



Классификация депрессивных эпизодов на основе ночных измерений: многомерный и одномерный анализ данных

Х.Г. Родригес-Пуис, ORCID: 0000-0002-8690-8049 <jr.ruiz68@uaz.edu.mx>
К.Э. Гальван-Техад, ORCID: 0000-0002-7635-4687 <ericgalvan@uaz.edu.mx>
С. Васкес-Рейес, ORCID: 0000-0002-9435-5499 <vazquez@uaz.edu.mx>
Х.И. Гальван-Техад, ORCID: 0000-0002-7555-5655 <gatejo@uaz.edu.mx>
Х. Гамбоа-Росалес, ORCID: 0000-0002-9498-6602 <hamurabigr@uaz.edu.mx>

*Автономный университет Сакатекаса,
Мексика, 98000, Сакатекас*

Аннотация. Психические расстройства типа депрессии составляют 28% от общего числа заболеваний, связанных с инвалидностью, и около 7,5% инвалидов в мире имеют подобные расстройства. Депрессия – это распространенное расстройство, которое влияет на душевное состояние, ежедневную деятельность, эмоции, а также вызывает нарушения сна. По некоторым оценкам, примерно 50% пациентов с депрессией страдают от нарушений сна. В данной работе процесс извлечения данных для классификации депрессивных и недепрессивных эпизодов в ночное время осуществляется на основе формального метода обнаружения знаний в базах данных (Knowledge Discovery in Databases, KDD). При использовании KDD процесс интеллектуального анализа данных имеет следующие четко выраженные этапы: предварительное обнаружение знаний в базах данных, отбор, предварительная обработка, преобразование, собственно анализ, оценка и последующее обнаружение знаний в базах данных. Для классификации был использован набор данных DEPESJON, в котором содержится информация о двигательной активности 23 пациентов с монополярным и биполярным расстройством и 32 здоровых людей. Для классификации депрессивных и недепрессивных эпизодов были использованы два различных метода – многомерный и одномерный анализ данных. Для многомерного анализа применяется алгоритм случайного леса с моделью, основанной на 8 признаках. Результаты классификации имеют специфичность 0,9927 и чувствительность 0,9991. Одномерный анализ показывает, что наиболее информативной характеристикой модели являются пики активности, обеспечивающие точность 0,908 при классификации депрессивных эпизодов.

Ключевые слова: депрессия; нарушение сна; классификация; добыча данных; обнаружение знаний в базах данных; случайный лес

Для цитирования: Родригес-Пуис Х.Г., Гальван-Техад К.Э., Васкес-Рейес С., Гальван-Техад Х.И., Гамбоа-Росалес Х. Классификация депрессивных эпизодов на основе ночных измерений: многомерный и одномерный анализ данных. Труды ИСП РАН, том 33, вып. 2, 2021 г., стр. 115-124. DOI: 10.15514/ISPRAS-2021-33(2)-6

Classification of Depressive Episodes Using Nighttime Data: Multivariate and Univariate Analysis

J.G. Rodríguez-Ruiz, ORCID: 0000-0002-8690-8049 <jr.ruiz68@uaz.edu.mx>
C.E. Galván-Tejada, ORCID: 0000-0002-7635-4687 <ericgalvan@uaz.edu.mx>
S. Vázquez-Reyes, ORCID: 0000-0002-9435-5499 <vazquez@uaz.edu.mx>
J.I. Galván-Tejada, ORCID: 0000-0002-7555-5655 <gatejo@uaz.edu.mx>
H. Gamboa-Rosales, ORCID: 0000-0002-9498-6602 <hamurabigr@uaz.edu.mx>

*Autonomous University of Zacatecas,
Juarez 147, Zacatecas, 98000, Mexico*

Abstract. Mental disorders like depression represent 28% of global disability, it affects around 7.5% percent of global disability. Depression is a common disorder that affects the state of mind, normal activities, emotions, and produces sleep disorders. It is estimated that approximately 50% of depressive patients suffering from sleep disturbances. In this paper, a data mining process to classify depressive and not depressive episodes during nighttime is carried out based on a formal method of data mining called Knowledge Discovery in Databases (KDD). KDD guides the process of data mining with stages well established: Pre-KDD, Selection, Pre-processing, Transformation, Data Mining, Evaluation, and Post-KDD. The dataset used for the classification is the DEPESJON dataset, which contains the motor activity of 23 unipolar and bipolar depressed patients and 32 healthy controls. The classification is carried out with two different approaches; a multivariate and univariate analysis to classify depressive and non-depressive episodes. For the multivariate analysis, the Random Forest algorithm is implemented with a model construct of 8 features, the results of the classification are specificity equal to 0.9927 and sensitivity equal to 0.9991. The univariate analysis shows that the maximum of the activity is the most descriptive characteristic of the model with 0.908 in accuracy for the classification of depressive episodes.

