

16. Блаттер К. Вейвлет-анализ. Основы теории. Москва, 2004. 280 с.
17. Frazier, Michael W. An Introduction to Wavelets through Linear Algebra. Springer, 1999. 503 p.
18. Новиков И.Я., Протасов В.Ю., Скопина М.А. Теория всплесков. Москва: Физматлит, 2005. 612 с.

Битюков Юрий Иванович, д-р техн. наук, профессор, yib72@mail.ru, Россия, Москва, Московский авиационный институт (национальный исследовательский университет),

Денискин Юрий Иванович, д-р техн. наук, профессор, yurideniskin@gmail.com, Россия, Москва, Московский авиационный институт (национальный исследовательский университет),

Битюков Павел Юрьевич, студент, p.bityukoff@yandex.ru, Россия, Москва, Московский энергетический институт (национальный исследовательский университет)

ON SOME COMPUTATIONAL ALGORITHMS AND ERROR ESTIMATES FOR WAVELET EXPANSION

Y.I. Bityukov, Y.I. Deniskin, P.Y. Bityukov

Based on the theory of stationary subdivision schemes, error estimates are obtained for wavelet expansions of functions specified on an interval, and some computational algorithms using convolutional transformations of sequences and operations with sparse matrices to find approximate values of the function and its derivatives using known wavelet coefficients.

Key words: CAD, subdivision schemes, wavelet, geometric modeling, image processing.

Bityukov Yuri Ivanovich, doctor of technical sciences, professor, yib72@mail.ru, Russia, Moscow, Moscow Aviation Institute (National Research University),

Deniskin Yuri Ivanovich, doctor of technical sciences, professor, yurideniskin@gmail.com, Russia, Moscow, Moscow Aviation Institute (National Research University),

Bityukov Pavel Yur'evich, student, p.bityukoff@yandex.ru, Russia, Moscow, National Research University «Moscow Power Engineering Institute»

УДК 004.052.42; 681.5.03
DOI: 10.24412/2071-6168-2024-3-48-49

НЕЙРОСЕТЕВОЙ МЕТОД ОБНАРУЖЕНИЯ СМЕНЫ РЕЖИМА РАБОТЫ НЕЛИНЕЙНОГО ДИНАМИЧЕСКОГО ОБЪЕКТА

С. Ван, В.Л. Елисеев

Исследуется задача обнаружения изменения характера поведения динамического объекта, обладающего нелинейными свойствами. Предлагается метод, основанный на выявлении новизны взаимной корреляционной функции вход-выход с помощью нейросетевого автокодировщика. Проводятся эксперименты с различными входными сигналами, демонстрирующие возможность диагностировать смену режима работы динамической системы.

Ключевые слова: функциональное диагностирование, взаимная корреляционная функция, динамический объект, динамический режим работы, нейросетевой автокодировщик, обнаружение новизны, разладка.

Функциональное диагностирование [1] является одной из наиболее важных задач в системах управления динамическими объектами для обеспечения качества целевых характеристик системы и безопасности её функционирования. Целью функционального диагностирования традиционно считается выявление фактов неправильного функционирования и их идентификация обнаруженных дефектов. В современных интеллектуальных системах, обладающих нелинейными характеристиками как в части объекта, так и в части алгоритма управления, приобретает актуальность задача идентификации режима работы системы [2]. Смена режима работы системы может рассматриваться как значимое событие для изменения алгоритма управления.

В стохастической постановке задача обнаружения момента изменения характеристик случайного процесса называется обнаружением разладки [3]. Часто задачу функционального диагностирования можно рассматривать именно в стохастической постановке, поскольку сигналы, наблюдаемые в системе, далеко не всегда можно считать детерминированными. Далее для краткости будем обозначать смену режима динамической системы термином разладка даже в том случае, если будем рассматривать детерминированные сигналы.

Разладка может возникать в следствие возникновения дефекта в датчике, исполнительном механизме или объекте управления независимо или одновременно. Для простой неисправности может быть достаточно обычной схемы пороговой сигнализации. Однако в сложных промышленных системах обычно трудно напрямую измерить состояния процесса, которые являются хорошими индикаторами неисправностей. Наблюдая одновременно за несколькими измеряемыми характеристиками процесса, квалифицированным операторам часто приходится принимать оперативные решения, основываясь только на своем опыте.

