

Научная конференция «Алгебраическая топология, гиперболическая
геометрия и компьютерный анализ данных»
5 – 9 декабря 2023 года, Томск, Россия

ПРОГНОЗ СКОРОСТИ И ПОРЫВОВ ВЕТРА НА ОСНОВЕ ИСКУССТВЕННЫХ НЕЙРОННЫХ СЕТЕЙ

И. В. Дель, А. В. Старченко

Национальный исследовательский Томский государственный университет

Механико-математический факультет

Актуальность работы

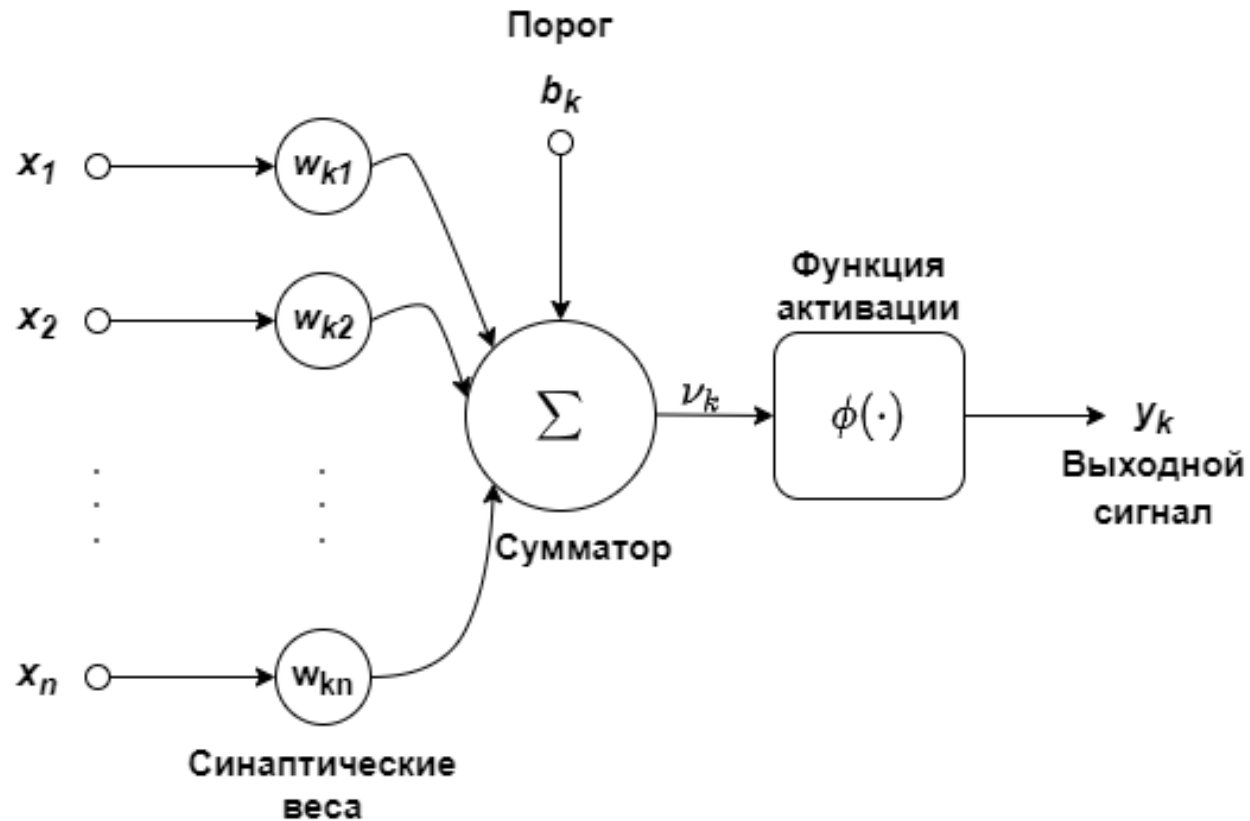
Продолжительные периоды с сильным ветром и его порывами вызывают дефляцию почвы, пыльные бури, приводят к обрывам ЛЭП, повреждению зданий, осложняют работу авиации. В связи с этим, необходимо иметь надежные методы успешного прогнозирования таких опасных гидрометеорологических погодных явлений. Современные методы прогнозирования порывов ветра можно разделить на динамические, использующие измеренные или численно рассчитанные значения скорости ветра, температуры и турбулентности в пограничном слое, статистические модели и методы машинного обучения, реализующие прогноз с использованием наблюдений.



