

УДК 004

АЛГОРИТМ АДАПТИВНОЙ ЦИФРОВОЙ ФИЛЬТРАЦИИ НА ОСНОВЕ НЕЙРОННОЙ СЕТИ

Валюх А.А., Хандецкий В.С.

*Факультет физики электроники и компьютерных систем
Днепропетровского национального университета им. О. Гончара
E-mail: valiuh@gmail.com.*

Аннотация

Валюх А.А., Хандецкий В.С. Алгоритм адаптивной цифровой фильтрации на основе нейронной сети. Рассматривается задача построения адаптивного цифрового фильтра на основе сети прямого распространения. Фильтрация базируется на основе прогнозирования поведения тренда временного ряда. Предложен, реализован и исследуется алгоритм обработки сигналов основанный на предварительном сглаживании и последующем моделировании шума путем предсказания сетью тренда шумового процесса.

Вступление

В настоящее время актуальным является совершенствование средств измерения расхода газа в потоке. Одним из наиболее перспективных в этом направлении является ультразвуковой метод контроля, особенно учитывая характеристики точности и надежности измерительной аппаратуры [1].

В основу работы ультразвуковых расходомеров и счетчиков газа положен время-импульсный принцип, сущность которого заключается в определении разности скоростей ультразвуковых зондирующих импульсов, проходящих по направлению потока и против него.

В ряде случаев в трубопроводе, на котором установлен ультразвуковой расходомер, появляется широкополосный шум. Источниками такого шума могут являться: открытые не к конца или износившиеся заслонки, редукторы, фильтры и т.д. В результате снижается точность измерения расхода газа.

Постановка задачи

С целью ослабления влияния шума целесообразно провести фильтрацию сигнала. Однако поскольку, спектр ультразвукового зондирующего сигнала и шума часто перекрываются, использование обычных цифровых фильтров с фиксированными коэффициентами не эффективно. Большие возможности для решения этой задачи представляют адаптивные фильтры. Данная работа посвящена исследованию возможностей нейросетевых технологий для построения и использования адаптивного фильтра с целью подавления шума в акустическом тракте ультразвукового счетчика газа (расходомера).

Основная часть

Работа искусственной нейронной сети в качестве адаптивного фильтра происходит следующим образом[2]. Исходный массив данных по времени можно разбить на два подмассива - подмассив в котором содержится исключительно шумовой фон (массив N), и подмассив в котором присутствуют как шумовой фон так и сигнал (массив SN). Процесс работы адаптивного фильтра состоит из двух основных этапов - этап обучения и этап непосредственной работы. На этапе обучения нейронная сеть обучается моделировать шум N путем предсказания сетью тренда шумового процесса. На этапе работы нейронная сеть вычитает из зашумленного сигнала SN смоделированный ею шум.

На эффективность работы адаптивного фильтра на основе нейронной сети большое влияние имеют характеристики шума. Чем более стационарным и менее случайным является характер шума, тем осуществляется более качественно фильтрация[2]. В свою очередь это связано с тем что алгоритм обработки сигналов основан на предсказании сетью тренда

шумового процесу. Так як предсказание временного тренда случайного процесса невозможно [3], то не возможна и качественная фильтрация от шума носящего случайный характер.

В свою очередь влияние случайной составляющей на полезный сигнал может быть существенно снижен путем обычного усреднения результатов измерения по всем реализациям этого сигнала [4]. На практике [5] в качестве алгоритмов сглаживания шумов большое распространение в различных областях получили разновидности алгоритмов скользящего среднего — МА (Moving Average) алгоритмы. Среди этих алгоритмов наиболее распространены: алгоритм простого скользящего среднего — SMA (Simple Moving Average). Фильтры скользящего среднего популярны для сглаживания данных, например, для анализа стоимости акций и т.д. [5]. Простое скользящее среднее периода n на момент k — это средняя арифметическая величина n значений от $k-n+1$ до k [5]. В аналитическом виде все вышесказанное можно записать в виде выражения (1).

$$y(n) = \frac{1}{N} \sum_{k=0}^{N-1} x(n-k) \quad (1)$$

Таким образом фильтр скользящего среднего является элементарной формой КИХ-фильтра, с равными весовыми коэффициентами для всех $x(n)$. Поэтому вычисления, требуемые для получения нового значения на выходе, состоят из одного суммирования, одного вычитания и одного умножения, независимо от длины фильтра скользящего среднего.

