

Глубокое обучение в задаче информационного анализа электрокардиограмм для диагностики заболеваний

Игнатов Андрей

Московский физико-технический институт
Факультет управления и прикладной математики
Кафедра интеллектуальных систем

Научный руководитель: д.ф.-м.н., с.н.с. ВЦ РАН К. В. Воронцов

1 июля 2015 г.

Цели исследования

Дано:

- выборка кардиограммы здоровых и больных людей
- для каждой ЭКГ — данные variability сердечного ритма: интервалы и амплитуды кардиоциклов (T_i, R_i)

Задача:

- построить **алгоритм диагностики**, не требующий преобразования исходных данных в признаковое описание
- алгоритм должен обучаться на **исходных временных рядах**

Критерий:

- процент верной диагностики заболеваний

Данные

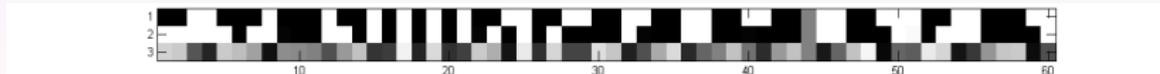
Выборка:

- данные variability сердечного ритма
- 192 здоровых людей
- 9396 людей с 14 различными заболеваниями

Вариабельность сердечного ритма:

- интервалы T_n между QRS комплексами
- амплитуды R_n комплексов
- отношение $\alpha_n = \arctg\left(\frac{R_n}{T_n}\right)$

Визуальное представление:



Особенности задачи

Особенности задачи:

- малый объем выборки (~ 600)
- стандартные алгоритмы классификации не работают на рассматриваемых данных

Требования к модели:

- учесть гипотезу о существовании паттернов заболеваний — коротких фрагментов временного ряда (T_n, R_n) , специфичных для заболеваний
- использование нескольких уровней представления данных
- наличие малого количества тренируемых параметров

Методы

Методы исследования:

- *Глубокое обучение*
- *Сверточные нейронные сети*
- *Автокодировщики*

Подходы:

- *обучение с учителем*
- *предварительное предобучение без учителя с целью выделения признаков*

Литература

- V. Uspenskiy. Information function of the heart. A measurement model // MEASUREMENT 2011, vol. 1, p. 383–386, 2011.
- Y. Bengio [et al.]. Representation learning: A review and new perspectives // IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 35, p. 1798–1828, 2013.
- H. Cecotti, A. Graeser. Convolutional neural network with embedded fourier transform for eeg classification // 19th International Conference on Pattern Recognition, p. 599–619, 2008.
- P. Baldi. Autoencoders, unsupervised learning, and deep architectures // ICML Unsupervised and Transfer Learning, vol. 27, p. 37–50, 2012.

Сверточные нейронные сети

Дано:

- $d_{x,y}$ - входное изображение
- $w_{i,j}$ - веса ядра свертки
- (k_m, k_n) - размер ядра свертки
- (s_x, s_y) - шаг свертки
- $\sigma()$ - нелинейная функция активации

Значения $d'_{x,y}$ на выходе слоя определяются по формуле:

$$d'_{x,y} = \sigma\left(\sum_{i=k_m}^{-k_m} \sum_{j=k_n}^{-k_n} d_{x+i,y+j} \times w_{i,j}\right)$$

Автокодировщик

Пусть:

- \mathbf{x} - исходный вектор
- $\mathbf{W}_1, \mathbf{W}_2$ - матрицы весов энкодера и декодера
- $\sigma()$ - нелинейная функция активации

Кодирование:

$$\mathbf{f}(\mathbf{x}) = \sigma(\mathbf{W}_1\mathbf{x} + \mathbf{b}_1),$$

Декодирование:

$$\tilde{\mathbf{x}} = \sigma(\mathbf{W}_2\mathbf{f}(\mathbf{x}) + \mathbf{b}_2),$$

Задача оптимизации:

$$\operatorname{argmin}_{\mathbf{W}, \mathbf{b}} \frac{1}{2} \sum_{\mathbf{x} \in X} \|\mathbf{x} - \tilde{\mathbf{x}}\|_2^2$$

Модификация сверточного слоя

Идея:

- вместо ядра свертки используется автоэнкодер
- обучение автоэнкодера проводится на небольших фрагментах исходных данных

Пусть:

- $D_{x,y} = |d_{x+i,y+j}|$, $i = \overline{0, k_m - 1}$, $j = \overline{0, k_n - 1}$
- $f()$, $g()$ - энкодер и декодер

