), \\ B(k) = B(k-1) + \eta_B(k)x^T(k-1)A(k)e_B(k), \\ e_B(k) = x(k) - A(k)x(k)B(k-1), \end{cases} \quad (11)$$

где $\eta_A(k), \eta_B(k) -$ параметры шага обучения (learning rate parameters).

В [13] были также оценены значения параметров шага $\eta_A(k), \eta_B(k)$, обеспечивающие максимальную скорость сходимости процедуры (11). При этом полученная процедура является аналогом векторного алгоритма (4) при $\alpha = 0$, т.е. крайне чувствительна к воздействию внешних шумов, что не позволяет различить изменения в сигнале от влияния шумов $\xi(k)$. В связи с этим в [14] был введен матричный аналог экспоненциально взвешенного метода наименьших квадратов. Введенный алгоритм, несмотря на высокое качество идентификации, оказался весьма громоздким с вычислительной точки зрения, что затрудняет его использование в режиме реального времени, когда данные на обработку поступают с высокой частотой.

В связи с этим, целесообразно ввести в рассмотрение матричный аналог алгоритма (4), который может быть записан в виде

$$\begin{cases} A(k) = A(k-1) + \\ + \frac{e_A(k)B^T(k-1)x^T(k)}{\alpha r_A(k-1) + \text{Sp}(B^T(k-1)x^T(k)x(k)B(k-1))}, \\ e_A(k) = x(k) - A(k-1)x(k)B(k-1), \\ r_A(k) = \alpha r_A(k-1) + \\ + \text{Sp}(B^T(k-1)x^T(k)x(k)B(k-1)), \\ B(k) = B(k-1) + \\ + \frac{x^T(k-1)A(k)e_B(k)}{\alpha r_B(k-1) + \text{Sp}(x^T(k-1)A(k)A^T(k)x(k-1))}, \\ e_B(k) = x(k) - A(k)x(k)B(k-1), \\ r_B(k) = \alpha r_B(k-1) + \\ + \text{Sp}(x^T(k-1)A(k)A^T(k)x(k-1)). \end{cases} \quad (12)$$

При $\alpha = 1$ процедура (12) приобретает свойства стохастической аппроксимации, т.е. реализует фильтрацию обрабатываемого сигнала, однако слишком инерционна, чтобы быстро обнаружить происходящие изменения.

Для обнаружения изменений в матричном сигнале в [11] было предложено использовать следящий сигнал, однако, как мы отмечали выше, такая процедура слишком инерционна в задачах быстрого обнаружения изменений свойств.

В связи с этим подобно ансамблю VAR-моделей с разными значениями параметра забывания α можно ввести ансамбль MAR-моделей, настраиваемых с помощью (12). Далее в рассмотрение можно ввести сигнал расхождения между прогнозами

$$T_{qr}(k) = (\text{Sp}(\hat{x}_q(k) - \hat{x}_r(k)(\hat{x}_q(k) - \hat{x}_r(k))^T))^{1/2}, \quad (13)$$

и сигналы расхождения между матрицами настраиваемых параметров

$$\begin{cases} T_{qr}^A(k) = (\text{Sp}(A_q(k) - A_r(k))(A_q(k) - A_r(k))^T)^{1/2}, \\ T_{qr}^B(k) = (\text{Sp}(B_q(k) - B_r(k))(B_q(k) - B_r(k))^T)^{1/2}, \\ \forall q, r = 1, 2, \dots, S. \end{cases} \quad (14)$$

При превышении контрольных уровней

$$T_{qr}(k) > \Delta, \quad T_{qr}^A(k) > \Delta^A, \quad T_{qr}^B(k) > \Delta^B \quad (15)$$

принимается решение о том, что в матричном сигнале $x(k)$ произошли изменения.

Выводы

Рассмотрена задача быстрого обнаружения изменения свойств векторных и матричных нестационарных

зашумленных сигналов. В основу предлагаемого подхода положена идея ансамбля адаптивных моделей, каждая из которых настраивается с помощью собственного алгоритма идентификации.

При этом для каждой из моделей используются алгоритмы с разной глубиной памяти. Решение о разладке принимается с помощью контроля сигналов расхождения между реальным процессом и выходами адаптивных моделей.

Предлагаемый подход достаточно прост в вычислительной реализации, обеспечивает высокое быстродействие и предназначен для анализа многомерных сигналов, поступающих на обработку в режиме реального времени.

