

Определение оптимальной структуры нейронной сети при разработке программ для поддержки принятия решений в дентальной имплантации

А. А. Долгалев^{1,2}, А. А. Мураев³, П. А. Ляхов⁴, У. А. Ляхова⁴, Д. З. Чониашвили⁵, К. Е. Золотаев¹, Д. Ю. Семериков⁶, В. М. Аванисян¹

¹ ФГБОУ ВО «Ставропольский государственный медицинский университет» Министерства здравоохранения РФ, Ставрополь, Российская Федерация

² Общество с ограниченной ответственностью «Имплант Аддитивные технологии», г. Ставрополь, Российская Федерация

³ ФГАОУ ВО «Российский университет дружбы народов», Москва, Российская Федерация

⁴ ФГАОУ ВО «Северо-Кавказский федеральный университет», Ставрополь, Российская Федерация

⁵ ФГБОУ ВО «Северо-Осетинский государственный университет имени Коста Левановича Хетагурова» (СОГУ), Владикавказ, Российская Федерация

⁶ Общество с ограниченной ответственностью «Стоматологическая клиника Валентина», г. Нягань, Российская Федерация

РЕЗЮМЕ

Введение. В настоящее время медицина считается одной из стратегических и перспективных областей для эффективного внедрения искусственного интеллекта. Искусственный интеллект в стоматологии является методом создания второго обоснованного мнения, которое основано на математическом принятии решений и прогнозировании. Нейросетевые технологии применяются в таких областях как анализ рентгенограмм зубов, прогнозирование потребности в лечении полости рта у детей, классификация зубных отложений и планирование лечения для ортогнатической хирургии, вспомогательное диагностирование кариеса.

Цель работы – разработка оптимальной структуры нейронной сети для оценки риска осложнений при имплантационном лечении частичной и полной потери зубов.

Материал и методы исследования. Для эффективного подбора оптимальной топологии нейронной сети оценки риска осложнений при имплантационном лечении потери зубов был проведен ряд экспериментальных моделирований нейросетевых архитектур методом проб и ошибок. База данных представляла собой таблицу клинических случаев пациентов в количестве 1800. Для моделирования были использованы 1626 клинических случаев, которые были разделены на данные для обучения и тестирования в процентном соотношении 80 к 20. Моделирование проводилось с использованием высокоуровневого языка программирования Python 3.8.8. Все расчеты проводились на ПК с процессором Intel(R) Core (TM) i5-8500 с частотой 3,00 ГГц с 16 Гб оперативной памяти и 64-битной операционной системой Windows 10.

Результаты исследования. В результате моделирования были получены графики точности распознавания, а также величины ошибки для каждой из разработанных топологий нейронных сетей. Для улучшения точности разработанных топологий нейронных сетей оценки риска осложнений при имплантационном лечении патологий челюстно-лицевой области было проведено статистическое исследование собранной базы данных для моделирования. Для исследования взаимосвязи между каждым параметром пациента и параметром «приживаемости имплантатов» был выбран метод параметрической статистики, представленный коэффициентом корреляции. В результате проведенного моделирования методом проб и ошибок было установлено что использование нейросетевой архитектуры № 7 без слоев пакетной нормализации (BatchNorm1d) позволяет добиться более быстрых результатов обучения с достаточно высокой точностью распознавания за меньшее количество эпох. Преобразование базы для моделирования и уменьшение размера входного сигнала позволило значительно повысить точность распознавания по сравнению с результатами первого моделирования различных нейросетевых систем распознавания успешности приживаемости имплантатов. Предложенная топология нейронной сети № 5 является наиболее оптимальной по точности распознавания успешности приживаемости имплантатов.

КЛЮЧЕВЫЕ СЛОВА: нейросетевые технологии, дентальные имплантаты, нейронные сети, математическое моделирование, архитектура нейронных сетей.

КОНФЛИКТ ИНТЕРЕСОВ. Авторы заявляют об отсутствии конфликта интересов.

Determining the optimal neural network structure for the development of decision support programmes in dental implantation

A. A. Dolgalev^{1,2}, A. A. Murayev³, P. A. Lyakhov⁴, U. A. Lyakhova⁴, D. Z. Choniashvili⁵, K. E. Zolotayev¹, D. Yu. Semerikov⁶, V. M. Avanisyan¹

¹ Stavropol State Medical University of the Ministry of Health of the Russian Federation, Stavropol, Russian Federation

² Limited Liability Company «Implant Additive Technologies», Stavropol, Russian Federation

³ Federal State Educational Institution of Higher Education «Peoples' Friendship University of Russia», Moscow, Russian Federation

⁴ Federal State Educational Institution of Higher Professional Education «North Caucasian Federal University», Stavropol, Russian Federation

⁵ Federal State Budgetary Educational Institution of Higher Professional Education «Kosta Khetagurov North Ossetian State University» (NOSU), Vladikavkaz, Russian Federation

⁶ Valentina Dental Clinic LLC, Nyagan, Russian Federation

SUMMARY

Introduction. Medicine is currently considered one of the strategic and promising areas for effective implementation of artificial intelligence. Artificial intelligence in dentistry is a method of creating a second informed opinion that is based on mathematical decision making and prediction. Neural network technologies are applied in areas such as analysis of dental radiographs, prediction of oral treatment needs in children, classification of dental plaque and treatment planning for orthognathic surgery, and assisted diagnosis of caries.