Другой причиной разладки может являться изменение внешних воздействий на систему. Это может быть изменение как внешних условий, приводящих к изменению динамических характеристик компонентов системы, так и сигналов уставки, отличающихся от ожидаемых.

Обзор литературы. Одним из распространённых подходов к обнаружению разладки является использование модельных методов [4-5]. Это требует моделирования процесса, фильтрации измеренных данных и оценки неизвестных переменных состояния. Основная идея состоит в том, чтобы сравнить выходные данные модели с измерениями процесса, тем самым генерируя невязку или ошибку, которая используется для принятия решения о рабочем состоянии системы.

Эффективные подходы, не требующие построения математических моделей процессов, вызвали значительный исследовательский интерес за последние десять лет. В частности, были хорошо изучены подходы, основанные на машинном обучении и связанные с идеей обнаружения аномалий с применением глубокого обучения на основе полносвязных [6], сверточных [7], рекуррентных [8] и генеративно-состязательных нейронных сетей [9]. Методы на основе нейронных сетей привлекли большое внимание из-за их быстрой и надежной реализации, их эффективности для произвольных нелинейных отображений и их способности распознавать образы и ассоциации.

В процессе управления сложными динамическими объектами с нелинейными свойствами могут быть моменты разладки, когда происходит скачкообразное изменение характеристик процесса [10-12]. Разладка означает изменение режима работы системы управления, что обычно снижает производительность всей системы. Своевременное обнаружение разладки позволяет использовать методы адаптивного управления для корректировки управляющих сигналов, тем самым позволяя сохранять устойчивость и качество управления системой [13].

Тем не менее, на практике математическая модель обычно не может точно описать поведение реальной системы из-за ошибок моделирования и неопределенности параметров модели. Более того, промышленно используемые системы обычно подвергаются воздействию шума и неизвестных помех. Точного моделирования объектов в сложных нелинейных системах для выявления разладки на практике добиться сложно. Качество построения модели будет влиять на качество обнаружения разладки. Поэтому представляют интерес такие методы обнаружения разладки, которые не требуют построения точной модели.

В работе [14] был предложен подход, позволяющий использовать корреляцию между входом и выходом динамического объекта для обнаружения нового режима работы нестационарного линейного объекта. Однако вопрос о применимости этого подхода для нелинейного объекта и возможность обнаружения смены режима, вызванного изменением входного сигнала, остаётся открытым. Основной идеей этой работы является использование взаимной корреляционной функции между входом и выходом как характеристики динамики нелинейного объекта, совместное с нейросетевым автокодировщиком, который помогает обнаружить момент смены режима на новый и непривычный по сравнению с эталонным периодом работы системы.

Методология. В работе исследуется возможность применения взаимной корреляционной функции (ВКФ) и нейросетевого автокодировщика для обнаружения разладки в нелинейной динамической системе.

Для двух случайных сигналов ВКФ определяет линейную оценку причинно-следственной связи между ними. Если сигналы независимы друг от друга, их корреляционная функция равна нулю. Чем шире корреляционная функция, тем более длительная во времени степень связи двух сигналов друг с другом.

Можно рассматривать вход и выход динамического объекта как сигналы, которые можно коррелировать. Для линейных динамических объектов ВКФ с белым шумом на входе однозначно соответствует передаточной функции объекта. Для нелинейных объектов и произвольных сигналов на их входе можно сказать только то, что ВКФ характеризует динамику взаимосвязи вход-выход объекта. Будем рассматривать множество ВКФ, как характеристику динамических свойств нелинейного объекта.

Для непрерывного времени ВКФ $r_{xy}(\tau)$ двух сигналов $x(t)$ и $y(t)$ вычисляется по формуле

$$r_{xy}(\tau) = \int_{-\infty}^{\infty} x(t)y(t+\tau)dt. \quad (1)$$

В дискретном времени для временных рядов $x(k)$ и $y(k)$ ВКФ в окне шириной d отсчётов начиная с отсчёта временного ряда k вычисляется по формуле:

$$r_{xy}(n) = \frac{1}{d} \sum_{i=k}^{k+d-1} x(i)y(i+n). \quad (2)$$

Индекс k указывает на место во временном ряде, в котором рассчитана данная ВКФ, а аргумент n описывает смещение одного ряда относительно другого, для которого рассчитывается одно значение дискретной ВКФ. Таким образом, ВКФ в позиции k можно рассматривать, как вектор $R_{xy}^k = (r_{xy}(0), r_{xy}(1), \dots, r_{xy}(d-1))^T$. Такой вектор является точкой в пространстве размерности d . ВКФ можно рассчитывать и для отрицательных сдвигов $n < 0$, что расширяет размерность вектора R_{xy}^k .

