

УДК 004.8

*Д.В. Дроботько¹, А.И. Шевченко¹, В.Ф. Дроботько², И.В. Качур¹*¹Институт информатики и искусственного интеллектаГВУЗ «Донецкий национальный технический университет», г. Донецк, Украина
Украина, 83050, г. Донецк, пр. Б. Хмельницкого, 84²Донецкий физико-технический институт им. А.А. Галкина НАН Украины

Украина, 83114, г. Донецк, ул. Розы Люксембург, 72

Неавтономное обнаружение выбросов и очистка сигналов мониторинга внутричерепного давления

*D.V. Drobotko¹, A.I. Shevchenko¹, V.F. Drobotko², I.V. Kachur¹*¹Institute of informatics and artificial intelligence DonNTU, Donetsk, Ukraine

Ukraine, 83050, Donetsk, Khmelnytsky ave, 84

²A. A. Galkin Donetsk Physical & Technical Institute NAS of Ukraine

Ukraine, 83114, Donetsk, Rosa Luxemburg st., 72

Online outliers detection and cleaning of intracranial pressure monitoring signals

*Д.В. Дроботько¹, А.И. Шевченко¹, В.Ф. Дроботько², И.В. Качур¹*¹Институт інформатики і штучного інтелекту

ДВНЗ «Донецький національний технічний університет», м. Донецьк, Україна

Україна, 83050, м. Донецьк, пр. Б. Хмельницького, 84

²Донецький фізико-технічний інститут ім. А.А. Галкіна НАН України

Україна, 83114, м. Донецьк, вул. Рози Люксембург, 72

Неавтономне виявлення викидів і очищення сигналів моніторингу внутрішньочерепного тиску

Сигнал мониторинга внутричерепного давления (ВЧД), полученный в отделениях нейрореанимации, часто содержит большое количество шумов и выбросов. Эти артефакты не только непосредственно приводят к ложным тревогам в автоматических аварийных системах мониторинга-диагностических комплексов для управляемой терапии больных, но и сильно загрязняют особенности основного сигнала, что делает невозможным точное прогнозирование вторичных повреждений головного мозга, вызванных внутричерепной гипертензией. В статье предлагается эффективный онлайн-двухэтапный метод очистки физиологических сигналов, основанный на идентификаторе Хампеля и калмановской фильтрации. Вначале измеряемые ВЧД сигналы проходят предварительную обработку, в которой осуществляется идентификация структуры данных сигнала, оценивается уровень шума, и удаляются выбросы с помощью робастного фильтра Хампеля. Точки выбросов заменяются значением медианы в этих точках. Затем производится коррекция этих точек, удаление шума и оценка спектра сигнала на основе адаптивной авторегрессионной (AAR) модели с помощью фильтра Калмана и сопряженного с ним RTS (Rauch-Tung-Striebel) сглаживающего фильтра. Настраиваемыми параметрами предлагаемого метода фильтрации являются полуширина скользящего окна, пороговая величина для обнаружения выбросов и порядок AAR модели

Ключевые слова: фильтр Хампеля, калмановская фильтрация, адаптивная авторегрессионная модель, выбросы, внутричерепное давление.

Intracranial pressure monitoring signal (ICP) obtained in Neuro Intensive Care Units, often contains a large amount of noise and outliers. These artifacts not only directly lead to false alarms in automatic alert systems of monitoring-diagnostic complex for controlled therapy patient, but they are also heavily pollute the main

features of the signal, making it impossible to accurately predict the secondary damage to the brain caused by intracranial hypertension. This paper proposes an efficient on-line two-step purification method of physiological signals based on Hampel identifier and Kalman filtering. Initially, clinical measurement of ICP signal undergo pretreatment in which the identification signal data structure, and the estimated level of noise outliers are removed by the filter Hampel robust. Outlier points are replaced by the median of those points. Next, the correction of these points, noise removal and evaluation of the signal based on adaptive autoregressive (AAR) model using the Kalman filter and its associated RTS (Rauch-Tung-Striebel) smoothing filter are performed. Adjustable parameters of the proposed filtering method is the half-width moving window, the threshold for detecting outliers and order AAR model.

Key Words: Hampel filter, Kalman filtering, adaptive AR model, outliers, intracranial pressure.

Сигнал моніторингу внутрішньочерепного тиску (ВЧД), здобутий у відділеннях нейроанестезії, часто містить велику кількість шумів і викидів. Ці артефакти не лише безпосередньо викликають помилкові тривоги в автоматичних аварійних системах моніторингово-діагностичних комплексів для керованої терапії хворих, але й сильно забруднюють особливості основного сигналу, що унеможливує точне прогнозування вторинного пошкодження головного мозку, викликаного внутрішньочерепною гіпертензією. У статті пропонується ефективний двоетапний метод онлайн-очистки фізіологічних сигналів, заснований на ідентифікаторі Хампеля і калмановській фільтрації. Спочатку вимірювані ВЧД сигнали проходять попереднє оброблення, під час якого здійснюється ідентифікація структури даних сигналу, оцінюється рівень шуму і усуваються викиди за допомогою робастного фільтра Хампеля. Точки викидів замінюються значенням медіани в цих точках. Потім відбувається корекція цих даних, усування шуму і оцінка спектра сигналу на основі адаптивної авторегресійної (AAR) моделі за допомогою фільтра Калмана і зв'язаного з ним RTS (Rauch-Tung-Striebel) згладжувального фільтра. Регульованими параметрами пропонованого методу фільтрації є півширина ковзного вікна, порогова величина для виявлення викидів і порядок AAR моделі.

