

*Н.М. Лыченко, А.В. Сороковая*

Институт машиноведения и автоматизации НАН КР, Бишкек, Кыргызстан

*E-mail: [nlychenko@mail.ru](mailto:nlychenko@mail.ru), [nastusha24sh-g@yandex.com](mailto:nastusha24sh-g@yandex.com)*

## **ПРИМЕНЕНИЕ LSTM-НЕЙРОННЫХ СЕТЕЙ ДЛЯ КЛАССИФИКАЦИИ ИНДЕКСА КАЧЕСТВА ВОЗДУХА Г. БИШКЕК**

Рассмотрена задача прогнозирования индекса качества воздуха AQI г. Бишкек в зависимости от метеопараметров как задача нейросетевой классификации. Обоснован выбор LSTM-нейронной сети как наиболее эффективной. Разработан классификатор индекса качества воздуха, решающий проблему прогноза классов AQI “Хороший”/“Нездоровый”, для различной истории наблюдений метеопараметров и различной глубины прогноза. Достигнута точность прогноза более 90%.

**Ключевые слова:** классификация, прогноз, индекс качества воздуха, LSTM-нейронная сеть.

**Введение.** Одним из интегрированных показателей загрязненности атмосферного воздуха является индекс качества воздуха (Air Quality Index, AQI [1]. Индекс качества воздуха является кусочно-линейной функцией концентрации загрязняющих веществ в атмосфере: диоксида серы (SO<sub>2</sub>), диоксида азота NO<sub>2</sub>, взвешенных частиц меньше 10 мкм (PM<sub>10</sub>) и взвешенных частиц меньше 2,5 мкм (PM<sub>2.5</sub>), окиси углерода (CO) и озона (O<sub>3</sub>). Для каждого из этих загрязнителей Агентство США по охране окружающей среды (EPA) установило национальные стандарты качества воздуха. В основе вычисления AQI – соотношение измеренной усредненной концентрации загрязнителя и стандартной (допустимой) концентрации этого загрязнителя. Значение AQI, равное 100, в целом соответствует национальному стандарту качества воздуха для загрязнителя. Поскольку AQI диоксида азота, диоксида серы и монооксида углерода чаще всего ниже 50, наибольшую угрозу для здоровья человека представляют озон и частицы PM. В общем, существует 6 уровней (классов) AQI:

- «Хороший» показатель AQI – от 0 до 50; качество воздуха считается удовлетворительным, а загрязнение воздуха представляет небольшой или нулевой риск;

- «Умеренный» AQI - от 51 до 100; качество воздуха приемлемое, однако, у очень небольшого числа людей могут возникнуть умеренные проблемы со здоровьем (например, люди, которые необычно чувствительны к озону, могут испытывать респираторные симптомы);

- «Нездоровый для чувствительных групп» AQI составляет от 101 до 150; люди с заболеванием легких и сердца, пожилые люди и дети подвергаются большему риску.

- «Нездоровый» показатель AQI - от 151 до 200; каждый человек может начать испытывать некоторые негативные последствия для здоровья, а члены чувствительных групп могут испытывать более серьезные последствия;

- «Очень нездоровый» AQI - от 201 до 300; такой уровень предупреждает о том, что каждый человек может испытывать серьезные последствия для здоровья;

- «Опасный» AQI больше 300; такой уровень соответствует чрезвычайным ситуациям, все население, скорее всего, будет затронуто негативным воздействием на здоровье.

Охрана окружающей среды предполагает не только оценку состояния здоровья населения в данный момент времени, но и прогнозирование последствий влияния загрязняющих веществ на здоровье жителей исследуемого региона. Поэтому задача анализа динамики изменения концентраций вредных веществ и построения моделей для прогноза их содержания в воздухе представляет особый интерес.

Для г. Бишкек проблема загрязнения атмосферного воздуха стоит крайне остро и построение прогностических моделей на основе актуальных для города данных – важная задача. В день, когда прогнозируется повышение AQI из-за загрязнения мелкими частицами, агентство по чрезвычайным ситуациям или организации общественного здравоохранения могут [1]:

- рекомендовать чувствительным группам, таким как пожилые люди, дети и лица с респираторными или сердечно-сосудистыми проблемами, избегать физических нагрузок на открытом воздухе;
- объявить «день действий» для поощрения добровольных мер по сокращению выбросов в атмосферу, таких как использование общественного транспорта;
- рекомендовать использовать маски для предотвращения попадания мелких частиц в легкие.