Список литературы

1. Montgomery D.C. Forecasting and Time Series Analysis / D.C. Montgomery, L.A. Johnson, J.S. Gardiner. – N.Y.: McGraw-Hill, 1990. – 394 p.
2. Lutkepohl H. Introduction to Multiple Time Series Analysis / H. Lutkepohl. – Berlin: Springer, 1993. – 545 p.
3. Basseville M. Detection of Abrupt Changes / M. Basseville, I. Nikforov. – N.J. Englewood Cliffs, 1993. – 528 p.
4. Pouliezios A.D. Real Time Fault Monitoring of Industrial Processes / A.D. Pouliezios, G.S. Stavrakakis. – Dordrecht: Cluver Academic Publishing, 1994. – 542 p.
5. Aggarwal C.C. Data Mining / C.C. Aggarwal. – Cham: Springer, Int. Publ. Switzerland, 2015. – 733p.
6. Aggarval C.C. Data Clustering Algorithms and Applications / C.C. Aggarval, C. Reddy. – CRC Press, Boca Raton, 2014. – 652p.
7. Abonyi J. Fuzzy clustering based segmentation of timeseries / J. Abonyi, B. Feil, S. Nemett, P. Arva // Lecture Notes in Computer Science. 2810. – Springer, Berlin, 2003. – P. 275-285.
8. Liao T.W. Clustering of time series data Pattern Recognition / T.W. Liao. – 2005. – 38. – No.11. – P. 1857-1874.
9. Juselius K. The Cointegrated VAR-model: methodology and applications / K. Juselius. – N.Y.: Oxford University Press, 2006. – 457 p.
10. Bodyanskiy Ye. Multilayer neuro-fuzzi network for short term electric load forecasting / Ye. Bodyanskiy, S. Popov, T. Rybalchenko // Lecture Notes in Computer Science. 5010. – Berlin-Heidelberg: Springer-Verlag, 2008. – P. 339-348.
11. Bodyanskiy Ye. On-line video segmentation using methods of fault detection in multidimensional time sequences / Ye. Bodyanskiy, D. Kinoshenko, S. Mashtalir, O. Mikhnova // International Journal of Electronic Commerce Studies. – 2012. – Vol. 3, No. 1. – P. 1-20.
12. Болянський Є.В. Виявлення змін у потоці відеоданих на основі аналізу багатовимірних часових рядів / Є.В. Болянський, С.В. Машталір // Доповіді Національної академії наук України. – 2012. – №11. – С. 30-33.
13. Bodyanskiy Ye. An adaptive learning algorithm for a neuro-fuzzy network / Ye. Bodyanskiy, V. Kolodyazhnyi, A. Stefan // Lecture Notes in Computer Science. 2206. – Berlin-Heidelberg New York, Springer. – 2011. – P. 68-75.
14. Rudenko O.G. Adaprive algorithm for prediction of random sequences / O.G. Rudenko, E.V. Bodyanskii, I.P. Pliss // Soviet automatic control. – 1979. – Vol.12, No. 1. – P. 46-48.

References

1. Montgomery, D.C., Johnson, L.A. and Gardiner, J.S. (1990), *Forecasting and Time Series Analysis*, McGraw-Hill, N.Y., 394 p.
2. Lutkepohl, H. (1993), *Introduction to Multiple Time Series Analysis*, Springer, Berlin, 545 p.
3. Basseville, M. and Nikforov, I. (1993), *Detection of Abrupt Changes*, Englewood Cliffs, N.J., 528 p.
4. Pouliezios, A.D. and Stavrakakis, G.S. (1994), *Real Time Fault Monitoring of Industrial Processes*, Cluver Academic Publishing, Dordrecht, 542 p.
5. Aggarwal, C.C. (2015), *Data Mining*, Springer, Int. Publ. Switzerland, Cham, 733 p.
6. Aggarval, C.C. and Reddy, C. (2014), *Data Clustering Algorithms and Applications*, CRC Press, Boca Raton, 652 p.
7. Abonyi, J., Feil, B., Nemett, S. and Arva, P. (2003), Fuzzy clustering based segmentation of timeseries, *Lecture Notes in Computer Science*. 2810, Springer, Berlin, pp. 275-285.
8. Liao, T.W. (2005), *Clustering of time series data Pattern Recognition*, 38, No. 11, pp. 1857-1874.
9. Juselius, K. (2006), *The Cointegrated VAR-model: methodology and applications*, Oxford University Press, N.Y., 457 p.
10. Bodyanskiy, Ye., Popov, S. and Rybalchenko, T. (2008), Multilayer neuro-fuzzi network for short term electric load forecasting, *Lecture Notes in Computer Science*, 5010, Springer-Verlag, Berlin-Heidelberg, pp. 339-348.
11. Bodyanskiy, Ye., Kinoshenko, D., Mashtalir, S. and Mikhnova, O. (2012), On-line video segmentation using methods of fault detection in multidimensional time sequences, *International Journal of Electronic Commerce Studies*, Vol. 3, No. 1, pp. 1-20.
12. Bodianskiy, Ye.V. and Mashtalir, S.V. (2012), "Vyiavlennia zmin u pototsi videodanykh na osnovi analizu bahatovymirnykh chasovykh riadiv" [Detect changes in the video stream based on the analysis of multidimensional time series], *Dopovidi Natsionalnoi akademii nauk Ukrainy*, No. 11, pp. 30-33.

