

УДК 004.032.26; 615.4

**А.В. Киселев**, преподаватель, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: kiselevalexey@gmail.com)

**Т.В. Петрова**, соискатель, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: ptata@ya.ru)

**С.В. Дегтярев**, д-р техн. наук, профессор, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: sergeyd12@gmail.com)

**А.Ф. Рыбочкин**, д-р техн. наук, профессор, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: truten01@yandex.ru)

**С.А. Филист**, д-р техн. наук, профессор, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: sfilist@gmail.com)

**О.В. Шаталова**, канд. техн. наук, доцент, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: shatolg@mail.ru)

**В. Н. Мишустин**, д-р мед. наук, профессор, ФГБОУ ВО «Юго-Западный государственный университет» (Курск, Россия) (e-mail: vladimirshf2011@yandex.ru)

## **НЕЙРОСЕТЕВЫЕ МОДУЛИ С ВИРТУАЛЬНЫМИ ПОТОКАМИ ДЛЯ КЛАССИФИКАЦИИ И ПРОГНОЗИРОВАНИЯ ФУНКЦИОНАЛЬНОГО СОСТОЯНИЯ СЛОЖНЫХ СИСТЕМ**

*В статье рассмотрена проблема построения интеллектуальных систем поддержки принятия решений по классификации и прогнозированию функционального состояния сложных систем. Для прогнозирования состояния сложных систем предложены нейросетевые решающие модули с виртуальными потоками, которые отражают скрытые системные связи между наблюдаемыми и не наблюдаемыми признаками. При этом вектор информативных признаков на входе решающего модуля состоит из двух подвекторов, первый из которых соответствует реальным потокам, а второй – виртуальным потокам.*

*Проведено имитационное моделирование процессов классификации с использованием латентных переменных, которое позволило оценить влияние на качество классификации искусственно введенных виртуальных потоков.*

*Разработана структура нейросетевой модели с виртуальными потоками рекуррентного типа. Структура состоит из N последовательно включенных нейросетевых аппроксиматоров. Выходы предыдущих аппроксиматоров объединяются с вектором информативных признаков последующих аппроксиматоров, что позволяет формировать виртуальные потоки различной размерности.*

*Разработан метод формирования нелинейных моделей виртуальных потоков, отличающийся использованием метода МГУА-моделирования для получения моделей влияния реальных потоков на виртуальные потоки, получаемых посредством нелинейных адалинов. Метод позволяет формировать подвектор латентных переменных неограниченной размерности.*

*Нелинейные модели виртуальных потоков формируются посредством метода, основанного на использовании МГУА-моделирования. Метод позволяет получить нейросетевые структуры, построенные на основе МГУА-моделей и нелинейных адалинов, позволяющие формировать подвектор латентных переменных неограниченной размерности.*

**Ключевые слова:** функциональное состояние сложных систем; нейросетевой решающий модуль; латентная переменная; аппроксиматоры; МГУА-модель; виртуальные потоки.

**DOI:** 10.21869/2223-1560-2018-22-4-123-134

**Ссылка для цитирования:** Нейросетевые модули с виртуальными потоками для классификации прогнозирования функционального состояния сложных систем / А.В. Киселев, Т.В. Петрова, С.В. Дегтярев, А.Ф. Рыбочкин, С.А. Филист, О.В. Шаталова, В.Н. Мишустин // Известия Юго-Западного государственного университета. 2018. Т. 22, № 4(79). С. 123-134.

\*\*\*

### **Введение**

Использование инструментария нейросетевого анализа дает возможность с

здавать качественно новые интеллектуальные системы, позволяющие решать большой круг задач классификации и прогнозирования состояния сложных си-

стем [1, 2, 3]. Однако при решении задач посредством нейросетевых технологий возникают проблемы, обусловленные недостаточным качеством принимаемых решений лицом, принимающим решение (ЛПР), при использовании этих технологий в системах поддержки принятия решений (СППР). Это обусловлено тем, что как при анализе состояния живой системы, так и при прогнозировании ее перехода из одного состояния в другое, необходимо учитывать латентные переменные, которые не входят в исследуемый комплекс параметров системы, на основе которого строится пространство информативных признаков. Эти дополнительные информативные признаки несут информацию о скрытых связях между исходными признаками [4, 5, 6]. Вектор, соответствующий дополнительным латентным информативным признакам, назовем виртуальным потоком. Для определения этих дополнительных признаков необходима системная надстройка, имеющая самоорганизующуюся структуру.

**Материалы и методы.** Идея построения такой надстройки состоит в следующем. Если данные в системе носят поточный характер, сущность которого заключается в том, что каждый из  $N$  потоков формируется множеством информативных признаков, сгруппированных по некоторому принципу, а затем сжатых, вплоть до скаляра, по определенному формальному методу, то к имеющимся  $N$  потокам могут быть добавлены дополнительные потоки – виртуальные потоки, представленные своими агрегированными латентными переменными (латентными признаками).

Присутствующие на входе нейронной сети признаки не отражают полностью свойства исследуемого объекта или системы, которые входят в область интересов лица, принимающего решение (ЛПР). Следовательно, можем выдвинуть гипотезу, что есть хотя бы один сегмент информативных признаков  $(N+1)$ -й, который включает хотя бы один информативный признак, существенно влияющий на качество принимаемых решений.

