

ЭКСПЕРИМЕНТАЛЬНОЕ СРАВНЕНИЕ МЕТОДОВ АНАЛИЗА СОЦИАЛЬНЫХ СЕТЕЙ В ЗАДАЧЕ ОБНАРУЖЕНИЯ СООБЩЕСТВ

Г. Г. Рапаков, В. А. Горбунов

Вологодский государственный университет

Поступила в редакцию 07.09.2017 г.

Аннотация. В статье исследованы алгоритмы и методы анализа социальных сетей. Проведено сопоставление лувенского метода максимизации модулярности и разделяющей кластеризации в задаче выделения сообществ. Лувенский метод обеспечивает максимальную оценку качества обнаружения и дает возможность выявлять аномалии социального графа. Результаты анализа сообществ социальной сети использованы при принятии управленческих решений в системе медико-социальной поддержки населения.

Ключевые слова: анализ социальных сетей, лувенский метод, разделяющая кластеризация, выделение сообществ, поддержка решений, активное долголетие.

Annotation. The article presents research results of the social networks analysis algorithms and methods. Comparison of Louvain method and divisive clustering was introduced. The Louvain method for community detection provides effective modularity maximization and graph anomaly detection. Results were used for decision support of medical-social population support.

Keywords: social networks analysis, louvain method, divisive clustering, community detection, decision support, active longevity.

ВВЕДЕНИЕ

Для постановки и решения статических и динамических научно-организационных задач в общественных системах используются модели социальных сетей [1, 2]. Прикладной характер теории графов нашел свое отражение в анализе социальных сетей (Social Network Analysis), который изучает социальные структуры на основе теорий графов и сетей [2]. Граф $G = (V, E)$, или применительно к прикладной предметной области исследования – сеть, рассматривается как совокупность множества V вершин v и множества E ребер e между ними. Визуальное представление структуры для графа $G = (V, E)$ выполняется в ходе построения его укладки L – отображения вершин и ребер (связей) на плоскости или в пространстве. Особенностью настоящего исследования является ненаправленный тип статичного социального графа, взаимосвязанные социальные объекты которого – ак-

торы соединяются ребрами, отражающими связи между ними. Множество ребер в этом случае состоит из неупорядоченных пар $(u, v) = (v, u)$ [1]. Обнаружение сообществ относится к числу важных задач, решаемых на социальном графе, при построении рекомендательных систем [2, 3, 4].

Изучение и анализ источников позволил выполнить сопоставление целей и методов исследования с имеющимися литературными данными. В обзорной работе [5] среди структурных, метрических и вероятностных алгоритмов кластеризации кратко рассматриваются виды иерархического кластерного анализа (ИКА): объединяющий (агломерационный) и разделяющий (дивизивный). Невозможность задать число кластеров отнесена к недостаткам ИКА. Одной из основных проблем кластерного анализа является задача определения числа кластеров. Особенностью сетевой кластеризации является необходимость учета не только атрибутов объектов, но и их связей. В случае, если аналитик испытывает вызванные этим затруднения, ав-

торы труда [6] рекомендуют обратиться к иерархическому кластерингу. Возможности, которые дает расширение методов неконтролируемого машинного обучения за счет использования аггломеративной иерархической кластеризации, рассматриваются в статье [7]. К сожалению, обзор альтернативных алгоритмов и обоснование использования выбранного метода не представлены, выбор алгоритма произволен. При анализе данных социологической природы применение разделяющий иерархической кластеризации (РИК) оправдано для выборок с числом объектов, большим 100 [8]. Результаты опросов зачастую представлены дихотомическими переменными. Монотетические дивизивные алгоритмы позволяют обрабатывать бинарные данные [6].

Использование показателя качества обнаружения сообществ на основе оптимизации модулярности дало начало важному направлению исследований дивизивных алгоритмов. В его основе лежит допущение, что случайный граф не обладает структурой сообществ. Модулярность, как мера качественного разбиения на сообщества, показывает, что существует много связей внутри сообщества и незначительное количество связей, соединяющих сообщества друг с другом, вне его [3, 4, 10]. Жадный алгоритм оптимизации модулярности Ньюмана–Гирвани рассмотрен в [9, 10].