Keywords: depression; sleep disorders; classification; data mining; kdd; random forest

For citation: Rodríguez-Ruiz J.G., Galván-Tejada C.E., Vázquez-Reyes S., Galván-Tejada J.I., Gamboa-Rosales H. Classification of Depressive Episodes Using Nighttime Data: Multivariate and Univariate Analysis. *Trudy ISP RAN/Proc. ISP RAS*, vol. 33, issue 2, 2021, pp. 115-124 (in Russian). DOI: 10.15514/ISPRAS-2021-33(2)-6

1. Введение

По данным Всемирной организации здравоохранения (ВОЗ), психоневрологические расстройства составляют в общей сложности 28% от общего числа заболеваний в мире, и более трети из них вызваны депрессивными расстройствами, от которых страдают около 322 миллионов человек во всем мире. Большое депрессивное расстройство (major depressive disorder, MDD) относится к числу наиболее распространенных причин инвалидности, встречающегося у около 7,5% населения мира, а также к числу основных причин самоубийств, число которых приближается к 800 000 в год [1]. MDD – это распространенное психическое расстройство, которое влияет на душевное состояние и наряду с аффективным, когнитивным, волевым и соматическим нарушением вызывает у пациентов отсутствие желания жить, а также сказывается на повседневной деятельности и работоспособности [2]. Диагностику MDD лучше всего проводить во время депрессивных эпизодов. При биполярном расстройстве они выражаются в виде резкой потери самообладания, а при монополярном – в виде ухудшения настроения. MDD можно диагностировать на основании шкалы Монтгомери-Асберга для оценки депрессии (Montgomery-Asberg Depression Rating Scale MADRS), которая является диагностическим опросом, используемым психиатрами для оценки тяжести протекающего MDD с помощью ряда вопросов, выявляющих факторы риска MDD [3].

В работе Р. Армитаж (Roseanne Armitage) [4] об электроэнцефалографии во время сна делается вывод о том, что сон является подходящим периодом для диагностики MDD. Нарушения сна влияют, по крайней мере, на четверть населения мира, и они напрямую связаны с MDD. Даже когда поставлен диагноз MDD и пациент начал лечение, нарушения сна, как правило, могут продолжаться в основном из-за побочных действий антидепрессантов [5], [6]. Бессонница, гиперсомния, гипосомния и заторможенность – это лишь некоторые виды нарушения сна, выявленные как при монополярной, так и биполярной депрессии [7].

Сегодня машинное обучение широко используется для прогнозирования, диагностики и выявления психических расстройств. Существует три типа обучения: с учителем, без учителя и с частичным привлечением учителя. Данные методы обычно используются для прогнозирования развития болезни или для выявления чрезвычайных ситуаций у пациентов с психическими заболеваниями, такими как болезнь Альцгеймера, депрессия и шизофрения. И среди них депрессия является заболеванием, наиболее изученным с помощью машинного обучения [8].

Й.И. Фрогнер (Joakim Ihle Frogner) и др. с использованием набора данных DEPRESJON определили оптимальный временной интервал для классификации пациентов с депрессией из контрольной группы. Они брали 48-часовые образцы и тренировали одномерную сверточную нейронную сеть для достижения 0,70 F-меры с трехкратной перекрестной проверкой [9]. Э. Гарсиа-Сеха (Enrique García-Ceja) и др. получили 0,78 взвешенной полноты с использованием алгоритма случайного леса SMOTE для классификации пациентов с депрессией и здоровых людей, входящих в контрольную группу [10]. Другой подход с использованием набора данных DEPRESJON представлен в работе Л.А. Занела-Кальсада (Laura A. Zanella-Calzada) и др., в которой с помощью алгоритма случайных лесов классифицируются депрессивные эпизоды со статистическими характеристиками, извлекаемыми раз в час. В этом подходе используются полные данные из набора данных и достигается точность 0,893 [11]. Эти и другие ранние исследования подтверждают эффективность применения машинного обучения для классификации депрессии.