Ключові слова: фільтр Хампеля, калмановська фільтрація, адаптивна авторегресійна модель, викиди, внутрішньочерепний тиск.

Введение

Подавляющее число исследований по цифровой обработке данных относится к сигналам техногенного происхождения, в которых решаются задачи помехоустойчивости и фильтрации зашумленных сигналов, формируемых различными средствами связи и вещания. В последние десятилетия, особенно за рубежом, стали интенсивно развиваться компьютерные методы обработки физиологических сигналов в медицинских приложениях. Наиболее развитыми в этом отношении являются методы обработки сигналов электрокардиограмм, электроэнцефалограмм, ультразвуковой диагностики. На основе современных информационных технологий возникли методики рентгеновской, магнито-резонансной, позитронно-эмиссионной томографий. Анализ физиологических сигналов оказался гораздо сложнее, чем техногенных. Это обусловлено двумя обстоятельствами: физиологическим процессам свойственны сигналы с низкими уровнями амплитуды и эти сигналы по своей природе являются нестационарными и нелинейными. Более того, эти сигналы загрязнены в большой степени стохастическими компонентами и случайными выбросами, произведенными другими органами тела, мускульными сокращениями и дыханием.

Выбросами в физиологических временных сигналах являются аномальные данные наблюдения, которые существенно отклоняются от большинства данных наблюдения и кажутся изолированными во временном ряду. Они могут возникать в результате шума измерительных детекторов, сбоя измерения и передачи данных в системах управления, внешних возмущений на измерительный процесс, например, из-за наводки на соединительные провода и детектор, а также из-за человеческого фактора при мониторинге диагностических биомедицинских сигналов у пациентов. Проводить компьютерный анализ загрязненных выбросами сигналов, на основе которого ставится

диагноз, бесполезно, потому что выбросы могут привести к ошибке конкретизации эмпирического моделирования, тенденциозной оценке параметров модели и к неправильным аналитическим результатам. Слабый физиологический сигнал, например, такой, как сигнал внутричерепного давления (ВЧД), главным образом погружен в артефакты движения, сопровождающиеся выбросами. Прежде чем делать выбор подходящего алгоритма цифровой обработки этого сигнала, необходимо использовать надлежащий метод предварительной обработки, чтобы ослабить мощность выбросов – помехи движения, сохранив при этом данные, искаженные только флуктуационной помехой. С этой точки зрения, предварительная обработка данных отличается от фильтрации данных. Фильтрация данных изменяет их структуру, не только удаляя выбросы, но также и уменьшая вариации данных. Предварительная обработка данных является в основном более трудной задачей, чем фильтрация, потому что она одновременно требует идентификации структуры данных и оценки уровня шума, чтобы удалить выбросы и сохранить «хорошие» данные.

Для обнаружения и удаления выбросов из обрабатываемых данных временного ряда существует, по-видимому, три базовых фильтра, которые в недавних работах получили дальнейшую модернизацию. Это медианный фильтр, близко связанный с ним и почти также прост – фильтр Хампеля (Hampel filter) [1] и фильтр-очиститель, разработанный Мартином и Томсоном (Martin and Thomson, MT filter-cleaner) [2]. Если два первых фильтра работают в неавтономном (онлайновом) режиме, то МП фильтр-очиститель – по существу автономная схема, которая основана на предварительно оцененной модели временного ряда. Этот МП фильтр-очиститель состоит из трех шагов. Вначале модель обработки данных временного ряда подгоняется линейной авторегрессионной AR(p) моделью низкого порядка, используя робастные обобщенные M-оценочные функции. Учитывая модель аддитивного выброса (АО), был разработан алгоритм фильтра в виде пространства состояний для последующего использования фильтра Калмана, в котором, с целью уменьшения выбросов, к последовательности обновлений применена Ψ -функция. Практически, Ψ -функция в основном выбирается как правило «трех-сигм» (« 3σ edit rule»). Наконец, калмановская фильтрация гауссовой части данных временного ряда используется для последующей спектральной оценки. Конечно, этот МП фильтр-очиститель сложен для практического применения, к тому же пороговая точка фильтра низка, когда порядок модели становится высоким.

В статье [3] авторы предложили модифицированный МП фильтр-очиститель, основанный на скользящем окне, которое может захватить динамические изменения данных временного ряда в процессе онлайнового режима. У предложенного фильтра-очистителя также есть фиксированная пороговая точка для любого порядка модели.

Эти три базовых фильтра проходили тестирования на идентификацию трех различных динамических систем, в одной из которых обрабатывался реальный, зашумленный выбросами, сигнал команды управления высотой и углом наклона полета вертолета и две другие модельные системы – линейная модель и нелинейная модель Волтерры второго порядка с аддитивными выбросами и гауссовыми шумами, для которых известны точные результаты [4]. Как оказалось, выбросы действительно неблагоприятно влияют на результаты анализа обрабатываемых данных или эмпирического моделирования, для эффективной очистки фильтры должны, в основном, быть нелинейными, хотя линейные фильтры действительно уменьшают выбросы, но они не устраняют их и вводят нежелательное уширение. И наконец, по мнению автора [4], не существует эффективного универсального фильтра очистки данных. Это наиболее наглядно на его примере с медианным фильтром, который был наиболее эффективным

для вертолетных данных, но наименее эффективным для модельной нелинейной системы Вольтерры. Точно так же, МП фильтр-очиститель оказался самым эффективным для линейного примера моделирования и неэффективным в смоделированном примере Вольтерры, и полностью неподходящим к вертолетным данным, поскольку номинальная вариация в вертолетной последовательности данных далека от гауссовой.