Во время периода очень низкого качества воздуха, когда AQI указывает, что острое воздействие может нанести значительный вред общественному здоровью, правительственные организации могут объявить о чрезвычайной ситуации и, согласно плану действий, ограничить выбросы основных источников загрязнения воздуха до тех пор, пока показатели степени загрязнения не опустятся до приемлемых значений.

Универсальных моделей для прогноза ИКВ быть не может, поскольку в них необходимо учитывать региональные природные, экономические, антропогенные и климатические особенности территории. В литературе опубликовано немало работ, связанных с построением моделей прогноза индекса качества воздуха для различных регионов и городов. Для г. Бишкек таких работ практически нет, главным образом, ввиду того, что открытая информация об уровне загрязненности атмосферного воздуха в городе появилась лишь в феврале 2019 г. на сайте [2]. Основываясь на этой информации, в [3] оценена временная изменчивость индекса качества воздуха и разработаны интегрированные модели авторегрессии-скользящего среднего (AutoRegressive Integrated Moving Average model, ARIMA-модели) для его краткосрочного прогноза на основе данных наблюдений для летнего периода 2019 года. В [4] выполнена оценка влияния метеорологических факторов (таких, как скорость ветра, температура, относительная влажность воздуха, температура точки росы, интенсивность осадков и атмосферное давление) на процесс загрязнения воздуха г. Бишкек частицами PM<sub>2.5</sub> в период с февраля по ноябрь 2019 г. и выявлены умеренные корреляции (как положительные, так и отрицательные) между концентрациями PM<sub>2.5</sub> и метеорологическими параметрами, измеренными в текущий и прошлые сроки. В связи с этим, интересной представляется задача прогноза индекса качества воздуха г. Бишкек с учетом метеорологических факторов.

**Задача прогноза AQI как задача классификации.** В настоящей работе задача прогноза индекса качества воздуха AQI по метеорологическим данным рассмотрена как задача классификации AQI в зависимости от метеорологических условий, соответствующих определенным уровням AQI.

Задача классификации в общем смысле представляет собой задачу разделения множества объектов на классы на основе обучающей выборки – конечного множества объектов, для которых классы заранее определены экспертом или иным способом [5]. Задача классификации заключается в построении алгоритма для определения классовой принадлежности объектов вне обучающей выборки.

Математически задачу классификации можно сформулировать следующим образом. Дано множество описаний объектов  $X$  и множество номеров (наименований) классов  $Y$ . Описание объекта  $x \in X$  представляет собой вектор признаков  $x = (f_1(x), f_2(x), \dots, f_n(x))$ , называемый признаковым описанием объекта  $x$ . Существует неизвестное отображение  $y': X \rightarrow Y$ , значения которого определены на обучающей выборке. Требуется построить алгоритм  $a: X \rightarrow Y$ , способный классифицировать любой объект  $x \in X$ .

Для AQI классы соответствуют определенным уровням загрязнения воздуха [1]. При анализе данных наблюдений AQI [2] в период с 6 февраля 2019 по 31 марта 2020 года было подсчитано количество наблюдений, указывающих на определенный класс AQI и их процентное соотношение (рисунок 1а)).

Из анализа количества наблюдений видно, что в подавляющем числе зафиксированы значения AQI класса “Умеренный”. Количества наблюдений для классов “Хороший”, “Нездоровый для чувствительных групп”, “Нездоровый”, “Очень нездоровый”, “Опасный” недостаточно для решения задачи классификации AQI по всем классам. В связи с этим будем классифицировать AQI по двум классам: “Хороший” (объединяет классы “Хороший” и “Умеренный”) и “Нездоровый” (объединяет классы “Нездоровый для чувствительных групп”, “Нездоровый”, “Очень нездоровый” и “Опасный”) (рисунок 1б)). При таком распределении данных, если всегда предсказывать “Умеренный” класс, то точность такого «наивного» прогноза составит 70%.