Латентные информативные признаки связаны с наблюдаемыми признаками скрытыми системными связями, которые определяются аппроксимирующей функцией, построенной по данным, извлеченным из обучающей выборки (независимым наблюдаемым переменным) и зависимым переменным (латентным переменным), полученным посредством вероятностного программирования [4, 7]. Если такая аппроксимирующая функция будет построена, то по данным неизвестного образца может быть найден дополнительный признак как функция входных наблюдаемых переменных.

Полагаем, что неизвестный образец характеризуется вектором наблюдаемых информативных признаков  $X$  с компонентами  $x_1, x_2, \dots, x_m$ . Необходимо получить функциональную зависимость латентной переменной  $Y$  от наблюдаемого вектора  $X$ , то есть

$$Y = F(x_1, x_2, \dots, x_m), \quad (1)$$

полагая априорно, что присутствие на входе классифицирующей модели этого латентного информативного признака улучшит качество классификации.

Модель нейросетевой структуры с виртуальным потоком показана на рис. 1 [8, 9].

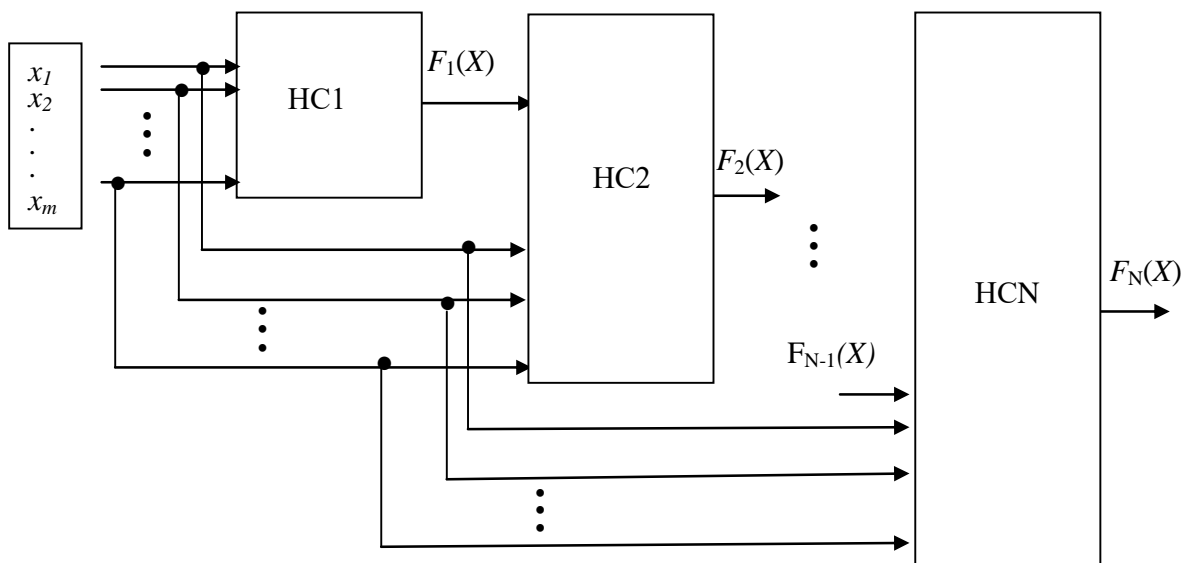


Рис. 1. Структура нейросетевой модели с виртуальными потоками

Отметим, что в обучающую выборку для аппроксиматоров – нейронных сетей входят не только экспериментальные данные, полученные на соответствующем интервале наблюдения сложной системы, но и данные, полученные в результате имитационного моделирования на предшествующей нейросетевой модели. Таким образом, каждый нейросетевой модуль (НС на рис. 1) в этой модели, кроме первого и последнего, является не только анализатором латентной переменной  $F_i(X)$ , но и источником виртуальных данных для настройки параметров (обучения) последующего нейросетевого модуля.

Для построения аппроксиматоров, которыми являются нейронные сети  $НС1...НС(N-1)$  на рис. 1, используем метод группового учета аргументов (МГУА) [10]. В качестве аппроксимирующей функции (1) при использовании этого метода очень часто используется полином Колмогорова-Габора [11]:

$$y = \alpha_0 + \sum_{i=1}^m \alpha_i x_i + \sum_{i=1}^m \sum_{j=1}^m \alpha_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m \alpha_{ijk} x_i x_j x_k + \dots, \quad (2)$$

так как с помощью такого полинома можно добиться достаточно точной аппроксимации любой дифференцируемой функции  $F$ .

Эта сложная зависимость заменяется множеством простых функций:

$$\begin{aligned} y_1 &= f(x_1, x_2); & y_2 &= f(x_1, x_3), \dots, \\ y_s &= f(x_{m-1}, x_m), \end{aligned} \quad (3)$$

где  $s = C_m^2$ , причем функция  $f$  повсюду одинакова.