К общим недостаткам всех МА фильтров следует отнести противоречие выбора оптимального значения ширины окна сглаживания [6]. Однако для нас существенным является тот факт, что фильтр скользящего среднего не имеет выброса по фронту входного сигнала. Это делает его полезным в приложениях обработки сигналов, где требуется фильтрация случайного белого шума при сохранении характеров входного импульса. Таким образом представляется интересной возможность совместного использования SMA алгоритма совместно с предложенным двухэтапным алгоритмом шумоподавления основанным на предсказании сетью тренда шумового процесса.

При таком подходе, данные которые подаются на вход нейросетевого шумоподавителя вначале обрабатываются SMA алгоритмом с целью уменьшения влияния случайной составляющей шума на результат шумоподавления. На выходе нейросетевого шумоподавителя сигнал так же содержит в незначительной степени случайную составляющую [2]. Это связано как неизбежной погрешностью шумоподавления. Поэтому целесообразным является повторное сглаживание результата фильтрации алгоритмом SMA.

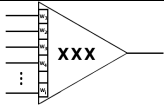
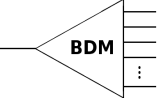
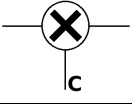
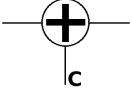
Все вышеописанное можно объединить в один адаптивный шумоподавляющий алгоритм который мы в дальнейшем будем называть SNS (SMA-NAF-SMA где NAF — Neural Adaptive Filter).

Рассмотрим выражение (1) аналитической записи SMA алгоритма. Видно аналитическое сходство между SMA, заданного в виде суммы входных значений умноженных на соответствующие весовые коэффициенты и классическим формальным нейроном в виде порогового сумматора. Различным остается лишь физический смысл и способ расчета соответствующих весов. В первом случае весовые коэффициенты выбираются по заранее детерминированным правилам, и не меняются в процессе работы (фильтрация, усреднение, корреляция, аппроксимация), в другом случае веса рассчитываются заданным алгоритмом обучения, и при необходимости могут модифицироваться (искусственные нейронные сети). Следовательно с точки зрения теории нейронных сетей SMA алгоритм в принципе можно рассматривать как отдельный специализированный нейрон весовые коэффициенты которого жестко рассчитаны и не меняются в процессе работы этих нейронов.

Таким образом есть смысл говорить о целом классе узкоспециализированных DSP-нейронах. Алгоритмы обучения этих DSP-нейронов на основе входных данных и характера решаемой задачи строго однозначно рассчитывают весовые коэффициенты. Таким образом обучение сводится к четкому расчету весов по заранее определенным правилам.

Для описания предложенного нами SNS алгоритма в контексте оговоренной выше DSP-нейронной парадигме введем ряд графических обозначений DSP-нейронов представленных в таблице 1.




Таблица 1. Основные DSP-нейроны.

Название нейрона.	Описание и назначение.	Обозначение.
DSP-нейрон	Выполняет обработку входных данных согласно специализации. К примеру при $XXX=SMA$ имеем нейрон скользящего среднего, а при $XXX=AN$ — классический формальный нейрон.	
Буфер-демультиплексор	Выполняет преобразование последовательного кода в параллельный путем сохранения нового значения в младший адрес шины и его дальнейшего поразрядного сдвига. Может использоваться в качестве векторного формирователя, буфера, элемента задержки, сдвигового регистра и т.д.	
Масштабирующий элемент	Выполняет умножение входного сигнала на константу C . Может быть использован в качестве масштабирующего усилителя, аттенюатора или ограничителя.	
Амплитудно сдвиговый элемент	Выполняет сложение входного сигнала с константой C . Обеспечивает смещение входного сигнала относительно виртуального нуля равного C .	