Рисунок 1 – Распределение наблюдений по классам AQI (а) и распределение наблюдений по объединенным классам AQI (б)

**Выбор модели решения.** Рассмотрим задачу классификации AQI на два класса в зависимости от метеорологических условий, соответствующих определенным уровням AQI. При этом будем считать классификатор приемлемым, если его точность превышает точность 70%.

Как показано в [3], на степень загрязнения воздуха влияют метеорологические условия не только на текущий момент, но и история изменения этих условий. Это говорит об инерционности процессов загрязнения, т.е. изменение происходит не моментально, а меняется постепенно вместе с изменением сопутствующих факторов. Очевидно предположить, что прогностические модели, учитывающие историю наблюдений, будут работать лучше, чем модели, основанные на оценке исключительно текущих данных. Для анализа исторических данных, как правило, используются искусственные нейронные сети, в частности, рекуррентные нейронные сети [6, 7].

Однако степень загрязнения воздуха может реагировать на различные факторы с разной скоростью. История каждого фактора должна быть оценена по-разному – для каких-то факторов важны только последние данные, влияние других может сказываться продолжительное время. Учитывая этот факт, в данной работе предложено для классификации AQI использовать LSTM-сети [8, 9]. Их архитектура содержит так называемые фильтры, которые в процессе обучения настраиваются сохранять/забывать информацию выборочно о различных факторах и, таким образом, могут взвесить влияние каждого фактора во времени.

LSTM-сеть (долгая краткосрочная память) – частный вид рекуррентной нейронной сети. Однако обычные рекуррентные сети могут учитывать только недавние прошлые состояния сети. Эту проблему называют проблемой долговременных зависимостей или проблемой исчезновения градиента [8]. В теории эта проблема решается правильным выбором параметров сети, однако проблема выбора этих параметров все еще остается нерешенной. LSTM-сети созданы специально для решения этой проблемы и позволяют обнаруживать как длинные, так и короткие шаблоны в данных, а также частично устраняют проблему исчезновения градиента [8, 9].

Рекуррентная нейронная сеть может быть представлена в форме последовательности одинаковых модулей нейронной сети (рисунок 2) [6].




Рисунок 2 - Рекуррентная нейронная сеть в виде последовательности модулей

В обычной рекуррентной сети, как рассматривалось ранее, модуль представляет собой один слой нейронов с обычной функцией активации. Модуль LSTM-сети представляет собой не один, а четыре слоя, которые взаимодействуют особым образом (рисунок 3). Желтым прямоугольником соответственно обозначен слой нейронной сети, розовым кружком – поточечная операция, стрелками – поток передачи целого вектора, сходящимися стрелками – конкатенация векторов.

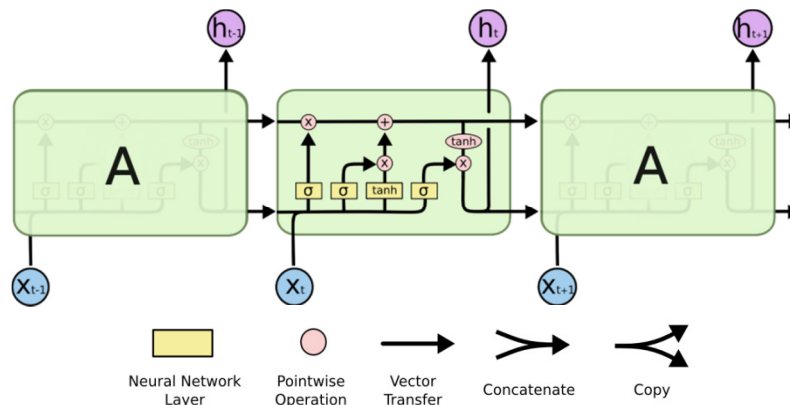


Рисунок 3 – Общая архитектура LSTM-сети

Ключевой компонент модуля LSTM-сети – вектор состояния (рисунок 4). Вектор состояния регулируется специальными фильтрами, они управляют удалением и обновлением информации в нем. Сигмоидальный слой в фильтре определяет, какую

долю информации перезаписать в векторе состояния (0 – не записывать ничего, 1 – записать все).

