



УДК 004.032.26 : 611.136.42
doi: 10.21685/2587-7704-2023-8-1-2



Open
Access

RESEARCH
ARTICLE

Нейросетевая модель внутриорганного артериального русла селезенки как квазифрактальной системы

Илья Сергеевич Милтых

Пензенский государственный университет, Россия, г. Пенза, ул. Красная, 40
contact@miltykh.com

Никита Александрович Захаров

Пензенский государственный университет, Россия, г. Пенза, ул. Красная, 40
nek.zaharov@yandex.ru

Аннотация. Селезенка является одним из наибольших по объему органов кроветворения, ее повреждение или удаление ведет к нарушению многих иммунных функций. Остро стоит вопрос о проведении органосохраняющих операций. Для их разработки необходимо детальное изучение внутриорганного артериального русла селезенки. В последнее время были предложены модели, позволяющие количественно описывать сосудистые русла, особое место среди которых занимает дихотомическая модель. Эта модель представляет русло в виде структуры, состоящей из взаимосвязанных бифуркаций. На основе данных морфометрии коррозионных препаратов артериального русла селезенки человека с использованием библиотеки Scikit Learn создана нейросетевая модель, позволяющая с высокой точностью предсказывать диаметры и длины сегментов, составляющие артериальную дихотомию.

Ключевые слова: селезенка, селезеночная артерия, внутриорганное русло, дихотомии, нейросетевое моделирование, Scikit Learn

Для цитирования: Милтых И. С., Захаров Н. А. Нейросетевая модель внутриорганного артериального русла селезенки как квазифрактальной системы // Инжиниринг и технологии. 2023. Т. 8 (1). С. 1–6. doi: 10.21685/2587-7704-2023-8-1-2

A Neural Network Model of Splenic Intraorgan Arterial System as a Quasi-fractal System

Ilya S. Miltykh

Penza State University, 40 Krasnaya Street, Penza, Russia
contact@miltykh.com

Nikita A. Zacharov

Penza State University, 40 Krasnaya Street, Penza, Russia
nek.zaharov@yandex.ru

Abstract. Spleen is one of the largest hemopoietic organs and its damage or removal leads to the impairment of immune functions. Organsaving surgeries are an urgent issue. In order to develop such surgeries, it is necessary to study in detail the intraorganic arterial system of the spleen. Recently, several models have been suggested to quantitatively describe the spleen arterial system, the dichotomous model occupies a unique role among them. This model represents the system as a structure consisting of interconnected bifurcations. A neural network model has been developed based on corrosion morphometry data of human spleen arterial system using Scikit Learn library, which allows to predict diameters and lengths of the segments making up the arterial dichotomy with high accuracy.

Keywords: spleen, spleen artery, intraorgan circulation, bifurcations, neural network modeling, Scikit Learn

For citation: Miltykh I.A., Zacharov N.A. A Neural Network Model of Splenic Intraorgan Arterial System as a Quasi-fractal System. *Inzhiniring i tekhnologii = Engineering and Technology*. 2023;8(1):1–6. (In Russ.). doi: 10.21685/2587-7704-2023-8-1-2

Селезенка является одним из наибольших по объему органов кроветворения [1], ее повреждение или удаление ведет к нарушению многих иммунных функций [2]. В настоящее время, в связи с ростом травматических повреждений селезенки, остро стоит вопрос о проведении органсберегающих (частичная резекция поврежденных тканей) операций [3]. Разработка подобного рода операций невозможна без глубокого исследования внутриорганный артериальный русла селезенки (ВАРС) [4].

В последнее время в морфологии наметилась перспективная тенденция исследования внутриорганных артериальных русел различных органов человека как фрактальной или квазифрактальной системы [5–7]. Были предложены концептуальные модели, позволяющие количественно описывать особенности сосудистых русел. Такой подход, по мнению авторов [8], будет способствовать созданию морфометрического эталона внутриорганный артериальный русла, что поможет объективной диагностике возможных отклонений от нормального строения.