Целью данной работы является построение основанного на идентификаторе Хампеля, простого робастного фильтра со скользящим окном для удаления выбросов в неавтономном режиме в комбинации с фильтром Калмана и сопряженным с ним RTS (Rauch-Tung-Striebel) сглаживающим фильтром для прогноза и коррекции оригинальных особенностей основного сигнала внутричерепного давления (ВЧД).

Методы поиска и замены выбросов

1 Робастное оценивание выбросов – фильтр Хампеля

Большинство методов обнаружения выброса основано на базовом предположении, что случайные переменные независимы и равномерно распределены, т.е. распределение вероятности каждой случайной переменной то же самое, что и у других, и все они взаимно независимы. Двумя самыми важными статистическими данными для анализа данных в присутствии выбросов являются местоположение (например, среднее) данных сигнала и их разброс (дисперсия, ковариация). Классическим методом оценивания параметров модели является метод наименьших квадратов, однако на практике не всегда выполняется гауссово распределение измеряемых данных и если равномерность распределения нарушается даже одним выбросом, его влияние, как на выборочное среднее \bar{X} , так и на дисперсию S^2 выборки $X_N = \{x_i\}_{i=1}^N$ может значительно исказить статистические параметры выборки. В связи с этим возникает необходимость в построении робастных методов оценивания, которые должны обнаружить выбросы и удалить их либо заменить на интерполированные значения.

Для измерения устойчивости М-оценочных функций в зависимости от влияния на них выбросов Хампель [5] ввел понятие пороговой точки. В упрощенном виде пороговой точкой является наименьшее процентное соотношение загрязнения данных выбросами, которое может привести к неограниченному значению ошибки. В целом, чем выше пороговая точка, тем более робастная оценочная функция. Для М-оценок пороговая точка не должна превышать $1/N$, где N – размерность параметрического пространства [5], поэтому при даже умеренном числе параметров значение пороговой точки становится очень малым и в случае оценок наименьших квадратов она стремится к нулю. В общем случае робастной оценки выбросами можно считать те величины, которые удовлетворяют критерию:

$$|x_i - x_{(0)}| > t\zeta,$$

где x_i – точка релевантных данных, которые оцениваются, $x_{(0)}$ – опорная величина номинальных данных, ζ – масштаб естественной вариации, t – пороговый параметр. Для устойчивой оценки местоположения наблюдаемых данных и их разброса часто рекомендуют использовать величину медианы и абсолютное отклонение от медианы (MAD) [6]:

$$\text{median}(X_N) = \frac{x_{[(N+1)/2]:N} + x_{[N/2]+1:N}}{2},$$

$$S = \text{MAD}(X_N) = 1.4826 \times \text{median} \left\{ \left| x_i - \text{median}(X_i) \right| \right\}_{j=1, \dots, N},$$

где $[\bullet]$ – функция округления в меньшую сторону к самому близкому целому числу, и $X_{1:N}, \dots, X_{N:N}$ – ранжирование выборки X_N . Поправочный коэффициент 1.4826 выбран с целью, чтобы S совпадало со среднеквадратическим отклонением, когда X_N является гауссовым распределением. Основным принципом идентификатора Хампеля является замена $x_i = \text{median}(X_N)$ и $\zeta = S$. Идентификатор Хампеля эффективен, когда данные не изменяются во времени. На практике последовательность данных, например, временной мониторинг внутричерепного давления, всегда искажена дрейфом базовой линии или другими динамическими событиями. Для того чтобы приспособиться к динамическим условиям, идентификатор Хампеля применяется в скользящем окне. Это подход известен как *фильтр Хампеля*.

Для любого целого числа K скользящее окно данных определяется как

$$w_i = [x_{i-K}, \dots, x_i, \dots, x_{i+K}]$$

и данные упорядочиваются по рангам, чтобы получить последовательность

$$x_{(-K)} \leq \dots \leq x_{(0)} \leq \dots \leq x_{(K)},$$

где $x_{(0)}$ центральный элемент в этом ранжированном списке. Следовательно, фильтр Хампеля определяется, как:

$$y_i = \begin{cases} x_i & |x_i - x_{(0)}| \leq tS_i \\ x_{(0)} & |x_i - x_{(0)}| > tS_i \end{cases}.$$

Как только выброс обнаружен, его величина заменяется медианой в этой точке. Пороговую величину t для обнаружения выброса принимают равной $t = 3$ для устойчивости к ошибкам. Отметим, что оба экстремальных предела порогового параметра представляют важные особые случаи: когда $t = 0$, мы возвращаемся к медианному фильтру, поскольку $y_i = x_{(0)}$ всегда поддерживается в этом случае, и в пределе, когда $t \rightarrow \infty$, мы приближаемся к фильтру идентичности $y_i = x_i$. Фильтрация отсутствует, так как в этом случае медианный критерий выбора никогда не может удовлетвориться.