Условные обозначения здесь:

- $x_t$  — входной вектор в момент времени  $t$ ,
- $h_t$  — выходной вектор в момент времени  $t$ ,
- $C_t$  — вектор состояний в момент времени  $t$ ,
- $W_k$  — матрица параметров слоя  $k$ , т.е. веса связей,
- $b_k$  — вектор смещений выходов слоя  $k$ ,
- $f_t$  — вектор фильтра забывания в момент времени  $t$ ,
- $i_t$  — вектор входного фильтра в момент времени  $t$ ,
- $o_t$  — вектор выходного фильтра в момент времени  $t$ .




Рисунок 4 – Состояние модуля LSTM-сети

LSTM работает следующим образом [6]:

1. Слой фильтра забывания определяет, какую информацию можно удалить из вектора состояния (Рисунок 5а). Для каждого числа из состояния  $C_{t-1}$  возвращается число от 0 до 1 (где нулевое значение значит, что значение надо забыть).

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

2. Сигмоидальный слой входного фильтра определяет, какие значения следует обновить, а тангенс-слой строит вектор новых значений  $C_t$ , которые могут быть добавлены в состояние  $C_t$  (Рисунок 5b).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$C_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

3. Для обновления состояния старое состояние необходимо умножить на  $f_t$  и прибавить к нему  $i_t * C_t$  (Рисунок 5с).

4. Выход LSTM-сети представляет собой состояние  $C_t$  с примененной к нему функцией активации, при этом выходной фильтр определяет, какие именно элементы состояния выводить (Рисунок 5d).

$$h_t = o_t * \tanh(C_t)$$

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o)$$




Рисунок 5 – Принцип работы LSTM-сети

**Методы оценки качества классификации.** Для проверки качества классификации необходима тестовая выборка – размеченный набор данных, т.е. набор объектов с номером (наименованием) класса, к которому они относятся. Классифицируя объекты тестовой выборки и сравнивая полученные классы с действительными, можно оценить качество классификации в виде численной метрики.

Простейшей метрикой является аккуратность (ассигасу) – доля правильно классифицированных объектов из всей тестовой выборки [10]:

$$acc = \frac{P}{N}$$

где  $P$  – количество правильно классифицированных объектов,  $N$  – размер тестовой выборки. Эта метрика присваивает одинаковый вес всем объектам, что неправильно, если распределение классов в выборке различно.

В общем виде все метрики можно вывести из так называемой матрицы ошибок (confusion matrix). Матрица ошибок  $A$  представляет собой матрицу размера  $n * n$ , где  $n$  – количество классов, представленных в выборке. Элемент матрицы  $A_{ij}$  содержит значение, показывающее, сколько раз классификатор определил класс  $j$  как класс  $i$ .

Имея матрицу ошибок, можно вывести две метрики [10]:

- точность в пределах класса – доля объектов, действительно принадлежащих классу относительно числа объектов, которые классификатор определил к этому классу:

$$precision_c = \frac{A_{c,c}}{\sum_{i=1}^n A_{c,i}}$$

- полнота в пределах класса – доля объектов, определенных классификатором к классу, относительно всех документов, действительно принадлежащих этому классу:

$$recall_c = \frac{A_{c,c}}{\sum_{i=1}^n A_{i,c}}$$

Для получения единой метрики значения точности и полноты для каждого класса обычно усредняются.

Метрикой, объединяющей точность и полноту, является так называемая F-мера – гармоническое среднее между точностью и полнотой [10]:

$$F = \frac{2 * precision * recall}{precision + recall}$$

Таким образом, чем больше F-мера, тем качественнее работает классификатор.

**Подготовка данных.** Для решения задачи классификации были подготовлены два файла данных за период наблюдений с 06.02.2019 по 31.03.2020: с историческими наблюдениями AQI [2] и историческими наблюдениями метеорологических условий [11], с интервалом наблюдений в 3 часа.

На рисунке 6 представлены график изменения индекса качества воздуха AQI г. Бишкек за указанный период и графики автокорреляционной (ACF AQI) и частичной автокорреляционной (PACF AQI) функций. Из графика автокорреляционной функции видно, что в данных содержится суточная периодичность в 24 часа (8 лагов).




Рисунок 6 – Значения индекса качества воздуха в г. Бишкек за период 06.02.2019-31.03.2020, автокорреляционная (ACF AQI) и частичная автокорреляционная (PACF AQI) функции.