Одной из таких моделей является дихотомическая модель, т.е. представление русла как структуры, состоящей из взаимосвязанных бифуркаций (дихотомий). Эта модель интересна еще и тем, что повреждение артерий наиболее часто возникает в местах их разветвлений [9].

Сосудистая дихотомия (рис. 1) – конструкция, состоящая из трех сосудистых сегментов, одного материнского и двух дочерних, каждый из которых характеризуется определенным диаметром (D , d_{max} и d_{min}) и длиной (L , l_{max} и l_{min}).

А. М. Шай в своей диссертационной работе приводит регрессионные модели, хорошо описывающие связи между диаметрами материнского и дочерних сегментов, составляющих бифуркации (дихотомии) различных уровней деления ВАРС [10]. Однако, используя регрессионный анализ связи между значениями длин сегментов и других исследуемых показателей различных уровней деления обнаружить не удалось, что осложняет моделирование сосудистого дерева.

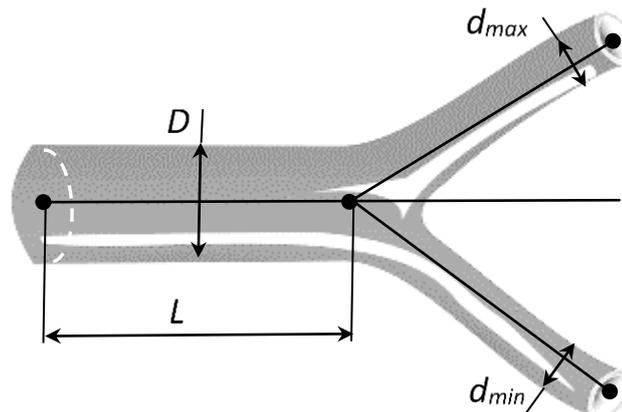


Рис. 1. Сосудистая дихотомия [7]: D – диаметр материнского сегмента, L – длина материнского сегмента, d_{max} – диаметр большего дочернего сегмента, d_{min} – диаметр меньшего дочернего сегмента

Мы посчитали возможным использование нейросетевого моделирования для предсказания значений длин материнских сегментов, составляющих бифуркации (дихотомии) ВАРС, расположенные на разных уровнях деления.

Таким образом, **цель исследования** – создать нейросетевую модель ВАРС как квазифрактальной системы, состоящей из бифуркаций (дихотомий) на основании результатов морфометрии.

В соответствии с целью работы решалась задача регрессии для предсказания диаметров и длин материнского и дочерних сегментов. Полносвязные нейронные сети прямого распространения являются универсальными аппроксиматорами функций. Доказательством является универсальная теорема аппроксимации (теорема Cybenko G.) [11]. Теорема утверждает, что сеть прямого распространения с одним скрытым слоем, содержащая нейроны с сигмоидальными функциями активации в скрытом слое и линейной функцией активации в выходном слое, позволяет аппроксимировать произвольную непрерывную функцию с любой точностью. Требуется только достаточно большое количество нейронов в скрытом слое. В [12] теорема обобщена на произвольные функции активации в скрытом слое. Результаты теорем о нейронной сети как универсальном аппроксиматоре функций обобщены в [13] на сети глубокой архитектуры с популярной в таких сетях функцией активации ReLU.



Для решения поставленной задачи была выбрана библиотека Scikit-Learn (<https://scikit-learn.org/stable/>). Scikit-Learn – это широко используемая библиотека машинного обучения, которая предоставляет широкий спектр инструментов для построения и оценки моделей машинного обучения [14]. Структура многослойных полносвязных нейронных сетей для решения задачи регрессии, реализованных в Scikit-Learn, показана на рис. 2. В Scikit-Learn первым слоем считается входной вектор. Выходной слой содержит один нейрон с линейной функцией активации.

