

УДК 519.71

**Н. И. ФЕДОРЕНКО¹, Р. В. СТЕЦИШИН², И. М. АНТОНЯН²,
С. П. ДОБРОЛЕЖА², В. С. ХАРЧЕНКО¹**¹ *Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», Украина*² *Харьковская медицинская академия последипломного образования, Украина*

СТАТИСТИЧЕСКИЙ ПОДХОД К ФОРМАЛИЗАЦИИ НЕЙРОСЕТЕВОГО РАСПОЗНАВАНИЯ УРОФЛОУРОГРАММ ЗАБОЛЕВАНИЙ В УРОЛОГИИ

Предлагается подход, основанный на элементах статистической теории обучения и вероятностных трактовках взаимозависимости между входами и выходами нейронных сетей по их обучению и тестированию при решении задач распознавания урофлоурограмм заболеваний в урологии. Оценки точности распознавания основываются не на вероятностных показателях, а на обучающих данных и вычисляемых синаптических весах. Экспериментально показано определение необходимого количества обучающих данных для сетей обратного распространения ошибки по обеспечению достаточной точности распознавания заболеваний. Рассматривается вопрос нейросетевого распознавания урофлоурограмм заболеваний, отражающих индивидуальные особенности пациентов.

Ключевые слова: *нейросетевое распознавание урофлоурограмм заболеваний, стохастика обучения сетей, функция потерь, функционал риска, эмпирический функционал риска, обобщающие способности сетей.*

Введение

Применение нейросетевого подхода к диагностированию заболеваний в урологии обусловлено взаимозависимостью урофлуометрических параметров, в частности изменением скорости мочеиспускания (урофлоурограммой) и видом заболевания [1]. В практическом плане процедура диагностирования сводится к визуальному сравнению врачом графика текущей урофлоурограммы пациента и графика “типовой” урофлоурограммы, характеризующей то или иное заболевание. В зависимости от степени совпадения графиков урофлоурограмм врач может судить о наличии или отсутствии заболевания. Для принятия решения о наличии или отсутствии заболевания, а также о его причинах широко используются системы поддержки принятия решений, основанные на применении нейросетевых технологий [2, 3], в том числе и для диагностирования урологических заболеваний [4, 5]. Применение таких технологий в урологии имеет ряд особенностей, заключающиеся в том, что вид графиков и параметры урофлоурограмм пациентов, диагностируемых по одному виду заболеваний, могут незначительно отличаться от типовых. Таким образом, проявляются индивидуальные особенности пациентов с одинаковыми заболеваниями, а используя общепринятую трактовку, такие урофлоурограммы являются слегка зашумленными, поэтому при распознавании заболеваний необходим достаточный уровень обоб-

щающей способности сети. Это достигается путем увеличения числа обучающих данных.

При реализации алгоритмов обучения нейронных сетей сложной остается проблема оценки соотношения между значениями показателя точности распознавания после обучения (на доступной выборке обучающих данных) и прогнозируемыми значениями этого показателя, полученными на этапе тестирования (на данных, не использовавшихся при обучении). При этом актуальным вопросом при таком подходе остается выбор необходимого количества обучающих данных, обеспечивающих достаточный уровень обобщающей способности сети для повышения точности распознавания заболеваний в урологии.

Целью данной работы является формализация процедуры определения необходимого количества обучающих данных для обеспечения требуемой точности распознавания заболеваний в урологии на основе статистической оценки обобщающей способности сети и учета вероятностного характера взаимосвязи между входами, выходами и вектором синаптических весов.

Стохастика обучения нейронных сетей по распознаванию заболеваний в урологии

Для обучения нейронной сети необходимо подготовить обучающие данные в виде двух множеств:

множества видов урологических заболеваний и множества “типовых” графиков (векторов значений) скорости мочеиспускания, взаимосвязанных со 100% достоверностью с видами заболеваний [6]. На вход сети подается вектор x дискретных значений скорости мочеиспускания, а учителем является вид заболевания. В данном подходе нейронная сеть является формой сохранения опытных, эмпирических знаний врача, которые посредством обучения аккумулируются в весовых коэффициентах w , а используя нейросетевой подход, моделируется работа врача по распознаванию заболеваний. Кроме того, обучение сети - это итерационный, циклический процесс появления случайного входного вектора урофлоуметрических показателей x , имеющий стохастическую природу. Элементами этого процесса являются целевая функция $f(x)$, идентифицирующая вид заболевания и фактическая функция отображения $F(x, w)$ – выход сети, характеризующий текущее приближение вида заболевания на каждом шаге обучения. Отличия между этими функциями можно выразить статистическими понятиями. При этом входные данные представлены случайным вектором x , размерности k , из множества “типовых” урофлоуметрических показателей (скорости мочеиспускания) X , а зависимой переменной является случайный скаляр p из множества P (видов заболеваний пациентов). Если предположить, что существует N реализаций случайного вектора X , обозначаемых $\{x_j\}_{j=1}^N$, и соответствующее им множество реализаций случайного вектора P , который обозначим $\{p_j\}_{j=1}^N$, то N обучающих воздействий на сеть реализуются множеством пар:

$$T = \{(x_j, p_j)\}_{j=1}^N. \quad (1)$$

На этапе обучения сети точная функциональная зависимость между множеством урофлоуметрических показателей X и множеством видов заболеваний P неизвестна, поэтому можно применить модель приближения между ними, описанную в [7]:

$$P = f(X) + \varepsilon, \quad (2)$$

где $f(\cdot)$ – функция от вектора урофлоуметрических параметров; ε – значение случайной ошибки со средним значением, равным нулю, отражающая степень незнания функциональной зависимости видов заболеваний P от урофлоуметрических параметров X . Статистическая модель, представленная формулой (2) является регрессионной и характеризуется двумя свойствами:

– среднее значение ожидаемой ошибки ε для любого входного вектора урофлоуметрических па-

раметров x равно нулю: $E[\varepsilon|x] = 0$ (E – оператор математического ожидания);

– ошибка ε не коррелируется с функцией регрессии $f(X)$: $E[\varepsilon f(X)] = 0$. Регрессионная модель математически описывает стохастическую входного воздействия на сеть и имеет целью, с помощью множества вектор-сигналов урофлоуметрических параметров X , предсказывать виды заболеваний – зависимые векторы P (рис. 1).

Такой подход реализации нейронной сети позволяет закодировать эмпирические знания врача, представленные в обучающей выборке T посредством настройки при обучении синаптических весов w : $T \rightarrow w$.

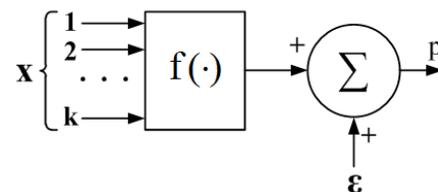


Рис. 1. Математическое представление нейронной сети

Статистические оценки обобщающей способности нейронной сети по распознаванию заболеваний в урологии

Пусть текущий отклик сети на входной вектор обозначается следующей вероятностной переменной $y = F(x, w)$, где $F(\cdot, w)$ – функция отображения урофлоуметрических показателей в виды заболеваний. Для обучающих данных, предъявляемых сети при обучении в виде множества (1), вектор синаптических весов w определяется путем минимизации разности между желаемым откликом p (видом заболеваний) и фактическим выходом сети $y_j = F(x_j, w_j)$, полученным на каждом шаге обучения сети.

Как следует из предыдущих разделов, основная проблема обучения нейронной сети по распознаванию заболеваний в урологии заключается в нахождении необходимого математического инструмента по управлению обобщающей способности сети. При этом модель обучения сети реализуется с учителем и состоит из трех взаимосвязанных компонент (рис. 2):

– входными данными для нейронной сети являются вектор-сигналы x значений скорости мочеиспускания размерности k с неизвестной функцией

распределения вероятности $Q_X(\mathbf{x})$;

– учитель продуцирует для сети отклик p для каждого входного вектора \mathbf{x} с условной функцией распределения вероятности $Q_X(\mathbf{x}|p)$. При этом отклик (вид заболевания) и входной вектор связаны между собой соотношением $p = f(\mathbf{x})$;

– обучаемая нейронная сеть на каждом шаге обучения реализует множество функций отображения вход-выход, которые описываются соотношением $y = F(\mathbf{x}, \mathbf{w})$, где y – фактический отклик сети в ответ на входной сигнал \mathbf{x} , \mathbf{w} – набор синаптических весов из множества \mathbf{W} .