The purpose of the study was to develop an optimal neural network structure to assess the risk of complications in implant treatment of partial and total tooth loss.

Material and methods. For the effective selection the optimal topology of the neural network to assess the risk of complications in the implant treatment of tooth loss a series of experimental simulations of neural network architectures by trial and error was conducted. The database was a table of 1800 patient clinical cases. A total of 1626 clinical cases were used for the simulations, which were divided into data for training and testing at a percentage of 80 to 20. Modelling was done using the high-level programming language Python 3.8.8. All the simulations were performed on a 3.00 GHz Intel(R) Core(TM) i5-8500 processor with 16 GB RAM and a 64-bit Windows 10 operating system.

Results. Because of the simulations, plots of recognition accuracy as well as error values for each of the developed neural network topologies were obtained. To improve the accuracy of the developed neural network topologies to assess the risk of complications during the implant treatment of maxillofacial pathology, a statistical study of the collected simulation database was conducted. For investigation the relationship between each patient parameter and the «implant engraftment acceptability» parameter, a parametric statistical method represented by the correlation coefficient was chosen. As a result of modeling by trial and error method it was found that using the neural network architecture № 7 without batch normalization layers (BatchNorm1d) allows achieving faster learning results with rather high recognition accuracy in a smaller number of epochs. Transforming the simulation base and reducing the input signal size significantly improved the recognition accuracy in comparison with the results of the first simulation of the different neural network systems for recognition of the implant engraftment success. The proposed topology of the neural network № 5 is the most optimal for the accuracy of recognition of the successful implant survival.

KEYWORDS: neural network technologies, dental implants, neural networks, mathematical modeling, neural network architecture.

CONFLICT OF INTEREST. The authors declare that they have no conflicts of interest.

Введение

В настоящее время медицина считается одной из стратегических и перспективных областей для эффективного внедрения искусственного интеллекта. Нейросетевые технологии имеют потенциал для обнаружения взаимосвязей и закономерностей в больших данных [1] и могут позволить компьютерам проводить вспомогательную диагностику и прогнозирование заболеваний, а также предлагать дальнейшие варианты лечения [2]. Искусственный интеллект в стоматологии является методом создания второго обоснованного мнения, которое основано на математическом принятии решений и прогнозировании. Машинное обучение, как правило, не предназначено для замены специалиста-стоматолога. Нейросетевые технологии применяются в таких областях как анализ рентгенограмм зубов [3], прогнозирование потребности в лечении полости рта у детей [4], классификация зубных отложений и планирование лечения для ортогнатической хирургии [5], вспомогательное диагностирование кариеса [6].

На сегодняшний день актуальным является применение технологий искусственного интеллекта в системах поддержки принятия клинических решений в области стоматологии [7–8]. Экспертные системы на основе нейронных сетей можно обучать только на клинических данных и их можно использовать в тех случаях, когда принятие решений «на основе правил» невозможно.

Выбор топологии и настройка весов связей искусственной нейронной сети являются одними из важнейших этапов при использовании нейросетевых технологий для решения практических задач, в частности, для задачи оценки риска осложнений при имплантационном лечении патологий челюстно-лицевой области.

Целью нашей работы является разработка оптимальной структуры нейронной сети для оценки риска осложнений при имплантационном лечении частичной и полной потери зубов. В качестве критерия оптималь-

ности топологии принимается способность обученной сети заданной топологии к обобщению, т. е. к правильному функционированию на примерах, не вошедших в обучающую выборку. В качестве типа нейронной сети был выбран многослойный персептрон с прямой связью. В качестве функции активации применялась функция ReLU, которая является наиболее часто используемой функцией активации при глубоком обучении. Функция ReLU обладает такими преимуществами перед сигмоидой и гиперболическим тангенсом как быстрый и простой расчет производной, а также разреженность активации, которая позволяет уменьшить количество включаемых нейронов.

Материал и методы исследования

Для эффективного подбора оптимальной топологии нейронной сети оценки риска осложнений при имплантационном лечении потери зубов был проведен ряд экспериментальных моделирований нейросетевых архитектур методом проб и ошибок. Для проведения моделирования были использованы клинические случаи базы данных приживаемости имплантатов на основе описания историй болезни пациентов. База данных представляла собой таблицу клинических случаев пациентов в количестве 1800, которые включали в себя 50 параметров, разделенные на 3 категории – состояние пациента (общие факторы; состояние зубочелюстной системы; состояние воспринимающего ложа. Параметр приживаемости имплантатов представлен двумя возможными значениями – «успешная приживаемость имплантата», «отторжение имплантата», которые являются классами для нейросетевого распознавания клинических случаев. Для моделирования были использованы 1626 клинических случаев, которые были разделены на данные для обучения и тестирования в процентном соотношении 80 к 20.

Моделирование проводилось с использованием высокоуровневого языка программирования Python

3.8.8. Все расчеты проводились на ПК с процессором Intel(R) Core (TM) i5-8500 с частотой 3,00 ГГц с 16 ГБ оперативной памяти и 64-битной операционной системой Windows 10.