В настоящее время широко распространенным методом машинного обучения, предназначенным для обнаружения сообществ в больших сетях данных, является лувенский метод (ЛМ). ЛМ обеспечивает баланс между универсальностью и производительностью [2]. Метод относится к аггломеративной иерархической кластеризации и основан на максимизации модулярности [3]. Алгоритм представляет собой многоэтапную процедуру и предусматривает локальную оптимизацию модулярности по отношению к соседям каждой вершины: пятишаговая процедура выполняется итеративно до тех пор, пока продолжается рост модулярности [11]. Иерархическая структура метода дает возможность

использовать его для анализа сообществ различных масштабов [4, 11].

Перспективным направлением исследования сложных объектов управления является разработка кластерных моделей [12]. В работе [13] представлен параллельный алгоритм обнаружения сообществ на основе лувенского метода максимизации модулярности для крупномасштабных суперкомпьютеров с применением хеш-таблиц в целях организации данных и поддержки обмена информацией.

В статье [14] выполнен сравнительный анализ алгоритмов выделения сообществ. Отмечены три алгоритма, обладающие высокой производительностью, отличающиеся низкой вычислительной сложностью и пригодные для использования в анализе больших систем. Однако тестирование было ограничено двенадцатью методами, включая алгоритм Ньюмана – Гирвани. Возможности лувенского метода максимизации модулярности не рассматривались.

В связи с этим актуальной является задача исследования методов анализа социальных сетей с разбиением на сообщества. Важность и практическая значимость работы заключается в том, что результаты сравнительной экспериментальной оценки алгоритмов были использованы в целях адресной коррекции поведенческих факторов риска (ФР) при формировании здоровьесберегающих активностей населения. Моделирование структуры неявных сообществ социального графа позволило повысить эффективность управленческих стратегий в системе медицинской профилактики лиц пожилого возраста и выявить аномалии.

Цель работы состоит в исследовании алгоритмов и методов анализа социальных сетей и обосновании их использования в сложном прикладном объекте исследования – системе медико-социальной поддержки населения и муниципальной концепции активного долголетия (КАД), включая вопросы принятия управленческих решений.

Научная новизна работы заключается в сопоставлении лувенского метода максими-

зации модулярности и разделяющей кластеризации в задаче выделения сообществ. Лувенский метод обеспечивает максимальную оценку качества обнаружения и дает возможность эффективно выявлять аномалии социального графа.

МАТЕРИАЛЫ И МЕТОДЫ

Межведомственную работу по формированию регионального здоровьесберегающего пространства активного долголетия регулируют ряд базовых нормативно-правовых актов [15]. Методы анализа данных показали высокую эффективность при информационно-аналитической поддержке управленческих решений в задачах здравоохранения [16, 17].

Сбор данных для анализа выполнен в ходе проведения мониторингового медико-социологического опроса. Объем выборки обеспечивает необходимую точность оценки не ниже 9 % с доверительной вероятностью $\alpha = 0,95$, что удовлетворяет требованиям пилотного исследования. Выбор объектов случаен. Компонента вектора признаков принимает значение, равное 1, в случае выбора опрашиваемым лицом соответствующего варианта для вопроса с множественными ответами. Мониторинговое медико-социологическое исследование посвящено оценке респондентами влияния факторов риска на состояние здоровья. Согласно национальным рекомендациям по сердечно-сосудистой профилактике (НРКП) наибольший вклад в преждевременную смертность населения Российской Федерации вносят 7 факторов риска. Степень отрицательного влияния каждого из них оценивается респондентом от 1 (наименьший вред), до 5 (наибольший вред). Для кодирования вопроса анкеты используется многовариантный тип с 7 одновариантными переменными. Тип шкалы одновариантных переменных является порядковым: метки для каждой такой переменной принимают целые значения от 1 до 5. Так выставляются варианты ответов на вопрос по степени отрицательного влияния факторов риска и формируется битовый поток, образующий исходную матрицу для анализа социальной сети.

Задача, решаемая на графе, состоит в обнаружении сообществ социальной сети. В качестве способа задания социального графа $G = (V, E)$ используется матрица смежности $A(G)$ порядка n ($n = |V|$), элемент которой a_{ij} равен числу ребер, соединяющих вершины v_i и v_j . Матрица смежности для неориентированного графа симметрична. Сумма элементов i строки равна сумме элементов i столбца и степени вершины i . Степень вершины v_i определяется как количество инцидентных ей ребер – $\text{deg}(v_i)$ [2].

