

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ В БИМЕДИЦИНСКИХ СИСТЕМАХ

INFORMATION TECHNOLOGIES IN BIOMEDICAL SYSTEMS

УДК 004.855.5

DOI: 10.17587/it.25.41-45

К. Ш. Исмаилова, канд. техн. наук, доц., e-mail: is_kamalya@yahoo.com,
Азербайджанский государственный университет нефти и промышленности, Баку

Применение различных методов оптимизации при расчете погрешности нейронной сети для диагностирования нервно-мышечных заболеваний

Проводится сравнение и выбор оптимального метода при расчете погрешности обучаемой нейронной сети для решения задачи диагностирования нервно-мышечных заболеваний. Выбрана совокупность значений электромиографических сигналов нормального и патологических состояний пациентов. Результаты тестирования оцениваются по абсолютным и относительным значениям ошибок на пяти интервалах для выявления лучшего метода оптимизации. Для поставленной задачи лучшие результаты получены при применении метода оптимизации BFGS.

Ключевые слова: нейронные сети, методы оптимизации, нервно-мышечные заболевания, абсолютная погрешность, относительная погрешность, градиентный спуск, модифицированный Par Tap, сопряженные градиенты, BFGS

Введение

Биомедицинские сигналы представляют собой электрические сигналы, генерируемые любым органом, отражающие функциональное состояние исследуемого органа. Электромиография (ЭМГ) является техникой для оценки и регистрации электрической деятельности скелетных мышц. Основные интересы исследований лежат в области клинической, а также биомедицинской инженерии. Достижения в области инженерии расширили возможности электромиографии за пределы традиционных диагностических приложений и позволяют использовать их в различных областях.

Традиционно нейрофизиолог может получить доступ к потенциалам мышечных единиц (ПМЕ) и оценивать информацию по полученным паттернам и параметрам сигналов. ПМЕ из разных моторных нейронов перекрывают друг друга, и это приводит к формированию интерференционной картины, что затрудняет точное определение отдельных паттернов. По этой причине были разработаны различные алгоритмы количественного компьютерного анализа ЭМГ. К числу таких алгоритмов относятся и алгоритмы искусственного интеллекта — нейронные, нейронечеткие, гибридные и т. д. Методы искусственного интеллекта эф-

фективно используются в медицинских диагностических инструментах для повышения точности диагностики и предоставления дополнительных знаний.

Искусственная нейронная сеть (ИНС) представляет собой систему соединенных и взаимодействующих между собой простых процессоров. Персептрон является одной из первых моделей нейронных сетей, способен обучаться и основывается при этом на статистических данных. Информация об образе распределяется по весовым коэффициентам (аналогично коэффициентам системы уравнений), которые в совокупности описывают те или иные фрагменты образа.

В информационных источниках существует много подходов для обработки ЭМГ сигналов с использованием этих алгоритмов. В работе [1] использованы различные виды методов обучения для классификации сигналов ЭМГ. Модель автоматически классифицирует сигналы ЭМГ как нормальную, миопатическую и нейропатическую. Чтобы извлечь полезную информацию из ЭМГ, используют различные способы экстракции признаков, такие как дискретное вейвлет-преобразование (DWT) и авторегрессивное моделирование (AR). Адаптивный нейронечеткий вывод системы (ANFIS) с гибридным алгоритмом обучения,

метод опорных векторов (SVM) и нечеткая модификация метода опорных векторов (FSVM) позволяют классифицировать ЭМГ-сигналы путем сравнения их по признаку точности.

В работе [2] предлагается классификация нервно-мышечных заболеваний из сигналов ЭМГ на основе сочетания различных методов извлечения объектов и типов классификаторов. Комбинация вейвлет-преобразования (WT) и метода опорных векторов улучшает точность классификации по сравнению с другими комбинациями.

