



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004.89

## АНАЛИЗ СУЩЕСТВУЮЩИХ МЕТОДОВ ПРОГНОЗИРОВАНИЯ, ПРИМЕНЯЕМЫХ В УМНОМ ДОМЕ

**Быков В.Э.**

Филиал ФГБОУ ВО «Национальный исследовательский университет «МЭИ» в г. Смоленске, Россия, (214013, г. Смоленск, Энергетический проезд, 1), e-mail: gypnopinkie@yandex.ru.

В данной работе рассмотрены методы прогнозирования, применяющиеся в системах умного дома. Проанализированы 3 метода прогнозирования: ActiveLezi (ALZ) – метод, основанный на алгоритме сжатия строк, а также искусственные нейронные сети (ИНС), а именно многослойный персептрон с обратным распространением ошибки и рекуррентная нейронная сеть (LSTM). Произведено сравнение точности рассмотренных методов в задаче предсказания следующей комнаты, которую посетит житель УД на основе датасета CASAS H114.

Ключевые слова: умный дом (УД), методы прогнозирования, ActiveLezi (ALZ), искусственные нейронные сети (ИНС), многослойные персептрон, рекуррентные нейронные сети, LSTM.

## ANALYSIS OF EXISTING FORECASTING METHODS, USED IN A SMART HOME

**Bykov V.Y.**

Smolensk Branch of the National Research University “Moscow Power Engineering Institute”, Smolensk, Russia (214013, Smolensk, Energetichesky proezd, 1), e-mail: gypnopinkie@yandex.ru

This paper looks at the forecasting methods used in smart home systems. Three forecasting methods are analyzed: ActiveLezi, a method based on the string compression algorithm, as well as artificial neural networks (INS), namely multi-layered perceptron with reverse spread of error and recurrent neural network (LSTM). A comparison of the accuracy of the methods reviewed is made in the task of predicting the next room, which will be visited by a resident of the UD based on the DATASET CASAS H114.

Keywords: Smart Home (UD), Predictive Methods, ActiveLezi (AL), Artificial Neural Networks (INS), Multi-Layered Perceptron, Recurrent Neural Networks, LSTM.

### 1. Умный дом

Умный дом – это система, предназначенная для автоматизации некоторых повседневных действий человека в комнате и\или доме.

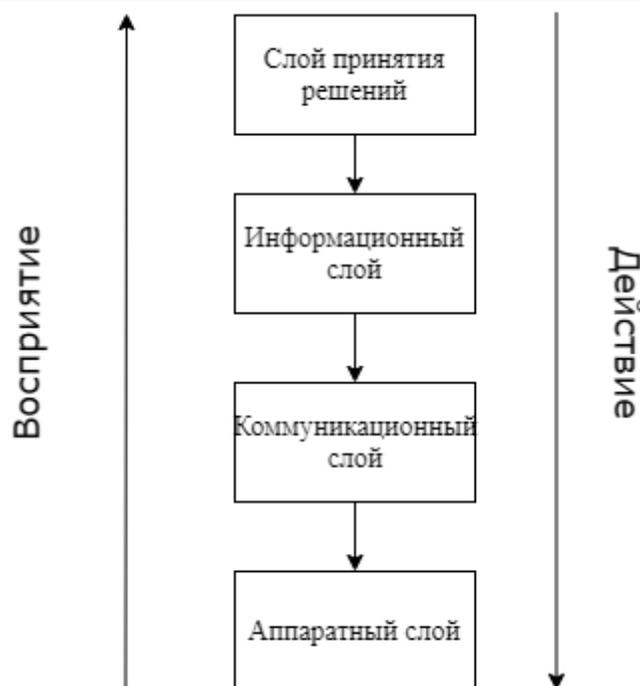


Рисунок 1 – Архитектура умного дома с точки зрения восприятия информации и принятия решений

Если рассматривать архитектуру умного дома с точки зрения восприятия информации и принятия решений, то можно выделить 4 слоя [1]: слой принятия решений, информационный слой, коммуникационный слой и аппаратный. Аппаратный слой состоит из датчиков, актуаторов (исполнительных устройств) и необходимого сетевого оборудования. Коммуникационный слой состоит из ПО, которое форматирует и перераспределяет информацию между различными устройствами (агентами) УД, между пользователем и УД, между другими внешними источниками и УД. Информационный слой собирает, хранит и генерирует необходимые данные полезные для принятия решения. Данный слой уже может выполнять задачи распознавания и классификации действий пользователя. Последний слой – слой принятия решений решает какие необходимые действия необходимо принять на основании принятой информации от информационного слоя. Исходя из данной иерархии, рисунок 1, можно сделать вывод о том, что процесс восприятия информации восходящий, тогда как процесс выбора необходимого действия нисходящий.