Значения $d'_{x,y}$ на выходе слоя определяются по формуле:

$$d'_{x,y} = f(D_{x,y})$$

$$\text{где } (f, g) = \operatorname{argmin}_{f, g} \frac{1}{2} \sum_{D_{x,y}} \|D_{x,y} - g \circ f(D_{x,y})\|_2^2$$

Модификация сверточного слоя

Преимущества метода:

- автоматическое нахождение паттернов в исходных данных
- снижение размерности почти без потери информации
- использование для обучения неразмеченных данных

Вычислительный эксперимент

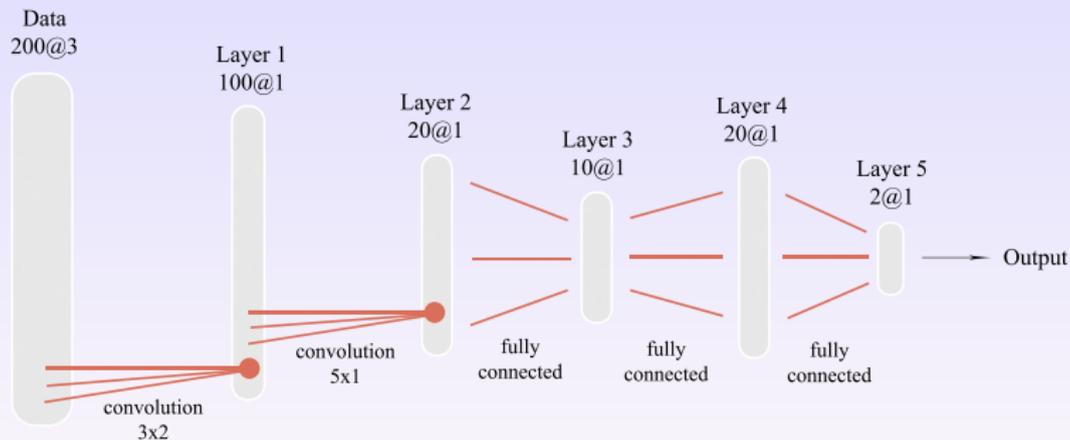
Проведено сравнение трех подходов:

- Алгоритм Успенского^[1] + KNN
- Сверточная нейронная сеть
- Сверточная нейронная сеть с модифицированным сверточным слоем

[1] Успенский В.М. Информационная функция сердца. - М.: «Экономика и информация», 2008. -116 с.