Цель работы

Целью работы является реализация, применение и сравнение различных архитектур нейронных сетей для прогнозирования скорости и порывов ветра. По измеренным стационарной метеостанцией историческим значениям температуры, атмосферного давления, относительной влажности, скорости и направления ветра за предыдущие часы поставлена задача предсказать скорость ветра на 1, 3, 6 часов вперед и порыв ветра на текущий час.

Искусственный нейрон



$$y_k = \varphi \left(\sum_{j=1}^n w_{kj} x_j + b_k \right) \quad (1)$$

Рис. 1. Модель нейрона.

Математическая постановка задачи прогнозирования скорости ветра

Дан многомерный временной ряд входных метеорологических данных $\vec{x}_t \in \mathbb{R}^m$, t – момент времени в часах от 0 до $L-1$, где L – количество почасовых наблюдений, m – количество используемых метеорологических параметров. Также задан многомерный временной ряд выходных данных $d_t \in \mathbb{R}^n$, n – количество прогнозируемых метеорологических параметров. Сформируем для решения задачи прогнозирования матрицы входных и выходных значений:

$$X_t = \begin{bmatrix} x_{1,t-q} & x_{2,t-q} & \dots & x_{m,t-q} \\ x_{1,t-q+1} & x_{2,t-q+1} & \dots & x_{m,t-q+1} \\ \dots & \dots & \dots & \dots \\ x_{1,t-1} & x_{2,t-1} & \dots & x_{m,t-1} \end{bmatrix} \text{ – матрица входных значений,}$$


$$D_t = \begin{bmatrix} d_{1,t} & d_{2,t} & \dots & d_{n,t} \\ d_{1,t+1} & d_{2,t+1} & \dots & d_{n,t+1} \\ \dots & \dots & \dots & \dots \\ d_{1,t+p-1} & d_{2,t+p-1} & \dots & d_{n,t+p-1} \end{bmatrix} \text{ – матрица выходных значений.}$$

где q – количество моментов времени в прошлом, используемых для прогноза, p – количество прогнозируемых временных состояний n метеорологических параметров, $t=q, q+step, q+2step, q+3step, \dots$ ($step$ – шаг по времени).

Математическая постановка задачи прогнозирования скорости ветра

Задача состоит в получении с помощью искусственных нейронных сетей функциональной зависимости $D_t = F(X_t)$, $t = q, q + step, q + 2 \cdot step, q + 3 \cdot step, \dots$, позволяющей с шагом $step$ часов по известным в момент времени $t-1, t-2, \dots, t-q$ характеристикам погоды x_t прогнозировать будущее состояние метеопараметров d_t в моменты времени $t, t+1, \dots, t+p-1$ ($p > 0, q > 0$).

Структура входных данных



Максимальная скорость ветра: 17 м/с.
Средняя скорость ветра: 3.8 м/с.

	date_time	temp	press	humid	ff	dd
0	2014-01-01 00:00:00	-8	755.4	73	8	257.0
1	2014-01-01 01:00:00	-8	755.4	79	8	257.0
2	2014-01-01 02:00:00	-8	755.4	86	8	235.0
3	2014-01-01 03:00:00	-8	755.4	86	7	235.0
4	2014-01-01 04:00:00	-8	756.2	86	7	235.0
...
78763	2022-12-31 19:00:00	-15	773.4	85	2	102.5
78764	2022-12-31 20:00:00	-14	773.4	85	2	157.5
78765	2022-12-31 21:00:00	-14	773.4	85	2	157.5
78766	2022-12-31 22:00:00	-14	773.4	85	1	135.0
78767	2022-12-31 23:00:00	-13	772.7	85	2	180.0

Рис. 2. Данные по температуре, атмосферному давлению, относительной влажности, скорости и направлению ветра.