2 Калмановская фильтрация

После обнаружения в онлайн-режиме с помощью фильтра Хампеля выбросов в наблюдаемом временном ряде данных и замены их медианой данных в скользящем окне эти точки сигнала подлежат восстановлению. Важным обстоятельством после удаления выбросов является то, что распределение измеряемых данных можно считать гауссовым распределением и использовать байесовское вероятностное оценивание сигнала из зашумленных наблюдений. В этой методологии задача оценивания рассматривается в виде последовательной двухэтапной процедуры прогноза и коррекции, основанной на предположении аддитивной модели линейных уравнений процессов оценивания и наблюдения, дополненных белыми гауссовыми шумами. В этом случае распределения вероятностей оценок также оказываются гауссовыми и решение задачи сводится к рекуррентной системе уравнений. Практическая реализация этого подхода известна как фильтр Калмана, в котором стадия оценивания и прогноза, основанная на марковском процессе, является моделью обновления во времени и используется для предсказания следующего состояния системы по данным текущего состояния. Стадия коррекции использует независимую модель измерения для коррекции предсказанной оценки по предоставленным данным наблюдения. Фильтр Калмана также включает динамический фактор усиления в уравнениях временных обновлений, который автоматически обновляется для точного определения, как много «доверия» вве-

дено в наблюдаемые данные. Поэтому, если наблюдения, как считают, очень зашумлены, больше «доверия» размещено в прогнозирующую стадию, и таким образом стадия коррекции оказывает небольшое влияние на сигнал. Для реализации фильтра Калмана необходима также начальная оценка состояния системы (значения переменных состояния) и ковариации ошибки оценки. Уравнения фильтра Калмана детализированы в книге [7].

Общим подходом для распознавания и прогноза сигнала является модель пространства состояний, которая может использоваться для описания большого количества различных моделей. Одной из таких моделей является адаптивная авторегрессионная AAR(p) модель p -го порядка. Параметры AAR могут использоваться для описания изменяющихся во времени данных, охватывая второй порядок статистических моментов. В этой модели не требуется почти никакого априорного знания, порядок модели p не очень важен и, так как он является одиночным коэффициентом, он может быть легко оптимизирован. Кроме того, нет необходимости в выборе особо дорогого алгоритма. Параметры AAR обеспечивают простой и робастный подход и, следовательно, хорошую отправную точку для адаптивного выявления характерных особенностей. Одномерная авторегрессионная (AR) модель, описывается следующим уравнением:

$$x(n) = \sum_{k=1}^p a_k x(n-k) + e(n),$$

где $x(n)$ – анализируемый физиологический сигнал (например, сигнал ВЧД) в момент времени n , $\{a_k\}_{k=1}^p$ – параметры модели, $\{x(n-k)\}_{k=1}^p$ – задержанные выборки сигнала с процессом обновления $e_n = N(\mu_n = 0, \sigma_n^2)$ с нулевым средним значением и дисперсией σ_n^2 . Чтобы выполнить оценку AAR параметров фильтром Калмана, модель AAR должна подходящим способом быть приспособлена к модели пространства состояний. С этой целью параметры AR(p) становятся векторами состояния $\mathbf{z}_k = \mathbf{a}_k = [a_{1,k}, \dots, a_{p,k}]^T$. Решение проблем выбора начальных значений, коэффициентов обновления и порядка модели фильтра Калмана для оценки AAR параметров, а также его применения для обработки сигналов электроэнцефалограмм (ЭЭГ) можно найти в работе [8]. Ранее мы использовали алгоритмы калмановской фильтрации и калмановского сглаживания для адаптивной оценки параметров авторегрессионной модели при изучении морфологии волн ВЧД при острой травме головного мозга [9].

Применение авторегрессионной модели, в частности, авторегрессионной модели проинтегрированного скользящего среднего (ARIMA) с выбором порядка на основе автокорреляционной (ACF) и частной автокорреляционной (PACF) функций для предсказания непрерывных трендов сигнала ВЧД было предложено в работе [10]. Было показано, что точность предсказания ВЧД значительно лучше, когда порядок модели ARIMA оценивается ACF и PACF, чем с помощью информационного критерия Акаике. Этими же авторами был предложен алгоритм, использующий авторегрессионную модель, для восстановления сигналов ВЧД после удаления артефактов и выбросов с помощью эмпирического метода декомпозиции [11-12].

Результаты и обсуждение

Инвазивные измерения внутричерепного давления (ВЧД) осуществлялись с помощью универсального сетевого мониторинго-диагностического комплекса для управляемой терапии больных. Составляющими звеньями этого комплекса были: прибор мониторинга ВЧД, основанный на жидкостно-заполненной системе катетер-тензометр с измерительным модулем M3500P (УкрЦЕНДИСИ НАН Украины, г. Киев) [13], и

Codman ICP Express монитор с тензометрическими микродатчиками давления [14]. Системное программное обеспечение позволяет адресное обращение к измерительным модулям, введение информации к компьютеру, накопление и математическую обработку данных и их графическое изображение в течение мониторинга несколько суток непрерывно. Мониторинг ВЧД проводился у 117 пострадавших в возрасте от 18 до 62 лет с тяжелой черепно-мозговой травмой (глубина коматозного состояния по шкале ком Глазго менее 8 баллов), находящихся на лечении в отделении нейрореанимации Донецкого областного клинического территориального медицинского объединения (ДОКТМО).

На рис. 1 а показан типичный пример сигнала ВЧД, неинвазивно регистрируемого в клинических условиях нейрореанимации, который искажен множественными выбросами из-за неконтролируемого движения пациентом головой. Процесс неавтономной предварительной обработки сигнала фильтром Хампеля показан на рис. 2, где вместе с измеренным ВЧД сигналом приведены результаты обработки медианным фильтром, верхняя и нижняя пороговые величины обнаружения выбросов, обнаруженные выбросы и конечный результат фильтрации. К обрабатываемым данным сигнала применено скользящее окно, сформированное последовательностью данных $\{x_i\}$ длиной K точек. Чувствительность фильтра Хампеля контролируется двумя параметрами – порогом обнаружения выбросов – t и K – шириной окна. Как упоминалось выше, пороговая точка средней статистической величины или отношение числа выбросов к общему количеству выборок в последовательности данных, для которой средняя статистическая величина становится выбросом, составляет 50%. Это обстоятельство предполагает, что ширина окна K должна быть, по крайней мере, вдвое шире отдельного выброса. Если в пределах ширины окна присутствуют два или больше близких выброса фильтр обнаружит их присутствие, если их суммарная ширина вдвое меньше ширины окна.