В данной статье будут рассматриваться алгоритмы, использующиеся для управления УД. На данный момент одной из основных задач для принятия решений в контексте умного дома является задача прогнозирования. Прогнозирование действий человека позволяет максимизировать комфорт хозяина дома и оптимизировать энергозатраты через уменьшение взаимодействия между ним и домом.

## 2. ActiveLeZi (ALZ)

ActiveLeZi (ALZ) – это модификация алгоритма сжатия последовательности символов (строки) LZ78, который в свою очередь основан на марковских моделях. Данный алгоритм предназначен для последовательного прогнозирования символов. В контексте умного дома последовательность символов может нести в себе информацию о последовательности

включений приборов, последовательности движений хозяина дома по различным комнатам. Например, на рисунке 2 изображено графовое представление планировки квартиры, в котором вершины имеют уникальный символ, означающий комнату, а рёбра представляют собой возможность перехода в другую комнату. Строка «dgoogdklrmcmamrlkdlrmamc» означает, что начало наблюдения за местонахождением пользователя началось в столовой, затем он перешел в гараж, два отрезка времени провел на улице и потом снова вернулся в гараж [2].

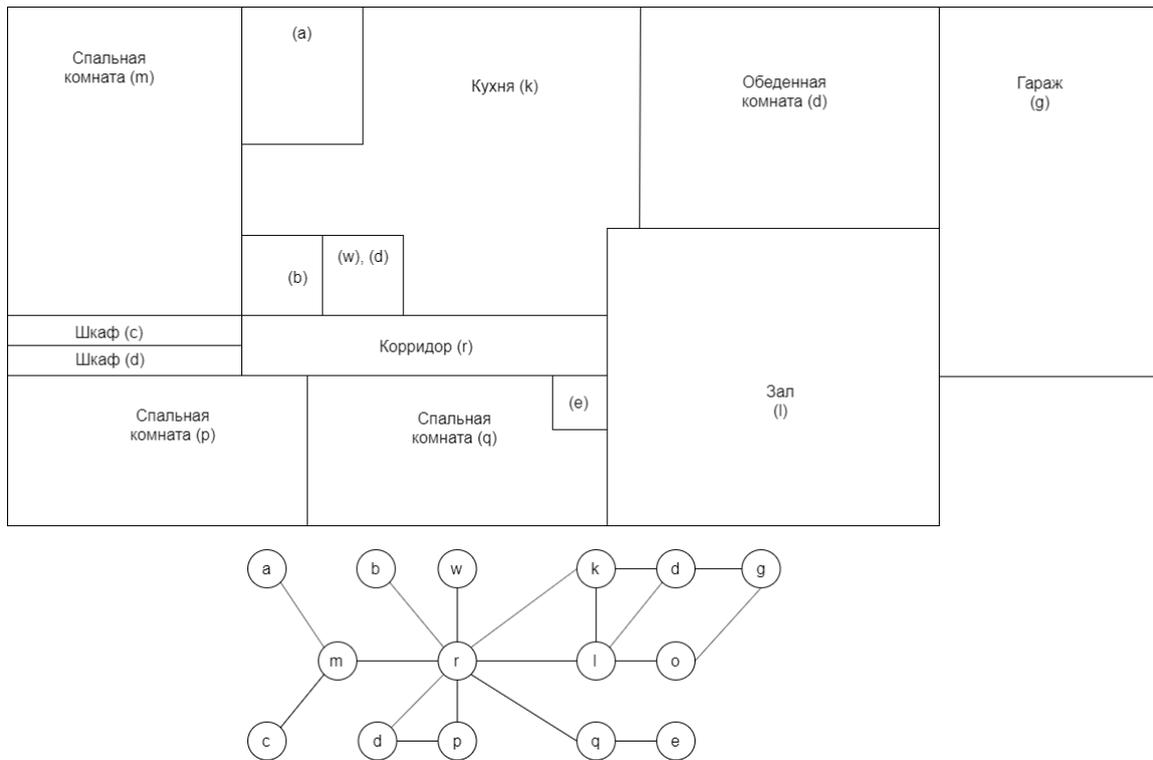


Рисунок 2 – Пример планировки квартиры представленной в виде графа

Суть алгоритма в том, что он преобразует входящую строку « $x_1, x_2, x_i$ » в несколько подстрок « $w_1, w_2, w_i$ ». Каждая подстрока может встречаться несколько раз как префикс в других подстроках (имеющей более большую длину) и на основе этого высчитываются и хранятся (чаще всего в виде дерева) вероятности появления следующего символа после префикса.