Меры близости для вершин графа делятся на два класса: меры, учитывающие локальную информацию, например, косинусная, и меры, основанные на распространяющейся активации (Spreading Activation). Последние дают более качественный результат, однако высокая вычислительная сложность алгоритмов $O(N^3)$ ограничивает их применение. Взвешенная матрица смежности строится на основе косинусного сходства (Cosine Similarity) – $\cos(\theta)$, которое определяет меру подобия для двух векторов признаков A и B :

$$\cos(\theta) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^n A_i \times B_i}{\sqrt{\sum_{i=1}^n (A_i)^2} \times \sqrt{\sum_{i=1}^n (B_i)^2}},$$

а поскольку $\cos(\theta)$ учитывает только ненулевые измерения, оно эффективно в качестве оценочной меры для разреженных векторов [10].

Взвешенную матрицу смежности называют матрицей сходства. Ее элементы – веса ребер принимают значения от 0 до 1. Результирующая матрица смежности $A(G)$ социальной сети представляет собой граф окрестности r , который строится на основе матрицы сходства с использованием обрезки ветвей. Для отсечения ребер из числа элементов матрицы сходства отбираются значения, превышающие порог. Так выделяют наиболее сильные зависимости.

В ходе проведенного опроса 114 респондентов дали 798 ответов, матрица сходства содержит 12562 положительных элемента. Величина порога задается как 95-й процентиль. Для задачи, решаемой на социальном графе,

его порядок равен 114 (количество вершин). Сумма элементов графа окрестности r составляет 1268 (количество ребер). Отобрано 5 % ребер с наибольшими весами.

Процесс иерархической кластеризации принято представлять в виде древовидной схемы (дендрограммы). Однако в целях удобства анализа лицом, принимающим решение, (ЛПР) в исследовании применяется радиальная визуализация результатов сетевой кластеризации – хордовая диаграмма (ХД) [2]. ХД пригодны для наглядного представления сложных паттернов многомерных данных. Использование двух наборов данных – хорд и дуг позволяет эффективно отобразить взаимосвязи множества объектов сложной структуры и обеспечить удобство их восприятия ЛПР. ХД также известны как радиальные сетевые диаграммы.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЙ

Иерархическая кластеризация на основе разделяющих (дивизивных) алгоритмов является эффективным методом неконтролируемого машинного обучения. Результатом построения структуры кластеров выступает граф. Сетевой граф является простым способом хранения и визуализации объектов (респондентов), которые объединены друг с другом (например, общими ответами в ходе проведения опроса).

Для оптимального назначения сообществ на графе используется метод разделяющий иерархической (аналитической) кластеризации (РИК, Divisive Clustering). РИК относится к иерархическому кластерному анализу (ИКА, Hierarchical Cluster Analysis). ИКА стремится создать иерархию кластеров, используя два типа стратегий: агломерации и иерархической декомпозиции (разделения). В зависимости от количества переменных объекта РИК относят к монотетической (для бинарных данных) или политетической (вычислительная таксономия) [6]. Достоинством иерархической декомпозиции перед агломерацией является ранний учет информации об общем распределении объектов, начиная с верхних уровней разделения. Это способ-

ствует росту точности иерархии кластеров. Недостатком иерархического кластерного анализа является то, что, в отличие от метода k -средних, назначение элемента группе впоследствии не может быть пересмотрено.

Для задания сети используются симметричные матрицы сходства и смежности. Матрица смежности является графом окрестности r , который строится путем обрезки ветвей. Так из числа элементов матрицы сходства отбираются сильные зависимости, превышающие порог в 95 %. В целях обеспечения естественности кластеризации на основе ожидаемого количества ребер строится функция штрафа, которая штрафует за объединение в сообщество узлов, слабо связанных друг с другом. Критерий оценки качества обнаружения сообществ – модулярность определяется на основе плотности связей внутри сообщества (Intra-Cluster Homogeneity) по сравнению со связями между сообществами (Inter-Cluster Separability).

При делении на g групп определяется матрица e размера $g \times g$. Для групп i и j ее элемент представляет собой ту часть ребер в исходной сети, которая соединяет вершины в группах i и j :

$$Q = \sum_i e_{ii} - \sum_{ijk} e_{ij} e_{ki} = \text{Tr } e - \|e\|^2,$$

где $\|e\|$ – сумма всех элементов e [9].