Нестационарный нелинейный процесс будет иметь столько точек ВКФ, сколько было окон, в которых рассчитывались ВКФ. Эти точки образуют множество R_{xy}^N , которое представляет характеристику динамического поведения наблюдаемого процесса и описывается некоторой областью в векторном пространстве ВКФ. Пример области для пространства размерностью $d = 3$ представлен на рис.1.




Рис. 1. Векторное пространство ВКФ

При изменении процесса ВКФ также будет меняться. Предположим что динамическое поведение процесса в момент времени p представлено точкой R_{xy}^p в области нормальных вариантов ВКФ R_{xy}^N . Тогда при изменении динамических свойств процесса ВКФ в другой момент времени $q > p$ будет представлена точкой R_{xy}^q в векторном пространстве ВКФ.

Выявленный в векторном пространстве ВКФ дрейф

$$R_{xy}^p \rightarrow R_{xy}^q$$

за пределы области R_{xy}^N эталонного динамического поведения процесса означает обнаружение его разладки в момент времени q .

Для того, чтобы применить изложенный подход, необходим способ для запоминания ВКФ эталонного динамического поведения процесса, а также способ найти отличие ВКФ от нормы. Для этого воспользуемся нейросетевым автокодировщиком, который может запоминать векторы чисел обучающего множества и потом воспроизводить запомненные. В качестве вектора, подаваемого на вход автокодировщика, возьмем рассчитанную ВКФ R_{xy}^k . Обучение автокодировщика будем производить на ВКФ наблюдаемого процесса в нормальных условиях.

Нейросетевой автокодировщик копирует входные данные на выход. По архитектуре он похож на многослойный персептрон. Автокодировщик сжимает входные данные для представления их в скрытом пространстве, а затем восстанавливает из этого представления выходные данные. Ошибка восстановления входного вектора на выходе зависит от того, похож ли входной вектор на те, которые были в обучающих данных.




Рис. 2. Архитектура автокодировщика

Автокодировщик состоит из двух частей (рис.2): энкодера (кодировщика) и декодера (декодировщика). Энкодер отвечает за сжатие входа в скрытое пространство и представлен функцией кодирования $z = f(W_{enc}x + b_{enc})$. Декодер предназначен для восстановления входа из скрытого пространства и представлен функцией декодирования $\tilde{x} = f(W_{dec}z + b_{dec})$. Таким образом,

$$\tilde{x} = AE(x) \equiv f(W_{dec} f(W_{enc}x + b_{enc}) + b_{dec})$$

Метод обнаружения разладки. Суммируем приведенные выше идеи в форме алгоритма:

1) Проведём моделирование целевого процесса или получим набор данных «вход-выход» при наблюдении за натурной системой управления. Это будут временные ряды входа $u(t)$ и выхода $y(t)$, где $1 \leq t \leq L$ – индекс отчёта времени, а L – длина времени моделирования или наблюдения.

2) Рассчитаем ВКФ по временным рядам входа $u(t)$ и выхода $y(t)$ с шагом d отсчётов и получим набор векторов ВКФ R_{uy}^k , описывающий эталонное (нормальное) поведение динамической системы. Далее для обозначения номера окна, в котором рассчитывалась ВКФ, будем использовать индекс k , значения которого находятся в интервале: $1 \leq k \leq \left\lfloor \frac{L}{d} \right\rfloor$.

3) Обучение автокодировщика. Динамические характеристики нелинейного процесса, представленные ВКФ при нормальных условиях, используются в качестве набора обучающих данных автокодировщика $x(k) = R_{uy}^k$. Обучение осуществляется для минимизации ошибки реконструкции $r(k) = \|\tilde{x}(k) - x(k)\|$, где $\tilde{x}(k) = AE(x(k))$ и $\|z\| = \sqrt{\sum_{i=0}^{d-1} z^2(i)}$ – евклидова длина вектора.