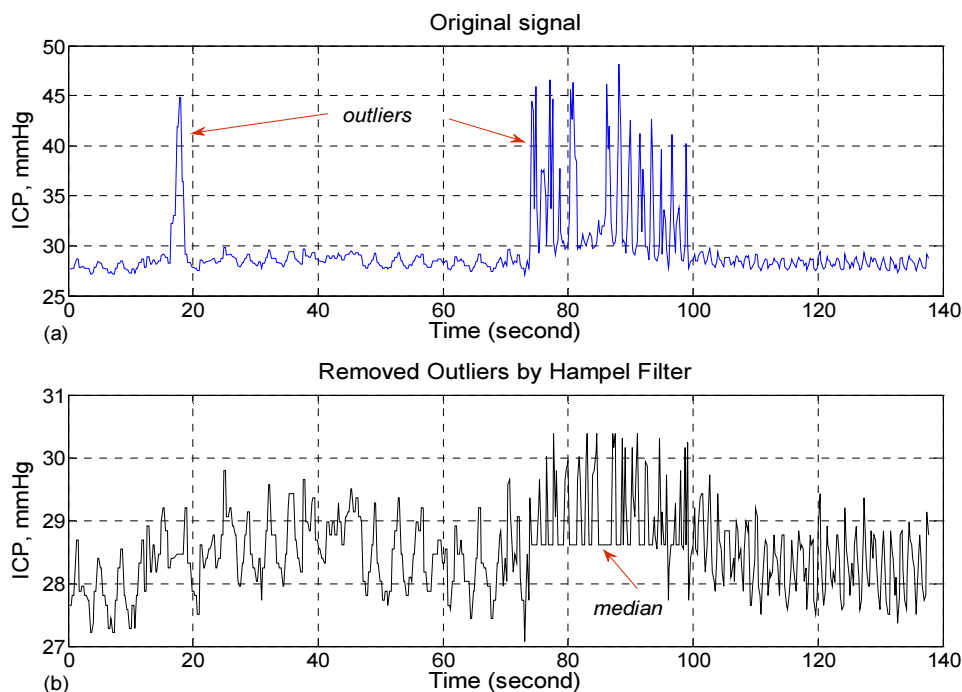


Рисунок 1 – Сравнение сигналов 138-секундного фрагмента мониторинга ВЧД сигнала у пациента Кос-ко: а) до и б) после обработки фильтром Хампеля в неавтономном режиме. Точки выбросов заменены значением медианы в этих точках

В работе [15] исследовалась возможность применения фильтра Хампеля для удаления выбросов в сигналах электроэнцефалограмм, где было найдено, что $K = 80$ измерительных точек и величина порога $\sim 5 - 6$ были подходящими для всех субъектов.

Для обнаружения выбросов в сигнале ВЧД, показанных на рис. 1 и рис. 2, мы использовали ширину окна $K = 210$ точек и пороговую величину равной $t = 3$. Обработанный фильтром Хампеля сигнал ВЧД показан на рис. 1b, где обнаруженные точки выбросов заменены на значение медианы в этих точках.

Задача второго (заключительного) этапа обработки состояла в фильтровании полученного после удаления выбросов сигнала – медианные значения следует заменить на «хорошие» данные, которые с наибольшей вероятностью будут соответствовать структуре исследуемого сигнала. Для этой цели использовалась AAR модель, параметры модели определялись с помощью алгоритма Калмана и последующим RTS сглаживанием. Фильтр Калмана представляет собой универсальный инструмент для онлайн-оценки коэффициентов модели. Однако производительность фильтра Калмана существенно зависит от его инициализации, выбора коэффициентов обновления и порядка модели, которые обычно неизвестны. Конечно, их можно принять навскидку, например, нулевыми, но такой подход приводит к длительному начальному переходному эффекту. Кроме того, нулевая установка начальных значений параметров AAR может иметь некоторое вредное влияние на результат. Основываясь на некоторых предварительных экспериментах, в работе [8] было показано, что в модели пространства состояний для запуска алгоритма рекомендуется ковариационная матрица начального состояния в виде диагональной матрицы, взвешенной дисперсией предыдущих данных и умноженной на коэффициент δ , который может принимать либо очень малые значения, либо очень большие $Q_0 = \delta \sigma^2 I$. В нашем случае мы приняли $\delta = 10^6$.