13. Bodyanskiy, Ye., Kolodyazhnyi, V. and Stefan, A. (2011), An adaptive learning algorithm for a neuro-fuzzy network, *Lecture Notes in Computer Science*, 2206, Springer, Berlin-Heidelberg New York, pp. 68-75.

14. Rudenko, O.G., Bodyanskii, E.V. and Pliss, I.P. (1979), Adaptive algorithm for prediction of random sequences, *Soviet automatic control*, Vol. 12, No. 1, pp. 46-48.

Поступила в редколлегию 7.08.2018

Одобрена к печати 11.09.2018

Відомості про авторів:

Богучарський Сергій Іванович

кандидат технічних наук доцент кафедри
Харківського національного університету
ім. В.Н. Каразіна,
Харків, Україна
<https://orcid.org/0000-0003-4971-4314>

Машталір Сергій Володимирович

доктор технічних наук доцент професор кафедри
Харківського національного університету
радіоелектроніки,
Харків, Україна
<https://orcid.org/0000-0002-0917-6622>

Столбовий Михайло Ігорович

аспірант кафедри
Харківського національного університету
радіоелектроніки,
Харків, Україна
<https://orcid.org/0000-0002-5080-0829>

Information about the authors:

Serhii Bohucharskyi

Ph.D. Associate Professor of Department
of V.N. Karazin Kharkiv National University,
Kharkiv, Ukraine
<https://orcid.org/0000-0003-4971-4314>

Sergii Mashtalir

Doctor of Technical Sciences Associate Professor
Professor of Department
of Kharkiv National University of Radio Electronics,
Kharkiv, Ukraine
<https://orcid.org/0000-0002-0917-6622>

Mykhailo Stolbovyi

Postgraduate Student
of Kharkiv National University of Radio Electronics,
Kharkiv, Ukraine
<https://orcid.org/0000-0002-5080-0829>

ШВИДКЕ ВИЯВЛЕННЯ ЗМІНИ ВЛАСТИВОСТЕЙ БАГАТОМІРНИХ ЧАСОВИХ РЯДІВ НА ОСНОВІ ІДЕНТИФІКАЦІЙНОГО ПІДХОДУ ДО АНСАМБЛЮ МОДЕЛЕЙ

С.І. Богучарський, С.В. Машталір, М.І. Столбовий

У даній статті розглядається задача швидкого виявлення змін властивостей багатовимірних часових рядів за допомогою ансамблю матричних авторегресійних моделей. Використання запропонованого підходу до формування ансамблю моделей дозволяє налаштовувати кожну адаптивну матричну авторегресійну модель за допомогою власного критерію ідентифікації з різною глибиною пам'яті. Запропонований підхід призначений для використання в задачах класифікації-сегментації багатовимірних даних, де в якості таких можуть служити високорозбиткові дані, такі як відео. Побудований ансамбль моделей є простим з точки зору програмної реалізації і дозволяє швидко обробляти відеодані в онлайн режимі.

Ключові слова: багатовимірні часові ряди, відеодані, ансамбль моделей.

FAST PROPERTIES CHANGE DETECTIONS IN MULTIDIMENSIONAL TIME SERIES BASED ON IDENTIFICATION APPROACH TO MODELS ENSEMBLE

S. Bohucharskyi, S. Mashtalir, M. Stolbovyi

At present, the information technologies development and the modern information society behavior has led to the huge volumes emergence of primarily multimedia information, as the most convenient point of view by human perception. At the same time, the necessary data search becomes more and more difficult, especially if there is a need to search for the content of multimedia data, especially video where exist approach so-called CBVR (Content-Based Video Retrieval). At the same time, there do exist many problems. First of all there is always a time limit for finding the necessary information, but the volumes processed information are not just large, but are constantly increasing.

One way to obtain the necessary information is a segmentation of the raw data into homogeneous segments with the subsequent possible replacement of the corresponding segment with key frames, which will substantially reduce the information needed for processing during content-based search in video data. Given that the video can be represented as a set of frames, it is possible to use a time series analysis.

In this paper, we consider the problem of fast properties change detections in multidimensional time series using an ensemble of matrix autoregressive (MAR) models. The use of the proposed approach to the formation of a model ensemble makes it possible to adjust each adaptive MAR model using its own identification criterion with different depth of memory. The proposed approach is intended for use in clustering-segmentation problems of high-margin multidimensional data, such as video. The constructed models ensemble is simple in terms of software implementation and allows you to quickly process video data online.

Keywords: multidimensional time series, video data, ensemble of models.