4) Вычисление порога. Максимальная ошибка реконструкции $r_{th} = \max_k r(k)$, полученная при обучении, является порогом срабатывания для обнаружения ВКФ, непохожих на нормальные. Возможны и другие способы вычисления порога срабатывания, описанные, например, в работах [15-16].

5) Применение автокодировщика. Динамические характеристики нелинейного процесса, наблюдаемого после обучения автокодировщика на наборе данных нормального поведения, каждые d отсчётов рассчитываются в форме ВКФ $x(m) = R_{uy}^m$, где m – порядковый номер окна расчёта ВКФ. Далее ВКФ $x(m)$ проверяются с помощью автокодировщика $\tilde{x}(m) = AE(x(m))$ путем расчёта ошибки реконструкции $r(m) = \|\tilde{x}(m) - x(m)\|$. Если оказалось, что $r(m) > r_{th}$, это значит ВКФ не похожа на нормальную и на интервале $md \leq t < (m+1)d$ имеет место разладка. В противном случае разладки нет.

Эксперименты. Для апробации предложенного алгоритма проведем ряд экспериментов, взяв в качестве примера нелинейный динамический объект, описываемый моделью ввод-вывод [17].

$$y_t = \frac{y_{t-1}y_{t-2}y_{t-3}u_{t-2}(y_{t-3} - 1) + u_{t-1}}{1 + y_{t-3}^2 + y_{t-2}^2} \quad (3)$$

При проведении экспериментов будем использовать три вида входных сигналов, достаточно типичных в системах управления: гармонический сигнал (синусоида), меандр и случайный.

Синусоида является плавно меняющимся непрерывным сигналом и характеризуется периодичностью, симметрией, интервальной монотонностью. Меандр – это вид периодического сигнала, который широко используется в цифровых схемах. Его особенностью является то, что значение сигнала на некотором интервале времени остаётся постоянным, а потом резко меняется на другое значение, также остающееся постоянным на следующем интервале. Свойством случайного сигнала является непредсказуемость изменения его значения в следующий момент времени при некоторых заданных ограничениях (среднее значение, дисперсия и др.).

Кроме собственно проверки эффективности предложенного алгоритма, исследуем влияние ширины окна расчёта ВКФ d на обнаружение разладки при различных входных сигналах.

Гармонический входной сигнал. В первой группе экспериментов будем подавать на вход сигнал

$$u_t = \begin{cases} \sin\left(\frac{2\pi t}{250}\right) & t \leq 5000 \\ 0.8 \sin\left(\frac{2\pi t}{250}\right) + 0.2 \sin\left(\frac{2\pi t}{25}\right) & t > 5000 \end{cases} \quad (4)$$

Общее количество точек выборки входного сигнала u_t составляет 10 000. После $t = 5000$ на входной сигнал u_t накладываются гармоники и изменяется режим нелинейного процесса: время до $t = 5000$ назовём «режим 1», а после – «режим 2».

Гармонический входной сигнал u и наблюдаемое выходное значение y показаны на рис. 3.




Рис. 3. Гармонический входной сигнал u и наблюдаемое выходное значение y

ВКФ рассчитываются для выходного сигнала u и наблюдаемого выходного значения y в пределах окна длиной 60. Изменение входного сигнала происходит в пределах 84-го окна, поскольку $5000/60 \approx 83.3$. Вид ВКФ в обоих режимах показан на рисунке 4. Видно, что наблюдается изменение вида ВКФ до и после смены режима динамического нелинейного процесса, однако имеется также и вариативность ВКФ в пределах одного режима.




Рис. 4. Результаты расчета ВКФ в различных окнах при гармоническом сигнале на входе

Представим ВКФ как вектор размерности 121. Для того, чтобы понять, можем ли мы различить ВКФ режима 1 от ВКФ режима 2, применим метод главных компонент к точкам векторного пространства ВКФ. График рисунка 5 является результатом проекции вектора ВКФ на три главных компонента. Видно, что в векторном пространстве ВКФ есть четкое разделение точек, соответствующих разным режимам, то есть, разным входным сигналам и отклику на них нелинейным динамическим объектом. Таким образом, изменение режима может быть обнаружено с помощью ВКФ.