Исследователи в работе [3] контролировали электрофизиологическую активность мышц, используя биологическую обратную связь, полученную из сигналов электромиограмм, собранных в соответствующих точках иннервации. Предлагается комплексный метод выявления нервно-мышечных заболеваний у субъекта и стратегия непрерывной терапевтической оценки с использованием матрицы оценки реабилитации. Инструмент принятия решений прошел обучение с использованием широкого спектра физиологических данных, включающих различную степень миопатии и невропатии от начальных стадий к острым. Статистические, спектральные и кепстральные признаки, извлеченные из ЭМГ, использовались для обучения классификатора нейронной сети с каскадной корреляцией для оценки заболеваний. Для оценки качества работы ИНС используются такие статистические показатели, как точность, специфичность и чувствительность. Диагностический выход классификатора составляет 91,2 % точности, 85,3 % специфичности и 91,35 % чувствительности. Стратегия также была расширена за счет включения изотонических сокращений в дополнение к статическим изометрическим сокращениям. Эта комплексная стратегия предлагается как помощь врачам при планировании процедуры лечения, чтобы максимально повысить терапевтическую ценность процесса реабилитации.

Методы вычислительной разведки (бесконтактный доступ к компьютерной информации, циркулирующей в информационной системе) и машинного обучения, такие как искусственные нейронные сети (ANN), служат мощным инструментом для анализа сигналов ЭМГ и создания оптимальных схем миоэлектрического контроля для протезов. В исследовании [4] анализируется эффективность четырех различных нейронных сетевых структур (прямое, повторяющееся, встречное распространение и самоорганизующаяся карта), которым было

поручено классифицировать скорость ходьбы при использовании входов ЭМГ из 14 различных мышц ног. Эксперименты свидетельствуют о том, что самоорганизующиеся карты нейронных сетей способны классифицировать скорость ходьбы с точностью более 99 %.

Метод опорных векторов — широко используемый метод машинного обучения со многими приложениями для классификации биомедицинских сигналов. В работе [5] предложена новая модель PSO-SVM, которая гибридизировала методы оптимизации роя частиц (PSO) и SVM для улучшения точности классификации сигналов ЭМГ. Этот механизм оптимизации включает настройку параметров ядра в процедуре обучения SVM, что существенно влияет на точность классификации. Эксперименты проводили на основе сигнала ЭМГ для классификации на нормальный, нейрогенный или миопатический. Полученные результаты, очевидно, подтверждают превосходство метода SVM по сравнению с обычными методами машинного обучения и предполагают, что предлагаемая система классификации PSO-SVM дает дополнительные существенные улучшения с точки зрения точности классификации.

В работе [6] представлена методология глобальной оптимизации нейронной сети. Целью является одновременная оптимизация многоуровневых весовых и архитектурных характеристик персептрона (MLP) для создания топологий с несколькими соединениями и высокой степенью классификации для любых наборов данных. Этот подход сочетает в себе преимущества имитационной модели и алгоритма обучения *backpropagation* для создания автоматического процесса проектирования сетей с высокой степенью классификации и низкой сложностью. Экспериментальные результаты, полученные для четырех задач классификации и одной задачи прогнозирования, оказались лучше, чем полученные с помощью наиболее часто используемых методов оптимизации.

В статье [7] дается обзор многочисленных методов, доступных для распознавания структур движения сигналов ЭМГ как для изотонических, так и для изометрических сокращений. Различные методы анализа сигналов сравниваются, результаты иллюстрируют их применимость в настройках реального времени. Это представляет интерес для исследователей, которые хотели бы выбрать наиболее подходящую методологию для классификации движений, особенно при различных типах сокращений мышц. Для извлечения признаков

в качестве основной принимается функция плотности вероятности (PDF) сигналов ЭМГ. После краткого описания различных методов предварительной обработки, извлечения признаков и классификации сигналов ЭМГ проведем их сравнение с точки зрения их производительности.

Метод расчета погрешностей нейронных сетей

Известно, что важным и самым доступным индикатором нейронно-сетевых систем являются погрешности вычислений. Самые распространенные виды погрешностей, характеризующиеся легкостью вычисления, — это абсолютные и относительные погрешности (ошибки), которые вычисляются по следующим формулам [8]:

- абсолютная погрешность

$$P_A = P_n - P_3;$$

- относительная погрешность

$$P_O = \frac{P_n - P_3}{P_3} \cdot 100,$$

где P_n — ответ (диагноз) сети; P_3 — истинный диагноз (входное значение).