Покажем работу алгоритма [3] на примере строки  $x = \langle \text{aaababbbbbaabccddcbaaaa} \rangle$ . После работы алгоритма выделен следующий набор фраз: «a, aa, b, ab, bb, bba, abc, c, d, dc, ba, aaa». Для каждой из фраз была посчитана частота появления в других фразах в качестве префикса, рисунок 3. Исходя из дерева, вероятность появления «a», после фразы «a(5)» равна  $\frac{2}{5}$ , появление первой «a»  $\frac{5}{12}$ .

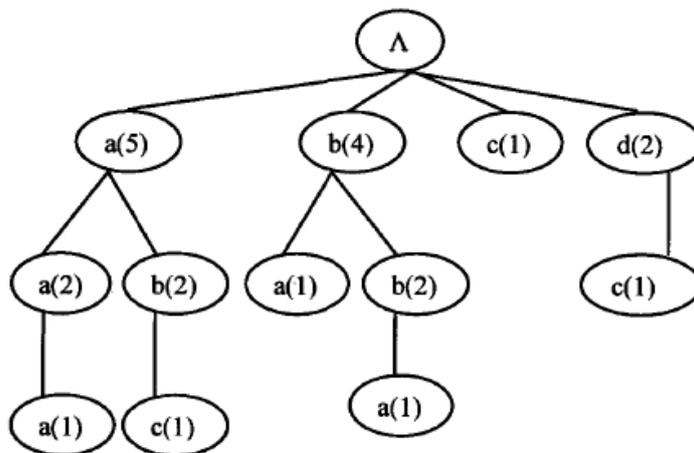


Рисунок 3 – Дерево, сформированное алгоритмом LZ78

Но у LZ78 есть проблема в том, что при увеличении длины изначальной входной строки, начинают теряться фразы. Потери такой информации избегает алгоритм ActiveLezi, путём введения окна, внутри которого и собирается статистика. Размер этого окна выбирается равным размеру самой длинной подстроки, найденной алгоритмом LZ78. Результат работы данного алгоритма можно увидеть на рисунке 4. Как можно заметить, после работы алгоритма сохранилось намного больше информации, что особенно важно для задачи прогнозирования.

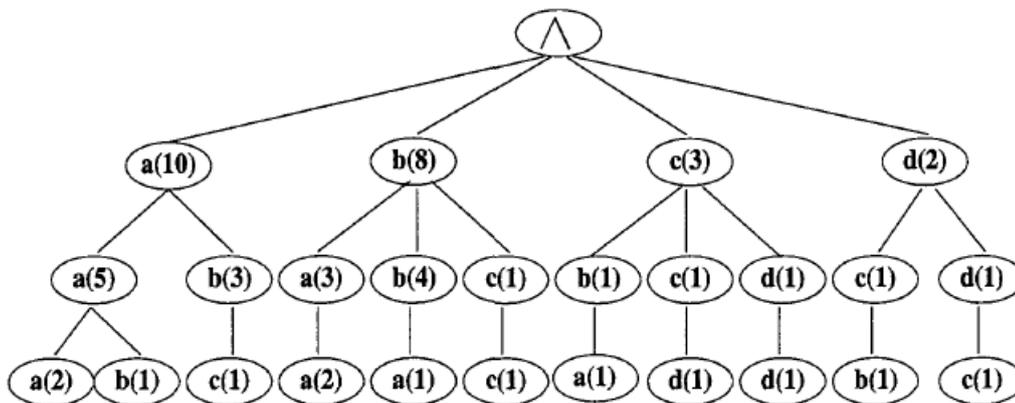


Рисунок 4 – Дерево, сформированное алгоритмом ActiveLezi

После формирования дерева можно вычислить вероятность появления жителя УД для каждой комнаты по некоторой истории передвижения. Например, вероятность появления жителя в комнате «с» при предыдущих передвижениях «аа», можно вычислить по формуле 1. Где  $\frac{0}{5}$  – вероятность появления «с» после фразы «аа», а  $\frac{2}{5}$  – вероятность возврата на порядок ниже (глубина дерева - 1), то есть вероятность отсутствия следующей буквы после «аа».  $\frac{0}{5}$  – вероятность появления «с» после «а», а  $\frac{2}{10}$  – вероятность возврата на порядок ниже после «а».