В качестве функции  $f$  выбираются простые зависимости

$$y(x_i, x_j) = a_0 + a_1 x_i + a_2 x_j + a_3 x_i x_j \quad (4)$$

или

$$\begin{aligned} y(x_i, x_j) &= a_0 + a_1 x_i + a_2 x_j + \\ &+ a_3 x_i x_j + a_4 x^2 i + a_5 x^2 j, \end{aligned} \quad (5)$$

связывающие только две переменные. Коэффициент этих зависимостей определяются с помощью МНК, имея соответственно 4 (уравнение (4)) или 6 (уравнение (5)) точек наблюдений в обучающей последовательности.

Среди моделей первого ряда выбираются несколько, например,  $S^*$  наилучших, показавших хорошие результаты на

контрольной выборке. Среди отобранных моделей остаются те, которые не только хорошо аппроксимируют данные в узлах интерполяции, но и «угадывают» поведение функции (2) в области, не охваченной экспериментом.

Во втором ряду алгоритма МГУА полученные на обучающей выборке значения  $y_i$ , соответствующие отобранным моделям, рассматриваются в качестве аргументов нового ряда:

$$\begin{aligned} z_1 &= f(y_1, y_2); \\ z_2 &= f(y_1, y_3); \dots; \\ z_{S^*} &= f(y_{S^*-1}, y_{S^*}). \end{aligned} \quad (6)$$

Здесь функции  $f$  остаются прежними и соответствуют соотношениям (4) или (5), но аргументами этих функций выступают переменные  $y_i$ . Коэффициенты новых моделей (6) находятся по МНК на точках той же обучающей последовательности. Новые модели проверяются на точках проверочной последовательности, и среди них выбирается  $S^*$  наилучших, которые используются в качестве аргументов следующего третьего ряда и т.д. Сложность полиномов возрастает от ряда к ряду.

Входные аргументы и промежуточные переменные сопрягаются попарно, и сложность комбинаций на каждом этапе (ряде) обработки информации возрастает (как при массовой селекции), пока не будет получена единственная модель оптимальной сложности.

Каждое частное описание является функцией только двух аргументов. Поэтому его коэффициенты легко определить по данным обучающей последовательности при малом числе узлов интерполяции. Исключая промежуточные переменные (если это удастся), можно по-

лучить аналог полного описания. Например, по десяти узлам интерполяции можно получить в результате оценки коэффициентов полинома сотой степени и т.д.

Из ряда в ряд селекции пропускается только некоторое количество самых регулярных переменных. Степень регулярности оценивается по величине среднеквадратичной ошибки (средней для всех выбираемых в каждом поколении переменных или для одной самой точной переменной) на отдельной проверочной последовательности данных. Иногда в качестве показателя регулярности используется коэффициент корреляции.

Ряды селекции наращиваются до тех пор, пока регулярность повышается. Как только достигнут минимум ошибки, селекцию, во избежание «инцухта», следует остановить. Практически рекомендуется остановить селекцию даже несколько раньше достижения полного минимума, как только ошибка начинает падать слишком медленно. Это приводит к более простым и более достоверным уравнениям [11].

Среди множества МГУА - моделей выбираем  $L$  наилучших, которые могут быть представлены в виде множества

$$\{f_\ell(X_k) = \tilde{y}\}, \quad (7)$$

где  $X_k \subseteq X$ ,  $X = (x_1, x_2, \dots, x_m)$  – множество информативных признаков, используемых решающими модулями;  $\ell = \overline{1, L}$ .

На рис. 2 представлена обобщенная структурная схема классифицирующего модуля, предназначенного для работы с дополненным на основе МГУА-моделей пространством информативных признаков.

Рассмотрим метод формирования множества (7). Метод должен синтезировать множество аппроксимирующих связей между элементами входного вектора  $X$  и позволить выбрать из этого множе-

ства  $L$  функциональных связей, которые формируют  $L$  дополнительных признаков, включение которых во входной вектор приводит к повышению качества классификации решающего модуля.

В случае вырождения нелинейных моделей в линейные многомерные аппроксиматоры блок нелинейных моделей (рис. 2) включает множество пар (в случае двухальтернативной классификации) классифицирующих функций (аппрокси-

маторов), каждый из которых выдает число, соответствующее состоянию входного вектора. При необходимости, эти два числа ( $a$  и  $b$ ) могут быть агрегированы в одно посредством одного из следующей группы агрегаторов:

$$\begin{aligned} x_{N+i} &= \max(a, b); & x_{N+i} &= a - b; \\ x_{N+i} &= \min(a, b); & & \\ x_{N+i} &= \begin{cases} 0, & \text{при } a \leq b; \\ 1, & \text{при } a > b. \end{cases} \end{aligned} \quad (8)$$