Для эксперимента выбраны электромиографические сигналы в норме и в патологическом состоянии: при карпальном туннельном синдроме, кубитальном туннельном синдроме и демиелинизирующей нейропатии. В качестве входных параметров сети выбраны данные 16 точек измерения для диагностирования. Использованы 26 нормальных и 34 патологических сигнала для создания обучающей совокупности сети.

Выход сети OUTPUT содержит четыре элемента:

1 — норма; 2 — полиневропатия; 3 — карпальный туннельный синдром; 4 — кубитальный туннельный синдром.

Компьютерная реализация эксперимента

Компьютерная реализация эксперимента проводилась в программной среде NeuroPro 0.25, и для обучения сети были выбраны методы оптимизации: градиентный спуск, модифицированный *Par Tan*, сопряженные градиенты, *BFGS*.

Фрагменты результатов первого эксперимента и расчет погрешности даны в табл. 1—4.

Таблица 1

Фрагмент результата прогнозирования с помощью многослойного персептрона методом оптимизации "градиентный спуск"

Заданное значение	Полученное значение	Абсолютная ошибка	Относительная ошибка
1	1,2463	0,2463	24,6313
1	1,2538	0,2538	25,3780
1	1,1084	0,1084	10,8361
1	1,2290	0,2290	22,9043
2	1,7661	-0,2339	-11,6943
2	2,1642	0,1642	8,2084
2	2,2029	0,2029	10,1441
3	2,7355	-0,2645	-8,8180
3	2,7288	-0,2712	-9,0384
4	4,2662	0,2662	6,6550
4	3,8891	-0,1109	-2,7716
4	4,2564	0,2564	6,4100

Таблица 2

Фрагмент результата прогнозирования с помощью многослойного персептрона методом оптимизации "модифицированный *Par Tan*"

Заданное значение	Полученное значение	Абсолютная ошибка	Относительная ошибка
1	1,2988	0,2988	29,8753
1	1,2725	0,2725	27,2539
1	1,1259	0,1259	12,5930
1	1,2302	0,2302	23,0237
2	1,7203	-0,2797	-13,9873
2	2,1983	0,1983	9,9146
2	2,2777	0,2777	13,8863
3	2,7718	-0,2282	-7,6082
3	2,7404	-0,2596	-8,6537
4	3,9893	-0,0107	-0,2681
4	3,7240	-0,2760	-6,9007
4	3,9131	-0,0869	-2,1725

Таблица 3

Фрагмент результата прогнозирования с помощью многослойного персептрона методом оптимизации "сопряженные градиенты"

Заданное значение	Полученное значение	Абсолютная ошибка	Относительная ошибка
1	1,2193	0,2193	21,9344
1	1,2832	0,2832	28,3217
1	1,0870	0,0870	8,7026
1	1,1494	0,1494	14,9437
2	1,7178	-0,2822	-14,1088
2	2,1470	0,1470	7,3521
2	2,8329	0,8329	41,6473
3	2,8329	-0,1671	-5,5685
3	2,7245	-0,2755	-9,1838
4	4,2747	0,2747	6,8685
4	3,9931	-0,0069	-0,1729
4	4,2719	0,2719	6,7966

Таблица 4

Фрагмент результата прогнозирования с помощью многослойного персептрона методом оптимизации "BFGS"

Заданное значение	Полученное значение	Абсолютная ошибка	Относительная ошибка
1	1,2903	0,2903	29,0290
1	1,2729	0,2729	27,2865
1	1,1298	0,1298	12,9763
1	1,2034	0,2034	20,3440
2	1,7179	-0,2821	-14,1065
2	2,1506	0,1506	7,5296
2	2,2543	0,2543	12,7168
3	2,7295	-0,2705	-9,0155
3	2,7724	-0,2276	-7,5863
4	4,0351	0,0351	0,8785
4	4,0744	0,0744	1,8596
4	4,0764	0,0764	1,9106

Для сравнения методов оптимизации использовано число значений ошибок, попавших в выбранный интервал. Выбрано пять интервалов для абсолютных ошибок. Значение интервалов и число абсолютных ошибок, попавших в соответствующий интервал, приведены в табл. 5.