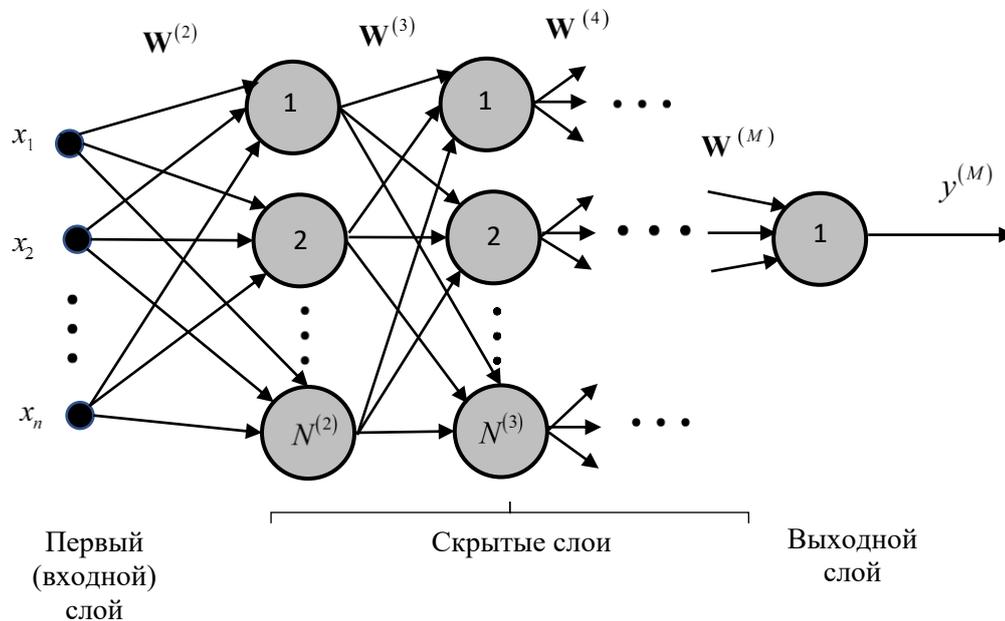


Рис. 2. Структура нейронной сети

Для скрытых слоев создаются одинаковые функции активации: логистическая сигмоидальная функция, гиперболический тангенс, функция ReLU. Обучение нейронной сети производится методом обратного распространения ошибки. При этом возможно использование следующих алгоритмов (оптимизаторов): оптимизатор LBFGS из семейства квазиньютоновских методов, стохастический градиентный спуск, оптимизатор Adam.

Выбор структуры сети и оптимизатора производился экспериментально с использованием набора обучающих данных. Набор содержит 6840 примеров. Признаковые описания примеров содержат признаки: пол, возраст, номер генерации, уровень деления, диаметр материнского артериального сегмента (D), фактор формы $FF1 = \frac{2L}{D}$ [8]. Исходные данные получены путем морфометрии 67 коррозийных слепков артериального русла селезенки человека, лиц обоего пола, 1-го и 2-го зрелого возраста [15]. Минимальный диаметр слепков артериальных сегментов составлял 0,1 мм. Целевыми (определяемыми нейросетевой моделью) являются: диаметр большего дочернего артериального сегмента (d_{\max}), диаметр меньшего дочернего артериального сегмента (d_{\min}), длина артериального сегмента (L), длина большего дочернего артериального сегмента (l_{\max}), длина меньшего дочернего артериального сегмента (l_{\min}). Набор не содержит пропуски данных и выбросы. Все атрибуты, кроме пола и возраста, являются числовыми. Качественные признаки закодированы целыми числами (Ordinal Encoder). Числовые признаки стандартизировались таким образом, чтобы они имели нулевое среднее значение и единичное стандартное отклонение.

У нейросетевого регрессора пакета Scikit-Learn (рис. 2) первым слоем считается входной вектор. Второй слой (первый скрытый слой) всегда содержит число нейронов, равное размерности входного вектора. Выходной слой содержит один нейрон. Количество скрытых слоев, количество нейронов в скрытых слоях и алгоритм обучения необходимо подбирать. Подбор этих параметров сети производился по результатам вычисления метрик качества регрессии [16]. Вычислялся коэффициент детерминации