Рис. 2. Модель обучения сети

Задача обучения нейронной сети заключается в нахождении функции $F(\mathbf{x}, \mathbf{w})$, которая оптимально (в статистическом смысле) аппроксимирует желаемый отклик p . Выбор этой функции основывается на множестве независимых и одинаково распределенных обучающих данных: $T = \{(\mathbf{x}_j, p_j)\}_{j=1}^N$. Для обучения сети на каждом шаге извлекается из множества T обучающая пара с некоторой совместной функцией распределения вероятности $Q_{X,P}(\mathbf{x}, p)$, являющейся фиксированной, но неизвестной. Результат процесса обучения сети зависит от того, обладает или нет данное обучающее множество необходимой информацией для обучения сети с хорошими обобщающими свойствами, т. е. сможет ли обученная сеть давать правильную реакцию на тестовые примеры, которые не участвовали в обучении, но имеют такие же свойства вероятностного распределения. Таким образом, задача обучения сети по распознаванию заболеваний в урологии квалифицируется как задача аппроксимации, заключающаяся в нахождении функции $F(\mathbf{x}, \mathbf{w})$, которая является наиболее точным приближением желаемой функции $f(\mathbf{x})$ – имитатора отображения сети указы-

ваемому учителем на вид заболевания.

Критерием выбора $F(\mathbf{x}, \mathbf{w})$, удовлетворяющему указанному выше условию, является мера несходства между откликом p – заданным видом заболевания, соответствующим входному вектору урофлюометрических показателей \mathbf{x} , и текущим выходом сети $F(\mathbf{x}, \mathbf{w})$. В качестве такой меры несходства можно использовать описанную в [7, 8] функцию потерь $L(p, F(\mathbf{x}, \mathbf{w}))$, вычисляемую как квадрат разности между $p = f(\mathbf{x})$ и $F(\mathbf{x}, \mathbf{w})$:

$$L(p, F(\mathbf{x}, \mathbf{w})) = (p - F(\mathbf{x}, \mathbf{w}))^2. \quad (3)$$

В дальнейшем, на основе функции потерь, определяется ожидаемая величина потерь с помощью функционала риска $R(\mathbf{w})$ как интеграл по всему множеству обучающих пар T :

$$R(\mathbf{w}) = \int L(p, F(\mathbf{x}, \mathbf{w})) dQ_{X,P}(\mathbf{x}, p). \quad (4)$$

Целью обучения нейронной сети является минимизация функционала риска $R(\mathbf{w})$ по классу функций аппроксимации $\{F(\mathbf{x}, \mathbf{w}), \mathbf{w} \in \mathbf{W}\}$. Однако оценка функционала риска усложняется неизвестностью совместной функции распределения вероятности $Q_{X,P}(\mathbf{x}, p)$. Эта трудность преодолевается путем использования, описанного в [9], принципа минимизации эмпирического риска. Этот принцип основывается на использовании множества обучающих данных $T = \{(\mathbf{x}_j, p_j)\}_{j=1}^N$ и хорошо соответствует процедуре получения минимума функционала риска, определяемого формулой (4). Эмпирический функционал риска для обучающей выборки T вычисляется с помощью функции потерь $L(p, F(\mathbf{x}, \mathbf{w}))$:

$$R_{\text{эмп}}(\mathbf{w}) = \frac{1}{N} \sum_{j=1}^N L(p_j, F(\mathbf{x}_j, \mathbf{w}_j)). \quad (5)$$

Как видно из (5) вычисление эмпирического функционала риска не зависит от неизвестной функции распределения вероятности $Q_{X,P}(\mathbf{x}, p)$, а его значение может быть минимизировано по значениям вектора весов \mathbf{w} . Вычисление эмпирического функционала риска осуществляется в пакетном режиме в результате предъявления сети всех N обучающих пар. Если предположить, что $\mathbf{w}_{\text{эмп}}$ и $F(\mathbf{x}, \mathbf{w}_{\text{эмп}})$ вектор весов и соответствующее ему отображение сети, минимизирующее эмпирический функционал риска (5). Аналогично, если \mathbf{w}_0 и $F(\mathbf{x}, \mathbf{w}_0)$ – вектор весов и отображение, минимизирующее функционал риска $R(\mathbf{w})$, а $\mathbf{w}_{\text{эмп}}$, \mathbf{w}_0 – принадлежат множеству весов \mathbf{W} , то отображение $F(\mathbf{x}, \mathbf{w}_{\text{эмп}})$ будет близким к желаемому ото-

бражению $F(\mathbf{x}, \mathbf{w}_0)$.