Для того, чтобы научиться различать режимы в автоматическом режиме, применим автокодировщик. Для этого проведём нормировку ВКФ для эталонного режима работы («режим 1»), относительно которого мы ходим определять разладку. Эти значения ВКФ будут использоваться для обучения автокодировщика. Используется нейросеть типа «многослойный перцептрон» (MLP) с двумя слоями и архитектурой $MLP(2d - 1, 25, 2d - 1)$, то есть, на входе вектор ВКФ размерности $2d - 1$, поступающий на скрытый слой 25 нейронов, далее выходной слой из $2d - 1$ нейронов. Количество эпох обучения - 300. Учитывая влияние длины окна ВКФ на качество разделения режимов, эксперименты проводились в условиях длин окна 50, 60 и 70, а полученная ошибка при сравнении полученного восстановленного значения ВКФ с входным значением ВКФ показана на рисунке 6. Слева направо показаны ошибки восстановления ВКФ при длинах окон 50, 60 и 70 соответственно. Ошибка r превышает порог r_{th} и существенно возрастает в 101-й, 84-й и 72-й точках соответственно, что согласуется с окном, в котором возникает смены режима.

Рассмотрим эксперимент, в котором на входной сигнал u_t накладывается шум – случайный сигнал со средним значением 0 и дисперсией 0,01.

Ошибка реконструкции ВКФ пересчитывается при длинах окон 50, 60 и 70, результаты показаны на рисунке 7. Ошибка r также существенно возрастает в 101-й, 84-й и 72-й точках соответственно, что согласуется с окном, в котором возникает смены режима.




Рис. 5. Векторное пространство ВКФ для синусоиды на входе




Рис. 6. Ошибка восстановления ВКФ автокодировщиком




Рис. 7. Ошибка восстановления ВКФ при шуме на входе

Входной сигнал – меандр. В следующей группе экспериментов входной сигнал u_t будет представлять собой меандр:

$$u_t = \begin{cases} \text{sign}(\sin(\frac{2\pi t}{250})) & t \leq 5000 \\ \text{sign}(0.8 \sin(\frac{2\pi t}{250})) + \text{sign}(0.2 \sin(\frac{2\pi t}{25})) & t > 5000 \end{cases} \quad (5)$$

Меандр в качестве входного сигнала u и наблюдаемое выходное значение y показаны на рис. 8.




Рис. 8. Меандр в качестве входного сигнала u и наблюдаемое выходное значение y




Рис. 9. Результаты расчета ВКФ в различных окнах при меандре на входе

ВКФ рассчитываются с использованием выходного сигнала u_t и наблюдаемого выходного значения y в пределах окна длиной 60. Изменение входного сигнала происходит в пределах 84-го окна. Результаты показаны на рисунке 9. Видно, что когда входной сигнал представляет собой меандр, значения ВКФ значительно изменяются до и после смены режима динамического нелинейного процесса.

График рисунка 10 является результатом проекции вектора ВКФ на три главных компонента. На рисунке видно, что в векторном пространстве ВКФ имеется четкое разделение точек, соответствующих изменениям меандра в качестве входного сигнала.




Рис. 10. Векторное пространство ВКФ для меандра на входе

При тех же условиях обучения автокодировщика ошибка, полученная путем сравнения восстановленного значения ВКФ, рассчитанного в окне 50, 60 и 70, с входным значением ВКФ, показана на рисунке 11. Аналогично, ошибка r существенно возрастает в точках 101, 84 и 72 соответственно, что соответствует окну, в котором происходят смены режима.




Рис. 11. Ошибка восстановления ВКФ автокодировщиком

Аналогично, на основе изменения входного сигнала u накладывается случайный сигнал со средним значением 0 и дисперсией 0,01.

Ошибка реконструкции ВКФ пересчитывается при длинах окон 50, 60 и 70, результаты показаны на рисунке 12. Ошибка r также существенно возрастает в 101-й, 84-й и 72-й точках соответственно, что согласуется с окном, в котором возникает смены режима.




Рис. 12. Ошибка восстановления ВКФ при шуме на входе

Входной сигнал – белый шум. Входной сигнал представляет собой нормальный (гауссов) белый шум со средним значением 0,1 и отклонением 0,01 до смены режима и нормальный (гауссов) белый шум со средним значением 0 и отклонением 0,01 после смены режима. Режим меняется при $t = 5000$, а общая длина входного сигнала равна 10 000.

Белый шум в качестве входного сигнала u и наблюдаемое выходное значение y ипоказаны на рисунке 13.




Рис. 13. Белый шум в качестве входного сигнала u и наблюдаемое выходное значение y

Рассчитанные значения ВКФ под разными окнами показаны на рисунке 14.




