

УДК 519.7:007.52

Е. В. Бодянский, Е. А. Винокурова, А. Н. Слипченко, А. В. Шило

ИДЕНТИФИКАЦИЯ ФАЗ СНА В РЕАЛЬНОМ ВРЕМЕНИ
НА ОСНОВЕ ГИБРИДНЫХ НЕЙРОННЫХ СЕТЕЙ

1. Введение

В связи с ростом количества заболеваний сердечно-сосудистой системы и сопутствующим ростом расстройств сна в середине 90-х годов прошлого века был развернут Европейский проект SIESTA, одной из целей которого является развитие новых способов описания цикла «сон—бодрствование» человека с высоким временным разрешением, полностью автоматических и свободных от субъективных критериев.

Для создания автоматических анализаторов сна используются системы, построенные на основе амплитудного и частотного анализа в отдельных диапазонах частот, скрытая модель Маркова, использующие один канал электроэнцефалограммы (ЭЭГ), вейвлет-преобразование (для идентификации специфических феноменов сна) и ряд других современных подходов [1–3]. Тем не менее, надежность определения стадий сна составляет 75...80 %, что является недостаточным для корректного анализа и обуславливает необходимость привлечения дополнительных критериев и разработки новых алгоритмов реального времени для более строгой идентификации нарушений цикла «сон — бодрствование». Четкая идентификация последних является чрезвычайно важной как для постановки правильного диагноза, так и для выработки оптимальной стратегии коррекции выявленной патологии [4].

2. Постановка задачи

На содержательном уровне задача идентификации фаз сна/бодрствования может быть разбита на два относительно независимых этапа. На первом этапе необходимо сформировать некоторый набор признаков, характеризующих наблюдаемый сигнал (ЭЭГ) в каждый момент времени. Второй этап будет заключаться собственно в определении класса, к которому относится текущее состояние (бодрствование, медленноволновой сон, парадоксальный сон и т. п.).

На формальном уровне первый этап заключается в идентификации наблюдаемого сигнала. Часто вместо модели системы, генерирующей наблюдаемый временной ряд, рассматривают модель предиктора этого временного ряда, так как эти модели во многих случаях эквивалентны [5]. Таким образом, в качестве набора признаков, характеризующих состояние объекта в текущий момент времени, могут использоваться параметры прогнозирующей модели.

Традиционно для получения прогноза временного ряда используется математическая конструкция, называемая предиктором, которая некоторым образом комбинирует имеющуюся информацию о предыдущих значениях исследуемой последовательности и ошибках прогнозирования. В зависимости от вида

этой комбинации различают линейные и нелинейные предикторы. Линейные модели предикторов (AR, MA, ARMA) получили широкое распространение, однако многие современные приложения (в частности, медико-биологические) явно требуют применения нелинейных подходов. Нелинейные модели предикторов (NAR, NMA, NARMA) являются обобщением соответствующих линейных.

Для того, чтобы иметь возможность отслеживать изменения свойств исследуемого процесса, необходимо проводить настройку параметров модели в реальном масштабе времени по мере поступления новых данных и уменьшать влияние устаревшей информации. Такая постановка приводит к решению следующей оптимизационной задачи:

$$E(k) = \frac{1}{2} \sum_{p=1}^k \alpha^{k-p} (y(p) - \hat{y}(p))^2 \rightarrow \min, \quad (1)$$

где k — текущий момент времени; $y(p)$ — наблюдаемый сигнал в момент времени p ; $\hat{y}(p)$ — прогноз значения наблюдаемого сигнала в момент времени p ; $\alpha \in [0, 1]$ — коэффициент дисконтирования, регулирующий скорость забывания устаревшей информации.