Для сравнения методов оптимизации с использованием относительных ошибок тоже выбрано пять интервалов. Значения интервалов и число относительных ошибок, попавших в соответствующие интервалы, даны в табл. 6.

Таблица 5

Сравнение абсолютных ошибок

№ эксперимента	Число абсолютных ошибок в соответствующем интервале				
	<0,05	0,05...0,09	0,1...0,19	0,2...0,29	>0,3
1	0	0	3	9	0
2	0	2	2	8	0
3	1	1	3	7	0
4	1	2	2	7	0

Таблица 6

Сравнение относительных ошибок

№ эксперимента	Число относительных ошибок в соответствующих интервалах				
	< 1	1...9	10...19	20...29	> 30
1	0	6	3	3	0
2	1	5	3	3	0
3	1	6	2	2	1
4	1	5	3	3	0

Сравнение проводили с точки зрения того, в каком из экспериментов было меньше ошибок с большими значениями. Так, результаты 1-го и 2-го экспериментов дают большое число ошибок с большими значениями (табл. 5). Несмотря на то, что число ошибок в результатах 3-го и 4-го экспериментов не очень различаются, выбран 4-й вариант с учетом малого числа ошибок в 3-м интервале.

Аналогичные рассуждения можно провести и для данных табл. 6. Здесь значения 2-го и 4-го экспериментов совпадают, но выбран 4-й вариант, так как в табл. 5 в этом эксперименте было получены наилучшие результаты.

Заключение

Сравнение методов оптимизации с помощью погрешностей сети дает возможность сделать вывод, что для поставленной задачи лучшие результаты получены при применении метода оптимизации BFGS.

Такой подход облегчает работу экспериментатора в выборе метода оптимизации при работе с нейронными сетями для задачи диагностирования нервно-мышечных заболеваний с точки зрения оценки погрешностей сети.

Список литературы

1. **Akhila Devi B. V., Priyadharsini S. S.** Diagnosis Of Neuromuscular Disorders Using Softcomputing Techniques // International Journal of Soft Computing and Engineering (IJSCE). 2013. Vol. 3, Iss. 5. P. 105—111.
2. **Kehri V., Ingle R., Awale R., Oimbe S.** Techniques of EMG signal analysis and classification of Neuromuscular diseases // Advances in Intelligent Systems Research. Vol. 137. P. 485—491.
3. **Sailesh Conjeti, Bijay Kumar Rout.** Strategy For Electromyography Based Diagnosis Of Neuromuscular Diseases For Assistive Rehabilitation // International Journal on Bioinformatics & Biosciences (IJBB). 2013. Vol. 3, N. 3. P. 25—39.
4. **Alayna Kennedy, Rory Lewis.** Optimization Of Neural Network Architecture For Biomechanic Classification Tasks With Electromyogram Inputs // International Journal of Artificial Intelligence and Applications (IJAIA). 2016. Vol. 7, N. 5. P. 1—16.
5. **Subasi A.** Classification of EMG Signals Using PSO optimized SVM for Diagnosis of Neuromuscular Disorders // Computers in Biology and Medicine. 2013. N. 43. P. 576—586.
6. **Ludermir T. B., Yamazaki A., Zanchettin C.** An Optimization Methodology for Neural Network Weights and Architectures // IEEE Transactions On Neural Networks. 2006. Vol. 17, N. 6. P. 1452—1459.
7. **Nurhazimah N.** et all. A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions // Sensors. 2016. N. 16. P. 1304—1332.
8. **Куликов Л. К., Быкова Н. М., Привалов Ю. А., Навтнович Н. А., Шабанова О. Г.** Диагностика гиперальдостеронизма Т больных с инциденталомиями надпочечников при помощи нейронных сетей // Фундаментальные исследования. 2010. № 3. С. 88—94. URL: <http://www.fundamental-research.ru/ru/article/view?id=6659> (дата обращения: 30.02.2018).