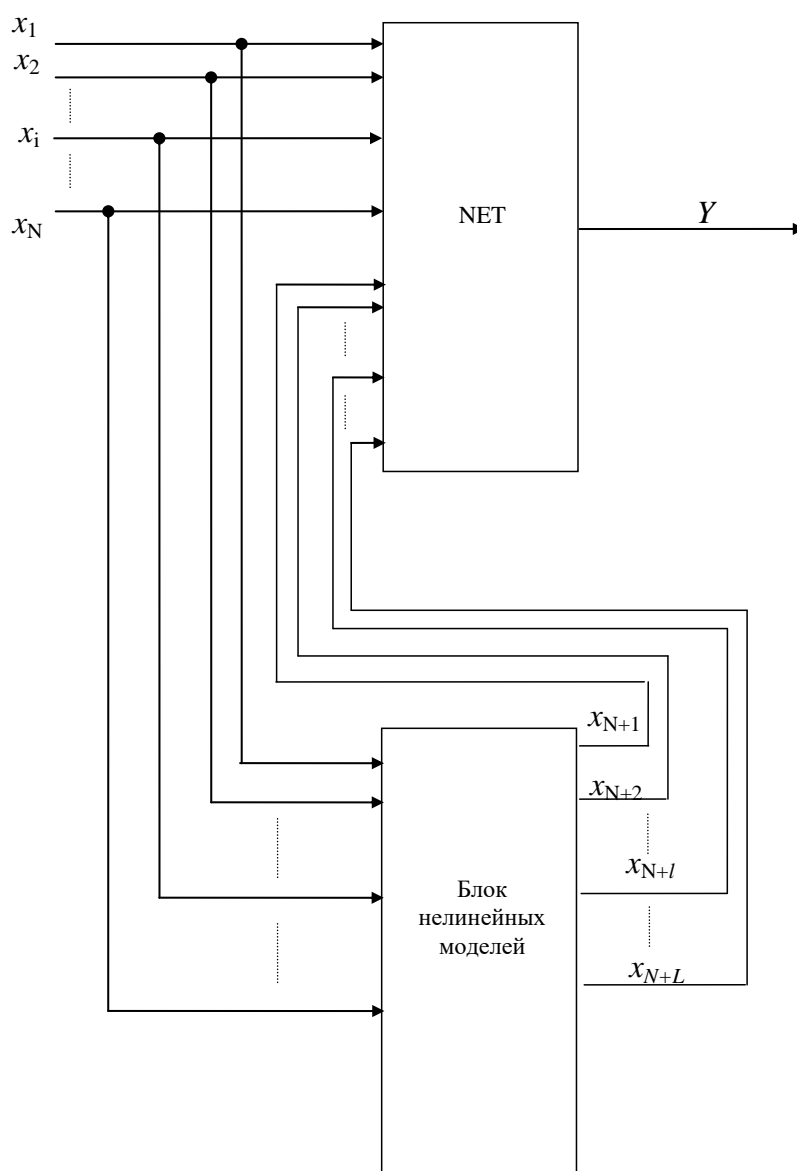


Рис. 2. Обобщенная структурная схема классифицирующего модуля, предназначенного для работы с виртуальными потоками, полученными на основе МГУА-моделей исходного пространства информативных признаков

При этом необходимо учитывать, что соответствующие выходы блоков, моделирующие корреляционные связи исходных информативных признаков, могут быть как двухкомпонентными векторами, так и скалярами, в зависимости от наличия в моделирующих модулях агрегирующих блоков вида (2).

Включение в множество моделей очередной,  $(\ell + 1)$ -й, модели, осуществляется по рекуррентной схеме, представленной на рис. 1. Эта схема позволяет оценить вклад в показатели качества принятия решений  $(\ell + 1)$ -го дополнительного информативного признака при наличии  $(\ell)$  дополнительных признаков.

В общем случае, для построения модели рис. 2 привлекаются алгоритмы эволюционного типа («жадные» алгоритмы) [11].

Блок нелинейных моделей виртуальных потоков составляет основу классифицирующего модуля (см. рис. 2). Блок нелинейных моделей состоит из двух слоев. Первый слой формирует множество моделей  $\hat{Y}$ . Для каждого виртуального потока посредством МГУА - моделирования получено свое подмножество моделей  $\{z_j\}_i \subseteq Z, \forall i = \overline{1, M}$ . Каждое подмножество моделей  $\{z_j\}_i, j = 1 \dots K_i$ , где  $K_i$  – число МГУ - моделей для  $i$ -го виртуального потока, полученных на основе МГУА-моделирования, которые предполагается использовать для описания взаимного влияния известных информативных признаков (реальных потоков) в системе простых комбинаций реальных и виртуальных потоков. Множество статических моделей  $\hat{Y}$  получается не посредством усложнения МГУА-моделей, а посредством МГУА-нейрон-

ной сети [10]. Отличие предлагаемой МГУА-нейронной сети от рассмотренной в [10] состоит в том, что каждый блок модели виртуального потока (второй слой модели) является МГУА-нейронной сетью, на входы которой поступают полученные путем МГУА-моделирования модели, включающие множество  $X$  реальных и виртуальных потоков. Структурная схема  $i$  - го блока модели виртуального потока представлена на рис. 3.

В качестве примера в ней использованы четыре МГУА - модели виртуального потока  $x_i : z_1, z_2, z_3, z_4$  с нелинейными адалинами (N-A).