Корреляционный анализ признаков

Для оценки взаимосвязи между метеорологическими параметрами $\{x_i\}$ и скоростью ветра $\{y_i\}$ в рядах с количеством наблюдений n рассчитывался коэффициент корреляции R_{xy} :

$$R_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}.$$

R	temp	press	humid	dd
wind speed	-0.03	-0.19	-0.16	0.18

Табл. 1. Значения корреляции.

Корреляционный анализ признаков

Кроме того, оценивалась его достоверность по критерию Стьюдента t_p для двух связанных выборок на уровне значимости 0.05:

$$t_p = \frac{|R_{xy}| \sqrt{n - 2}}{\sqrt{1 - R_{xy}^2}}.$$

Также рассчитывался параметр t_T – теоретическое значение критерия, которое зависит от числа наблюдений и уровня значимости. Нулевая гипотеза H_0 заключается в том, что связь отсутствует: $R_{xy} = 0$. Если $t_p > t_T$ то H_0 отвергается, т.е., речь идет о существовании достоверной статистической связи между рядами x и y – скоростью ветра и значениями остальных метеопараметров.

По критерию Стьюдента зависимость скорости ветра от всех метеорологических параметров является статистически значимой.

Имеются тенденции увеличения скорости ветра с уменьшением атмосферного давления и влажности, а также с увеличением угла направления ветра. Связь скорости ветра от температуры выражена слабо, хотя и является статистически значимой.

Рассмотренные в работе архитектуры

- 1) Многослойный персептрон (MLP – Multilayer Perceptron).
- 2) Рекуррентная нейронная сеть с долгой краткосрочной памятью (LSTM – Long short-term memory).
- 3) Сверточная нейронная сеть (CNN – Convolutional neural network).

Многослойный персептрон (MLP)

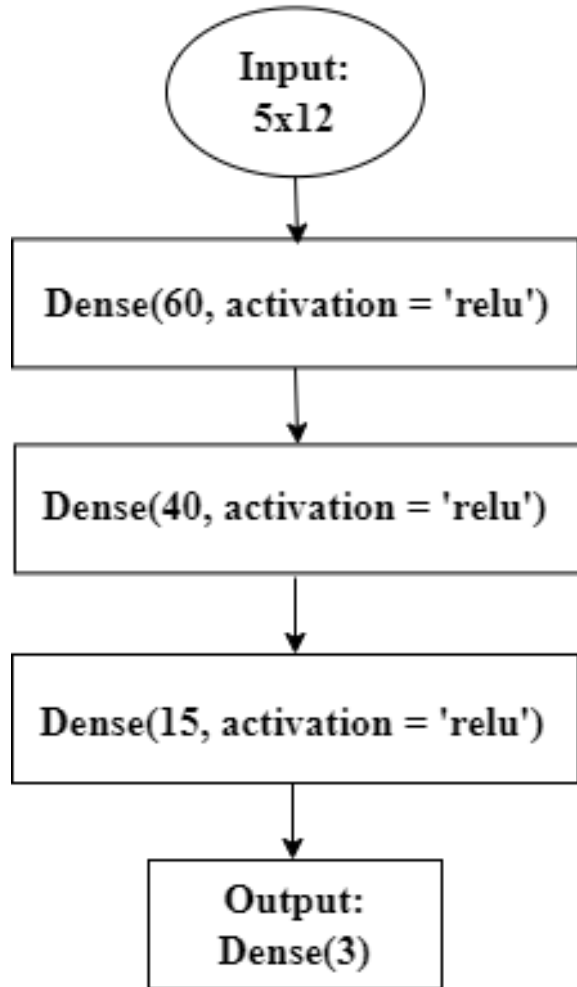


Рис. 3. Архитектура MLP.

$$f(x) = \max(0, x)$$




Рис. 4. Функция активации ReLU.

Оптимальное количество скрытых слоев и нейронов было получено экспериментально, путем изменения архитектуры сети и запуска процесса обучения до получения хорошей производительности.

В этой нейронной сети осуществляется оптимизация целевой функции с подбором весовых коэффициентов методом адаптивной оценки моментов **Adam (Adaptive Moment Estimation)** (вариант стохастического градиентного спуска).