Application of Various Optimization Methods for Calculating the Neural Network Error for the Diagnosis of Neuromuscular Diseases

The proposed work is devoted to the calculation of the error of the neural network for comparison and the choice of the optimal method for teaching this problem. Analysis of the literature shows that the problem of finding the optimal number of neurons of the hidden layer does not have a unique solution due to the lack of an established methodology. There are four specific limitations that distinguish the training of a neurocomputer from common optimization tasks: the astronomical number of parameters, the need for high parallelism in learning, the multicriteria nature of the problems being solved, the need to find a sufficiently wide area in which the values of all minimized functions are close to minimal. It is known that the most important and most accessible indicator of such systems are the results of errors. The most common of the errors, and at the same time, the absolute and relative errors that are easy to calculate. The output of the OUTPUT network contains four elements: 1 is the norm; 2 — polyneuropathy; 3 — carpal tunnel syndrome; 4 — a cubital tunnel syndrome. Computer implementation of the experiment was carried out in the NeuroPro 0.25 software environment and optimization methods were chosen for network training: Gradient descent, Modified Par Tan, Conjugate gradients, BFGS. To compare the optimization methods, the number of error values within the selected interval is used. Five intervals for absolute errors are selected. To compare optimization methods using relative errors, five intervals are chosen. Comparison of optimization methods with the help of network errors makes it possible to conclude that for this task the best results were obtained using the BFGS optimization method.

Keywords: neural network errors, optimization methods, neuromuscular diseases, absolute error, relative error, gradient descent, modified Par Tan, conjugate gradients, BFGS

DOI: 10.17587/it.25.41-45

References

1. Akhila Devi B. V., Priyadharsini S. S. Diagnosis Of Neuromuscular Disorders Using Softcomputing Techniques, *International Journal of Soft Computing and Engineering (IJSC)*, 2013, vol. 3, iss. 5, pp. 105—111.
2. Kehri V., Ingle R., Awale R., Oimbe S. Techniques of EMG signal analysis and classification of Neuromuscular diseases, *Advances in Intelligent Systems Research*, vol. 137, pp. 485—491.
3. Sailesh Conjeti, Bijay Kumar Rout. Strategy For Electromyography Based Diagnosis Of Neuromuscular Diseases For Assistive Rehabilitation, *International Journal on Bioinformatics & Biosciences (IJBB)*, 2013, vol. 3, no.3, pp. 25—39.
4. Alayna Kennedy, Rory Lewis. Optimization Of Neural Network Architecture For Biomechanic Classification Tasks With Electromyogram Inputs. *International Journal of Artificial Intelligence and Applications (IJAA)*, 2016, vol. 7, no. 5, pp. 1—16
5. Subasi A. Classification of EMG Signals Using PSO optimized SVM for Diagnosis of Neuromuscular Disorders, *Computers in Biology and Medicine*, 2013, no. 43, pp. 576—586.
6. Ludermir T. B., Yamazaki A., Zanchettin C. An Optimization Methodology for Neural Network Weights and Architectures, *IEEE Transactions On Neural Networks*, 2006, vol. 17, no. 6, pp. 1452—1459.
7. Nurhazimah N. et al. A Review of Classification Techniques of EMG Signals during Isotonic and Isometric Contractions. *Sensors*, 2016, no. 16, pp. 1304—1332.
8. Kulikov L. K., Bykova N. M., Privalov Ju. A., Navtanovich N. A., Shabanova O. G. Diagnostika giperaldosteronizma T bolnyh s incidentalomami nadpochechnikov pri pomoshhi neyronnyh setey (Diagnosis of hyperaldosteronism in patients with adrenal incidents with neural networks), *Fundamentalniye issledovaniya*, 2010, vol. 3, pp. 88—94 (in Russian), available at: <http://www.fundamental-research.ru/ru/article/view?id=6659> (date of access: 30.02.2018) (in Russian).