Второй этап, как уже отмечалось, заключается в классификации состояния объекта, которое характеризуется вектором параметров предиктора в каждый момент времени. Как известно, оптимальным в смысле минимизации вероятности ошибки является байесовский классификатор [6, 7]. Формально задача классификации состояния объекта сводится к проверке статистической гипотезы при наличии нескольких альтернатив. При этом предполагается, что известны условные плотности распределения вероятностей вектора признаков $P(X | \omega_i)$ и априорные вероятности каждого класса $P(\omega_i)$. В этом случае решающее правило будет иметь следующий вид:

$$X \in \omega_i; \\ P(\omega_i | X) > P(\omega_j | X), \forall j \neq i.$$

С учетом теоремы Байеса это выражение может быть переписано следующим образом:

$$X \in \omega_i; \\ P(\omega_i)P(X | \omega_i) > P(\omega_j)P(X | \omega_j), \forall j \neq i. \quad (2)$$

С целью обеспечения возможности более тонкой настройки классификатора, а также в силу того, что не все классы одинаково важны для последователей, решающее правило (2) может быть модифицировано следующим образом:

$$X \in \omega_i; \\ c_i P(\omega_i)P(X | \omega_i) > c_j P(\omega_j)P(X | \omega_j), \forall j \neq i, \quad (3)$$

где c_i — вес, связанный с i -м классом.

3. Архитектура нейронной сети

Для восстановления нелинейной комбинации входов прогнозирующей модели была применена нейронная сеть [8–11], реализующая отображение вида

$$\hat{y}(k) = \hat{f}(x(k)) = \sum_{i=1}^n \sum_{j=1}^{h_i} w_{ij} \varphi_{ij}(x_i(k)), \quad (4)$$

где w_{ij} — синаптические веса, подлежащие определению; $\varphi_{ij}(\bullet)$ — активационные функции скалярного аргумента. При этом для каждого зафиксированного i функции $\varphi_{ij}(\bullet)$ образуют ортогональную систему. Отметим, что предлагаемая архитектура содержит $h = \sum_{i=1}^n h_i$ настраиваемых параметров, т. е. не подвержена проклятию размерности [8].

Данная архитектура была выбрана в силу того, что:

1) выход сети линейно зависит от настраиваемых параметров, что позволяет использовать оптимальные по быстродействию алгоритмы обучения и решать задачу (1) в реальном времени по мере поступления новых данных [8, 9];

2) данная ИНС обеспечивает возможность восстановления нелинейных отображений [12, 13];

3) поскольку используемые активационные функции образуют ортогональную систему, алгоритм обучения обладает высокой численной устойчивостью [8, 9].

Для классификации временного ряда была разработана модель на основе байесовского подхода.

4. Алгоритм обучения нейронной сети

Для удобства дальнейшего изложения перепишем выражение для выхода нейронной сети в виде:

$$\hat{y}(k+1) = \Phi^T(k) \hat{W}(k),$$

где $\Phi(k) = (\varphi_{11}(k), \dots, \varphi_{1h_1}(k), \dots, \varphi_{nh_n}(k))^T - ((h_1 + \dots + h_n) \times 1)$ — вектор ортогональных функций активации в момент времени k ; $\hat{W}(k) = (\hat{w}_{11}(k), \dots, \hat{w}_{1h_1}(k), \dots, \hat{w}_{nh_n}(k))^T - ((h_1 + \dots + h_n) \times 1)$ — вектор текущих значений синаптических весов.

В силу того, что выход нейронной сети линейно зависит от настраиваемых параметров, для оценки синаптических весов можно применить метод наименьших квадратов

$$\hat{W}(k+1) = (\Phi^T(k) \Phi(k))^{-1} \Phi^T(k) Y(k+1), \quad (5)$$

где $\Phi = (\Phi(0), \Phi(2), \dots, \Phi(k))$, $Y(k) = (y(1), y(2), \dots, y(k))^T$.