Входной вектор классификатора определяется пятью параметрами: температура воздуха, атмосферное давление, относительная влажность, скорость ветра, температура точки росы. При этом данные о температуре воздуха, атмосферном давлении, температуре точки росы нормализуются с помощью Z-нормы.

Выходной вектор, к которому должен приближаться выход классификатора, определяется двумя параметрами – вероятностью отнесения выхода классификатора к классу “Хороший”, равной 1 для AQI  $\leq$  100 и вероятностью отнесения выхода классификатора к классу “Нездоровый”, равной 1 для AQI  $>$  100.

При проведении вычислительных экспериментов по прогнозированию класса AQI варьировались следующие параметры:

- $S$  – длина последовательности векторов исторических данных - входных векторов (ВВ) классификатора;
- $P$  – глубина прогноза (на сколько шагов вперед прогнозируется AQI). Шаг прогноза – 3 часа.

Программная реализация проведения экспериментов извлекает данные, соотнося их по времени, нормализует данные по заданной функции нормализации, по заданным  $S$  и  $P$  генерирует все возможные последовательности входных векторов классификатора длиной  $S$  и сопоставляет им значения AQI в моменты времени, удаленные на  $P$  шагов от момента последних значений этих последовательностей.

Так как анализ показал несбалансированность данных (70% - относятся к классу AQI “Хороший” и 30% - к классу “Нездоровый”), для обучения классификатора необходимо было сбалансировать эти группы. С этой целью из выборки “Хороший” случайным образом выбрано такое же количество примеров, которое содержится в выборке “Нездоровый”.

**Разработка классификатора.** Для подтверждения эффективности LSTM-сети в решении задачи классификации AQI проведены эксперименты на различных однослойных сетях с одинаковым количеством нейронов на скрытом слое (50 нейронов с тангенциальной функцией активации). Эксперимент проводился на выборке наблюдений с 06.02.2019 по 26.11.2019.

Тестируемые модели классификаторов – следующие.

1. Полносвязная сеть прямого распространения, не учитывающая исторические данные. Вход – вектор признаков в один момент времени.
2. Полносвязная сеть прямого распространения, учитывающая исторические данные. Вход – вектор, конкатенирующий векторы входной последовательности.
3. Рекуррентная нейронная сеть. Вход – последовательность векторов.
4. LSTM-сеть.

Выход каждой сети – вероятности того, что AQI в момент времени через  $P$  шагов от момента, соответствующего последнему вектору последовательности, будет отнесен к классу “Хороший” и “Нездоровый”. Предсказанный класс определяется большей вероятностью.

Для каждой модели проведено 3 эксперимента. В каждом эксперименте из набора данных выделяются 5 непересекающихся частей. Согласно алгоритму перекрестной проверки, каждая из этих частей единожды выступает в качестве тестовой выборки, а оставшиеся части – в качестве обучающей. F-мера точности классификатора в каждом эксперименте определяется средним значением F-меры точности, полученной на каждом этапе перекрестной проверки. Результаты каждого эксперимента также усреднялись. В таблице 1 представлены полученные значения F-меры точности перечисленных однослойных моделей.

Из таблицы видно, что предположение о том, что классификатор, учитывающий историю изменения векторов, должен давать более высокую точность, чем учитывающий только последние данные, действительно верно. При этом LSTM-сеть действительно оказалась наиболее эффективной из рассмотренных.

Таблица 1 – Оценка F-меры точности моделей – различных однослойных сетей

Номер тестируемой модели	Эксперименты (F-мера точности)			Среднее
	I	II	III	
1	0.7340	0.7279	0.7282	0.7300
2	0.7630	0.7690	0.7800	0.7707
3	0.7969	0.8201	0.7898	0.8023
4	0.8214	0.8340	0.8368	0.8307



Дальнейшие эксперименты проводились на LSTM-сетях для выборки с 06.02.2019 по 31.03.2020.

Выбранная модель LSTM-сети несколько усложнена для предотвращения переобучения и возможного увеличения точности.