Сеть обучалась за фиксированное количество эпох (epochs = 80).

Метод адаптивной оценки моментов (Adam)

Правило обновления весов определяется на основе использования оценок двух различных моментов:

$$m_N = \alpha_1 m_{N-1} + (1 - \alpha_1) h_N, \quad (2)$$

$$v_N = \alpha_2 v_{N-1} + (1 - \alpha_2) h_N^2. \quad (3)$$

Вычисленные моменты корректируются по формулам

$$\bar{m}_N = \frac{m_N}{1 - \alpha_1^N}, \quad (4)$$

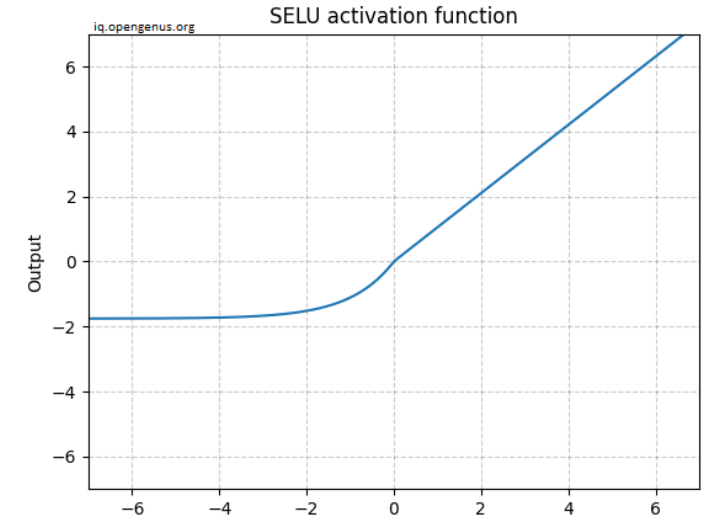
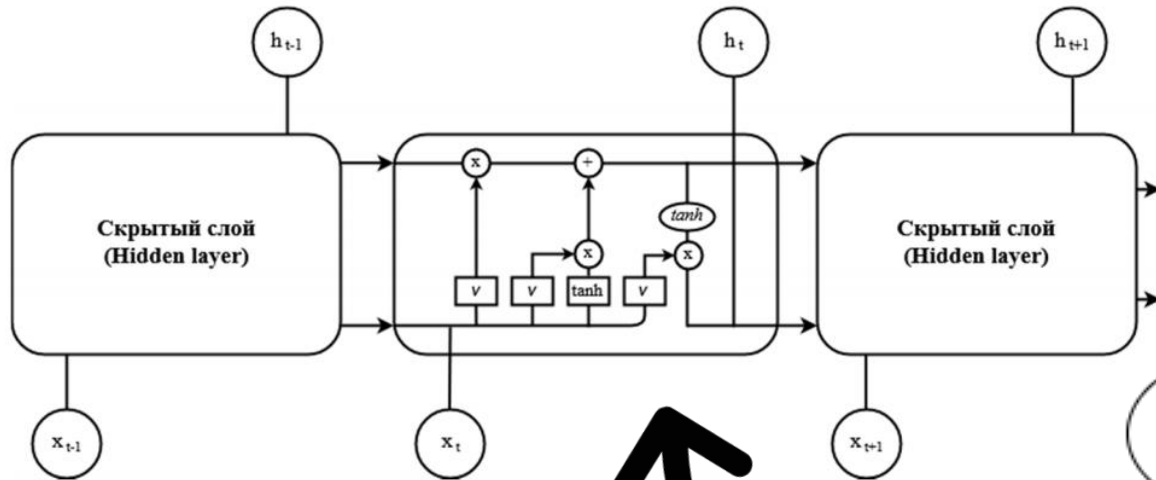
$$\bar{v}_N = \frac{v_N}{1 - \alpha_2^N}, \quad (5)$$

а затем производится пересчет весов по формуле

$$w_{N+1} = w_N - \frac{\eta}{\sqrt{\bar{v}_N + \varepsilon}} \bar{m}_N. \quad (6)$$

Здесь $h_N = \nabla_{w_N} E(w_N)$.