Таким образом, на основе подхода, изложенного в [9], можно сформулировать принцип минимизации эмпирического функционала риска для определения величины несходства между заданным видом заболевания и выходными значениями обучаемой сети. Этот принцип состоит из трех взаимосвязанных частей:

– вместо функционала риска $R(\mathbf{w})$ вычисляется эмпирический функционал риска

$$R_{\text{эмп}}(\mathbf{w}) = \frac{1}{N} \sum_{j=1}^N L(p_j, F(\mathbf{x}_j, \mathbf{w}_j))$$

на основе множества обучающих данных $T = \{(\mathbf{x}_j, p_j)\}_{j=1}^N$;

– если $\mathbf{w}_{\text{эмп}}$ - вектор весовых коэффициентов, минимизирующий эмпирический функционал риска $R_{\text{эмп}}(\mathbf{w})$ в пространстве весов \mathbf{W} , тогда $R_{\text{эмп}}(\mathbf{w})$ сходится по вероятности к минимально возможным значениям действительного функционала риска $R(\mathbf{w})$, при условии увеличения обучающей выборки ($N \rightarrow \infty$) и условия равномерной сходимости эмпирического функционала риска $R_{\text{эмп}}(\mathbf{w})$ к действительному функционалу риска $R(\mathbf{w})$;

– необходимым и достаточным условием непротиворечивости минимизации эмпирического риска является равномерная сходимость, определяемая условием:

$$\text{Вер}\{\min_{\mathbf{w} \in \mathbf{W}} |R(\mathbf{w}) - R_{\text{эмп}}(\mathbf{w})| > \varepsilon\} \rightarrow 0, \text{ при } N \rightarrow \infty.$$

Физическая интерпретация, имеющая практическую значимость для нейросетевого распознавания заболеваний в урологии этого принципа, заключается в следующем:

– до начала обучения сети все аппроксимирующие функции $F(\mathbf{x}, \mathbf{w})$ равнозначны;

– в процессе обучения сети правдоподобие распознавания заболеваний (приближение к эталону отклика $f(\mathbf{x})$ - виду заболевания функции аппроксимации $F(\mathbf{x}, \mathbf{w})$) возрастает;

– при увеличении числа обучающих пар фактическое значение ожидаемой величины потерь (функционал риска $R(\mathbf{w})$) для обучаемой сети приближается к ее среднеарифметическому значению (эмпирическому функционалу риска $R_{\text{эмп}}(\mathbf{w})$).

Результаты экспериментов

Для экспериментального подтверждения предложенного подхода по статистической оценке, обобщающей способности сети, разработаны 3-и

программы в среде MATLAB R2010a по обучению и тестированию сети обратного распространения ошибки для распознавания заболеваний в урологии.

С помощью первой программы осуществляется обучение нейронной сети, при этом на вход подаются последовательно векторы дискретных значений скорости мочеиспускания с частотой 4-е значения в секунду. После завершения обучения осуществляется процесс тестирования сети с помощью 50-ти векторов скорости мочеиспускания, не участвующих в обучении. Третья программа обеспечивает построение графиков обучения, представленных по результатам экспериментов на рис. 3, отображающих зависимость выходных значений обучаемой сети от количества обучающих пар $T = \{(\mathbf{x}_j, p_j)\}_{j=1}^N$.

График построен для заболевания под номером 4 (незначительная инфравезикальная обструкция).

Из анализа рис. 3 следует, что по мере увеличения числа обучающих пар, график выходных значений обучаемой сети $F(\mathbf{x}, \mathbf{w})$ приближается к эталону отклика $f(\mathbf{x})$ - виду заболевания, что свидетельствует об уменьшении значений функции потерь, а, следовательно, увеличивается правдоподобие распознавания заболеваний. При этом на графике визуально определяется количество обучающих данных ($N=350$), достаточных для получения необходимой точности распознавания заболеваний.

Таким образом, при проведении экспериментальных исследований подтверждаются выводы, изложенные в физической интерпретации принципа минимизации эмпирического риска предыдущего раздела.