Остается однако открытым вопрос как осуществлять передачу данных между нейронами и их обучение. Очевидно что нейроны в такой DSP-нейронной сети могут работать только в асинхронном режиме. Это связано с тем что на лицо так называемая зависимость по данным — когда выход какого либо нейрона не может быть вычислен, до тех пор пока не вычислен выход предыдущего нейрона.

Для преодоления этой проблемы введем понятия состояния нейрона и управляющих связей между нейронами. Введем два основных состояния нейронов: возбужденное состояние в котором нейрон выполняет обработку поступивших данных согласно своей специализации; и состояние торможения в котором нейрон прекращает обработку, выдает или не выдает результат своей работы следующему нейрону, и возбуждает либо следующий за ним нейрон, либо предыдущий. Таким образом для каждого DSP-нейрона запрашивается введения помимо информационных связей дополнительных управляющих связей. Эти управляющие связи представлены в таблице 2.

Таблица 2. обозначения управляющих связей DSP-нейронов.

Название	Назначение	Обозначение
Вход возбуждения	Переходит в возбужденное состояние.	
Выход прямого возбуждения	Возбуждение последующего нейрона в цепи.	
Выход обратного возбуждения	Возбуждение предыдущего нейрона в цепи.	

Переход между состояниями для DSP-нейронов может быть представлен на рисунке 4.



Рисунок 1 Граф переходов между состояниями для DSP-нейронов.

Таким образом DSP-нейрон может быть представлен в виде связки операционного автомата — реализующего непосредственно алгоритм обработки данных; и управляющего автомата с конечным числом состояний — для управления процессом обработки.

Подход при котором формальные нейроны представлялись в виде конечных цифровых автоматов пересекается с идеями Д. Фон-Неймана предложившим рассматривать нейронные сети в виде кристаллической решетки в узлах которой находились цифровые автоматы[7].

Теперь можно описать наш SNS алгоритм в контексте DSP-нейронной парадигмы. Для этого обратимся к DSP-нейронной сети на рисунке 4.

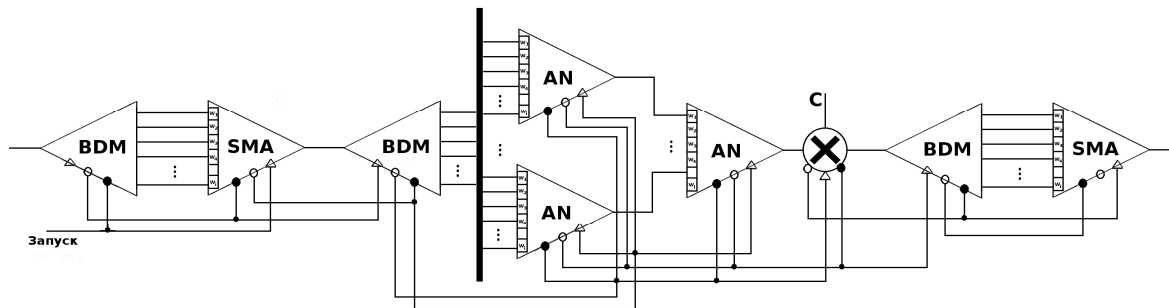


Рисунок 2. Полная DSP-нейронная сеть реализовывающая SNS алгоритм.

Входной BDM-нейрон производит преобразование последовательного зашумленного сигнала в параллельный вектор, который в свою очередь подается на вход SMA-нейрона для сглаживания случайного шума. Количество выводов в BDM-нейроне соответствует длине окна сглаживания. Второй BDM-нейрон производит формирование вектора который подается на вход нейронов составляющих «классическую» нейронную сеть из N- скрытых и одного выходного нейронов. Результат работы нейронной сети подается на вход усилителя. Это делается исключительно из практических соображений, так как на основе полученных ранее данных видно что амплитуда выходного сигнала слабее амплитуды исходного опорного[4]. И наконец два последних нейрона выполняют формирование и окончательное сглаживание результата. Для проверки работоспособности и применимости данной модели была написана программа в вычислительной среде Matlab 7.0 позволяющая реализовать основные моменты алгоритма SNS и проверить их на зашумленном сигнале. В данной работе были использованы сети обратного распространения ошибки. Использовалась архитектура нейронной сети содержащая один входной слой, один скрытый слой и один выходной слой состоящий из одного нейрона. Для устранения возможной ситуации с переобучением нейронной сети, использован алгоритм обучения автоматической регуляции на основе правила Байеса. В адаптивный фильтр на основе нейронной сети с наиболее удачной архитектурой и параметрами обучения из [2], были добавлены две процедуры SMA — на вход и выход соответственно.