Рекуррентная нейронная сеть типа LSTM



$$f(x) = \lambda x \quad \text{if } x > 0$$

$$f(x) = \lambda\alpha(e^x - 1) \quad \text{if } x \leq 0$$

$$\lambda \approx 1.0507009873554804934193349852946$$

$$\alpha \approx 1.6732632423543772848170429916717$$

Рис. 6. Функция активации SeLU.

В этой нейронной сети осуществляется оптимизация целевой функции с подбором весовых коэффициентов методом адаптивной инерции **Adam (Adaptive Moment Estimation)** (вариант стохастического градиентного спуска).

Сеть обучалась за фиксированное количество эпох (epochs = 50).

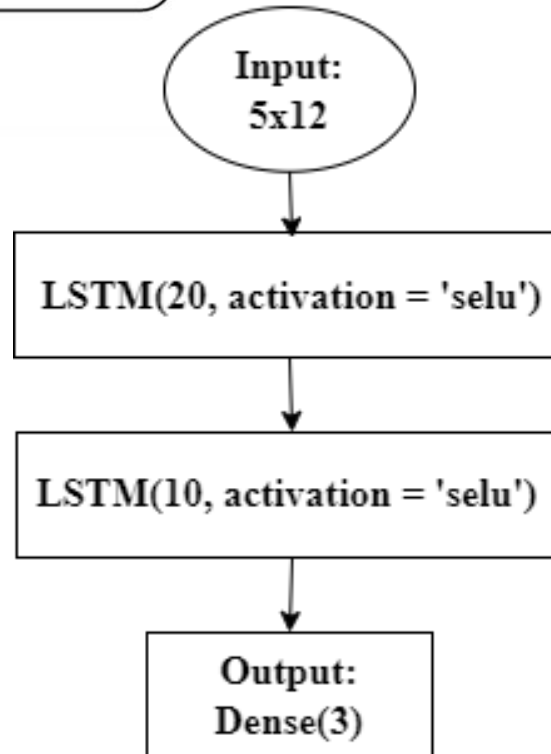
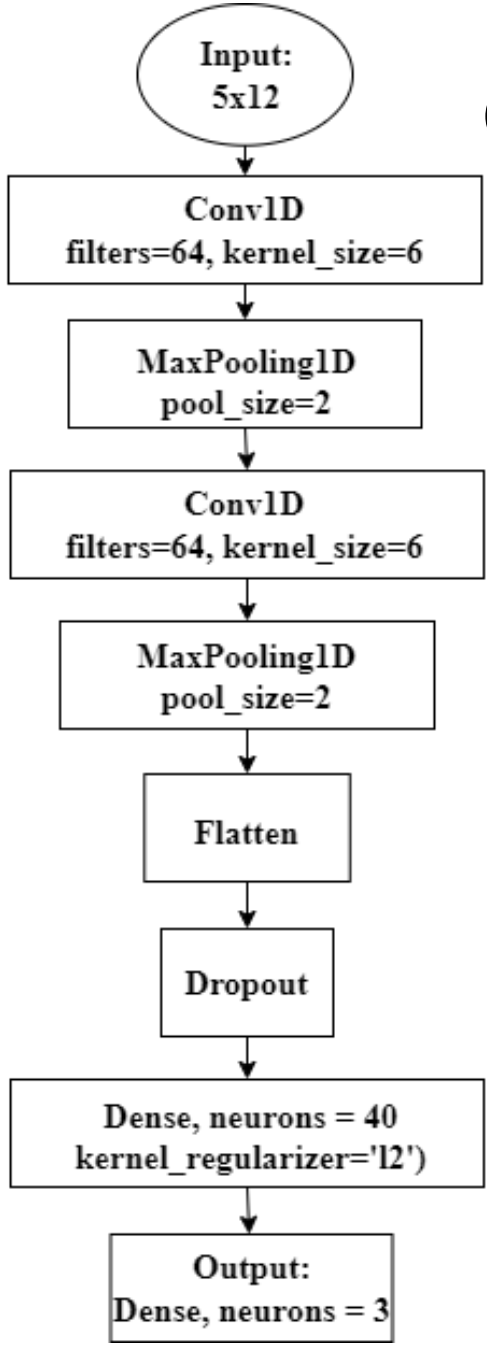


Рис. 5. Архитектура LSTM.