$$\frac{0}{5} + \frac{2}{5} * \left( \frac{0}{5} + \frac{2}{10} * \left( \frac{3}{23} \right) \right) \quad (1)$$

### 3. Нейросетевой подход

Сегодня использование нейросетевых моделей становится наиболее популярным методом машинного обучения на основе собранных данных. Нейросети могут выполнять задачи классификации (в контексте умного дома используется для распознаваний действий пользователя, принятие решений по управлению исполнительными устройствами УД), прогнозирования (предугадывание действий пользователя). Грубо говоря, искусственные нейронные сети (ИНС) отображают входные данные на соответствующие выходы. Свойство обобщения ИНС позволяет найти незаметные паттерны (закономерность) среди данных и получить подходящий результат на выходе.

ИНС состоят из множества простых взаимосвязанных элементов, называемых нейронами. Каждый нейрон на вход получает множество входных значений, которые перемножаются со своим весовым коэффициентом, складывается, а затем подается на вход функции активации (обычно сигмоида или гиперболический тангенс), как показано на рисунке 5. Далее множество нейронов объединяются в слои. Слой – множество нейронов, которые получают входную информацию из одного источника (входного или скрытого слоя) и все их выходы соединены с теми же нейронами следующего слоя (скрытого или выходного слоя) [4].

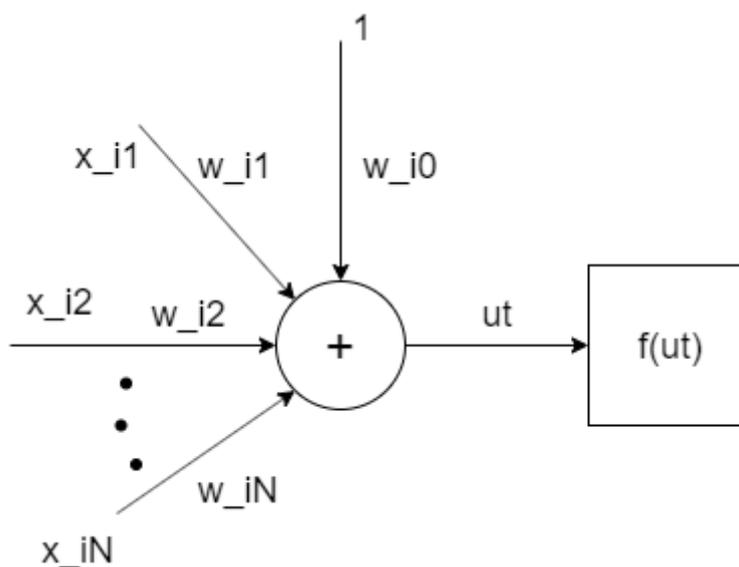


Рисунок 5 – Модель нейрона

Существует множество различных типов ИНС, применяющиеся для решения различных в контексте УД. Есть, например, многослойный персептрон (МП) (использующийся для классификации и реже прогнозирования), рекуррентные сети (хороши в задаче прогнозирования, особенно если они заданы как в случае, когда мы рассматривали ActiveLezi), свёрточные нейронные сети (распознавание изображений с видеокамер (ССТV)).

В рамках данной статьи, рассмотрим следующий пример использования многослойной ИНС. Так в работе [5], ИНС используется для прогнозирования температуры внутри УД на

основе полученных ранее данных. В данной работе автор рассматривает несколько способов обучения многослойного персептрона, а именно MLP, AMLP, OMLP, OAMLР.

1. MLP: ИНС обучена единожды на одном наборе данных.

2. AMLP: ИНС обучена на старом наборе данных, а также итерационно до обучается еженедельно на основе и старых, и новых данных.

3. OMLP: ИНС обучена на старом наборе данных, а также корректировка весов происходит после получения нового паттерна данных (то есть, например, если температура собирается раз в полчаса, то и корректировка весов ИНС происходит с тем же интервалом).

4. OAMLР = OMLP + AMLP.

На вход МП подается следующие данные, таблица 1.