МГУА-сеть имеет переменную структуру, которая настраивается в процессе обучения. Каждый нейрон сети – N-A представляет собой адаптивный линейный ассоциатор с двумя входами  $z_g$  и  $z_h$  и нелинейным процессором, образованным тремя блоками умножения, и вычисляет квадратичную комбинацию входов вида

$$\hat{y}_{gh} = f_{gh}(z_g, z_h) = w_{gh_0} + w_{gh_1} z_g + w_{gh_2} z_g^2 + w_{gh_3} z_g z_h + w_{gh_4} z_h^2 + w_{gh_5} z_h = w_{gh}^T z_{gh}, \quad (9)$$

где  $w_{gh} = (w_{gh_0}, w_{gh_1}, w_{gh_2}, w_{gh_3}, w_{gh_4}, w_{gh_5})^T$ ,  $z_{gh} = (1, z_g, z_g^2, z_g z_h, z_h^2, z_h)^T$ .

Процесс обучения МГУА-модели виртуального потока состоит в конфигурации нейронных сетей (рис. 3), начиная с первого скрытого слоя, независимой настройке синаптических весов каждой нелинейной адалины и наращивании количества слоев для достижения необходимой точности прогнозирования.

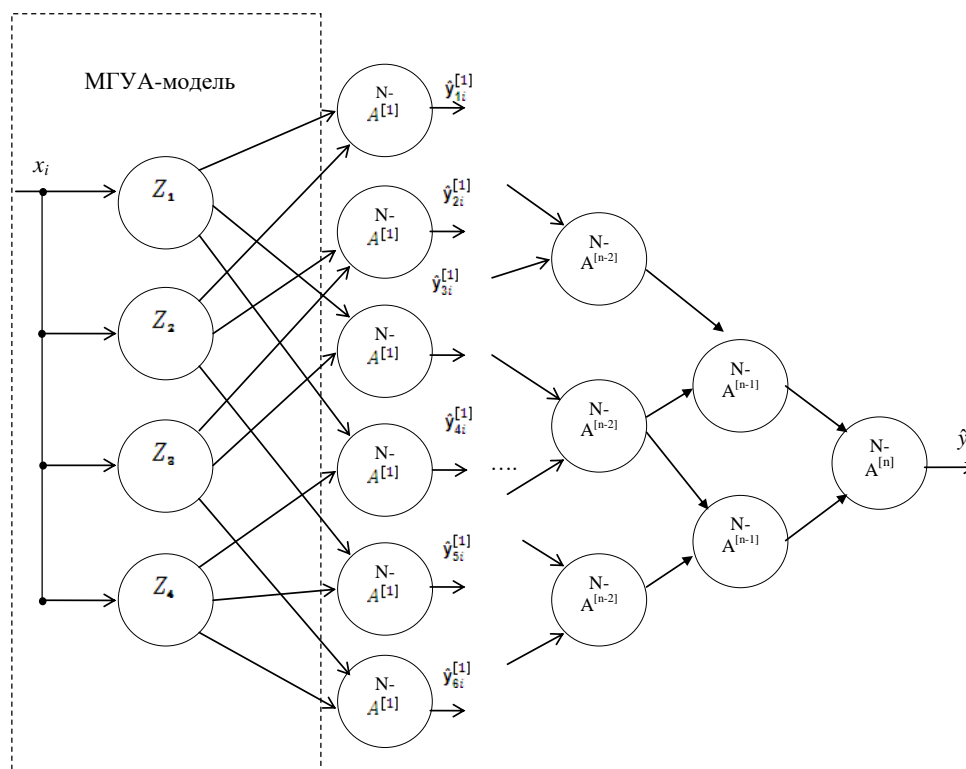


Рис. 3. Структурная схема  $i$ -й нелинейной модели на основе МГУА-моделирования

Количество нейронов первого скрытого слоя сети определяется количеством  $K$  МГУА – моделей соответствующего эндогенного фактора и не превышает значение  $K(K-1)/2$  – количества сочетаний из  $K$  по 2.

После обучения нейронной сети посредством любого из известных алгоритмов обучение [12, 13, 14] оценивается точность моделирования, например, с помощью дисперсии ошибки предсказания для каждого нейрона и формируется группа нейронов, дающих ошибку ниже некоторого априорно заданного порога. Выходы этой группы  $\hat{y}_i^{[1]}$  являются входами нейросетевой структуры (см. рис.3) [10, 15].

Для оценки степени управляемости показателями качества классификации нейронной сети посредством виртуального входа использовалось имитационное моделирование в среде MATLAB [7].

Графики зависимости показателя качества классификации  $S$  от величины дисперсии виртуального входа, представлены на рис. 4. Управляемость величиной  $S$  посредством изменения дисперсии виртуального потока исследовалась при различных размерностях пространства информативных признаков 3, 5 и 7.

Представленные на рис. 4 зависимости показывают, что для широкого значения размерностей пространства информативных признаков может быть подобрана дисперсия виртуального потока, которая позволяет управлять показателем качества классификации нейронной сети в широком диапазоне. При этом управляемость показателя качества классификации снижается с ростом пространства информативных признаков, откуда следует, что при увеличении размерности пространства информативных признаков необходимо увеличивать число виртуальных потоков.




Рис. 4. Влияние дисперсии виртуального входа на качество классификации нейронной сети прямого распространения при размерности пространства информативных признаков три, пять и семь

## Выводы

1. Для прогнозирования состояния сложных систем предложены нейронные сети с виртуальными потоками, которые отражают скрытые системные связи между наблюдаемыми и не наблюдаемыми независимыми параметрами системы. При этом вектор информативных признаков состоит из двух подвекторов, первый из которых соответствует реальным потокам, а второй – виртуальным потокам.