Максимум модулярности при анализе сетевой структуры был достигнут для 4 кластеров (табл. 1). Использован алгоритм линейной оптимизации – симплекс-метод. Мощность кластеров 0–3 составляет 32,5 %, 31,6 %, 10,5 % и 25,4 % соответственно.

Таблица 1
Модулярность для различного количества кластеров

Количество кластеров	2	3	4	5
Модулярность	0,374	0,513	0,527	0,527

Визуализация РИК реализована при помощи хордовой диаграммы. При ее построении использовалась старшая пятая степень влияния (СВ 5) факторов риска, обуславливающих преждевременную смертность населения (рис. 2). Анализ радиального дерева

показывает, что лишь четверть опрошенных лиц ставят фактор риска артериальной гипертензии (АГ) (реальный вклад 35,5 %) на первое место (кластер № 3). Остальные основными факторами риска считают разрешенные наркотики (реальный вклад 29 %). С точки зрения профилактики сердечно-сосудистых заболеваний респонденты кластеров 0, 1 и 2 представляют собой целевую группу влияния (Target Group) по коррекции факторов риска артериальной гипертензии.

Эффективным подходом к выделению сообществ в больших сетях данных является лувенский метод максимизации модулярности (Louvain Modularity Maximization), который относится к числу жадных эвристик [2, 3, 13]. Вычислительная сложность алгоритма равна $O(N \log N)$. Критерий оценки качества обнаружения сообществ – модулярность определяется на основе плотности связей внутри сообщества по сравнению со связями между сообществами. Для взвешенного графа модулярность Q выражается как [11]:

$$Q = \frac{1}{2m} \sum_{ij} \left[A_{ij} - \frac{k_i k_j}{2m} \right] \delta(c_i, c_j),$$

где A_{ij} – вес ребра между вершинами i, j ; k_i, k_j – сумма весов ребер, примыкающих к вершинам i, j ; m – полусумма всех весов ребер графа; c_i, c_j – сообщества вершин; δ – дельта-функция.

Для эффективной максимизации модулярности Q алгоритм многократно оптимизирует сообщества на локальном уровне с группировкой каждого малого сообщества в одну вершину до тех пор, пока не будет достигнут максимальный уровень модулярности. При этом вначале каждая вершина сети назначается ее собственному сообществу. Далее для каждой вершины i рассчитывается изменение модулярности ΔQ , для этого i перемещается из собственного сообщества в сообщество каждого своего соседа j :

$$\Delta Q = \left[\frac{\sum_{in} + 2k_{i,in}}{2m} - \left(\frac{\sum_{tot} + k_i}{2m} \right)^2 \right] - \left[\frac{\sum_{in}}{2m} - \left(\frac{\sum_{tot}}{2m} \right)^2 - \left(\frac{k_i}{2m} \right)^2 \right],$$

где \sum_{in} – сумма весов всех связей внутри сообщества C , из которого перемещается вершина i ; \sum_{tot} – сумма весов всех связей к вершинам в C ; k_i – сумма весов связей к вершине i ; $k_{i,in}$ – сумма весов связей между i и прочими вершинами C [11].

К недостаткам метода относят предельное разрешение – отказ в обнаружении по отношению к кластерам, меньшим некоторого масштаба, зависящего от размера сети. В результате кластеризации вершины сети относятся к непересекающимся множествам. Каждое сообщество представлено своим множеством вершин. Вершины в сообществах расположены плотнее, чем в сети в целом [4, 11].

По итогам использования лувенского метода для данных мониторингового медико-социологического исследования выполнена максимизация модулярности, при этом достигнуто значение Q , равное 0,534. Это свидетельствует о том, что сеть представлена вполне различной структурой, содержащей сообщества, и применение алгоритма оправдано. Оценка качества обнаружения для разделяющей иерархической кластеризации составляет 0,527, что уступает значению 0,534, полученному при помощи лувенского метода.