Структура используемой далее LSTM-сети:

1. Входной слой длиной 5 (5 признаков входного вектора ВВ), который принимает последовательность векторов признаков длиной  $S$ .
2. Первый скрытый слой – слой прямого распространения с числом нейронов 100 и тангенциальной функцией активации, отображает входные векторы в векторы большей длины, для дальнейшего внесения шума в данные.
3. Второй скрытый слой – слой регуляризации, который меняет некоторый процент значений выхода предыдущего слоя для предотвращения переобучения (вносит шумы);
4. Третий скрытый слой – LSTM-сеть с 50 нейронными модулями и тангенциальной функцией активации как основной классифицирующий слой;
5. Четвертый скрытый слой – слой прямого распространения с числом нейронов 10 и тангенциальной функцией активации;
6. Выходной слой – слой с 2 нейронами и функцией активации *SOFTMAX*.  
Функция взвешивает входы и предсказывает вероятности активации каждого нейрона. При этом сумма выходов нейронов всегда равна 1.

Все слои сети полносвязные, т.е. каждый нейрон имеет связь с каждым предыдущим нейроном, а для рекуррентных слоев (LSTM-сеть) каждый вход слоя также связан с каждым выходом слоя.

В качестве визуализации процесса обучения на рисунке 7 представлены графики изменения точности (Accuracy) и функции потерь (Loss) в зависимости от номера эпохи обучения (epoch) сети с параметрами  $S=12$ ,  $P=8$  для обучающей (train) и тестовой (validation) выборок. Заметим, что процесс обучения вполне отвечает рекомендациям, приведенным в [12].

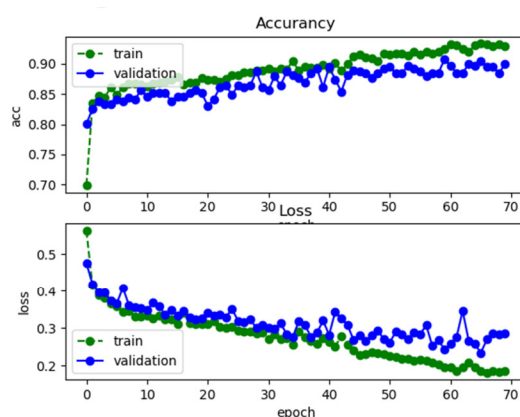


Рисунок 7 – Графики изменения точности (Accuracy) и функции потерь (Loss) в зависимости от номера эпохи обучения (epoch) сети с параметрами  $S=12$ ,  $P=8$ .

**Обсуждение результатов.** Эксперименты с LSTM-сетью дали результаты, представленные в таблице 2.

Из экспериментов видно, что все классификаторы дали приемлемую точность прогноза (>70%), однако лучшую точность прогнозирования дали классификаторы, учитывающие историю данных глубиной 8-16 шагов (1 – 2 дня).

Таблица 2 – F-мера точности моделей в зависимости от длины последовательности входных векторов (*S*) и глубины прогноза (*P*).

S	P	F-мера	S	P	F-мера	S	P	F-мера	S	P	F-мера	S	P	F-мера
2	2	0.8842	4	2	0.8748	8	2	0.8976	12	2	0.9018	16	2	0.9120
2	4	0.8696	4	4	0.8787	8	4	0.8924	12	4	0.9021	16	4	0.8885
2	8	0.8617	4	8	0.8753	8	8	0.9011	12	8	0.9093	16	8	0.9085
2	16	0.8408	4	16	0.8684	8	16	0.8955	12	16	0.8972	16	16	0.9051
2	24	0.8615	4	24	0.8585	8	24	0.8889	12	24	0.8958	16	24	0.9083
2	32	0.8387	4	32	0.8552	8	32	0.8824	12	32	0.8998	16	32	0.9115

Как видно, модели, основанные на истории наблюдения погодных условий более 1 суток ( $S \geq 8$ ) мало отличаются по точности. Это можно связать с тем, что погодные условия, наблюдаемые за 24 часа, несут максимум полезной информации. Влияние более ранних погодных условий практически угасает.

При прогнозе AQI до 2х дней вперед ( $P \leq 16$ ) точность модели практически не меняется на исторических данных за 24 часа и более, F-мера остается примерно 90%. Таким образом в этом случае нецелесообразно для классификации AQI рассматривать историю изменения погодных условия длинее 24 часов.