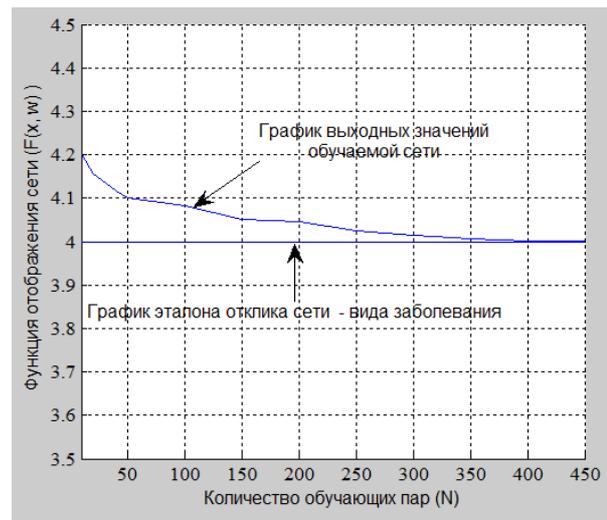


Рис. 3. График зависимости функции отображения обучаемой сети от количества обучающих данных

Заключение

В данной статье проанализирован вопрос формализации процессов обучения нейросетевых архитектур для решения задач распознавания заболеваний в урологии. Предложен подход с вероятностным описанием по входу и выходу нейронной сети и ориентацией не на вероятностные показатели, а на данные обучающей выборки.

Проведена оценка обобщающей способности нейронной сети с использованием функции отображения нейронной сети, функции потерь, функционала риска, эмпирического функционала риска. Указанные термины базируются на векторе w настраиваемых синаптических весов нейронной сети, что создает возможности практического использования указанных статистических характеристик по оценке обобщающих возможностей нейронных сетей при распознавании заболеваний в урологии.

Исследования проведены с использованием описанной в научной литературе статистической природы обучения сетей. Новизной предложенного в работе подхода является формализация применения нейросетевых архитектур для распознавания урофлоурограмм отражающих индивидуальные особенности пациентов с одинаковыми заболеваниями на основе использования элементов статистической концепции обучения. Используя общепринятую трактовку, такие урофлоурограммы можно назвать слегка зашумленными. Для их распознавания требуется повышение обобщающей способности нейронных сетей. Это, в свою очередь, требует решения задачи по определению необходимого количества обучающих данных для правильного распознавания заболеваний. В экспериментальной части работы приведено подтверждение того, что увеличение количества обучающих пар приводит к увеличению правдоподобия распознавания заболеваний в урологии. При этом определяется количество обучающих данных, необходимых для достижения достаточной точности распознавания. Таким образом, полученные практические результаты подтверждают математическое обоснование по статистическим оценкам обобщающей способности сети при диагностировании заболеваний в урологии, изложенные в работе.

Дальнейшие исследования целесообразно направить на поиск количественных показателей оценки точности распознавания заболеваний и отказоустойчивости сетей, с учетом использования в этом процессе различных архитектур и методов обучения нейросетевых архитектур для выбора и обоснования оптимального варианта. Кроме того, качество функционирования диагностической процедуры необходимо оценивать с учетом значений

интегральных характеристик: чувствительности и специфичности метода распознавания заболеваний.

Литература

1. Урофлоуметрия [Текст]/ Е. Л. Вишневецкий, Д. Ю. Пушкарь, О. Б. Лоран, В. В. Данилов, А. Е. Вишневецкий. – М.: Печатный город, 2004. – 220 с.
2. Статистический и нейросетевой методы идентификации и прогнозирования в медицине [Текст] / В. Б. Лифшиц, Т. И. Булдакова, С. И. Суятинов, С. В. Колентьев // Информационные технологии. – 2004. – № 3. – С. 60–63.
3. Соломаха, А. А. Нейросетевая экспертная медико-технологическая система прогнозирования риска развития осложнений у больных с хроническими заболеваниями легких [Текст] / А. А. Соломаха, К. А. Милова, В. И. Горбаченко // Информационные технологии. – 2012. – № 3. – С. 66–69.
4. Development of an artificial neural network for helping to diagnose diseases in urology [Text] / A. Paya, D. Fernandez, D. Mendez, C. Montejo Hernandez // BIONETICS '06 : Proceedings of the 1st international conference on Bio inspired models of network, information and computing systems Article. – 2006. – № 9. – P. 1–4.
5. A new approach to urinary system dynamics problems: Evaluation and classification of uroflowmeter signals using artificial neural networks [Text] / Altunay Semih, Telatar Ziya, Erogul Osman, Aydur Emin // Expert Systems With Applications. – 2009. – Vol. 36, issue 3. – P. 4891–4895.
6. Федоренко, Н. И. Разработка нейросетевого классификатора урофлоуметрограмм болезней в урологии [Текст] / Н. И. Федоренко // Радиоэлектронные и компьютерные системы. – 2011. – № 2. – С. 96–100.
7. Меркушева, А. В. Нейросетевые методы обработки сигналов в информационных системах. Элементы структуры, принципы обучения и мера многообразия отображений, реализуемых нейронной сетью [Текст] / А. В. Меркушева // Информационные технологии. – 2005. – № 3. – С. 9–20.
8. Малыхина, Г. Ф. Элементы статистической концепции обучения нейронной сети и прогнозирование точности ее функционирования [Текст] / Г. Ф. Малыхина, А. В. Меркушева // Научное приборостроение. – 2005. – Т. 15, № 1. – С. 29–45.
9. Хайкин, С. Нейронные сети: полный курс [Текст] : пер. с англ. / С. Хайкин. – 2-е издание. – М. : Издательский дом "Вильямс", 2006. – 1104 с.