Рис. 14. Результаты расчета ВКФ в различных окнах при случайном сигнале на входе

Результат проекции вектора ВКФ на три главных компонента показан на рисунке 15. Аналогично и в векторном пространстве ВКФ при изменении статистического распределения входного сигнала соответствующие точки явно разделяются.




Рис. 15. Векторное пространство ВКФ для случайного сигнала на входе

При тех же условиях обучения автокодировщика ошибка, полученная путем сравнения восстановленного значения ВКФ, рассчитанного в окне 50, 60 и 70, с входным значением ВКФ, показана на рисунке 16. Аналогично, ошибка r превышает порог r_{th} и существенно возрастает в точках 101, 84 и 72 соответственно, что соответствует окну, в котором происходит смена режима.




Рис. 16. Ошибка восстановления ВКФ автокодировщиком

Обсуждение. Проведенные эксперименты показывают, что разработанный метод позволяет обнаруживать разладку процесса, вызванную сменой режима работы нелинейного динамического объекта. Отметим сильные и слабые стороны метода. К его достоинствам относится возможность реагировать на изменение поведения нелинейного объекта, вызванного изменением вида и характеристик входного сигнала. Предложенный метод не требует построения модели динамического объекта и обладает хорошей помехоустойчивостью.

Недостатком метода является медленная реакция на смену режима, которая составляет не менее ширины одного окна, поскольку это нужно для расчёта ВКФ. Уменьшение ширины окна приводит к увеличению разброса значений ВКФ и усложняет обнаружение разладки с помощью нейросетевого автокодировщика.

Также к особенностям метода относится необходимость обучения нейросетевого автокодировщика и выбора порогового значения ошибки реконструкции. Малое значение порога может вызвать ложное обнаружение разладки, а слишком большое оставит событие разладки незамеченным.

Таким образом, представляется актуальным продолжить исследования, направленные на разработку методики подбора ширины окна ВКФ, выбора структуры нейросети автокодировщика и расчета порога ошибки реконструкции.

Заключение. В работе предложено применение векторного пространства ВКФ входных и выходных временных рядов наблюдаемого нелинейного динамического объекта для обнаружения смены режима. С точностью до ширины окна вектор значений ВКФ может использоваться в качестве эффективной мгновенной характеристики динамического поведения наблюдаемого процесса. Предложенный подход по использованию ВКФ в качестве характеристики динамики нелинейного процесса может быть использован для оценки качества модели в процессе моделирования нелинейных процессов.

Разработан метод обнаружения разладки нелинейных объектов в системах управления, не требующий синтеза точной динамической модели объекта. В качестве динамических характеристик нелинейного процесса используется только ВКФ входных и выходных данных, момент возникновения разладки оценивается по ошибке реконструкции нейросетевого автокодировщика.

Целесообразно проведение исследований в направлении рационализации выбора параметров метода (ширина окна ВКФ, структура нейросети и порог ошибки), что позволит упростить применение метода на практике и сделать его эффективным. Мы протестировали наш метод только на наборе данных моделирования. Имеет смысл протестировать его работоспособность на более реальных моделях и объектах.