Каждый из 50 параметров клинического случая был преобразован в двоичный код. Возраст пациентов был округлен до значений, кратных 5. В результате двоичной кодировки каждый клинический случай был представлен 426 символами, состоящими из «0» и «1». Пример закодированных клинических случаев представлен в таблице 1.

Для моделирования были использованы различные линейные нейросетевые архитектуры. На вход каждой нейронной сети поступали 426 символов после двоичной кодировки каждого клинического случая. В результате ряда проведенных экспериментальных моделирований были разработаны 4 варианта топологии нейронной сети для оценки риска осложнений при имплантационном лечении патологий челюстно-лицевой области, которые позволили получить высокие результаты точности распознавания успешности приживаемости имплантатов. Разработанные топологии нейронных сетей представлены на рис. 1.

Таблица 1

Пример клинических случаев приживаемости имплантатов, представленный в виде двоичного кода

№	20	25	30	35	40	45	50	55	60	65	Статус соседнего медиального зуба отсутствует	Статус соседнего медиального зуба пломба	Статус соседнего дистального зуба здоровый	Статус соседнего дистального зуба коронка	Статус соседнего дистального зуба коронка	Статус соседнего дистального зуба отсутствует
2	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0
3	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0
4	0	0	0	0	0	0	0	0	1	0	1	0	0	0	0	1
5	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1
6	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0

Топология № 1

```
BinaryClassification(
  (layer_1): Linear(in_features=426, out_features=128, bias=True)
  (layer_2): Linear(in_features=128, out_features=32, bias=True)
  (layer_out): Linear(in_features=32, out_features=1, bias=True)
  (relu): ReLU()
  (dropout): Dropout(p=0.1, inplace=False)
  (batchnorm1): BatchNorm1d(128, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (batchnorm2): BatchNorm1d(32, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
)
```

Топология № 2

```
BinaryClassification(
  (fc1): Linear(in_features=426, out_features=50, bias=True)
  (relu1): ReLU()
  (dout): Dropout(p=0.2, inplace=False)
  (fc2): Linear(in_features=50, out_features=100, bias=True)
  (prelu): ReLU(inplace=True)
  (out): Linear(in_features=100, out_features=1, bias=True)
)
```

Топология № 3

```
BinaryClassification(
  (layer_1): Linear(in_features=426, out_features=256, bias=True)
  (layer_2): Linear(in_features=256, out_features=128, bias=True)
  (layer_3): Linear(in_features=128, out_features=64, bias=True)
  (layer_out): Linear(in_features=64, out_features=1, bias=True)
  (relu): ReLU()
  (dropout): Dropout(p=0.2, inplace=False)
  (batchnorm1): BatchNorm1d(256, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (batchnorm2): BatchNorm1d(128, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (batchnorm3): BatchNorm1d(64, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
)
```

Топология № 4

```
BinaryClassification(
  (fc1): Linear(in_features=426, out_features=512, bias=True)
  (relu1): ReLU()
  (dout): Dropout(p=0.2, inplace=False)
  (fc2): Linear(in_features=512, out_features=256, bias=True)
  (prelu): PReLU(num_parameters=1)
  (out): Linear(in_features=256, out_features=1, bias=True)
)
```

Рисунок 1. Топологии нейронных сетей 1–4 для распознавания успешности приживаемости имплантатов

Результаты исследования

В результате моделирования были получены графики точности распознавания, а также величины ошибки для

каждой из разработанных топологий нейронных сетей, которые представлены на рис. 2–5.




Рисунок 2. Графики обучения и тестирования топологии нейронной сети № 1: а – величина ошибки; б – точность распознавания