Как уже отмечалось, для решения задачи идентификации временного ряда (1) в реальном времени целесообразно применение рекуррентной модификации алгоритма (5), обеспечивающей забывание устаревшей информации (экспоненциально-взвешенный рекуррентный метод наименьших квадратов):

$$\begin{cases} \hat{W}(k+1) = \hat{W}(k) + \\ + \frac{P(k)(y(k+1) - \hat{W}^T(k)\Phi(k+1))\Phi(k+1)}{\alpha + \Phi^T(k+1)P(k)\Phi(k+1)}, \\ P(k+1) = \frac{1}{\alpha} \left(P(k) - \frac{P(k)\Phi(k+1)\Phi^T(k+1)P(k)}{\alpha + \Phi^T(k+1)P(k)\Phi(k+1)} \right) \end{cases} \quad (6)$$

где $\alpha \in (0; 1]$ — фактор забывания.

5. Результаты моделирования

Эксперименты были проведены на 7–8-месячных белых крысах линии Вистар массой 180...200 г в летний период времени (июнь — август). Животных содержали в условиях вивария при регулируемом цикле «свет — темнота» (12:12), где они получали стандартный рацион и воду *ad libitum*. Для контроля за функциональным состоянием животного под тиопенталовым наркозом (смесь тиопентала натрия/оксibuтирата натрия) производили стереотаксическую операцию по вживлению двух корковых электродов (область сенсомоторной и зрительной коры, биполярное отведение) и двух электродов для регистрации активности мышц шеи. Опыты начинали не ранее, чем через неделю после операции. По истечении послеоперационного восстановительного периода животных помещали в экспериментальную камеру и через вращающийся токосъемник (не ограничивающий двигательную активность животного) подсоединяли к электроэнцефалографу (BST-1). Усиленные сигналы биоэлектрической активности мозга и мышц через аналогово-цифровой преобразователь (ADDA-14) записывались на жесткий диск персонального компьютера типа Pentium в режиме *on-line* для визуального мониторинга и сохранения. Последующая обработка проводилась с помощью специально разработанного пакета программ или на М-языке. Первые сутки регистрации рассматривались как адаптационные к условиям регистрации и из анализа исключались. Визуальное выявление стадий сна производили по общепринятым критериям по изменению спектра мощности ЭЭГ, ЭМГ использовалась в качестве вспомогательного параметра.

Эксперименты были проведены в соответствии с «Общими этическими принципами экспериментов на животных», одобренными Первым национальным конгрессом по биоэтике (20 сентября 2001 г., г. Киев, Украина) и согласованными с положениями «Европейской конвенции о защите позвоночных животных, используемых для экспериментальных и других научных целей» (Страсбург, 1985 г.), а также согласно рекомендациям, составляющим один из разделов «Руководства к дотациям и контрактам Национального института здравоохранения США» (1975 г.) — «Принципы использования животных».

Для начальной настройки классификатора часть данных была обработана экспертом, который выделил в них четыре класса: «sws» (медленноволновой сон), «artifact» (нехарактерные участки), «rem» (парадоксальный сон) и «awake» (бодрствование).

Анализ автокорреляционной функции имеющихся данных показал, что для построения прогнозирующей модели достаточно будет взять последние 20 значений (рис. 1). Кроме того, даже визуальный анализ показывает, что автокорреляционные функции, соответствующие различным состояниям, существенно различаются, что свидетельствует о принципиальной возможности их разделения.

В то же время, применение для этих целей самой автокорреляционной функции является плохим решением по целому ряду причин, среди которых стоит отметить следующие:

- для вычисления автокорреляционной функции необходимо наличие достаточно большого объема данных, и такое вычисление не может производиться в реальном времени;
- вычисление автокорреляционной функции на «скользящем» окне приводит к значительному усилению влияния шумов, что в значительной мере усложняет разделение состояний.

Для непосредственной идентификации измеряемого временного ряда использовалась нейронная сеть, на основе которой был синтезирован предиктор на один шаг вперед. Структура входов соответствует модели авторегрессии порядка 21. На каждый вход ИНС было добавлено 5 активационных функций, что дало в сумме 106 настраиваемых параметров.