Известно, что по меньшей мере 50% пациентов с MDD не могут выполнить минимальный рекомендуемый объем физической активности [12]. По этой причине для распознавания закономерностей или аномалий поведения двигательная активность хорошо воспринимаются через умную одежду [13].

Изменения поведения также происходят в ночное время суток. Так, можно увидеть, что у большинства пациентов с депрессией имеются нарушения сна и фазы сна изменены. Решение данных проблем способствует улучшению состояния пациентов [14]. Учитывая тот факт, что нарушения сна являются серьезной проблемой и имеют связь с психическими расстройствами, особенно с депрессией, являясь ее причиной или в большинстве случаев симптомом [15], в данной работе основное внимание уделяется данным, собранным в ночное время, с помощью которых можно найти закономерности, позволяющих выявить депрессивные эпизоды.

Структурно каждый раздел данной статьи подробно описывает определенный этап анализа данных, проводимого по методологии обнаружения знаний в базах данных (KDD) [16], и, наконец, завершается статья разделом «Заключение».

2. Датасет

Датасет Depresjon содержит информацию о двигательной активности 23 пациентов с MDD (монополярным и биполярным расстройством) и 32 участников контрольной группы, не имеющих депрессию. Все они проходили исследование актиграфом (Actiwatch, Cambridge Neurotechnology Ltd, Англия, Модель AW4) с частотой дискретизации 32 Гц и регистрацией движений свыше 0,05 г в минуту. Интенсивность движения прямо пропорциональна подсчету

активности в минуту. Актиграфы – это устройства, используемые для неинвазивного мониторинга деятельности человека и представляющие собой браслет с акселерометром внутри [17].

Датасет можно загрузить по ссылке с [18] и там же ознакомиться с его характеристиками и описанием.

3. Предварительная обработка

Первая задача на этапе предварительной обработки – это стандартизировать данные, сигнализирующие об активности, так, чтобы среднее значение было равно 0, а среднеквадратическое отклонение – 1 для масштабирования данных. Для этого используется z-оценка, задаваемая формулой (1):

$$z_i = \frac{x_i - \underline{x}}{s}, \quad (1)$$

где x – точка сигнала активности во времени, \underline{x} – среднее значение активности, а s – среднеквадратическое отклонение активности. В процессе стандартизации учитывается общая выборка из датасета после очистки данных от записей с пропущенными значениями. В данной работе целевыми данными являются сигналы, которые были собраны с помощью актиграфа в ночное время (с 9 часов вечера до 7 часов утра). Выбрано именно 10 часов, поскольку необходимо учитывать время, предшествующее сну, и все часы сна от заката до рассвета.

Для процесса стандартизации все данные от каждого пациента и участников контрольной группы были объединены в один датасет. В результате этого процесса получается набор данных из 716700 наблюдений со столбцами, содержащими информацию о времени, дате, активности и лице, к которому относится наблюдение.

4. Преобразование

Выделение признаков выполняется для каждого наблюдения во временном и частотном доменах.

Сигнал активности изначально находится во временном домене, для преобразования его в частотный домен используется быстрое преобразование Фурье (БПФ). Таким образом, за часовой промежуток некоторые признаки извлекаются во временном домене, а другие – в частотном домене.

БПФ определяется формулой (2):

$$x(k) = \sum_{n=0}^{N-1} x(n) * e^{-j2\pi \left(\frac{k}{N}\right)n}, \quad (2)$$

где $x(n)$ – выборки во временном домене, то есть подсчет активности в минуту в течение одного часа, N – общий размер выборки (60), k – текущее значение частоты диапазоне от 0 до $N-1$, и $x(k)$ – спектральные компоненты выборки. После применения БПФ необходимо вычислить спектральную плотность сигнала с помощью формулы (3) для устранения мнимой части БПФ и нормализации спектра по длине временного ряда:

$$P = \frac{1}{T} \int_0^T |x(k)|^2 dt. \quad (3)$$

Извлеченные из данных признаки представлены в табл. 1.