Список литературы

1. Мироновский Л.А. Функциональное диагностирование динамических систем (обзор) // Автомат. и телемех. 1980. №8. С. 96-121.
2. Голубков А.В., Цыганов А.В., Петрищев И.О. Обнаружение изменения режима движения объекта по сложной траектории // Информационные технологии и нанотехнологии. Самар: Самарский национальный исследовательский университет имени академика С.П. Королева, 2020. С. 858-864.
3. Колмогоров А.Н., Прохоров Ю.В., Ширяев А.Н. Вероятностно-статистические методы обнаружения спонтанно возникающих эффектов // Теория вероятностей, теория функций, механика. Сборник обзорных статей 5. К 50-летию Института. Москва: ФГБУ «Издательство «Наука», 1988. С. 4-23.
4. Gao Z., Cecati C., Ding S.X. A Survey of Fault Diagnosis and Fault-Tolerant Techniques. Part I: Fault Diagnosis With Model-Based and Signal-Based Approaches // IEEE Transactions on Industrial Electronics. 2015. №62(6). С. 3757 - 3767.
5. Simani S., Patton R.J., Daley S., Pike A. Identification and fault diagnosis of an industrial gas turbine prototype model // IEEE Conference on Decision & Control. Sydney: IEEE, 2000. С. 2615-2620.
6. Shalyga D., Filonov P., Lavrentyev A. Anomaly detection for water treatment system based on neural network with automatic architecture optimization // arXiv:1807.07282 preprint. 2018. С. 1-9.
7. Kravchik M., Shabtai A. Detecting Cyber Attacks in Industrial Control Systems Using Convolutional Neural Networks // Proceedings of the 2018 Workshop on Cyber-Physical Systems Security and Privacy. Toronto: ACM, 2018. С. 72-83.
8. Goh J., Adepu S., Tan M., Lee Z.S. Anomaly detection in cyber physical systems using recurrent neural networks // 2017 IEEE 18th International Symposium on High Assurance Systems Engineering (HASE). Singapore: IEEE, 2017. P. 140-145.
9. Li D., Chen D., Shi L., Jin B., Goh J. MAD-GAN: Multivariate anomaly detection for time series data with generative adversarial networks // International conference on artificial neural networks. Cham: Springer, 2019. P. 703-716.
10. Воробейчиков С.Э., Конев В.В. Об обнаружении разладок в динамических системах // Автомат. и телемех. 1990. №3. С. 56-68.
11. Filaretov V., Zhirabok A., Zuev A., Protchenko A. Fault identification in nonlinear dynamic systems // Proceedings of the 2016 5th International Conference on Systems and Control. Morocco: IEEE, 2016. P. 273-277.
12. Мальцев А.А., Силаев А.М. Обнаружение скачкообразных изменений параметров и оптимальное оценивание состояния дискретных динамических систем // Автомат. и телемех. 1985. №1. С. 48-58.
13. Елисеев В.Л., Филаретов Г.Ф. Методика синтеза нейросетевой системы управления нестационарным объектом // Вестник МЭИ. 2010. №3. С. 100-106.
14. Гурина А.О., Елисеев В.Л. Нейросетевой метод выявления новизны в модели нестационарной динамической системы // Проблемы автоматизации и управления в технических системах. Сборник статей по материалам XXXIII Международной научно-технической конференции, посвященной 55-летию образования кафедры «Автоматика и телемеханика»: в 2 т. 2019, Пенза, 2019. С. 237-241.
15. Jin Uk Ko, Kyumin Na, Joon-Seok Oh, Jaedong Kim, Byeng D. Youn, A new auto-encoder-based dynamic threshold to reduce false alarm rate for anomaly detection of steam turbines // Expert Systems with Applications, Vol.189, 2022, 116094. DOI: 10.1016/j.eswa.2021.116094.
16. Fernández-Saúco I.A., Acosta-Mendoza N., Gago-Alonso A., García-Reyes E.B. Computing Anomaly Score Threshold with Autoencoders Pipeline. In: Vera-Rodriguez, R., Fierrez, J., Morales, A. (eds) Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications. CIARP 2018. Lecture Notes in Computer Science, Vol.11401. Springer, Cham. DOI: 10.1007/978-3-030-13469-3_28.
17. Narendra K.S., Parthasarathy K. Identification and control of dynamical systems using neural networks // IEEE Transactions on neural networks. 1990. №1(1). P. 4-27.

Ван Сюэчунь, аспирант, vansuech@mppei.ru, Россия, Москва, Национальный исследовательский университет «Московский энергетический институт»,

Елисеев Владимир Леонидович, канд. техн. наук, доцент, vlad-eliseev@mail.ru, Россия, Москва, Национальный исследовательский университет «Московский энергетический институт»

NEURAL NETWORK METHOD FOR DETECTING CHANGES IN THE OPERATING MODE OF A NONLINEAR DYNAMIC OBJECT

X. Wang, V.L. Eliseev

The problem of detecting changes in the behavior of a dynamic object with nonlinear properties is studied. A method is proposed based on identifying the novelty of the input-output cross-correlation function using a neural network autoencoder. Experiments are carried out with various input signals, demonstrating the ability to diagnose mode changes in a dynamic system.

Key words: functional diagnostics, cross-correlation function, dynamic object, dynamic mode of operation, neural network autoencoder, novelty detection, disorder.