У нейросетевого регрессора пакета Scikit-Learn (рис. 2) первым слоем считается входной вектор. Второй слой (первый скрытый слой) всегда содержит число нейронов, равное размерности входного вектора. Выходной слой содержит один нейрон. Количество скрытых слоев, количество нейронов в скрытых слоях и алгоритм обучения необходимо подбирать. Подбор этих параметров сети производился по результатам вычисления метрик качества регрессии [16]. Вычислялся коэффициент детерминации



$$R^2 = 1 - \frac{\|y - \tilde{y}\|^2}{\|y - \bar{y}\|^2},$$

где y – фактическое значение зависимой переменной, \bar{y} – среднее значение y , \tilde{y} – спрогнозированное значение зависимой переменной.

Чем ближе R^2 к единице, тем выше качество регрессионной модели. Вычислялись также средняя квадратическая ошибка (Mean Squared Error) $MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2$ и корень из среднеквадрати-

ческой ошибки модели (Root Mean Squared Error) $RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{n}}$, где n – общее количество

наблюдений. Метрики качества вычислялись по результатам работы обученной нейронной сети на тестовом наборе данных, на котором сеть не обучалась. В качестве тестового набора выделялось 25 % от общего набора данных. В качестве функции потерь нейросетевой регрессор использует среднюю сумму квадратов ошибок сети.

По результатам экспериментов лучшие значения метрик качества получены для двух скрытых слоев, причем подбираемый второй скрытый слой содержит 70 нейронов с функцией активации ReLU. Лучшим алгоритмом обучения оказался алгоритм с адаптивной скоростью обучения Adam (adaptive moments) [14]. На k -м шаге (эпохе) обучения алгоритм реализуется по формулам

$$m = \beta_1 m^{(k-1)} + (1 - \beta_1) g(w^{(k-1)}), \quad s = \beta_2 s^{(k-1)} + (1 - \beta_2) g(w^{(k-1)}) \otimes g(w^{(k-1)}),$$

$$m^{(k)} = \frac{m}{1 - \beta_1^k}, \quad s^{(k)} = \frac{s}{1 - \beta_2^k}, \quad w^{(k)} = w^{(k-1)} - \eta m^{(k)} ./ \sqrt{s^{(k)} + \varepsilon},$$

где $g(w^{(k)})$ – вектор градиента k -м шаге; $w^{(k)}$ – вектор весов сети; \otimes – поэлементное умножение; $./$ – поэлементное деление; $\beta_1 = 0,9$, $\beta_2 = 0,999$ – параметры ослабления, ε – сглаживающий член, для избежания деления на ноль, обычно $\varepsilon \approx 10^{-10}$.

Начальные значения векторов $m = 0$, $s = 0$. При вычислении $m^{(k+1)}$ и $s^{(k+1)}$ коэффициенты ослабления возводятся в степень, равную номеру текущей итерации. Использован мини-пакетный режим обучения нейронной сети с размером пакета, равным 200. Для предотвращения переобучения применена ранняя остановка (early stopping): выделяется 10 % обучающих данных для проверки и обучение прекращается, когда результат проверки не улучшается по крайней мере на 0,0001 в течение 10 последовательных эпох.

Эксперименты показали, что длина артериального сегмента (L) предсказывается очень точно: коэффициент детерминации равен 0,997; средняя абсолютная ошибка равна 0,0765 (все результаты приведены для тестового набора). Диаметр большего дочернего артериального сегмента (d_{\max}) также прогнозируется точно: коэффициент детерминации равен 0,950, средняя абсолютная ошибка – 0,079. Несколько хуже предсказывается диаметр меньшего дочернего артериального сегмента (d_{\min}): коэффициент детерминации равен 0,747, средняя абсолютная ошибка – 0,113. Длины дочерних артериальных сегментов точно предсказать не удастся: коэффициент не превышает 0,3. Однако длины дочерних сегментов, составляющих артериальную бифуркацию, возможно рассчитать используя формулу показателя фактора формы:

$$FF1 = \frac{2L}{D}.$$

В результате данного исследования разработана нейросетевая модель для определения значений диаметров и длин сегментов, составляющих артериальную бифуркацию. Это в будущем, в клинических условиях, после соответствующих доработок позволит прогнозировать объем и площадь участка селезенки, который обеспечивается кровью данным сосудом, и судить об адекватности кровоснабжения. Возможно также создание методики предоперационного моделирования, которая в условиях виртуального эксперимента позволит объективно прогнозировать исход оперативных вмешательств.