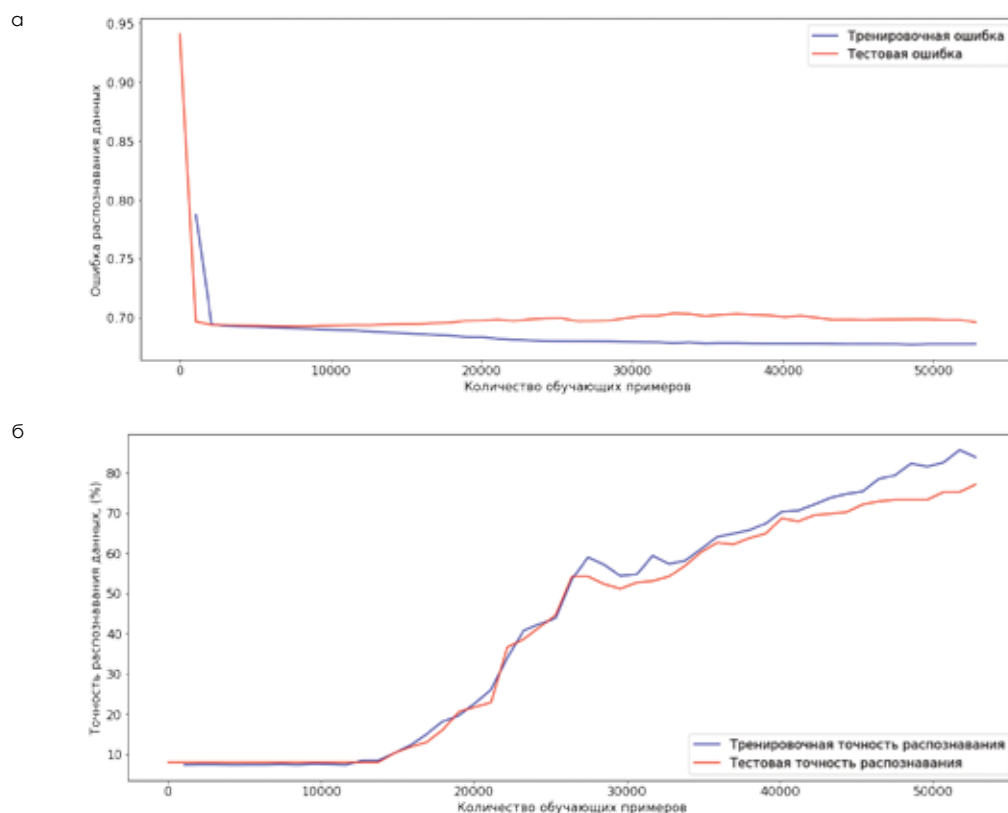


Рисунок 3. Графики обучения и тестирования топологии нейронной сети № 2: а – величина ошибки; б – точность распознавания




Рисунок 4. Графики обучения и тестирования топологии нейронной сети № 3: а – величина ошибки; б – точность распознавания




Рисунок 5. Графики обучения и тестирования топологии нейронной сети № 4: а – величина ошибки; б – точность распознавания

В результате проведенного моделирования методом проб и ошибок было установлено что использование нейросетевых архитектур № 2 и № 4 без слоев пакетной нормализации (BatchNorm1d) позволяет добиться более высокой точности распознавания за меньшее количество эпох. На первой эпохе наблюдается переобучение нейронных сетей без слоев пакетной нормализации. Модели адаптируются к обучающим примерам, вместо улучшения результатов классификации тестовых данных. Результаты моделирования разработанных топологий нейронных сетей для распознавания успешности приживаемости имплантатов представлены в таблице 2.

Таблица 2
Результаты моделирования разработанных топологий нейронных сетей для распознавания успешности приживаемости имплантатов

Нейросетевая архитектура	Точность распознавания, %	Значение ошибки	Время обучения, с.
№ 1	90,07	0,51	14,44
№ 2	77,09	0,69	10,00
№ 3	90,84	0,56	27,47
№ 4	79,77	0,69	17,70

В результате анализа таблицы 2 можно сделать вывод о том, что использование слоев пакетной нормализации (BatchNorm1d) ускоряет время обучения моделей, при этом для достижения более высоких результатов точности распознавания требуется большее количество эпох обучения.

Для улучшения точности разработанных топологий нейронных сетей оценки риска осложнений при имплантационном лечении патологий челюстно-лицевой области было проведено статистическое исследование собранной базы данных для моделирования. Для исследования взаимосвязи между каждым параметром пациента и параметром «приживаемости имплантатов» был выбран метод параметрической статистики, представленный коэффициентом корреляции. Наиболее распространенными типами коэффициентов связи являются коэффициент корреляции Пирсона [23], коэффициент ранговой корреляции Кендалла [24] и коэффициент ранговой корреляции Спирмена [25].

Коэффициент корреляции Пирсона позволяет определить наличие или отсутствие линейной зависимости между двумя параметрами, а также оценить статическую значимость. Коэффициент корреляции Пирсона r_{xy} может принимать значения $-1 \leq r_{xy} \leq 1$, где $r_{xy} = \pm 1$ свидетельствует о полной зависимости между параметрами, $r_{xy} = 0$ означает, что корреляция между параметрами отсутствует. Чем больше абсолютное значение r_{xy} – тем выше взаимосвязь и корреляционная сила между двумя параметрами. Коэффициент ранговой корреляции Кендалла τ может также принимать значения $-1 \leq \tau \leq 1$. Коэффициент ранговой корреляции Спирмена принимает значение $\rho = 1$ если оба параметра обладают прямой линейной зависимостью, а $\rho = -1$ обозначает обратную линейную зависимость параметров.

Параметр «Возраст на момент имплантации» разделен на три группы в соответствии с классификацией

возрастов, принятой Всемирной организацией здравоохранения (ВОЗ). Первая группа «молодого возраста» представлена пациентами в возрасте до 44 лет. Вторая группа «среднего возраста» представлена пациентами в возрасте от 45 до 59 лет. Третья группа «пожилого возраста» представлена пациентами в возрасте от 60 лет и выше.

Для расчета коэффициентов корреляции все параметры были преобразованы в ранги. Если параметр «Пол» представляет собой выборку y , которая включает в себя значения $y = (y_1, y_2, y_3, \dots, y_m)$, где m является количеством клинических случаев базы данных. То при преобразовании параметра в ранги, каждая переменная выборки y принимает значения $ym = 0$, если пол пациента женский и $ym = 1$, если пол пациента мужской. Пример преобразования параметров пациентов в ранги представлен в таблице 3.