Табл. 1. Признаки, извлеченные во временной и частотной областях
Table 1. Features extracted on time and frequency domain

Признак	Временная область	Частотная область
Коэффициент эксцесса	*	*
Среднее значение	*	*
Медиана	*	*
Среднеквадратическое отклонение	*	*
Дисперсия случайной величины	*	*
Коэффициент вариации	*	*
Межквартильный размах	*	*
Минимальное значение	*	*
Максимальное значение	*	*
Усеченное среднее	*	*
Спектральная плотность		*
Энтропия		*
Коэффициент асимметрии		*
Спектральная плоскостность		*

Отбор признаков осуществляется с помощью рекурсивного исключения признаков с перекрестной проверкой (Recursive Feature Elimination with Cross-Validation, RFECV) с использованием алгоритма случайного леса (Random Forest, RF).




Рис. 1. График отбора признаков с использованием RFECV
Fig. 2. Feature selection plot using RFECV

На рис. 1 изображен график отбора признаков, на котором видно, что оптимальное количество признаков в модели для этого датасета равно 8. При оценивании значимости признаков с помощью RFECV было получено 8 «лучших» признаков из «лучшей» модели, перечисленные ниже.
Из временного домена:

- коэффициент эксцесса;
 - медиана;
 - среднеквадратическое отклонение;
 - дисперсия случайной величины;
 - максимальное значение.
- Из частотной области:
- среднее значение;
 - дисперсия случайной величины;
 - коэффициент вариации.

5. Интеллектуальный анализ данных

Алгоритм случайного леса (RF) доказал свою эффективность в классификации подобных депрессивных эпизодов [11]. В нем объединены схожие функциональные возможности других алгоритмов машинного обучения для создания нового, более мощного алгоритма [19]. Именно RF был выбран для работы с моделью, имеющей 8 признаков, с использованием сбалансированной выборки для достижения заданной цели выявления депрессивных эпизодов и их классификации. Кроме того, с применением алгоритма случайного леса проводится одномерный анализ данных для повышения качества анализа отобранных признаков и их классификации.

Для реализации алгоритма случайного леса используется Python 3.6, применяется случайное разбиение данных на обучающие и тестовые, и соотношение обучающих и тестовых данных – 70:30 (8361 и 3584 наблюдения). Обучающий набор содержит признаки модели с известным результатом для того, чтобы классификатор учился на основе этих данных. Тестовый набор состоит из 2346:0 и 1238:1. Как в обучающем, так и тестовом наборе наблюдается проблема несбалансированных данных. Для ее решения в классификатор алгоритма случайного леса включается атрибут веса класса.

Сбалансированная подвыборка веса классов (bs) используется для корректировки весов классов на основе бутстрэп-выборки для каждого дерева, построенное с помощью формулы (4):

$$bs = \frac{nsamples}{nclasses * np.bincount(y)}, \tag{4}$$

где *nsamples* – общее число единиц выборки в наборе данных, *nclasses* – общее число классов в датасете, в данном случае – 2, а *np.bincount(y)* – частоты классов во входных данных. Алгоритм обучается на обучающих данных, а после классификации проверяется на тестовых данных.

Данный процесс реализуется на полной модели с 8 признаками в одномерном режиме, т.е. алгоритм обучается и тестируется по каждому признаку в отдельности.

6. Оценка

6.1. Многомерный анализ данных

По итогам двоичной классификации методом RF получается матрица ошибок, изображенная на рис. 2. Значения в матрице ошибок соответствуют TN (true negative), TP (true positive), FN (false negative) и FP (false positive). На основе этих значений можно вычислить следующие показатели:

- чувствительность: 0.999147;
- специфичность: 0.992730;
- точность: 0.9969.

Процедура классификации сопровождается «слепым» тестом с использованием 30 процентов случайно отобранных наблюдений, т.е. признаков, выявленных в двигательной активности за часовой период. Матрица ошибок на рис. 2 отражает общее количество условий и контрольных использований для тестирования модели с использованием алгоритма случайного леса.

6.2. Одномерный анализ

Из результатов одномерного анализа важно выделить то, что максимальный признак, извлеченный во временной области, имеет точность 0,908. Максимальный признак представляет собой максимальную точку сигнала деятельности пациента или участника контрольной группы в течение одного часа. Напомним, что одно из значений чувствительности – это подсчет движений, достигающих 0,05 g в минуту, поэтому максимальное значение равно самому интенсивному движению в течение часа. Полученные результаты по признакам приведены в табл. 2.