Таблица 1 – Данные на входе МП

Название	Тип
Статус системы отопления	Бинарный
Температура, которую вырабатывает система отопления внутри УД	Действительное число
Статус системы кондиционирования воздуха	Бинарный
Температура, которую вырабатывает система кондиционирования воздуха	Действительное число
Влажность «за окном»	Действительное число
Температура «за окном»	Действительное число
Солнечная радиация	Действительное число
Температура внутри УД (Т)	Действительное число
Предыдущая температура (Т - 1)	Действительное число

На основе входных данных была разработана следующая топология ИНС:

- 10 нейронов входного слоя;
- 1 нейрон выходного слоя;
- 20 нейронов выходного слоя ( $2 \cdot$  кол-во нейронов входного слоя) [8];
- скорость обучения 0.01;
- функция активации скрытого слоя – сигмоидальная функция;
- функция активации выходного слоя – линейная функция.

По результату тестирования ИНС с 4 подходами к обучению описанным выше, в работе [7] было установлено, что OMLP и OAMLР позволяют получить довольно точный прогноз температуры в следующей отрезок времени, со среднеквадратичной ошибкой меньше 0.05.

Ещё одной разновидностью нейронных сетей являются рекуррентные нейронные сети. До этого многослойная нейронная сеть обрабатывала текущие входные данные независимо от предыдущих. Рекуррентная нейронная сеть также как и человеческий интеллект воспринимает информацию последовательно, сохраняя состояние, полученное от предыдущих элементов данных. Схематично такую сеть изображают, рисунок 6, с внутренним циклом и говорят, что

она имеет память [7]. Такого типа нейронные сети хорошо себя показывают в предсказании следующего символа или слова исходя из предыдущего текста.

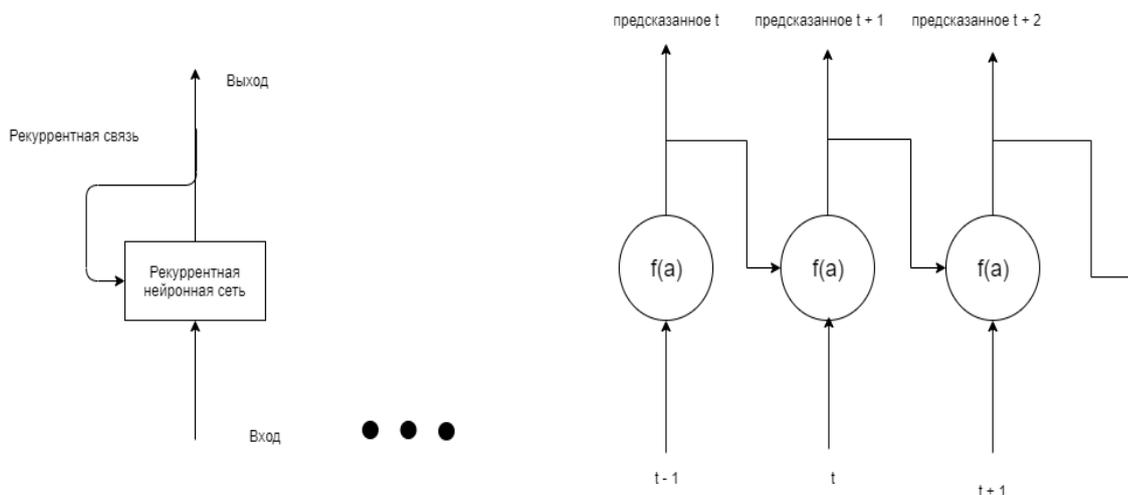


Рисунок 6 – Упрощенная схема рекуррентной нейронной сети

На данный момент два типа рекуррентных сетей получили широкое распространение при решении задачи прогнозирования – это LSTM и GRU. Они имеют разную внутреннюю структуру, но очень схожи поэтому в рамках данной работы рассмотрим применение LSTM для предсказания последующих событий (например, перемещение жителя по комнатам) в УД. Так, например, в работе [8] представлено сравнение LSTM с другими методами последовательного прогнозирования действий пользователя, а также продолжительности этого действия. Наилучшую точность показала нейронная сеть с двумя последовательными слоями LSTM.

## 5. Сравнение методов прогнозирования, плюсы и минусы

Для сравнения методов была выбрана задача прогнозирования следующей комнаты, в которую войдет житель УД. Все результаты получены с использованием датасета CASAS NH14. В данном датасете находятся показания датчиков передвижения по квартире за 1 месяц. В квартире имеется 4 комнаты, и прихожая в которых расположены 13 датчиков движения, рисунок 7. Сам датасет имеет формат в виде таблицы (дата, время, датчик, показание датчика (для датчика движения булево значение)). После обработки нужных строк таблицы получено 87 000 строк, 80 % процентов которых будет использоваться для обучения, а 20 % для проверки точности модели.