Моделирование структуры сообществ социального графа при помощи алгоритма машинного обучения – лувенского метода позволяет выделить 8 кластеров. Обнаружение сообществ делает возможным сформировать рекомендации по коррекции факторов риска участников опроса. В соответствии с НРКП вклад 3 из 7 ведущих факторов риска: артериальной гипертензии (35,5 %), гиперхолестеринемии (23 %) и курения (17,1 %) в преждевременную смертность составляет 75,6 %. Для ее предотвращения необходимо обеспечить длительное умеренное снижение отрицательного влияния, в первую очередь, указанных факторов риска по отношению к возможно большей части населения. Суммарная доля трех наибольших по размеру кластеров 0, 4 и 6 составляет 74,6 % опрошенных.

Необходимо усилить степень отрицательного влияния артериальной гипертензии для участников кластера 6. По отношению ко всем кластерам требуется обеспечить моду




Рис. 1. Визуализация социального графа

этого фактора риска, сделав его наиболее часто встречающимся вариантом ответа. Требуемая коррекция выражена в минимальной степени для кластера 4. Фактор риска, связанный с избыточным потреблением алкоголя, является в нем модой, что не отвечает НРКП.

Учитывая частоту вариантов ответов, участникам нулевого сообщества можно рекомендовать усилить внимание к факторам риска, ответственным за гиперхолестеринемию, и к фактору риска курения. Выделение сообществ использовано для идентификации аномальных ситуаций. Выявлены кластеры 2, 5 и 7, представленные одиночными вершинами с номерами 10, 24 и 61 соответственно. Управление поведенческими факторами риска для их участников сводится к работе в группе в соответствии с национальными рекомендациями по кардиоваскулярной профилактике.

Построение социального графа по итогам обнаружения сообществ на основе лувенского метода было выполнено при помощи алгоритма Фрутермана–Рейнгольда с использованием критерия равномерного распределения. Связи между узлами сети являются ненаправленными. Сложность алгоритма $O(N^2)$

[10]. Полученное размещение графа отражает результат использования лувенского обнаружения сообществ (рис. 1). Результаты сетевой кластеризации на основе лувенского метода для лиц, принимающих решения, представлены в виде хордовой диаграммы (рис. 3).

ЗАКЛЮЧЕНИЕ

Выполнено экспериментальное исследование алгоритмов и методов анализа социальных сетей в задаче обнаружения сообществ. Обосновано их использования в сложном прикладном объекте исследования — системе медико–социальной поддержки населения и муниципальной концепции активного долголетия, включая вопросы принятия управленческих решений. На основе сравнительного анализа лувенского метода максимизации модулярности и разделяющей кластеризации проведено изучение выделения сообществ.

По итогам эмпирического исследования метода разделяющей иерархической кластеризации выполнена максимизация модулярности на графе. Получена оценка качества обнаружения 0,527. В результате сегментации выделены 4 кластера. Анализ радиального




Рис. 2. Хордовая диаграмма (разделяющая кластеризация)




Рис. 3. Хордовая диаграмма (лувенский метод)

дерева показывает, что лишь четверть опрошенных лиц ставят фактор риска артериальной гипертонии (реальный вклад 35,5 %) на первое место. Остальные основными факторами риска считают разрешенные наркотики (реальный вклад 29 %).

В ходе исследования лувенского метода достигнуто максимальное значение модуляр-

ности 0,534, что превосходит оценку качества обнаружения дивизивного алгоритма. Визуализация графа выполнена при помощи силового алгоритма Фрутермана – Рейнгольда и позволила наглядно представить сеть и результат обнаружения сообществ.

Результаты моделирования структуры сообществ социального графа при помощи

лугвенского метода позволили выделить 8 кластеров и обеспечить рекомендации по управлению поведенческими факторами риска. Выявлены аномалии – 3 одноэлементных кластера. Дальнейшие перспективы исследования связаны с выделением недекларируемых сообществ в больших сетях, представленных региональным регистром АГ.