Рис. 2. Матрица ошибок бинарной классификации с использованием алгоритме случайного леса депрессивных эпизодов
Fig. 2. Confusion Matrix of the binary classification with Random Forest of depressive episodes

Табл. 2. Результаты одномерного анализа данных
Table 2. Results for univariate analysis

Признаки	TP	TN	FP	FN	Чувстви- тельность	Специ- фичность	Точность
Временной коэффициент экссцесса	540	1578	702	764	0,401	0,677	0,583
Среднее значение времени	753	1945	522	364	0,553	0,876	0,702
Временное среднеквадратическое отклонение	612	1684	646	642	0,494	0,723	0,642
Временная дисперсия случайной величины	616	1685	657	626	0,540	0,721	0,647

Максимальное время	1074	2193	137	180	0,854	0,940	0,908
Среднее значение частоты	716	1761	547	716	0,540	0,765	0,689
Частотная дисперсия случайной величины	310	1666	619	689	0,497	0,730	0,647
Частотный коэффициент вариации	518	157	758	734	0,431	0,694	0,603

7. Обсуждение и выводы

Эффективность анализа депрессивных и недепрессивных эпизодов с использованием только данных о двигательной активности в ночное время суток наглядно демонстрируется в данной работе на примере добычи данных, проведенной с помощью метода обнаружения знаний в базах данных (KDD). При данной классификации у модели достигается точность 99%. Для оценки классификации алгоритма существуют четыре важных термина: истинно положительный (true positive – TP), истинно отрицательный (true negative – TN), ложно отрицательный (false negative – FN) и ложно положительный (false positive – FP). Эти результаты могут быть лучше интерпретированы с помощью одномерного анализа. Максимальный сигнал двигательной активности за каждый часовой промежуток является наиболее описательным признаком явления. Даже если сигнал состояния представляет собой меньшее движение по сравнению с контрольным сигналом движения, закономерности между обоими сигналами отличаются до такой степени, что при классификации депрессивных эпизодов сама по себе достигается 90% точность. Несмотря на первый аргумент об использовании только данных, собранных в ночное время, поскольку 50% пациентов с депрессией имеют расстройства сна, для диагностирования депрессии или выявления нарушений сна не может применяться исключительно этот тип классификации. Он может быть использован для выявления депрессивных эпизодов у ранее диагностированного пациента, для контроля лечения и вспомогательного участия в диагностике или оценке пациента.

Список литературы / References

[1] Depression and other common mental disorders: global health estimates. World Health Organization, 2017, 24 p.

[2] Espinosa-Aguilar J. Caraveo-Anduaga M., Zamora-Olvera A. et al. Guía de práctica clínica para el diagnóstico y tratamiento de depresión en los adultos mayores. *Salud Mental*, vol. 30, no. 6, 2007, pp. 69-80 (in Spanish).

[3] S.A. Montgomery and M. Asberg. A new depression scale designed to be sensitive to change. *The British Journal of Psychiatry*, vol. 134, no. 4, 1979, pp. 382-389.

[4] Armitage R. Sleep and circadian rhythms in mood disorders. *Acta Psychiatrica Scandinavica*, vol. 115, issue s403, 2007, pp. 104-115.

[5] Koffel E., Polusny M.A., Arbisi P.A., and Erbes C.R. Pre-deployment day time and nighttime sleep complaints as predictors of post-deployment PTSD and depression in national guard troops. *Journal of Anxiety Disorders*, vol. 27, no. 5, 2013, pp. 512-519.

[6] Wichniak A., Wierzbicka A., Walecka M., and Jernajczyk W. Effects of antidepressants on sleep. *Current Psychiatry Reports*, vol. 19, no. 9, 2017, article no. 63.

[7] Kuhs H. and Reschke D. Psychomotor activity in unipolar and bipolar depressive patients. *Psychopathology*, vol. 25, no. 2, 1992, pp. 109-116.

[8] Shatte A.B., Hutchinson D.M., & Teague S.J. Machine learning in mental health: a scoping review of methods and applications. *Psychological Medicine*, vol. 49, no. 9, 2019, pp. 1426-1448.

[9] Frogner J.I., Noori F.M., Halvorsen P. et al. One-Dimensional Convolutional Neural Networks on Motor Activity Measurements in Detection of Depression. In *Proc. of the 4th International Workshop on Multimedia for Personal Health & Health Care*, 2019, pp. 9-15.