Для моделирования процесса обучения и тестирования нейронных сетей использовалась вычислительная среда Matlab 7.0 развернутая на компьютере следующей

конфігурації: Athlon XP 1800+ (1,53GHz), 1GB DDR. Исследовались, зависимости соотношения сигнал шум ($\Delta_{S/N}$), а также коэффициента взаимокорреляции полученного и опорного сигналов после обработки алгоритмом SNS в зависимости от количества точек внутри входного и выходного среднескользящего усреднения. В качестве нейронной сети входящей в состав алгоритма SNS была выбрана нейронная сеть состоящая из 10-ти нейронов скрытого слоя, 1-го нейрона выходного слоя и обучавшаяся на 10 эпохах (длительность эпохи составляет 12 секунд) [2]. Количество эпох работы сети задавалось в процессе эксперимента. Мы исходили из необходимости сокращения общего времени работы сети для повышения для повышения производительности работы расходомера.

При зашумлении исходного опорного сигнала гармоническим шумом были получены характеристики для $\Delta_{S/N}$, а также r представленные на рисунках 7 и 8 соответственно. Изменение длины окна для сглаживания в проводилось в диапазоне от 5 до 40 точек и исследовалось влияние этих изменений на качество работы алгоритма в целом.




Рисунок 3. Зависимость коэффициента взаимокорреляции r от количества точек внутри входного и выходного среднескользящего усреднения в SNS при зашумлении гармоническим шумом.

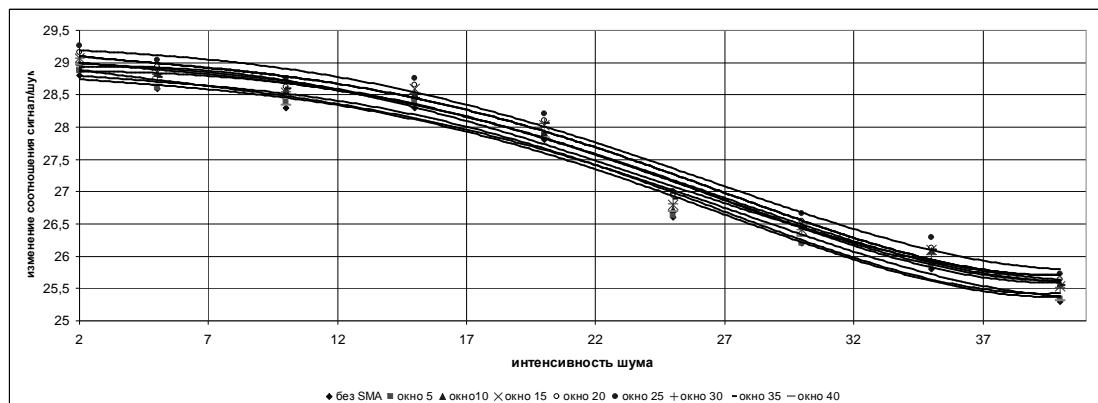


Рисунок 4. Зависимость $\Delta_{S/N}$ от количества точек внутри входного и выходного среднескользящего усреднения в SNS при зашумлении гармоническим шумом.

Из приведенных выше графиков видно что характер работы алгоритма практически не изменился по сравнению с нейронной сетью без входного и выходного среднескользящего сглаживания (нижний график на рисунках 7 и 8). Лучшие результаты были получены с длиной окна равной 25 точкам. При такой длине окна удавалось получить увеличение соотношения сигнал/шум на 1,6% и коэффициента взаимокорреляции на 0,6% по сравнению с обработкой одной только нейронной сетью в случае интенсивности шума в два раза превышающей опорный сигнал. В случае двадцатикратного превышения уровня шума по сравнению с уровнем сигнала, удавалось получить увеличение соотношения сигнал/шум на

1,7% и коэффициента взаимокорреляции на 1% по сравнению с обработкой одной только нейронной сетью.