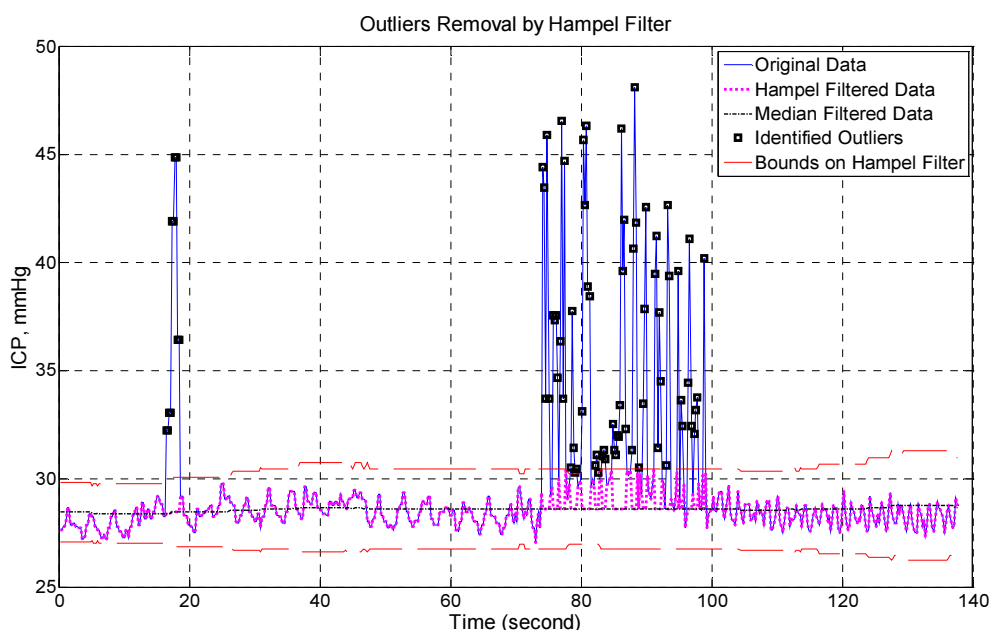


Рисунок 2 – Предварительная обработка фильтром Хампеля фрагмента сигнала мониторинга ВЧД, полученного в клинике у пациента Кос-ко.

Ширина скользящего окна взята размером $K = 120$ точек. Штрихпунктирная линия показывает параметры прогноза опорной величины номинальных данных $x_{(t)} = \text{median}(x)$. Пунктирные линии показывают прогнозируемый порог выбросов $(x_{(t)} + 3S)$. Точки обнаруженных выбросов показаны квадратом (\square).

Точечной линией показан сигнал ВЧД, очищенный от выбросов

Выбор коэффициента обновления подробно обсуждался в работе [16] и было установлено, что в случае AAR оценки сигналов ЭЭГ оптимальный выбор коэффициента обновления является компромиссным решением между скоростью адаптации и точностью оценки. С этой целью, ковариационная матрица шума процесса W_k и дисперсия процесса обновления V_k в зависимости от коэффициента обновления UC были взяты в виде:

$$W_k = I \cdot UC \cdot \text{trace}(Q_{k-1})/p,$$

$$V_k = 1 - UC,$$

где коэффициент обновления в нашей работе мы приняли равным $UC = 4^{-6}$ [16].

Оптимальный порядок модели мы определяли, используя информационный критерий Акаике (AIC) и байесовский информационный критерий (BIC). Результаты такой оценки представлены на рис.3б. К сожалению, порядок модели, полученный этими подходами, не был обязательно лучшим для обработки сигналов ВЧД других пациентов или разных фрагментов длительного мониторинга одного пациента. Наш опыт показывает, для устойчивой работы алгоритма RTS сглаживания часто требуются намного меньшие порядки, чем определяют критерии AIC и BIC. В основном, мы использовали порядок 5 или 6. Из доступной нам литературы, мы полагаем, что вопрос оптимальных начальных параметров AAR оценки остается все еще открытым.

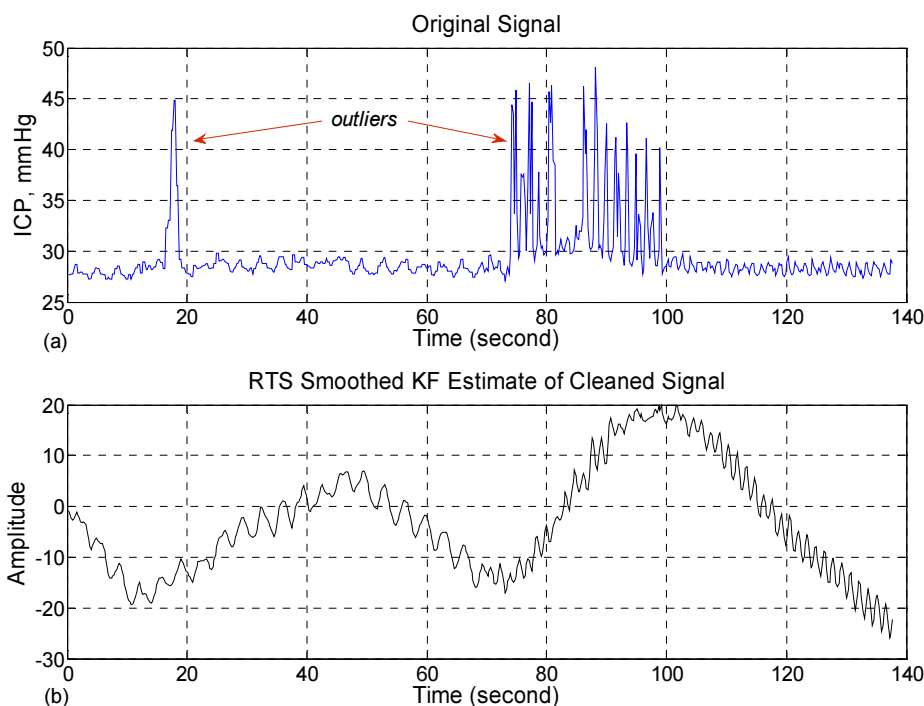


Рисунок 3 – Результат онлайн-двухэтапной обработки ВЧД сигнала, загрязненного множеством выбросов – артефактов движения, возникших при мониторинге пациента К-ко в клинических условиях нейрореанимации: (а) загрязненный ВЧД сигнал; (б) очищенный сигнал после обнаружения и замены выбросов фильтром Хампеля, прогноза замененных данных фильтром Калмана и окончательным RTS сглаживанием

Для этого случая наилучшая оценка $p = 13$ порядка AAR модели была определена BIC критерием.