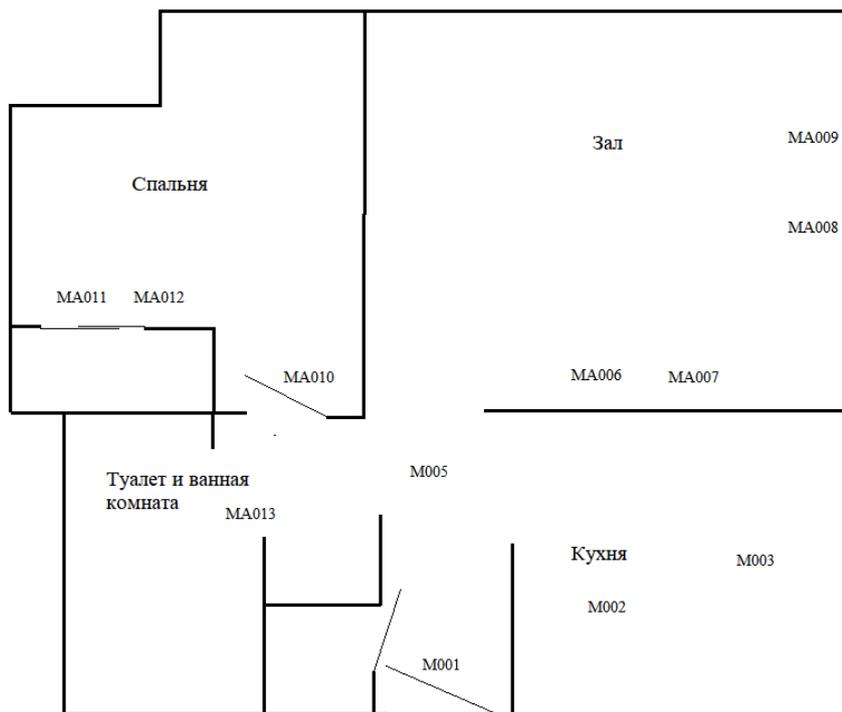


Рисунок 7 – Схема квартиры из датасета NH114

Начнём с ActiveLezi. Точность данного алгоритма можно увидеть на рисунке 8. Точность ALZ сравним с точностью многослойного персептрона, но меньше, чем у LSTM. Однако недостатком данного алгоритма можно выделить сложность его распараллеливания, так как он основан на алгоритме последовательного сжатия и данные на предыдущем шаге важны для следующего. В итоге распараллелить можно только в месте, где мы высчитываем вероятность каждого отдельного символа. Данный факт негативно влияет на скорость предсказания (даже не на скорость обучения (формирование статистики строки в дерево))



Рисунок 8 – Точность прогнозирования ActiveLezi

Многослойный перцептрон. В данном случае входные данные были закодированы в двоичном виде (номер датчика в двоичном виде ( $4 = [0\ 1\ 0\ 0]$ )). Поэтому 1 нейрон входного слоя принимает булево значение, а всего нейронов во входном слое равняется произведению 4 и количества последних показаний с датчика (например модель, предсказывающая срабатывание следующего датчика по 4 последним показаниям, имеет  $4*30=120$  входов). Выходные данные модели закодированы с помощью one-hot encoding и поэтому выходной слой имеет 14 (13 датчиков + 1) выходов и функцию активации softmax. Так же имеется 2 скрытых слоя с сигмной и размером в N нейронов. N вычисляется по формуле 2. В скобках вычисляется сумма из размеров входного и выходного слоев. Эмпирическим путем было установлено что лучшая точность достигается при предсказании на основе 30 последних показаний с датчика и поэтому  $N = 89$ .