Поступила в редакцію 30.10.2014, рассмотрена на редколлегии 18.11.2014

Рецензент: д-р техн. наук, проф., проф. каф. программной инженерии И. В. Шостак, Национальный аэрокосмический университет им. Н. Е. Жуковского «ХАИ», Харьков.

СТАТИСТИЧНИЙ ПІДХІД ДО ФОРМАЛІЗАЦІЇ НЕЙРОМЕРЕЖЕВОГО РОЗПІЗНАВАННЯ УРОФЛОУРОГРАМ ЗАХВОРЮВАНЬ В УРОЛОГІЇ

М. І. Федоренко, Р. В. Стецишин, І. М. Антонян, С. П. Добролежа, В. С. Харченко

Пропонується підхід, заснований на елементах статистичної теорії навчання та імовірнісних трактуваннях взаємозв'язку між входами та виходами нейронних мереж по їх навчання та тестуванню при вирішенні задач розпізнавання урофлюорограм захворювань в урології. Оцінка точності розпізнавання базується не на імовірнісних показниках, а на навчальних даних і обчислювальних синаптичних вагах. Експериментально показано визначення необхідної кількості навчальних даних для мереж зворотнього розповсюдження помилки для забезпечення необхідної точності розпізнавання захворювань. Розглянуто питання нейромережевого розпізнавання урофлюорограм захворювань що відображають індивідуальні особливості пацієнтів.

Ключові слова: нейромережеве розпізнавання захворювань, стохастика навчання мереж, функція втрат, функціонал ризику, емпіричний функціонал ризику, узагальнюючі властивості мереж.

STATISTICAL APPROACH OF DISEASES UROFLOUROGRAMS NEURONET RECOGNITION FORMALIZATION IN UROLOGY

N. I. Fedorenko, R. V. Stetsyshyn, I. M. Antonyan, S. P. Dobrolezha, V. S. Kharchenko

We offer the approach based on elements of the statistical theory of training and likelihood treatments of interdependence between inputs and outputs of neural nets on their training and testing when solving the problems of recognition of diseases urofourograms in urology. Estimations of recognition accuracy are based not on likelihood indicators, and on training data and calculated synaptic weight. Calculation of required quantity of training data for nets of return diffusion of an error on maintaining the sufficient accuracy of diseases recognition is experimentally shown. The problem of neuronet recognition of diseases urofourograms of patients reflecting specific features is under consideration.

Keywords: neuronet recognition of diseases urofourograms, stochastics of neuronets training, function of losses, functional of risk, empirical functional of risk, generalising abilities of neuronets.

Федоренко Николай Иванович – зав. лаб. каф. прикладной лингвистики, Национальный аэрокосмический университет им. Н. Е. Жуковского “ХАИ”, Харьков, Украина, e-mail: Fednic-07@yandex.ua.

Стецишин Роман Васильевич – канд. мед. наук, доцент, доцент каф. урологии, Харьковская медицинская академия последипломного образования, Харьков, Украина, e-mail: r.stetsyshyn@gmail.com.

Антонян Игорь Михайлович – канд. мед. наук, доцент, зав. каф. урологии, Харьковская медицинская академия последипломного образования, Харьков, Украина, e-mail: info@urology.kharkov.ua.

Добролежа Сергей Петрович – ст. лаборант каф. урологии, Харьковская медицинская академия последипломного образования, Харьков, Украина, e-mail: dobrolega@gmail.com.

Харченко Вячеслав Сергеевич – д-р техн. наук, профессор, зав. каф. компьютерных систем и сетей, Национальный аэрокосмический университет им. Н. Е. Жуковского “ХАИ”, Харьков, Украина.