Выводы

В этой статье представлена методика неавтономного фильтрования физиологических сигналов. Исследование сосредоточено на обнаружении выбросов и очистке сигналов ВЧД мониторинга. Удаление выбросов является необходимым шагом предварительной обработки жизненно важных медицинских сигналов, чтобы усилить их характеристики для дальнейшего диагноза. Данная схема фильтрования осуществляется в два этапа – сначала используется робастный фильтр Хампеля со скользящим окном для обнаружения и удаления выбросов, затем калмановская фильтрация и калмановское сглаживание для оценки и восстановления ВЧД сигнала. Эффективность предложенного метода удаления артефакта экспериментально оправдана, основываясь на сигналах ВЧД мониторинга 117 больных в возрасте от 18 до 62 лет с тяжелой черепно-мозговой травмой; выбросы и шум удаляются без искажений оригинального ВЧД сигнала. Этот метод может также использоваться для фильтрации любых нестационарных техногенных сигналов.

Литература

1. Hampel F.R. The Breakdown Points of the Mean Combined With Some Rejection Rules / F.R Hampel // *Technometrics*. – 1985. – V. 27. – P. 95-107.
2. Martin R.D. Robust-resistant spectrum estimation / R.D Martin, D.J Thomson // *Proceeding of the IEEE*. – 1982. – V. 70. – P. 1097-1115.
3. H. Liu. On-line outlier detection and data cleaning. / H. Liu, S. Shah, W. Jiang // *Computers and Chemical Engineering*. – 2004. – V. 28. – P. 1635-1647.
4. Data cleaning for dynamic modeling and control / R.K. Pearson // *European Control Conference, ETH*. – Zurich, Switzerland, 1999.
5. Хампель Ф. Робастность в статистике. Подход на основе функции влияния / Хампель Ф., Рончетти Э., Пауссеу П., Штаэль В. – М. : Мир, 1989. – 512 с.
6. Pearson R.K. Outliers in process modeling and identification / R.K Pearson // *IEEE Transactions On Control Systems Technology*. – 2002. – V. 10. – P. 55-63.
7. Vaseghi Saeed V. *Advanced digital signal processing and noise reduction* / Saeed Vaseghi. – 4th ed., JohnWiley & Sons Ltd, United Kingdom, 2008. – 514 p.
8. Schlögl A. Adaptive Methods in BCI Research – An Introductory Tutorial / A. Schlögl, C. Vidaurre, K.-R. Müller // *Brain Computer Interfaces – Revolutionizing Human-Computer Interfaces*. – 2010. – Springer. – P. 331-355.
9. Дроботько Д.В. Система мониторинга и морфология формы нестационарных сигналов внутричерепного давления / Д.В. Дроботько, И.В. Качур, В.Ф. Дроботько, Г.А. Городник // *Штучний інтелект*. – 2010. – № 4. – С. 651-661.
10. Zhang F. Online ICP Forecast for Patients with Traumatic Brain Injury / F. Zhang, M. Feng, L.Y. Loy, Z. Zhang, C. Guan // *In Proc. ICPR-2012*. – 2012. – P. 37-40. – Tsukuba, Japan.
11. Feng M. Artifact removal from intracranial pressure monitoring signals: a robust solution with signal decomposition / M. Feng, L.Y. Loy, F. Zhang, C. Guan // *in Proc. IEEE EMBC'11*. – Boston, USA. – 2011. – P. 797-801.
12. Feng M. Artifact Correction with Robust Statistics for Non-Stationary Intracranial Pressure Signal Monitoring / M. Feng, L.Y. Loy, K. Sim [and other] // *In Proc. ICPR-2012*. Tsukuba, Japan. – 2012. – P. 557-560.
13. Черний В.И. Нейрофизиологический мониторинг интенсивной терапии в остром периоде тяжелой черепно-мозговой травмы. Медицина неотложных состояний / В.И. Черний, Г.А. Городник, А.М. Кардаш [и др.] // *Специализированный научно-практический журнал*. – 2008. – № 2 (15). – С. 72-76.
14. ICP Monitoring Codman. – <http://freepdfdb.com/pdf/icp-monitoring-codman>.
15. Allen D.P. Suppression of deep brain stimulation artifacts from the electroencephalogram by frequency-domain Hampel filtering / D.P. Allen, E.L. Stegemöller, C. Zadikoff, J.M. Rosenow, C.D. MacKinnon // *Clin Neurophysiol*. – 2010. – V.121, № 8. – P. 1227-1232.
16. Schlögl A. *The Electroencephalogram and the Adaptive Autoregressive Model: Theory and Applications*. Dissertation, (Dr. techn.) / Schlögl A. – April 2000, Graz. – 83 p.