Wang Xuechun, postgraduate, vansiuech@mpei.ru, Russia, Moscow, National Research University «Moscow Power Engineering Institute»,

Eliseev Vladimir Leonidovich, candidate of technical sciences, docent, vlad-eliseev@mail.ru, Russia, Moscow, National Research University «Moscow Power Engineering Institute»

УДК 004.032.26

DOI: 10.24412/2071-6168-2024-3-56-57

ОПТИМИЗАЦИЯ РЕКРУТИНГОВЫХ ПРОЦЕССОВ ПУТЕМ ВНЕДРЕНИЯ ИНТЕЛЛЕКТУАЛЬНЫХ ТЕХНОЛОГИЙ АНАЛИЗА ДАННЫХ

Е.В. Ляпунцова, А.Н. Семенюта

В статье рассмотрен метод повышения эффективности процессов рекрутинга в области подбора кандидатов на стажировку, а именно этапа видеointервью, с помощью искусственных нейронных сетей, которые помогают автоматизировать рутинную работу сотрудников, а также рассмотрены проблемы, с которыми может столкнуться компания при внедрении такой технологии.

Ключевые слова: рекрутинг, нейронная сеть, интеллектуальные технологии, видеointервью.

В современном мире прогресс неумолимо наступает, заставляя компании стремиться к цифровой трансформации своих бизнес-процессов. Это позволяет сделать рабочие процессы более удобными и эффективными как для себя, так и для своих клиентов. Данная тенденция затрагивает все сферы деятельности человека, включая в том числе и процесс подбора персонала.

Отбор молодых специалистов является критически важным процессом для всех отраслей промышленности, включая машиностроение, металлургию, электроэнергетику и многие другие по следующим причинам [1]:

1. Инновации и развитие: Молодые специалисты часто вносят свежие идеи, инновации и энергию в организацию, способствуя ее развитию и конкурентоспособности на рынке.

2. Обновление кадров: Приток молодых специалистов позволяет компании обновлять кадровый резерв, заполнять вакансии и замещать уходящий персонал, обеспечивая стабильность и непрерывность бизнес-процессов.

3. Мультипликативный эффект: Обучение и развитие молодых специалистов сегодня может привести к появлению квалифицированных специалистов в будущем, обеспечивая долгосрочные перспективы для предприятия.

4. Актуализация знаний и технологий: Молодые специалисты, особенно выпускники современных образовательных учреждений, часто обладают свежими знаниями и умениями, что позволяет компании быть в курсе последних тенденций и технологических новшеств.

5. Конкурентное преимущество: Компании, способные эффективно привлекать и удерживать талантливых молодых специалистов, могут получить значительное конкурентное преимущество на рынке труда и в своей отрасли.

В связи с этим для успешного отбора кандидатов отделы управления человеческими ресурсами переходят на новый уровень - модель "HR 3.0". Она способствует повышению эффективности и скорости решения задач по найму, удержанию и развитию персонала благодаря инновационным технологиям [2]. Цифровой рекрутинг становится заменой традиционному подбору персонала, открывая новые возможности для эффективного отбора кандидатов (рис. 1).

В традиционном понимании процесса отбора на работу каждый кандидат оценивается рекрутером, который вносит свою субъективную оценку в способности кандидата как теоретические, так и практические. Однако, стоит задать себе вопрос о честности такой оценки и о том, насколько личные предпочтения HR-специалиста могут повлиять на окончательное решение о найме будущего сотрудника, а также подумать о том, сколько времени уходит на анализ информации о кандидатах на первом этапе отбора, когда их мотивация и подход к работодателю еще не ясны.

Рассмотрим, как интеллектуальные технологии могут повысить эффективность отбора молодых специалистов на стажировки и лидерские программы. Некоторые отборы на программы различных компаний проводятся ежегодно, успешность таких проектов растет, и поэтому количество желающих принять участие в них активно увеличивается. В связи с этим для компаний все острее стоит вопрос автоматизации бизнес-процессов, в том числе одним из таких процессов, подход к которому нужно срочно изменять, является этап анализа видеointервью кандидатов на вакансию на платформе VCV (сайт для автоматизированного отбора соискателей) после прохождения первоначального отсеивания потенциальных работников по формальным критериям. Однако, для того чтобы просмотреть все видеозаписи и оценить их по заданным критериям, требуется большое количество рабочего времени рекрутеров, несмотря на то что это лишь один из начальных этапов отбора, на котором у нас имеется еще очень большое количество нерелевантных кандидатов [3].