Обучение ИНС производилось в реальном времени по мере поступления данных с помощью алгоритма (6). Последующие вычислительные эксперименты в ускоренном машинном времени показали, что ПЭВМ с процессором AMD Athlon XP 2000+ и 512 Мб оперативной памяти в состоянии обрабатывать поступающие данные с частотой до 250 Гц.

Настройка параметров c_i модифицированного решающего правила (3) осуществлялась исходя из соображений минимизации ошибки классификации.

Геометрическая интерпретация решающего правила (3) заключается в определении для каждого класса некоторой области Γ_i , при попадании в которую вектора признаков $X(k)$ мы констатируем принадлежность этого вектора классу i . Тогда коэффициенты c_j должны удовлетворять следующей системе неравенств:

$$\forall i, \forall j \neq i:$$

$$\int_{\Gamma_i} c_i P(\omega_i) p(X | \omega_i) dX > \int_{\Gamma_j} c_j P(\omega_j) p(X | \omega_j) dX. \quad (7)$$

В общем случае эта система содержит $n(n-1)$ неравенств, где n — число различаемых классов.

Вычисление интегралов в неравенствах (7) затруднено в силу того, что нам неизвестен ни аналитический вид областей Γ_i , ни условные плотности




Рис. 1. Усредненная нормированная автокорреляционная функция для каждого состояния

$p(X | \omega_i)$. Очевидно, что при наличии выборки, обработанной экспертом, мы можем перейти к более простой задаче:

$$\forall X \in \omega_i, j \neq i:$$

$$c_i \sum P(\omega_i) p(X | \omega_i) > c_j \sum P(\omega_j) p(X | \omega_j).$$

Собственно настройка классификатора была произведена на данных, обработанных экспертом. На них была получена относительная частота появления каждого класса, которая затем использовалась в качестве $P(\omega_i)$. На этих же данных проводилось оценивание условных плотностей $p(X | \omega_i)$. Состояния были пронумерованы следующим образом: 1 — «sws», 2 — «artifact», 3 — «rem», 4 — «awake».

Предварительная «ручная» обработка позволила составить систему из 12 неравенств для $c_i, i = 1, 4$. В результате их решения было получено следующее описание области оптимальных значений этих параметров:

$$c_1 > 0, c_2 > 0, c_3 > 0,$$

$$520.345c_1 < c_2 < 964338c_1,$$

$$4.068c_1 < c_3 < 4.0755c_1,$$

$$3939450c_2 < c_3 < 0.00782841c_2,$$

$$2.92521c_1 < c_4 < 2.92657c_1,$$

$$2833330c_2 < c_4 < 0.00562333c_2,$$

$$0.717458c_3 < c_4 < 0.719219c_3.$$

Анализ полученной области показывает, что она не содержит ни одной точки. Причиной этого является класс № 2 «artifact», для которого не может быть выполнено требование правильной классификации. Исключение этого класса при составлении неравенств позволило получить следующую область для параметров c_1, c_3, c_4 :

$$c_1 > 0, c_3 > 0,$$

$$4.068c_1 < c_3 < 4.075c_1,$$

$$2.925c_1 < c_4 < 2.926c_1,$$

$$0.717c_3 < c_4 < 0.719c_3.$$

Данная область является открытой и содержит бесконечное число точек. Для классификации временного ряда был использованы следующие значения параметров:

$$c_1 = 1, c_2 = 1, c_3 = 4.0726, c_4 = 2.9261. \quad (8)$$

которые были определены с учетом полученных неравенств исходя из $c_1 = 1$.

С учетом полученных значений классификатора была проведена классификация временного ряда. Качество работы предложенного алгоритма было проверено на 400 000 наблюдений, среди которых 22 фрагмента «sws», 10 фрагментов «rem» и 19 фрагментов «awake» (по мнению эксперта). Параллельно и независимо от эксперта проводилась идентификация временного ряда с последующей автоматической классификацией состояния объекта. Далее результат, полученный с помощью разработанной системы, сравнивался с мнением эксперта. На тестовой выборке ошибка классификации составила 5,0919 %, что является хорошим показателем.