В результате проведения корреляционных расчетов были получены таблицы с коэффициентами корреляции, которые представлены в таблице 4. Полученные коэффициенты корреляции показали низкую зависимость каждого из параметров пациентов на успешность приживаемости имплантатов. В результате анализа полученных данных была установлена необходимость уменьшения вариативности значений каждого из параметров.

Дальнейшая обработка имеющихся данных для моделирования позволила уменьшить требуемое для нейросетевой архитектуры количество входных нейронов с 426 до 50 за счет преобразования каждой переменной в одно из трех возможных значений – положительное влияние (значение переменной «хорошо»), нейтральное влияние (значение переменной «средне») и негативное влияние на успешность приживаемости имплантатов (значение переменной «плохо»). Пример преобразованных переменных представлен в таблице 5.

На полученной базе данных было повторно проведено моделирование методом проб и ошибок для установления оптимальных топологий нейронных сетей оценки риска осложнений при имплантационном лечении патологий челюстно-лицевой области.

На вход каждой нейронной сети поступали данные, включающие в себя 50 символов после кодировки каждого клинического случая. В результате ряда проведенных экспериментальных моделирований были разработаны еще 3 варианта топологии нейронной сети для оценки риска осложнений при имплантационном лечении патологий челюстно-лицевой области, которые позволили получить высокие результаты точности распознавания успешности приживаемости имплантатов. Разработанные топологии нейронных сетей представлены на рис. 6.

В результате моделирования были получены графики точности распознавания, а также величины ошибки для каждой из разработанных топологий нейронных сетей, которые представлены на рис. 7–9. Результаты моделирования разработанных топологий нейронных сетей для распознавания успешности приживаемости имплантатов представлены в таблице 6.

Таблица 3
Пример преобразования в ранги базы данных приживаемости имплантатов

Таблица клинических случаев пациентов

Состояние пациента (общие факторы), все заболевания указывать при наличии установленного диагноза.				
Пол	Доступность для постоянного контроля (время необходимое пациенту для явки на прием)	Особенности профессиональной деятельности	Ишемическая болезнь сердца	Степени артериальной гипертензии
Жен.	Постоянный контроль непрогнозируем	Не связана с вредными условиями труда	Не наблюдается	Оптимальная менее 120/80
Жен.	Доступен для постоянного контроля	Не связана с вредными условиями труда	Не наблюдается	АГ 2 степень – 160–179/100–109
Муж.	Доступен для постоянного контроля	Не связана с вредными условиями труда	Не наблюдается	АГ 2 степень – 160–179/100–109
Жен.	Доступен для постоянного контроля	Не связана с вредными условиями труда	Не наблюдается	АГ 2 степень – 160–179/100–109
Жен.	Доступен для постоянного контроля	Не связана с вредными условиями труда	Не наблюдается	АГ 2 степень – 160–179/100–109
Жен.	Доступен для постоянного контроля	Не связана с вредными условиями труда	Не наблюдается	АГ 2 степень – 160–179/100–109
Жен.	Постоянный контроль непрогнозируем	Не связана с вредными условиями труда	Не наблюдается	Оптимальная менее 120/80
Жен.	Постоянный контроль непрогнозируем	Не связана с вредными условиями труда	Не наблюдается	Оптимальная менее 120/80

↓
Преобразование в ранги
↓

Таблица клинических случаев пациентов, преобразованных в ранги

Состояние пациента (общие факторы), все заболевания указывать при наличии установленного диагноза.				
Доступность для постоянного контроля (время необходимое пациенту для явки на прием)	Особенности профессиональной деятельности	Ишемическая болезнь сердца	Степени артериальной гипертензии	
1	0	0	0	
0	0	0	1	
0	0	0	1	
0	0	0	1	
0	0	0	1	
0	0	0	1	
1	0	0	0	
1	0	0	0	

Таблица 4
Результаты расчетов коэффициентов корреляции между параметрами пациентов и параметром «приживаемости имплантатов»

		Корреляция Пирсона категории	Корреляция Спирмена категории	Корреляция Кендалла категории
Состояние пациента (общие факторы), все заболевания указывать при наличии установленного диагноза	Возраст на момент имплантации, лет	-0,0120	-0,0121	-0,0115
	Пол	0,0044	0,0044	0,0044
	Доступность для постоянного контроля (время необходимое пациенту для явки на прием)	-0,0154	-0,0154	-0,0154
	Особенности профессиональной деятельности	-0,0124	-0,0161	-0,0160
	Ишемическая болезнь сердца	-0,0008	-0,0179	-0,0174
	Степени артериальной гипертензии	-0,0458	-0,0587	-0,0541
	Препараты, связанные с заболеваниями ССС	0,0345	0,0309	0,0297
	Заболевания желудочно-кишечного тракта (ОФ – острая форма, ХФ – хроническая форма)	0,0749	0,0509	0,0494
	Эндокринные нарушения	0,0699	0,0712	0,0711
	Сахарный диабет, по классификации ВОЗ	0,1088	0,1011	0,1006
	Препараты при сахарном диабете	-0,1059	-0,1061	-0,1056
	Заболевания опорно-двигательного аппарата	0,0862	0,0862	0,0862
	Остеопороз	-0,0022	-0,0018	-0,0018
	Онкологические заболевания ЧЛО головы и шеи III клиническая группа	-0,0107	-0,0113	-0,0113
	Онкологические заболевания отдаленных органов, системные заболевания III клиническая группа	0,0776	0,0817	0,0816
	Прием бифосфонатов	-	-	-
	Прием антикоагулянтов	0,0093	0,0100	0,0100
	Гепатит	-0,0018	0,0064	0,0063
	COVID-19	0,0522	0,0292	0,0292
Состояние зубочелюстной системы	Психические расстройства, со слов пациент	-0,0113	-0,0113	-0,0113
	Аллергические реакции	-0,0344	-0,0389	-0,0381
	Курение			
	Гигиена полости рта (индекс Силнеса – Лоз)	0,1075	0,1369	0,1245
	Заболевания СОПР	0,0230	0,0229	0,0229
	Височно-нижнечелюстной расстройство	0,0533	0,0533	0,0533
	Бруксизм	0,0853	0,0796	0,0796
	Пародонтальное заболевание	-0,0466	-0,0531	-0,0490
	Состояние правой верхне-челюстной пазухи	-0,0523	-0,0458	-0,0439
	Состояние левой верхне-челюстной пазухи	-0,0380	-0,0323	-0,0311
	Ортодонтическое лечение	-0,0318	-0,0310	-0,0309
	Проводимое ранее имплантационное лечение в полости рта	0,0997	0,1183	0,1168