СПИСОК ЛИТЕРАТУРЫ

1. *Bornholdt S.* Handbook of Graphs and Networks: From the Genome to the Internet / S. Bornholdt, H. Schuster. – Wiley-VCH Verlag GmbH & Co. KGaA, Weinheim, 2003. – 401 p.
2. *Brath R.* Graph Analysis and Visualization: Discovering Business Opportunity in Linked Data / R. Brath. – John Wiley & Sons, Inc., 2015. – 513 p.
3. *Tang L.* Community Detection and Mining in Social Media / L. Tang, H. Liu. – Morgan & Claypool Publishers, 2010. – 137 p.
4. *Missaoui R.* Social Network Analysis — Community Detection and Evolution, Lecture Notes in Social Networks / R. Missaoui, I. Sarr. – Springer International Publishing Switzerland, 2014. – 272 p.
5. *Черезов Д. С.* Обзор основных методов классификации и кластеризации данных / Д. С. Черезов, Н. А. Тюкачев // Вестник Воронеж. гос. ун-та. Сер. Системный анализ и информационные технологии. – 2009. – № 2. – С. 25–29.
6. *Kaufman L.* Finding Groups in Data: An Introduction to Cluster Analysis / L. Kaufman, P. Rousseeuw. – John Wiley & Sons, Inc., 2005. – 342 p.
7. *Сычев А. В.* Исследование изменений в профилях русскоязычных сообществ в «Живом журнале» / А. В. Сычев // Вестник Воронеж. гос. ун-та. Сер. Системный анализ и информационные технологии. – 2011. – № 2. – С. 106–111.
8. *Kempf-Leonard K.* Encyclopedia of Social Measurement, Volume 1 / K. Kempf-Leonard. – Elsevier Inc., 2005. – 899p.
9. *Newman M.* Detecting Community Structure in Networks/ M. Newman // The European Physical Journal B, Condensed Matter and Complex Systems. – 2004. – V. 38, Issue 2. – P. 321–330.
10. *Fortunato S.* Community Detection in Graphs/ S. Fortunato // Physics Reports. – 2010. – V. 486, Issue 3–5. – P. 75–174.
11. Fast Unfolding of Communities in Large Networks / V. Blondel, J. Guillemin, R. Lambiotte, E. Lefebvre // Journal of Statistical Mechanics: Theory and Experiment. – 2008. – № 10. – P. 10008–10020.
12. *Шилов С. Н.* Двухуровневая схема организации таблиц распределения запросов в кластерной системе DNS / С. Н. Шилов, С. Д. Кургалин, А. А. Крыловецкий // Вестник Воронеж. гос. ун-та. Сер. Системный анализ и информационные технологии. – 2014. – № 1. – С. 90–96.
13. Scalable Community Detection with the Louvain Algorithm / X. Que, F. Checconi, F. Petrini, J. Gunnels // 2015 IEEE 29-th International Parallel and Distributed Processing Symposium. – 2015. – P. 28–37.
14. *Lancichinetti A.* Community Detection Algorithms: a Comparative Analysis / A. Lancichinetti, S. Fortunato // Physical Review. – 2009. – V. E80, No. 5. – 056117. – P. 056117-1 – 056117-11.
15. Вологда – город долгожителей: концепция активного долголетия на территории муниципального образования «Город Вологда» на период до 2035 г: решение Вологодской городской Думы от 29 декабря 2014 г. № 129 // Консультант Плюс: справ. – правовая система / Компания «Консультант Плюс».
16. *Рапаков Г. Г.* Методы и алгоритмы машинного обучения при принятии управленческих решений в региональной системе медицинской профилактики (опыт Вологодской области): монография / Г. Г. Рапаков, Р. А. Касимов. – Вологда: ВоГУ, 2014. – 143 с.
17. *Рапаков Г. Г.* Исследование методов анализа времени до события при обработке демографических данных / Г. Г. Рапаков, В. А. Горбунов // Вестник Воронеж. гос. ун-та. Сер. Системный анализ и информационные технологии. – 2015. – № 4. – С. 110–120.

Рапаков Георгий Германович – канд. техн. наук, доцент кафедры информационных систем и технологий, Вологодский государственный университет.

Тел.: +7(8172)72-95-71

E-mail: grapakov@yandex.ru

Горбунов Вячеслав Алексеевич – д-р физ.-мат. наук, профессор, заведующий кафедрой информационных систем и технологий, Вологодский государственный университет.

Тел.: +7(8172)72-95-71

E-mail: gorbunov1945@inbox.ru

Rapakov G. G. – PhD in Technical Science, Associate Professor, Information Systems and Technologies Department, Vologda State University.

Gorbunov V. A. – Doctor of Physico-Mathematical Science, Professor, Information Systems and Technologies Department, Head of Department, Vologda State University.