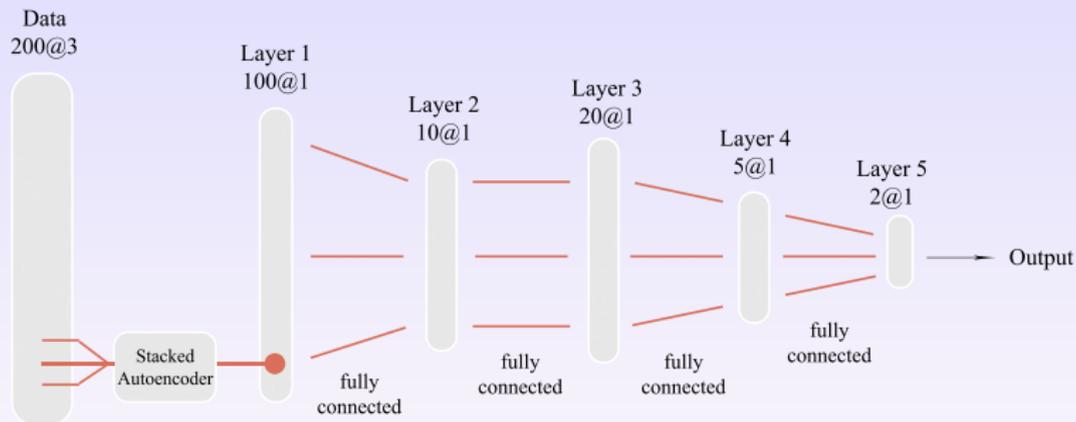
Первая модель

Архитектура сверточной нейронной сети



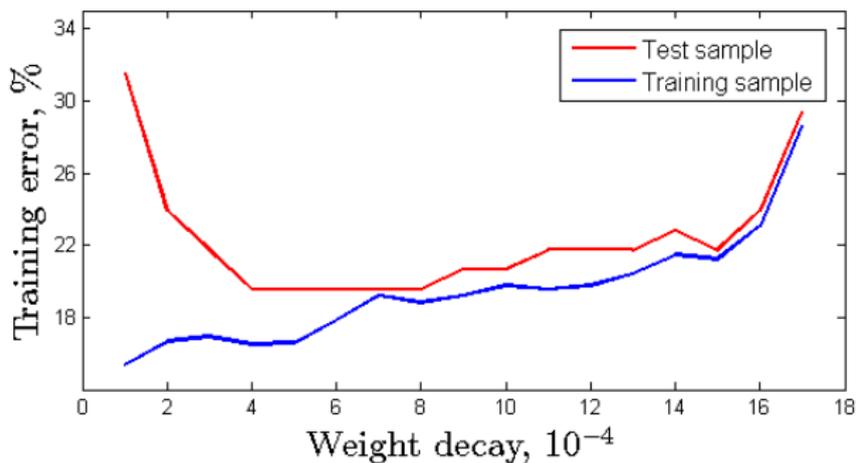
Вторая модель

Архитектура сети с модифицированным сверточным слоем



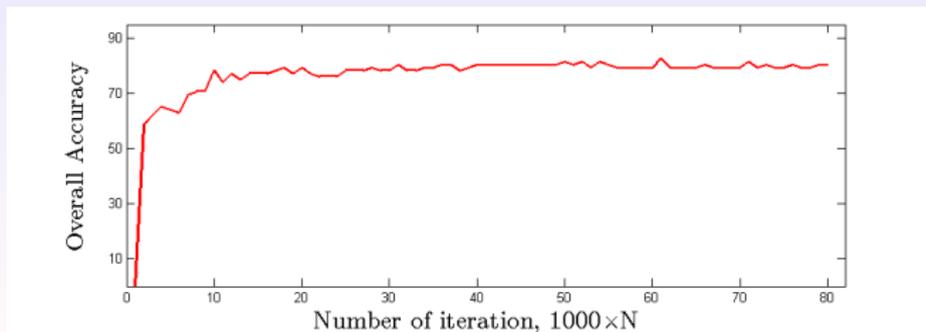
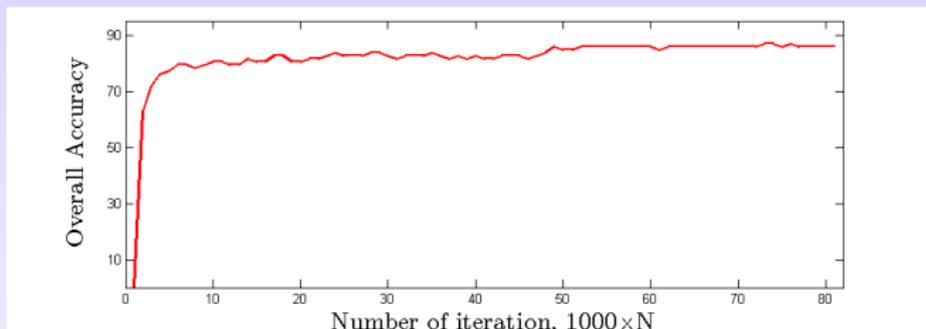
Регуляризация

Зависимость результатов обучения от коэффициента регуляризации для болезни 13



Обучение

Зависимость ошибки на контрольной выборке от номера итерации



Результаты классификации по всем болезням

Болезнь	Метод Успенского	Сверточная НС	Модификация НС
1	73.53	78.24	82.35
2	94.83	97.04	97.54
3	90.22	90.22	92.39
4	96.84	95.09	97.19
5	84.05	88.96	89.57
6	90.37	88.23	91.44
7	92.23	93.20	93.20
8	92.13	92.13	92.70
9	86.55	88.30	88.30
10	84.62	90.38	90.38
11	78.16	80.46	83.90
12	89.53	87.21	93.02
13	85.87	80.43	86.96
14	88.95	88.42	90.00

Результаты классификации

Средняя точность классификации по всем болезням:

- Алгоритм Успенского + *KNN*: | 87.71%
- Сверточная нейронная сеть: | 88.45%
- Сверточная сеть предложенной модификации: | 90,64%

Заключение

- предложен метод диагностики заболеваний по исходным данным variability сердечного ритма, основанный на использовании архитектуры сверточной нейронной сети
- предложена модификация структуры сверточного слоя, позволившего поднять качество классификации

Публикации:

Andrey D. Ignatov, Vadim V. Strijov. Human activity recognition using quasiperiodic time series collected from a single tri-axial accelerometer // Multimedia Tools and Applications, 2015, vol. 74, no. 11.