Точность прогнозирования многослойного нейрона можно увидеть на рисунке 9. Многослойный перцептрон имеет довольно быструю скорость работы по сравнению с ALZ (при обучении и непосредственно прогнозировании) за счёт параллельных вычислений. Но всё же имеет более низкую точность по сравнению с рекуррентными сетями в такого рода задачах.

$$N = \frac{2}{3} * (N_o + N_i) \quad (2)$$

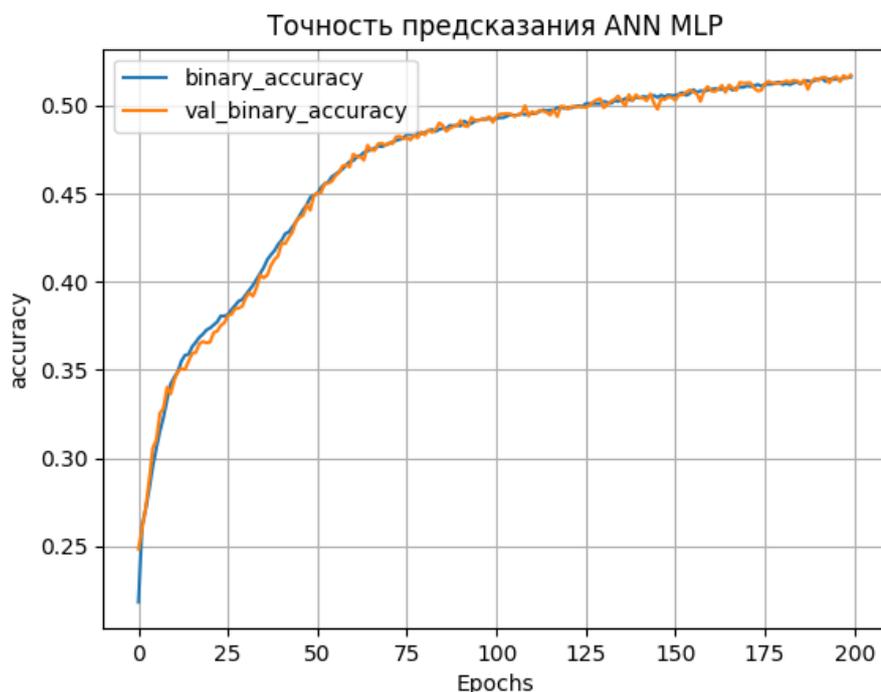


Рисунок 9 – Точность прогнозирования многослойного перцептрона

И наконец LSTM. Такие параметры сети как количество нейронов в слоях, функции активации подбирались так же, как и у многослойного перцептрона. Отличие в том, что предсказание делалось на основе 50 показаний с датчиков, а номер датчика во входных данных кодировался с помощью минимаксной нормализации.

Точность прогнозирования можно видеть на рисунке 10. LSTM имеет наилучшую точность среди рассмотренных методов. Однако, можно выделить один недостаток – большая вычислительная сложность при обучении модели. При большом количестве скрытых слоев и количестве нейронов в них, возникает необходимость обучения модели на машине с достаточно производительным GPU.