Таблица 5

Пример преобразования переменных экспериментальной базы данных приживаемости имплантатов на основе описания историй болезни пациентов

	Гигиена полости рта	Заболевания СОПР	Височно-нижнечелюстное расстройство	Бруксизм	Пародонтальное заболевание	Состояние правой верхней челюстной пазухи	Ортодонтическое лечение	Проводимое ранее имплантационное лечение полости рта
0	средне	хорошо	хорошо	хорошо	хорошо	средне	хорошо	хорошо
2	средне	хорошо	хорошо	хорошо	средне	хорошо	хорошо	хорошо
3	средне	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо
3	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо
4	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо	хорошо
...								
1622	средне	средне	хорошо	хорошо	Плохо	хорошо	хорошо	хорошо
1623	средне	средне	хорошо	хорошо	Плохо	хорошо	хорошо	хорошо
1624	средне	средне	хорошо	хорошо	Плохо	хорошо	хорошо	хорошо
1625	средне	средне	хорошо	хорошо	Плохо	хорошо	хорошо	хорошо
1626	средне	средне	хорошо	хорошо	Плохо	хорошо	хорошо	хорошо

Топология № 5

```
BinaryClassification(
  (layer_1): Linear(in_features=50, out_features=1000, bias=True)
  (layer_2): Linear(in_features=1000, out_features=500, bias=True)
  (layer_out): Linear(in_features=500, out_features=1, bias=True)
  (relu): ReLU()
  (dropout): Dropout(p=0.1, inplace=False)
  (batchnorm1): BatchNorm1d(1000, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
  (batchnorm2): BatchNorm1d(500, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
)
```

Топология № 6

```
BinaryClassification(
  (layer_1): Linear(in_features=50, out_features=128, bias=True)
  (layer_out): Linear(in_features=128, out_features=1, bias=True)
  (relu): ReLU()
  (dropout): Dropout(p=0.1, inplace=False)
  (batchnorm1): BatchNorm1d(128, eps=1e-05, momentum=0.1, affine=True, track_running_stats=True)
)
```

Топология № 7

```
BinaryClassification(
  (fc1): Linear(in_features=50, out_features=100, bias=True)
  (relu1): ReLU()
  (dout): Dropout(p=0.2, inplace=False)
  (fc2): Linear(in_features=100, out_features=150, bias=True)
  (prelu): ReLU(inplace=True)
  (out): Linear(in_features=150, out_features=1, bias=True)
)
```

Рисунок 6. Топологии нейронных сетей 7–10 для распознавания успешности приживаемости имплантатов




Рисунок 11. Графики обучения и тестирования топологии нейронной сети № 5: а – величина ошибки; б – точность распознавания




Рисунок 12. Графики обучения и тестирования топологии нейронной сети № 6: а – величина ошибки; б – точность распознавания




Рисунок 13. Графики обучения и тестирования топологии нейронной сети № 6: а – величина ошибки; б – точность распознавания

Таблица 6

Результаты моделирования разработанных топологий нейронных сетей распознавания успешности приживаемости имплантатов

Нейросетевая архитектура	Точность распознавания, %	Значение ошибки	Время обучения, с.
№ 5	94,08	0,14	54,53
№ 6	93,47	0,15	48,92
№ 7	93,55	0,69	12,65

Заключение

В результате проведенного моделирования методом проб и ошибок было установлено что использование нейросетевой архитектуры № 7 без слоев пакетной нормализации (BatchNorm1d) позволяет добиться более быстрых результатов обучения с достаточно высокой точностью распознавания за меньшее количество эпох. Преобразование базы для моделирования и уменьшение размера входного сигнала позволило значительно повысить точность распознавания по сравнению с результатами первого моделирования различных нейросетевых систем распознавания успешности приживаемости имплантатов. Предложенная топология нейронной сети № 5 является наиболее оптимальной по точности распознавания успешности приживаемости имплантатов.