Literatura

1. Hampel F.R. The Breakdown Points of the Mean Combined With Some Rejection Rules / F.R Hampel // *Technometrics*. - 1985. - V. 27. - P. 95 - 107.
2. Martin, R. D. Robust-resistant spectrum estimation / R. D Martin, D. J Thomson // *Proceeding of the IEEE*. - 1982 - V. 70. - P. 1097-1115.
3. H. Liu, S. Shah, W. Jiang. On-line outlier detection and data cleaning. // *Computers and Chemical Engineering*. - 2004. - V. 28.- P. 1635-1647.
4. Data cleaning for dynamic modeling and control / R. K. Pearson // *European Control Conference, ETH*. - 1999. - Zurich, Switzerland.
5. F.R. Hampel, .E.M. Ronchetti, P.J. Rousseeuw, W.A. Stahel. *Robuts Statistics. The Approach Based on Influence Functions*. John Wiley & Sjns, Inc., New York 1986. 502 p.
6. Pearson, R. K. (). Outliers in process modeling and identification / R. K Pearson // *IEEE Transactions On Control Systems Technology*. - 2002. - V. 10. - P. 55–63.
7. Vaseghi Saeed V. *Advanced digital signal processing and noise reduction* / Saeed Vaseghi. — 4th ed., JohnWiley & Sons Ltd, United Kingdom. - 2008. - 514 p.
8. Schlögl A. Adaptive Methods in BCI Research - An Introductory Tutorial / A. Schlögl, C. Vidaurre, K.-R. Müller // In "Brain Computer Interfaces - Revolutionizing Human-Computer Interfaces" Springer. - 2010. - P. 331-355.
9. Drobotko D.V. Monitoring System and Morphology of Non-stationary Signals of Intracranial Pressure / D.V. Drobotko, I.V. Kachur, V.F. Drobotko, G.A. Gorodnik // *Artificial intelligence*. – 2010. - № 4. – С. 651-661.
10. . Online ICP Forecast for Patients with Traumatic Brain Injury / F. Zhang, M. Feng, L.Y. Loy, Z. Zhang, C. Guan // In Proc. ICPR-2012. - 2012. P. 37-40. -Tsukuba, Japan.
11. Artifact removal from intracranial pressure monitoring signals: a robust solution with signal decomposition / M. Feng, L. Y. Loy, F. Zhang, and C. Guan // in Proc. IEEE EMBC'11. - 2011. - P. 797 - 801. - Boston, USA.
12. Artifact Correction with Robust Statistics for Non-Stationary Intracranial Pressure Signal Monitoring / M. Feng, L. Y. Loy, K. Sim, C. Phua, F. Zhang, C. Guan // In Proc. ICPR-2012. - 2012. - P. 557-560. - Tsukuba, Japan
13. Neurophysiological monitoring of intensive therapy in the sharp period of a heavy craniocerebral trauma. Medicine of urgent conditions / V.I. Cherny, G.A. Gorodnik, A.M. Kardash [etc.] // *Specialised scientifically-practical magazine*. – 2008. – № 2 (15). – P. 72-76. .
14. ICP Monitoring Codman. <http://freepdfdb.com/pdf/icp-monitoring-codman>.
15. Allen D. P.. Suppression of deep brain stimulation artifacts from the electroencephalogram by frequency-domain Hampel filtering / D. P. Allen, E. L. Stegemöller, C. Zadikoff, J. M. Rosenow, C. D. MacKinnon // *Clin Neurophysiol*. - 2010. - V.121, № 8. - P. 1227–1232.
16. Schlögl A. *The Electroencephalogram and the Adaptive Autoregressive Model: Theory and Applications*. Dissertation, (Dr. techn.) / Schlögl A. – April 2000, Graz. – 83 p.

RESUME

D.V. Drobotko, A.I. Shevchenko, V.F. Drobotko, I.V. Kachur

Online outliers detection and cleaning of intracranial pressure monitoring signals

The vast majority of researches in the digital data processing refer to the signals of anthropogenic origin, in which problems of noise stability and noise filtering of noisy signals generated by different means of communication and broadcasting are solved. At last decades, especially abroad, have been intensively developed computer-based processing of physiological signals in medical applications. The physiological signals analysis was much harder than anthropogenic signals. That issue due by the two factors: physiological processes has signals with low amplitude, and these signals are inherently non-stationary and non-linear. In addition, these signals are contaminated heavily stochastic components, for example, the signal monitoring of intracranial pressure (ICP), resulting in Neuro Intensive Care Units often contains a large amount of noise and outliers. These artifacts not only directly lead to false alarms in automatic alert systems of monitoring-diagnostic complex for controlled

therapy patient, and they also severely contaminate the characteristics of the underlying signal, which makes accurate forecasting of secondary brain damages caused by Intracranial Hypertension impossible.

Apparently exists, three basic filter for detection and removal of outliers from process data series, which had modernization in recent works. This is the median filter, closely related to it and almost as simple - Hampel filter and the filter-cleaner, designed by Martin and Thomson (MT filter-cleaner). If the first two filters can work in the on-line mode, the MP filter-cleaner – works by essentially autonomous scheme, which is based on a pre-estimated model of the time series. These three basic filters were tested for the identification of three different dynamic systems, one of which was treated with real outlier noisy signal of the helicopter height and angle commands and the other two model systems – linear model and nonlinear second-order Volterra model with additive Gaussian noise and outliers, which are known for accurate results. In fact, there is no effective universal cleaning filter data.

This article offers an efficient on-line two-step purification method of physiological signals based on Hampel identifier and Kalman filtering. Initially, clinical measurement of ICP signal undergo pretreatment in which the identification of signal data structure are realized, and the estimated level of noise outliers are removed by the Hampel filter robust. Outlier points are replaced by the median value at those points. Next, the correction of these points, noise removal and evaluation of the signal based on adaptive autoregressive (AAR) model using the Kalman filter and its associated RTS (Rauch-Tung-Striebel) smoothing filter are performed. Proposed filtering method customizable parameters are the half-width moving window, the threshold for detecting outliers and order AAR model. The effectiveness of the proposed method is justified by the experimental artifact removal, based on the signals of ICP monitoring at 117 patients aged 18 to 62 years with severe traumatic brain injury, outliers and noise are removed without distortion of the original ICP signal. This method can also be used to filter out any non-stationary anthropogenic signals.

Статья поступила в редакцию 26.04.2013.