Проведем зашумление исходного сигнала аддитивной смесью гармонического и белого гаусовского шума. При зашумлении исходного опорного сигнала смесью гармоническим и белым гаусовским шумом были получены характеристики для $\Delta_{S/N}$, а также γ представленные на рисунках 9 и 10 соответственно. По осям абсцисс отложены значения масштабирующего коэффициента на который умножалась интенсивность результирующего шума. Интенсивности составляющих результирующего шума брались в равными.




Рисунок 5. Зависимость коэффициента взаимокорреляции γ от количества точек внутри входного и выходного среднескользящего усреднения в SNS при зашумлении аддитивной смесью гармонического и белого гаусовского шума.




Рисунок 6. Зависимость $\Delta_{S/N}$ от количества точек внутри входного и выходного среднескользящего усреднения в SNS при зашумлении аддитивной смесью гармонического и белого гаусовского шума.

Из приведенных выше графиков видно что характер работы алгоритма меняется при добавлении входного и выходного среднескользящего сглаживания. Также видно что на результат работы алгоритма SNS существенно влияет количество точек внутри среднеквадратичного сглаживания. Изменение длины окна для сглаживания в диапазоне от 5 до 40 точек меняет результатов работы алгоритма как в плане повышения соотношения сигнал/шум так и в плане повышения автокорреляции между опорным сигналом и результатом. Нижний пунктирный график на рисунках 9 и 10 отображает результат работы нейронной сети на зашумленных данных без предварительного сглаживания. Лучшие результаты были получены с длиной окна равной 25 точкам(верхний пунктирный график на рисунках 9 и 10). При такой длине окна удавалось получить увеличение соотношения сигнал/шум в 2,3 раза и коэффициента взаимокорреляции на 36,9% по сравнению с обработкой одной только нейронной сетью в случае интенсивности шума на уровне

опорного сигнала. Результат работы алгоритма SNS для окна равного 25 точкам при зашумлении шумом с амплитудой на уровне полезного сигнала имеем результат представленный на рисунке 11.




Рисунок 7 Результат работы алгоритма SNS.

Выводы

Предложен двухэтапный алгоритм обработки сигналов, основанный на предварительном сглаживании и последующем моделировании шума путем предсказания сетью тренда шумового процесса. Показано что эффективность работы предложенного алгоритма на основе нейронной сети [2] может быть улучшена путем введения предварительного сглаживания входного шума скользящим средним. Добавление входного и выходного среднескользящего усреднения существенным образом не повлияло на качество работы нейросетевого адаптивного фильтра при подавлении гармонического шума. В тоже время аналогичное входное и выходное усреднения существенно улучшило качество работы нейросетевого адаптивного фильтра при подавлении смеси гармонического и белого шума и позволило улучшить результат фильтрации подобного шума по сравнению с обработкой лишь нейронной сетью.

Список литературы

1. Кремлевский П.П. Расходомеры и счетчики количества веществ. Книга 1/2 из-во. – СПб, из-во «Политехника» 2002. – 410с./416с.
2. В.С. Хандецкий, А.А. Валюх Адаптивный цифровой фильтр на основе нейронных сетей. Сборник научных трудов в 2-х частях. Ч. 1. М.: НИЯУ МИФИ, 2010. 332 с., с 167-175.
3. А.А Ежов, С.А. Шумский Нейрокомпьютинг и его применение в экономике и бизнесе Спб.: «Питер», 1998 г.
4. Э. Айфичер Б. Джервис Цифровая обработка сигналов: практический подход, Перевод с английского И.Ю. Дорошенко, А.В. Назаренко М. СПб. К.: Издательский дом «Вильямс», 2004
5. У. Кастер Цифровые фильтры. СПб.: Издательский дом «Вильямс», 2006
6. Файнзельберг Л.С. Адаптивное сглаживание шумов в информационных технологиях обработки физиологических сигналов. Журнал «Математические машины и системы», 2002, №3, с. 96-104.
7. Д. Фон-Нейман Теория самовоспроизводящихся автоматов. -Москва, из-во «Мир», 1971.-382с.