6. Заключение

Проведенные эксперименты подтверждают эффективность предложенного подхода, который позволяет проводить идентификацию фаз сон/бодрствование в автоматическом режиме в реальном масштабе времени.

Работа выполнена в рамках выполнения договора о научном сотрудничестве между Институтом проблем криобиологии и криомедицины РАН Укр-

раины и Харьковским национальным университетом радиоэлектроники.

Дальнейшее развитие данных исследований видится в доработке классифицирующей части алгоритма. Предложенная система все еще не может обойтись без эксперта, проводящего классификацию обучающей выборки. Кроме того, на данном этапе невозможно определить, когда наблюдаемый ряд ведет себя нетипично относительно обучающих примеров, т. е. когда объект приходит в аномальное состояние. Требуется дальнейшего улучшения процедуры настройки параметров классификатора.

Список литературы: 1. Anderer P., Gruber G., Parapatics S. An e-health solution for automatic sleep classification according to Rechtschaffen and Kales: validation study of the somnolyzer 24 x 7 utilizing the siesta database // *Neuropsychobiology*. – 2005. – 51. – P. 115–133. 2. Jobert M., Degans A. Wavelets — an improvement in the detection of sleep EEG patterns // *Proc. of 16th Congress of the European Sleep Research Society*, Reykjavik, June 3–7, 2002, P. 168–171. 3. Clark F.M., Radulovacki M. An inexpensive sleep-wake state analyzer for the rat // *Physiol. Behav.* – 1988. – 43. – P. 681–683. 4. Вейн А. М. Сон человека. Физиология и патология. – М.: Медицина, 1989. – 272 с. 5. Льюис Л. Идентификация систем. Теория для пользователя: Пер. с англ. / Под ред. Я. З. Цыпкина. – М.: Наука, 1991. – 432 с. 6. Фукунага К. Введение в статистическую теорию распознавания образов. – М.: Наука, 1979. – 367 с. 7. Xu R., Wunsch D. Survey of Clustering Algorithms // *IEEE Trans. on Neural Networks*. – 2005. – 16, No. 3. – P. 645–687. 8. Bodyanskiy Ye., Kolodyazhnyi V., Slipchenko O. Artificial neural network with orthogonal activation functions for dynamic system identification / Eds. by Sawodny O., Scharff P. «Synergies between Information Processing and Automation». – Aachen: Shaker Verlag, 2004. – P. 24–30. 9. Bodyanskiy Ye., Kolodyazhnyi V., Slipchenko O. Structural and synaptic adaptation in the artificial neural networks with orthogonal activation functions // *Sci. Proc. of Riga Technical University. Comp. Sci., Inf. Technology and Management Sci.* – 2004. – № 20. – P. 69–76. 10. Бодянский Е. В., Винокурова Е. А. Адаптивный вейвлет-нейронный предиктор // *Проблемы бионики*. – 2003. – Вып. 58. – С. 10–17. 11. Bodyanskiy Ye., Lamontova N., Pliss I., Vynokurova O. An adaptive learning algorithm for a wavelet neural network // *Blackwell Synergy: Expert Systems*. – 2005. – Vol. 22, No. 5 – P. 235–240. 12. Liying M., Khorasani K. Constructive Feed-forward Neural Network Using Hermite Polynomial Activation Functions // *IEEE Trans. on Neural Networks*. – 2005. – 16, No. 4. – P. 821–833. 13. Patra J.C., Kot A.C. Nonlinear dynamic system identification using Chebyshev functional link artificial neural network // *IEEE Trans. on System, Man, and Cybernetics*. – Part B. – 2002. – 32. – P. 505–511.

Поступила в редакцию 12.05.2006