Список литературы

1. Vahidy F. S., Parsha K. N., Rashbar M. H. [et al.]. Acute splenic responses in patients with ischemic stroke and intracerebral hemorrhage // *Journal of Cerebral Blood Flow & Metabolism*. 2016. Vol. 36, № 6. P. 1012–1021.
2. Weledji E. P. Benefits and risks of splenectomy // *International Journal of Surgery*. 2014. Vol. 12, № 2. P. 113–119.
3. Ruiz C. C., Romboli A., Costi R. [et al.]. Partial splenectomy: Who, when and how. A systematic review of the 2130 published cases // *Journal of Pediatric Surgery*. 2019. Vol. 54, № 8. P. 1527–1538.
4. Manciu S., Tudor S., Vasilescu C. Splenic Cysts: A Strong Indication for a Minimally Invasive Partial Splenectomy. Could the Splenic Hilar Vasculature Type Hold a Defining Role? // *World Journal of Surgery*. 2018. Vol. 42, № 11. P. 3543–3550.
5. Kamiya A., Takahashi T. Quantitative assessments of morphological and functional properties of biological trees based on their fractal nature // *Journal of Applied Physiology*. 2007. Vol. 102, № 6. P. 2315–2323.
6. Glenny R. W. Emergence of matched airway and vascular trees from fractal rules // *Journal of Applied Physiology*. 2011. Vol. 110, № 4. P. 1119–1129.
7. Зенин О. Косников Ю. Н., Кафаров Э. С. Моделирование внутриорганного сосудистого русла методами процедурно-математической трансформации пространства // *Siberian Journal of Life Sciences and Agriculture*. 2021. Т. 13, № 6. С. 307–323.
8. Зенин О. К., Милтых И. С., Дмитриев А. В., Юрченко О. О. [и др.]. Морфометрический анализ применимости уравнений Murray C. D. для численного моделирования сосудистых дихотомий почки человека // *Siberian Journal of Life Sciences and Agriculture*. 2021. Т. 13, № 3. С. 170–192.
9. Kiss A., Nadasy G. L., Fees A., Arnold Z. Alterations in Coronary Resistance Artery Network Geometry in Diabetes and the Role of Tenascin C // *Reviews in Cardiovascular Medicine*. 2023. Vol. 24, № 1. P. 6.
10. Шай А. М. Кількісна анатомія внутрішньорганного судинного русла селезінки людини : автореф. дис. ... канд. мед. наук : 14.03.01. Харків, 2014. 25 с.
11. Cybenko G. Approximation by Superposition of a Sigmoidal Function // *Mathematics of Control, Signals and Systems*. 1989. Vol. 2. P. 303–314.
12. Hornik K. Approximation capabilities of multilayer feedforward networks // *Neural Networks*. 1999. Vol. 4, № 2. P. 251–257.
13. Hanin B. Universal Function Approximation by Deep Neural Nets with Bounded Width and ReLU Activations. URL: <https://arxiv.org/abs/1708.02691>
14. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn, Keras и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем. СПб. : Диалектика, 2020. 1040 с.
15. Кафаров Э. С., Дадашев А. Ш., Милтых И. С., Зенин О. Свидетельство о государственной регистрации базы данных № 2023620288 Российской Федерация. Количественная анатомия внутриорганного артериального русла селезенки : заявл. 23.12.2022 : опубл. 19.01.2023. № 2022624010.
16. Груздев А. В. Предварительная подготовка данных в Python. Т. 2: План, примеры и метрики качества. М. : ДМК Пресс, 2023. 814 с.