На данном этапе разработанная топология нейронной сети способна выдавать прогноз о положительном или отрицательном исходе операции по установке одиночного дентального имплантата. Также разработанная интеллектуальная система может быть использована для выработки конкретных рекомендаций врачу и пациенту следующим

образом. Для пациента генерируются «виртуальные копии» с различными значениями в параметрах, на которые может быть оказано влияние (например, статус курения, характер питания и т. д.). После чего сгенерированные «виртуальные копии» поочередно обрабатываются предложенной нейронной сетью. При улучшении результата интеллектуального прогноза по сравнению с исходными параметрами пациента врачу выдается рекомендация об изменении параметра для снижения рисков осложнений.

В качестве дальнейших исследований планируется разработка модуля детального нейросетевого исследования для выведения процента влияния каждого фактора в общей картине клинического случая. Также планируется разработка и внедрение технологий для генерации рекомендаций по снижению рисков осложнений с указанием определенных факторов, влияющих на клиническую ситуацию.

Список литературы / References

1. D.W. Kim, H. Kim, W. Nam et. al. «Machine learning to predict the occurrence of bisphosphonate-related osteonecrosis of the jaw associated with dental extraction: A preliminary report», Bone, vol. 116, p. 207–214, Nov. 2018, doi: 10.1016/J.BONE.2018.04.020.

2. Y.K. Chan, Y.F. Chen, T. Pham et. al. «Artificial Intelligence in Medical Applications», *J Healthc Eng*, 2018, July. 2018, doi: 10.1155/2018/4827875.
3. J.H. Lee, D.H. Kim, and S.N. Jeong. «Diagnosis of cystic lesions using panoramic and cone beam computed tomographic images based on deep learning neural network», *Oral Dis*, t. 26, vol. 1, p. 152–158, Jan. 2020, doi: 10.1111/ODI.13223.
4. Y. Wang et. al. «Developing Children's Oral Health Assessment Toolkits Using Machine Learning Algorithm», *JDR Clin Trans Res*, t. 5, vol. 3, p. 233–243, Jul. 2020, doi: 10.1177/2380084419885612.
5. H. il Choi et. al. «Artificial Intelligent Model with Neural Network Machine Learning for the Diagnosis of Orthognathic Surgery», *Journal of Craniofacial Surgery*, t. 30, vol. 7, p. 1986–1989, Oct. 2019, doi: 10.1097/SCS.0000000000005650.
6. R. Mansour, A. Al-Marghilnai, and Z.A. Hagas, «Use of artificial intelligence techniques to determine dental caries : A systematic review», 2019.
7. F. Jiang et. al. «Artificial intelligence in healthcare: past, present and future», *Stroke Vasc Neurol*, t. 2, vol. 4, p. 230–243, Dec. 2017, doi: 10.1136/SVN-2017-000101.
8. S. Khanna. «Artificial intelligence: contemporary applications and future compass», *Int Dent J*, t. 60, vol. 4, p. 269–272, Aug. 2010, doi: 10.1922/IDJ_2422KHAN-NA04.

Данное исследование проведено в рамках выполнения гранта по программе Старт-1, договор №4521ГС1/73957 с ФГБУ «Фонд содействия развитию малых форм предприятий в научно-технической сфере» о предоставлении гранта на проведение научно-исследовательских и опытно-конструкторских работ по теме: «Разработка и тестирование прототипа программного обеспечения поддержки принятия врачебных решений при установке дентальных имплантатов, с учетом прогнозирования нейронными сетями на основе индивидуальных особенностей пациента».

Статья поступила / Received 09.11.2022
Получена после рецензирования / Revised 19.11.2022
Принята в печать / Accepted 21.11.2022

Информация об авторах

Долгалева Александр Александрович^{1, 2}, д. м. н., профессор кафедры стоматологии общей практики и детской стоматологии, начальник центра инноваций и трансфера технологий научно-инновационного объединения, профессор кафедры клинической стоматологии с курсом ХС и ЧЛХ.

ORCID: 0000-0002-6352-6750. E-mail: dolgalev@dolgalev.pro

Мурьев Александр Александрович³, д. м. н., профессор кафедры челюстно-лицевой хирургии и хирургической стоматологии.

ORCID: 0000-0003-3982-5512. SPIN-код: 1431-5936. AuthorID: 611838.

E-mail: muraev_aa@pfur.ru

Ляхов Павел Алексеевич⁴, заведующий кафедрой математического моделирования, факультета математики и компьютерных наук имени профессора Н.И. Червякова.

ORCID: 0000-0003-0487-4779. E-mail: ljahov@mail.ru

Ляхова Ульяна Алексеевна⁴, младший научный сотрудник отдела модулярных вычислений и искусственного интеллекта.

ORCID: 0000-0002-2949-7036. E-mail: uljahovs@mail.ru

Чонияшвили Давид Зурабович⁵, к. м. н., доцент кафедры терапевтической, хирургической и детской стоматологии с курсом имплантология, реконструктивная хирургия полости рта, детская ЧЛХ, декан медицинского факультета, главный врач.

ORCID: 0000-0003-4218-1359. E-mail: davidchoniashvili@mail.ru

Золотаев Кирилл Евгеньевич¹, соискатель кафедры стоматологии общей практики и детской стоматологии.