2. Имитационное моделирование процессов классификации с использованием латентных переменных позволили оценить влияние на качество классификации искусственно введенных виртуальных потоков.

3. Разработана структура нейросетевой модели с виртуальными потоками рекуррентного типа, состоящая из  $N$  последовательно включенных нейросетевых аппроксиматоров, отличающаяся тем, что выходы предыдущих аппроксиматоров объединяются с вектором информативных признаков последующих аппрокси-

маторов, позволяющая формировать виртуальные потоки различной размерности.

4. Разработан метод формирования нелинейных моделей виртуальных потоков, отличающийся использованием метода МГУА-моделирования для получения моделей влияния реальных потоков на виртуальные потоки, получаемых посредством нелинейных адалинов, позволяющий формировать подвектор латентных переменных неограниченной размерности.

## Список литературы

1. Филист С.А., Волков И.И., Емельянов С.Г. Метод классификации сложных объектов на основе анализа структурных функций медленных волн // Биомедицинская радиоэлектроника. 2012. №4. С.6-11.
2. Филист С.А., Томакова Р.А., Яа Зар До. Универсальные сетевые модели для задач классификации биомедицинских данных // Известия Юго-Западного государственного университета. 2012. № 4 (43). Ч. 2. С. 44-50.
3. Использование гибридных нейросетевых моделей для многоагентных систем



классификации в гетерогенном пространстве информативных признаков / С.А. Филист, А.Г. Курочкин, В.В. Жилин [и др.] // Прикаспийский журнал: управление и высокие технологии. Научно-технический журнал. 2015. № 3 (31). С.85-95.

4. Синтез дополнительного информативного признака для нейронной сети прямого распространения / А.О. Позин, С.А. Филист, А.Н. Шуткин [и др.] // Новые решения в области упрочняющих технологий: взгляд молодых специалистов: сборник научных статей по материалам Международной научно-практической конференции. Курск, 2016. С. 212-217.

5. Позин А.О., Филист С.А., Шуткин А.Н. Тестирующие гибридные системы с дополнительным пространством информативных признаков // Современные информационные технологии в управлении качеством: сборник статей V Международной научно-прикладной конференции. Пенза: Приволжский Дом знаний, 2016. С.46-50.

6. Теория проектирования нечетких сетевых экспертных систем для управления медико-экологической безопасностью / Н.А. Корневский, С.А. Филист, А.Б. Красковский [и др.] // Научные ведомости Белгородского государственного университета. Серия: История. Политология. Экономика. Информатика. 2009. № 9-1 (64). Т. 11. С.146-151.

7. Леоненков А.В. Нечеткое моделирование в среде Matlab и fuzzyTECH. СПб.: БХВ – Петербург, 2005. 736 с.

8. Шуткин А.Н., Позин А.О., Филист С.А. Адаптируемые к структуре данных классификаторы в задачах прогнозирования профессиональных заболеваний // Искусственный интеллект в решении ак-

туальных социальных и экономических проблем XXI века: сб. ст. по материалам Второй Всерос. науч.-практ. конф. Пермь, 2017. С.161-164.

9. Старцев Е.А., Шаталова О.В., Уварова В.В. Двумерные нейросетевые структуры мета-анализа медико-экологических данных // Искусственный интеллект в решении актуальных социальных и экономических проблем XXI века: сб. ст. по материалам Всерос. науч.-практ. конф. Пермь, 2016. С.161-164.

10. Позин А.О., Старцев Е.А., Уварова В.В. МГУА-нейронные сети для прогнозирования состояния сложных систем с временными лагами // Нейроинформатика, ее приложения и анализ данных: материалы XXIV Всероссийского семинара. Красноярск: Институт вычислительного моделирования СО РАН, 2016. С. 50-55.

11. Артеменко М.В., Калугина Н.М., Шуткин А.Н. Формирование множества информативных показателей на основании аппроксимирующего полинома Колмогорова-Габора и максимального градиента функциональных различий // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2016. №1(18). С.116-123.

12. Хайкин С. Нейронные сети: полный курс: [пер. с англ.]. 2-е изд., испр. М.: ООО «И.Д. Вильямс», 2006. 1104 с.

13. Мохаммед А.А., Филист С.А., Шаталова О.В. Моделирование импеданса биоматериалов в среде MATLAB // Известия Юго-Западного государственного университета. Серия: Управление, вычислительная техника, информатика. Медицинское приборостроение. 2013. № 4. С. 73-78.

14. Томакова Р.А., Шаталова О.В., Томаков М.В. Теоретико-множественный подход и теория графов в обработке сложноструктурируемых изображений : монография. Курск, 2012. 119 с.

15. Способ моделирования нечетких моделей в пакете MATLAB для биомеди-

цинских приложений / В.В. Жилин, С.А. Филист, Халед Абдул Рахим, О.В. Шаталова // Медицинская техника. 2008. №2. С. 15-17.