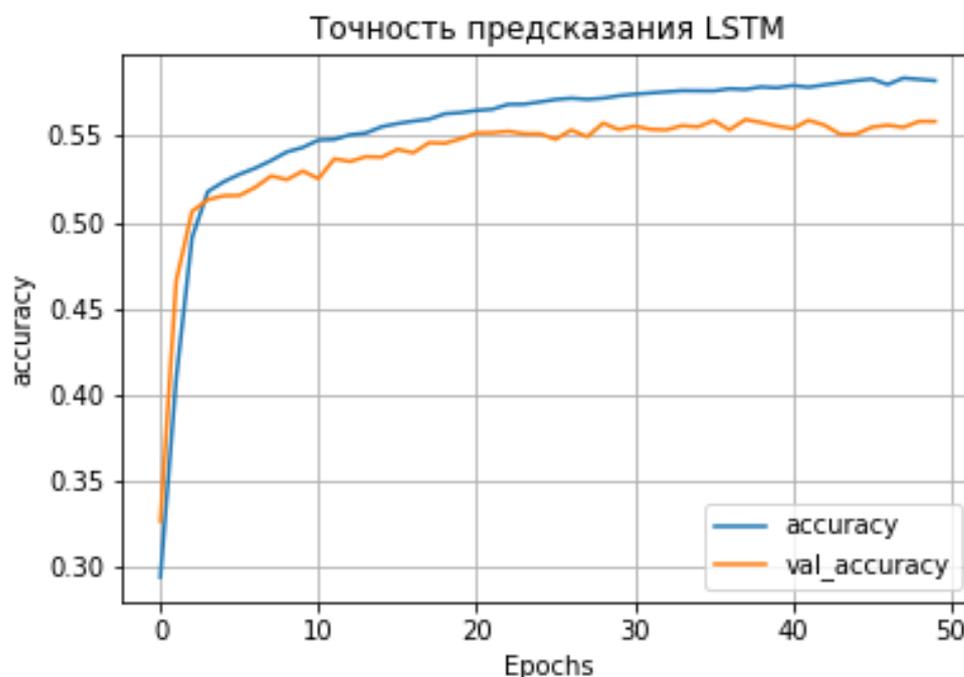


Рисунок 10 – Точность прогнозирования LSTM

Сравнение точности всех методов прогнозирования можно увидеть в итоговой таблице 2. Для замера времени выполнения использовались данные первых 4 дней датасета, а сами алгоритмы выполнялись на CPU Intel(R) Xeon(R) CPU @ 2.20GHz, предоставленный сервисом Google Colaboratory. Как видно из данной таблицы лучшую точность показал LSTM. Лучшее время обучения и прогнозирования в сумме показал многослойный перцептрон, это означает что в задачах, которые подразумевают периодическое дообучение модели при недостатке вычислительной мощности лучше использовать именно его. Алгоритм ActiveLezi же показал худшее время из-за сложности его распараллеливания.

Таблица 2 – Сравнение методов прогнозирования

Метод	ActiveLezi	Многослойный перцептрон	LSTM
Точность, %	49.48	51.60	56.40
Время обучения\ сбора статистики, мм:сс	00:0,06	00:18,79	00:21,96
Время прогнозирования, мм:сс	36:13,69	00:0,15	00:0,64

### **Список литературы**

1. Aditi Dixit, Anjali Naik. Use of Prediction Algorithms in Smart Homes // International Journal of Machine Learning and Computing. April 2014. Vol. 4, No. 2.
2. Sajal K. Das, Diane J. Cook, Amiya Bhattacharya, Edwin O. Heierman And Tze-Yun Lin. The role of prediction algorithms in the MavHome smart home architecture // University of Texas at Arlington: IEEE Wireless Communications. December 2002. pp. 78 – 84.
3. K. Gopalratnam and D. J. Cook. Active Lezi: an incremental parsing algorithm for sequential prediction // International Journal on Artificial Intelligence Tools. 2004. Vol. 13, No.4. pp. 917 – 929.
4. Нейронные сети для обработки информации / И.Д. Рудинского. — М.: Финансы и статистика, 2002. — с. 344.
5. Sadi Alawadi, David Mera, Manuel Fern´andez-Delgado, and Jos´e A. Taboada. Comparative Study of Artificial Neural Network Models for Forecasting the Indoor Temperature in Smart Buildings // Springer International Publishing. 2017. pp. 29 – 38.
6. Swingler, K.: Applying Neural Networks: A Practical Guide. Morgan Kaufmann // San Francisco. 1996.
7. Глубокое обучение на Python. / Шолле Франсуа. — СПб.: Питер, 2018. — 400 с.:
8. Niek Tax.: Human Activity Prediction in Smart Home Environments with LSTM Neural Networks. // 2018 International Conference on Intelligent Environments. 2018.

### **References**

1. Aditi Dixit, Anjali Naik. Use of Prediction Algorithms in Smart Homes // International Journal of Machine Learning and Computing. April 2014. Vol. 4, No. 2.
  2. Sajal K. Das, Diane J. Cook, Amiya Bhattacharya, Edwin O. Heierman And Tze-Yun Lin. The role of prediction algorithms in the MavHome smart home architecture // University of Texas at Arlington: IEEE Wireless Communications. December 2002. pp. 78 – 84.
  3. K. Gopalratnam and D. J. Cook. Active Lezi: an incremental parsing algorithm for sequential prediction // International Journal on Artificial Intelligence Tools. 2004. Vol. 13, No.4. pp. 917 – 929.
  4. Neural networks for processing information / I.D. Rudinsky. M.: Finance and statistics, 2002. – 344p.
  5. Sadi Alawadi, David Mera, Manuel Fern´andez-Delgado, and Jos´e A. Taboada. Comparative Study of Artificial Neural Network Models for Forecasting the Indoor Temperature in Smart Buildings // Springer International Publishing. 2017. pp. 29 – 38.
  6. Swingler, K.: Applying Neural Networks: A Practical Guide. Morgan Kaufmann // San Francisco. 1996.
  7. Deep learning on Python. / Scholle Francois. St. Petersburg: Peter, 2018. 400 p.:
  8. Niek Tax.: Human Activity Prediction in Smart Home Environments with LSTM Neural Networks. // 2018 International Conference on Intelligent Environments. 2018.
-