ORCID: 0000-0003-2347-5378. E-mail: kzolotaev@yandex.ru

Семериков Дмитрий Юрьевич⁶, врач стоматолог-ортопед, стоматолог-хирург.

ORCID: 0000-0001-8843-4580. E-mail: sim2457@gmail.com

Аванисян Вазген Михайлович¹, ординатор 1 года обучения кафедры терапевтической стоматологии.

ORCID: 0000-0002-0316-5957, SPIN-код: 1207-9234. E-mail: avanvaz@yandex.ru

¹ ФГБОУ ВО «Ставропольский государственный медицинский университет» Министерства здравоохранения РФ, Ставрополь, Российская Федерация

² Общество с ограниченной ответственностью «Имплант Аддитивные технологии», г. Ставрополь, Российская Федерация

³ ФГАОУ ВО «Российский университет дружбы народов», Москва, Российская Федерация

⁴ ФГАОУ ВО «Северо-Кавказский федеральный университет», Ставрополь, Российская Федерация

⁵ ФГБОУ ВО «Северо-Осетинский государственный университет имени Коста Левановича Хетагурова» (СОГУ), Владикавказ, Российская Федерация

⁶ Общество с ограниченной ответственностью «Стоматологическая клиника Валентина», г. Нягань, Российская Федерация

Контактная информация:

Вазген Михайлович Аванисян. E-mail: avanvaz@yandex.ru

Author information

Dolgalev Alexander Alexandrovich^{1, 2}, PhD, MD, Head of the Center for Innovation and Technology Transfer, Professor of the Department of General Practice Dentistry and Pediatric Dentistry, Professor of the Department of Clinical Dentistry with a course of OS and MFS.

ORCID: 0000-0002-6352-6750. E-mail: dolgalev@dolgalev.pro

Muraev Alexander Alexandrovich³, MD, Professor, Department of maxillofacial surgery and surgical dentistry

ORCID: 0000-0003-3982-5512. SPIN-код: 1431-5936. AuthorID: 611838.

E-mail: muraev_aa@pfur.ru

Lyakhov Pavel Alekseyevich⁴, Head of Mathematical Modelling Department, Faculty of Mathematics and Computer Science named after Professor N.I. Chervyakov

ORCID: 0000-0003-0487-4779. E-mail: ljahov@mail.ru

Lyakhova Ulyana Alekseevna⁴, Junior Researcher at the Department of Modular Computing and Artificial Intelligence.

ORCID: 0000-0002-2949-7036. E-mail: uljahovs@mail.ru

Choniashvili David Zurabovich⁵, Candidate of Medical Sciences, Associate Professor of the Department of Therapeutic, Surgical and Pediatric Dentistry with courses in Implantology, Reconstructive Oral Surgery, Pediatric maxillofacial surgery, Dean of the Medical Faculty

ORCID: 0000-0003-4218-1359. E-mail: davidchoniashvili@mail.ru

Zolotaev Kirill Evgenievich¹, Postgraduate student of the Department of General Practice and Pediatric Dentistry

ORCID: 0000-0003-2347-5378. E-mail: kzolotaev@yandex.ru

Semerikov Dmitry Yurievich, Dental prosthodontist, dental surgeon.

ORCID: 0000-0001-8843-4580. E-mail: sim2457@gmail.com

Avanysyan Vazgen Mikhailovich¹, 1st year resident at the Department of Therapeutic Dentistry

ORCID: 0000-0002-0316-5957, SPIN-код: 1207-9234. E-mail: avanvaz@yandex.ru

¹ Stavropol State Medical University of the Ministry of Health of the Russian Federation, Stavropol, Russian Federation

² Limited Liability Company «Implant Additive Technologies», Stavropol, Russian Federation

³ Federal State Educational Institution of Higher Education «Peoples' Friendship University of Russia», Moscow, Russian Federation

⁴ Federal State Educational Institution of Higher Professional Education «North Caucasian Federal University», Stavropol, Russian Federation

⁵ Federal State Budgetary Educational Institution of Higher Professional Education «Kosta Khetagurov North Ossetian State University» (NOSU), Vladikavkaz, Russian Federation

⁶ Valentina Dental Clinic LLC, Nyagan, Russian Federation

Contact information

Vazgen Mikhailovich Avanysyan. E-mail: avanvaz@yandex.ru

Для цитирования: Долгалева А.А., Мурьев А.А., Ляхов П.А., Ляхова У.А., Чонияшвили Д.З., Золотаев К.Е., Семериков Д.Ю., Аванисян В.М. Определение оптимальной структуры нейронной сети при разработке программ для поддержки принятия решений в дентальной имплантации. Медицинский алфавит. 2022;(34):54-64. <https://doi.org/10.33667/2078-5631-2022-34-54-64>

For citation: Dolgalev A.A., Muraev A.A., Lyakhov P.A., Lyakhova U.A., Choniashvili D.Z., Zolotaev K.E., Semerikov D.Yu., Avanysyan V.M. Determining the optimal neural network structure for the development of decision support programmes in dental implantation. Medical alphabet. 2022;(34):54-64. <https://doi.org/10.33667/2078-5631-2022-34-54-64>