*Поступила в редакцию 29.06.18*

UDC 004.032.26; 615.4

**A.V. Kiselev**, Lecturer, Southwest State University (Kursk, Russia)  
(e-mail: kiselevalexey@gmail.com)

**T.V. Petrova**, Competitor, Southwest State University (Kursk, Russia) (e-mail: ptata@ya.ru)

**S.V. Degtyaryov**, Doctor of Engineering Sciences, Professor, Southwest State University (Kursk, Russia) (e-mail: sergeyd12@gmail.com)

**A.F. Rybochkin**, Doctor of Engineering Sciences, Professor, Southwest State University (Kursk, Russia) (e-mail: truten01@yandex.ru)

**S.A. Filist**, Doctor of Engineering Sciences, Professor, Southwest State University (Kursk, Russia) (e-mail: sfilist@gmail.com)

**O.V. Shatalova**, Candidate of Engineering Sciences, Associate Professor, Southwest State University (Kursk, Russia) (e-mail: shatolg@mail.ru)

**V. N. Mishustin**, Doctor of Medical Sciences, Professor, Southwest State University (Kursk, Russia) (e-mail: vladimirshf2011@yandex.ru)

#### **HYBRID DECIDING MODULES WITH VIRTUAL STREAMS FOR CLASSIFICATION AND PREDICTION OF FUNCTIONAL STATE OF COMPLEX SYSTEMS**

*The problem reviewed of building intelligent decision support systems for classification and prediction of the functional state of complex systems in the article. To predict the state of complex systems, hybrid decision modules with virtual flows are proposed, which reflect the hidden system connections between real and virtual data. The vector of informative features at the input of the hybrid decision module consists of two subsectors, the first of which corresponds to real flows, and the second – to virtual flows.*

*Simulation modeling of classification processes using latent variables was performed, which allowed to evaluate the effect on the quality of classification of artificially introduced virtual flows.*

*The structure of a neural network model with virtual recurrent-type streams is developed. The structure consists of N consecutively included neural network approximants. The outputs of the previous approximants are combined with the vector of in-formative attributes of the subsequent approximants, which allows forming virtual flows of different dimensions.*

*A method is developed for the formation of non-linear models of virtual flows, characterized by the use of the GMDH-simulation method to obtain models of the influence of real flows on virtual flows, learned through nonlinear adalines. The method makes it possible to form a subvector of latent variables of unlimited dimension.*

*Non-linear models of virtual flows are formed through a method based on the use of GMDH modeling. The method makes it possible to obtain neural network structures built on the basis of GMDH models and nonlinear adalines, which make it possible to form a subvector of latent variables of unlimited dimensionality.*

**Key words:** functional state of complex systems; neural network decision module; latent variable; approximants; GMDH model; virtual flows.

**DOI:** 10.21869/2223-1560-2018-22-4-123-134

**For citation:** Kiselev A.V., Petrova T.V., Degtyaryov S.V., Rybochkin A.F., Filist S.A., Shatalova O.V., Mishustin V. N. Hybrid Deciding Modules with Virtual Streams for Classification and Prediction of Functional State of Complex Systems. Proceedings of the Southwest State University, 2018, vol. 22, no. 4(79), pp. 123-134 (in Russ.).

\*\*\*

## Reference

1. Filist S.A., Volkov I.I., Emel'yanov S.G. Metod klassifikatsii slozhnykh ob"ektov na osnove analiza strukturnykh funktsiy medlennykh voln [Method of classification of complex objects based on the analysis of structural functions of slow waves]. *Biomeditsinskaya radioelektronika* [Biomedical radioelectronics], 2012, no.4, pp.6-11.

2. Filist S.A., Tomakova R.A., Yaa Zar Do. Universal'nye setevye modeli dlya zadach klassifikatsii biomeditsinskiykh dannykh [Generic network model for classification of biomedical data]. *Izvestiya Jugo-Zapadnogo gosudarstvennogo universiteta* [Proceedings of Southwest State University], 2012, no. 4 (43), part. 2, pp. 44-50.

3. Filist S.A., Kurochkin A.G., Zhilin V.V. i dr. Ispol'zovanie gibridnykh neyrosetevykh modeley dlya mnogoagentnykh sistem klassifikatsii v geterogennom prostranstve informativnykh priznakov [Use of hybrid neural network models for multi-agent classification systems in heterogeneous space of informative features]. *Pri-kaspiyskiy zhurnal: upravlenie i vysokie tekhnologii. Nauchno-tekhnicheskii zhurnal* [Caspian journal: management and high technologies. Scientific and technical journal], 2015, no. 3 (31), pp.85-95.

4. Pozin A.O., Filist S.A., Shutkin A.N. i dr. Sintez dopolnitel'nogo informativnogo priznaka dlya neyronnoy seti pryamogo rasprostraneniya [Synthesis of additional informative feature for direct propagation neural network]. *Novye resheniya v oblasti uprochnyayushchih tekhnologiy: vzglyad molodykh spetsialistov. Sbornik nauchnykh statey po materialam Mezhdunarodnoy nauchno-prakticheskoy konferentsii* [New solutions in the field of strengthening technologies: the

view of young professionals: collection of scientific articles on the materials of the International scientific-practical conference]. Kursk, 2016, pp. 212-217.