References

1. Vahidy F.S., Parsha K.N., Rashbar M.H. et al. Acute splenic responses in patients with ischemic stroke and intracerebral hemorrhage. *Journal of Cerebral Blood Flow & Metabolism*. 2016;36(6):1012–1021.
2. Weledji E.P. Benefits and risks of splenectomy. *International Journal of Surgery*. 2014;12(2):113–119.
3. Ruiz C.C., Romboli A., Costi R. et al. Partial splenectomy: Who, when and how. A systematic review of the 2130 published cases. *Journal of Pediatric Surgery*. 2019;54(8):1527–1538.
4. Manciu S., Tudor S., Vasilescu C. Splenic Cysts: A Strong Indication for a Minimally Invasive Partial Splenectomy. Could the Splenic Hilar Vasculature Type Hold a Defining Role? *World Journal of Surgery*. 2018;42(11):3543–3550.
5. Kamiya A., Takahashi T. Quantitative assessments of morphological and functional properties of biological trees based on their fractal nature. *Journal of Applied Physiology*. 2007;102(6):2315–2323.
6. Glenny R.W. Emergence of matched airway and vascular trees from fractal rules. *Journal of Applied Physiology*. 2011;110(4):1119–1129.
7. Zenin O., Kosnikov Yu.N., Kafarov E.S. Modeling of the intraorgan vascular bed by methods of procedural and mathematical transformation of space. *Siberian Journal of Life Sciences and Agriculture*. 2021;13(6):307–323. (In Russ.)
8. Zenin O.K., Milykh I.S., Dmitriev A.V., Yurchenko O.O. et al. Morphometric analysis of the applicability of the Murray C. D. equations for numerical modeling of vascular dichotomies of the human kidney. *Siberian Journal of Life Sciences and Agriculture*. 2021;13(3):170–192. (In Russ.)
9. Kiss A., Nadasy G.L., Fees A., Arnold Z. Alterations in Coronary Resistance Artery Network Geometry in Diabetes and the Role of Tenascin C. *Reviews in Cardiovascular Medicine*. 2023;24(1):6.
10. Shay A.M. *Quantitative anatomy of the internal organ vascular bed of the human spleen*. PhD abstract. Kharkiv, 2014:25.
11. Cybenko G. Approximation by Superposition of a Sigmoidal Function. *Mathematics of Control, Signals and Systems*. 1989;2:303–314.
12. Hornik K. Approximation capabilities of multilayer feedforward networks. *Neural Networks*. 1999;4(2):251–257.



13. Hanin B. *Universal Function Approximation by Deep Neural Nets with Bounded Width and ReLU Activations*. Available at: <https://arxiv.org/abs/1708.02691>
14. Zheron O. *Prikladnoe mashinnoe obuchenie s pomoshch'yu Scikit Learn, Keras i TensorFlow: kontseptsii, instrumenty i tekhniki dlya sozdaniya intellektual'nykh system = Applied Machine Learning using Scikit Learn, Kurs and TensorFlow: concepts, tools and techniques for creating intelligent systems*. Saint Petersburg: Dialektika, 2020:1040. (In Russ.)
15. Kafarov E.S., Dadashev A.Sh., Miltykh I.S., Zenin O. *Svidetel'stvo o gosudarstvennoy registratsii bazy dannykh № 2023620288 Rossiyskaya Federatsiya. Kolichestvennaya anatomiya vnuriorgannogo arterial'nogo rusla selezenki: zayavl. 23.12.2022: opubl. 19.01.2023. № 2022624010 = Certificate of state registration of the database No. 2023620288 Russian Federation. Quantitative anatomy of the intraorgan arterial bed of the spleen: application 23.12.2022: publ. 19.01.2023. No. 2022624010*. (In Russ.)
16. Gruzdev A.V. *Predvaritel'naya podgotovka dannykh v Python. T. 2: Plan, primery i metriki kachestva = Preliminary data preparation in Python. Vol. 2: Plan, examples and quality metrics*. Moscow: DMK Press, 2023:814. (In Russ.)

Поступила в редакцию / Received 03.04.2023

Поступила после рецензирования и доработки / Revised 07.05.2023

Принята к публикации / Accepted 25.05.2023