- [10] García-Ceja E., Riegler M., Jakobsen P. et al. Depresjon: a motor activity database of depression episodes in unipolar and bipolar patients. In Proc. of the 9th ACM Multimedia Systems Conference, 2018, pp.472-477.
- [11] Zanella-Calzada L.A., Galván-Tejada C.E., Chávez-Lamas N.M. et al. Feature extraction in motor activity signal: Towards a depression episodes detection in unipolar and bipolar patients. *Diagnostics*, vol. 9, no. 1, 2019, pp. 1-13.
- [12] Schuch F.B., Vancampfort D., Firth J. et al. Physical activity and incident depression: a meta-analysis of prospective cohort studies. *American Journal of Psychiatry*, vol. 175, no. 7, 2018, pp. 631-648.
- [13] Gruenerbl A., Osmani V., Bahle G. et al. Using smartphone mobility traces for the diagnosis of depressive and manic episodes in bipolar patients. In Proc. of the 5th Augmented Human International Conference, 2014, p. 1-8.
- [14] Murphy M.J. and Peterson M.J. Sleep disturbances in depression. *Sleep Medicine Clinics*, vol. 10, no. 1, 2015, pp. 17-23.
- [15] Guglielmi O., Magnavita N., and Garbarino S. Sleep quality, obstructive sleep apnea, and psychological distress in truck drivers: A cross-sectional study. *Social Psychiatry and Psychiatric Epidemiology*, vol. 53, no. 5, 2018, pp. 531–536.
- [16] Dåderman A. and Rosander S. Evaluating Frameworks for Implementing Machine Learning in Signal Processing: A Comparative Study of CRISP-DM, SEMMA and KDD. Bachelor's Thesis. KTH, School of Electrical Engineering and Computer Science, 2018, 43 p.
- [17] Srinivasan R., Chen C., and Cook D. Activity recognition using actigraph sensor. In Proc. of the Fourth Int. Workshop on Knowledge Discovery from Sensor Data, 2010, pp. 25-28.
- [18] Garcia-Ceja E., Riegler M., Jakobsen P. et al. Depresjon: A Motor Activity Database of Depression Episodes in Unipolar and Bipolar Patients. In Proc. of the 9th ACM Multimedia Systems Conference, 2018, pp. 472-477.
- [19] Vijayashree J. & Sultana H. P. A machine learning framework for feature selection in heart disease classification using improved particle swarm optimization with support vector machine classifier. *Programming and Computer Software*, vol. 44, no. 6, 2018, pp. 388-397.

Информация об авторах / Information about authors

Джультета Г. РОДРИГЕС-РУИЗ, аспирант. Область научных интересов: программная инженерия, анализ биомедицинских данных, машинное обучение, интеллектуальный анализ данных.

Julieta G. RODRÍGUEZ-RUIZ, PhD Student. Research interests: Software Engineering, Biomedical Data Analysis, Machine Learning, Data Mining.

Карлос Эрик ГАЛЬВАН-ТЕХАДА, кандидат наук, профессор-исследователь. Научные интересы: искусственный интеллект, контекстные вычисления, повсеместные вычисления.

Carlos Eric GALVÁN-TEJADA, Ph.D., Professor Researcher. Research interests: Artificial Intelligence, Context Computing, Ubiquitous Computing.

Содел ВАСКЕС-РЕЙЕС, кандидат наук, разработчик. Область научных интересов: программная инженерия, интеллектуальный анализ текста, обработка естественного языка.

Sodel VÁZQUEZ-REYES, Ph.D., Developer. Research interests: Software Engineering, Text Mining, Natural Language Processing.

Хорхе Исак ГАЛЬВАН-ТЕХАДА, кандидат наук, профессор-исследователь. Область научных интересов: биоинформатика, цифровая обработка сигналов при остеоартрозе.

Jorge Issac GALVÁN-TEJADA, Ph.D., Professor Researcher. Research interests: Bioinformatics, Osteoarthritis Digital Signal Processing.

Хамурапи ГАМБОА-РОСАЛЕС, кандидат наук, доцент. Область научных интересов: обработка голоса, телекоммуникации, программирование на C/C ++.

Hamurabi GAMBOA-ROSALES, Ph.D., Associate Professor. Research interests: Voice Processing, Telecommunications, C / C ++ Programming.