При прогнозе на более чем 2 суток вперед ( $P > 16$ ) более эффективными оказались модели, учитывающие исторические данные в промежутке более 24 часов. Это влияние небольшое - F-мера увеличивается на 1–2%.

Таким образом, настоящим исследованием доказана эффективность рекуррентных сетей для классификации индекса качества воздуха. Представлен классификатор на основе LSTM-сети, решающий проблему прогноза классов AQI “Хороший”/“Нездоровый”. Найдены параметры классификатора, дающие достаточно хорошую точность прогноза. На основе полученных результатов можно сделать вывод, что прогноз AQI возможен до 4х дней вперед с точностью 88-90%, что значительно выше точности «наивного» прогноза (70%).

Проблемой при исследовании классификаторов стала недостаточность данных. Для обучения сети обычно требуется значительное количество примеров, в то время как при исследовании использовалась всего по 970 примеров каждого класса, учитывая удаление части выборки, соответствующей классу “Хороший” для сбалансированности данных. Увеличение истории наблюдений позволит увеличить количество примеров и построить классификатор AQI на большее количество классов. С этой же целью можно искусственно увеличивать количество примеров для «плохих» данных различными методами (oversampling).

*Литература*

1. Air Quality Index (AQI) – A Guide to Air Quality and Your Health. US EPA. 9 December 2011.
2. AirNow Department of State // [https://airnow.gov/index.cfm?action=airnow.global\\_summary#U.S.\\_Department\\_of\\_State](https://airnow.gov/index.cfm?action=airnow.global_summary#U.S._Department_of_State) \$Bishkek, (дата обращения: 30.04.2020).
3. Верзунов С.Н., Лыченко Н.М. Краткосрочное прогнозирование индекса качества воздуха на основе ARIMA-моделей // Математическое и компьютерное моделирование: сборник материалов VII Международной научной конференции (22 ноября 2019г.). – Омск: Изд-во Омск. гос. ун-т, 2019.
4. Лыченко Н.М. Регрессионный анализ метеорологических факторов и концентраций частиц PM2.5 в атмосферном воздухе г. Бишкек // Проблемы автоматки и управления. – 2019. №2 (37). – С. 5-15.
5. Барсегян А.А., Куприянов М.С., Степаненко В.В., Холод И.И. Методы и модели анализа данных: OLAP и Data Mining. – СПб.: БХВ-Петербург, 2004. – 336 с.: ил.
6. X. Zhao, R. Zhang, J.-L. Wu, P.-C. Chang. A Deep Recurrent Neural Network for Air Quality Classification // Journal of Information Hiding and Multimedia Signal Processing. – V.9, N.2, March 2018.
7. B. Carremans. Forecasting Air Pollution with Recurrent Neural Networks. – Nov 19, 2018 <https://towardsdatascience.com/forecasting-air-pollution-with-recurrent-neural-networks-ffb095763a5c> (дата обращения: 30.04.2020).
8. Deep Learning, NLP, and Representations Posted. – URL: <http://colah.github.io/posts/2014-07-NLP-RNNs-Representations/> (дата обращения 06.07.2019).
9. Understanding LSTM Networks. – URL: <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> (дата обращения 14.09.2019).
10. Оценка классификатора (точность, полнота, F-мера). – URL: <http://bazhenov.me/blog/2012/07/21/classification-performance-evaluation.html> (дата обращения 29.05.2019)
11. Сайт «Расписание погоды rp5.ru» Архив погоды в Бишкеке [https://rp5.ru/%D0%90%D1%80%D1%85%D0%B8%D0%B2\\_%D0%BF%D0%BE%D0%B3%D0%BE%D0%B4%D1%8B\\_%D0%B2\\_%D0%91%D0%B8%D1%88%D0%BA%D0%B5%D0%BA%D0%B5](https://rp5.ru/%D0%90%D1%80%D1%85%D0%B8%D0%B2_%D0%BF%D0%BE%D0%B3%D0%BE%D0%B4%D1%8B_%D0%B2_%D0%91%D0%B8%D1%88%D0%BA%D0%B5%D0%BA%D0%B5) (дата обращения: 30.04.2020).
12. Курс CS231n: Convolutional Neural Networks for Visual Recognition. – URL: <https://cs231n.github.io/neural-networks-3/#baby> (дата обращения 01.09.2020).