5. Pozin A.O., Filist S.A., Shutkin A.N. Testiruyushchie gibridnye sistemy s dopolnitel'nym prostranstvom informativnykh priznakov [Testing hybrid systems with additional space of informative features]. *Sovremennye informatsionnye tekhnologii v upravlenii kachestvom. Sbornik statey V Mezhdunarodnoy nauchno-prikladnoy konferentsii* [Modern information technologies in quality management: collection of articles of the V International scientific and applied conference]. Penza, 2016, pp.46-50.

6. Korenevskiy N.A., Filist S.A., Kraskovskiy A.B. i dr. Teoriya proektirovaniya nechetkiykh setevykh ekspertnykh sistem dlya upravleniya mediko-ekologicheskoy bezopasnost'yu [The theory of network designing of fuzzy expert systems to manage health and environmental safety]. *Nauchnye vedomosti Belgorodskogo gosudarstvennogo universiteta. Seriya: Istoriya. Politologiya. Ekonomika. Informatika* [Belgorod State University Scientific Bulletin. History Political science Economics Information technologies], 2009, no. 9-1 (64), vol. 11, pp.146-151.

7. Leonenkov A.V. Nechetkoe modelirovanie v srede Matlab i fuzzyTECH [Fuzzy modeling in Matlab and fuzzyTECH]. St. Petersburg, 2005, 736 p.

8. Shutkin A.N., Pozin A.O., Filist S.A. Adaptiruemye k strukture dannykh klassifikatory v zadachah prognozirovaniya professional'nykh zabolevaniy [Adapted to structure given qualifiers in problem of the forecasting of the professional diseases]. *Iskusstvennyy intellekt v reshenii aktual'nykh sotsial'nykh i ekonomicheskikh problem XXI*

veka. Sb. st. po materialam Vtoroy Vseros. nauch.-prakt. konf. [Artificial intelligence in the solution of urgent social and economic problems of the XXI century. Collection of articles on materials of all-Russian scientific.-practice. conf.] Perm', 2017, pp.161-164.

9. Startsev E.A., Shatalova O.V., Uvarova V.V. Dvumernye neyrosetevye struktury meta-analiza mediko-ekologicheskikh dannyh [Two-dimensional neural networks structures meta-analysis physician-ecological data]. *Iskusstvennyy intellekt v reshenii aktual'nyh sotsial'nyh i ekonomicheskikh problem XXI veka. Sb. st. po materialam Vseros. nauch.-prakt. konf. [Artificial intelligence in the solution of urgent social and economic problems of the XXI century: collection of articles on materials of all-Russian scientific.-practice. conf.] Perm', 2016, pp.161-164.*

10. Pozin A.O., Startsev E.A., Uvarova V.V. MGUA-neyronnye seti dlya prognozirovaniya sostoyaniya slozhnyh sistem s vremennymi lagami [MGAA-neural networks for predicting the state of complex systems with time lags]. *Neyroinformatika, ee prilozheniya i analiz dannyh. Materialy XXIV Vserossiyskogo seminaru [Neuroinformatics and its applications. Proceedings XXIV National Workshop]. Krasnoyarsk, 2016, pp. 50-55.*

11. Artemenko M.V., Kalugina N.M., Shutkin A.N. Formirovanie mnozhestva informativnyh pokazateley na osnovanii approksimiruyushchego polinoma Kolmogorova-Gabora i maksimal'nogo gradienta funktsional'nyh razlichiy [Formation of a set of informative indicators on the basis of the approximating Kolmogorov-Gabor polyno-

mial and the maximum gradient of functional differences]. *Izvestiya Jugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, Vychislitel'naya Tekhnika, Informatika. Meditsinskoe priborostroenie [Proceedings of Southwest State University. Series: Control, computer engineering, computer science. Medical devices], 2016, no. 1(18), pp.116-123.*

12. Haykin S. Neyronnye seti: polnyy kurs. [Neural networks: full course: Translation from English] 2-e izd., ispr. Moscow, 2006, 1104 p.

13. Mokhammed A.A., Filist S.A., Shatalova O.V. Modelirovanie impedansa biomaterialov v srede MATLAB [Modeling of impedance of biomaterials in MATLAB]. *Izvestiya Jugo-Zapadnogo gosudarstvennogo universiteta. Seriya: Upravlenie, Vychislitel'naya Tekhnika, Informatika. Meditsinskoe priborostroenie [Proceedings of Southwest State University. Series: Control, computer engineering, computer science. Medical devices], 2013, no. 4, pp. 73-78.*

14. Tomakova R.A., Shatalova O.V., Tomakov M.V. Teoretiko-mnozhestvennyy podkhod i teoriya grafov v obrabotke slozhnostrukturiruemyykh izobrazhenii. [A set-theoretic approach and graph theory in the treatment of difficult structured images: monography]. Kursk, 2012, 119 p.

15. Zhilin V.V., Filist S.A., Khaled Abdul Rahim, Shatalova O.V. Sposob modelirovaniya nechetkikh modeley v pakete MATLAB dlya biomeditsinskih prilozheniy [Method of modeling fuzzy models in MATLAB for biomedical applications]. *Meditsinskaya tekhnika [Medical technics], 2008, no. 2, pp. 15-17.*