Сверточная нейронная сеть (CNN)



Слой пулинга (подвыборки) используется для снижения размерности и выделения основных элементов.

Так как полносвязный слой не может работать с двумерными данными, преобразуем их в одномерные при помощи слоя flatten.

Dropout исключает определённый процент (например 50 %) случайных нейронов на разных итерациях (эпохах) во время обучения нейронной сети. В результате более обученные нейроны получают в сети больший вес. Такой приём значительно увеличивает скорость обучения, качество обучения на тренировочных данных, а также повышает качество предсказаний модели на новых тестовых данных.

В этой нейронной сети осуществляется оптимизация целевой функции с подбором весовых коэффициентов методом адаптивной инерции **Adam (Adaptive Moment Estimation)** (вариант стохастического градиентного спуска).

Сеть обучалась за фиксированное количество эпох (epochs = 80).




Рис. 8. Функция активации ReLU.

Рис. 7. Архитектура CNN.

Функция потерь и метрики

За функцию потерь принята средняя абсолютная ошибка

$$MAE = \frac{1}{n} \sum_{i=1}^n |d_i - y_i|,$$

где y – предсказанное выходное значение, d – реальное выходное значение.

Метрики: MAE , коэффициент детерминации R^2 , индекс согласия IOA:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (d_i - y_i)^2}{n}}, R^2 = 1 - \frac{\sum_{i=1}^n (d_i - y_i)^2}{\sum_{i=1}^n (d_i - \bar{d})^2}, IOA = 1 - \frac{\sum_{i=1}^n (d_i - y_i)^2}{\sum_{i=1}^n (|y_i - \bar{d}| + |d_i - \bar{d}|)^2}.$$

Сравнение результатов прогнозирования различных архитектур нейронных сетей: прогноз на 1 час вперед

Имеем следующие значения метрик:

	<i>MAE</i>	<i>R²</i>	<i>IOA</i>
MLP	0.71	0.82	0.95
LSTM	0.70	0.82	0.95
CNN	0.71	0.83	0.95

С учетом того, что значения метрик разнятся в тысячных долях, результат прогнозирования всех трех архитектур удовлетворительный.

Сравним время фазы обучения трех архитектур: **MLP** – 159.8 с, **LSTM** – 1460.4 с, **CNN** – 219.7 с. Таким образом, в данном случае оптимальнее использовать модель многослойного персептрона (*MLP*).

Также приведем значение коэффициента корреляции между прогнозируемой скоростью ветра и историческими наблюдениями: $R = 0.90$ – достаточно высокая корреляция между прогнозируемыми и историческими наблюдениями.

Сравнение результатов прогнозирования различных архитектур нейронных сетей: прогноз на 3 часа вперед

Имеем следующие значения метрик:

	<i>MAE</i>	<i>R²</i>	<i>IOA</i>
MLP	0.85	0.76	0.93
LSTM	0.85	0.76	0.93
CNN	0.84	0.76	0.93

Сравним время фазы обучения трех архитектур: **MLP** – 54.8 с, **LSTM** – 375.9 с, **CNN** – 75.4 с. Таким образом, в данном случае оптимальнее использовать модель многослойного персептрона (*MLP*).

Значение коэффициента корреляции между прогнозируемой скоростью ветра и историческими наблюдениями: $R = 0.87$.

Сравнение результатов прогнозирования различных архитектур нейронных сетей: прогноз на 6 часов вперед

Имеем следующие значения метрик:


	<i>MAE</i>	<i>R²</i>	<i>IOA</i>
MLP	0.97	0.68	0.90
LSTM	0.97	0.68	0.90
CNN	0.96	0.69	0.90

Сравним время фазы обучения трех архитектур: **MLP** – 28.5 с, **LSTM** – 184.9 с, **CNN** – 38.8 с. Таким образом, в данном случае оптимальнее использовать модель многослойного персептрона (*MLP*).

Значение коэффициента корреляции между прогнозируемой скоростью ветра и историческими наблюдениями: $R = 0.82$.

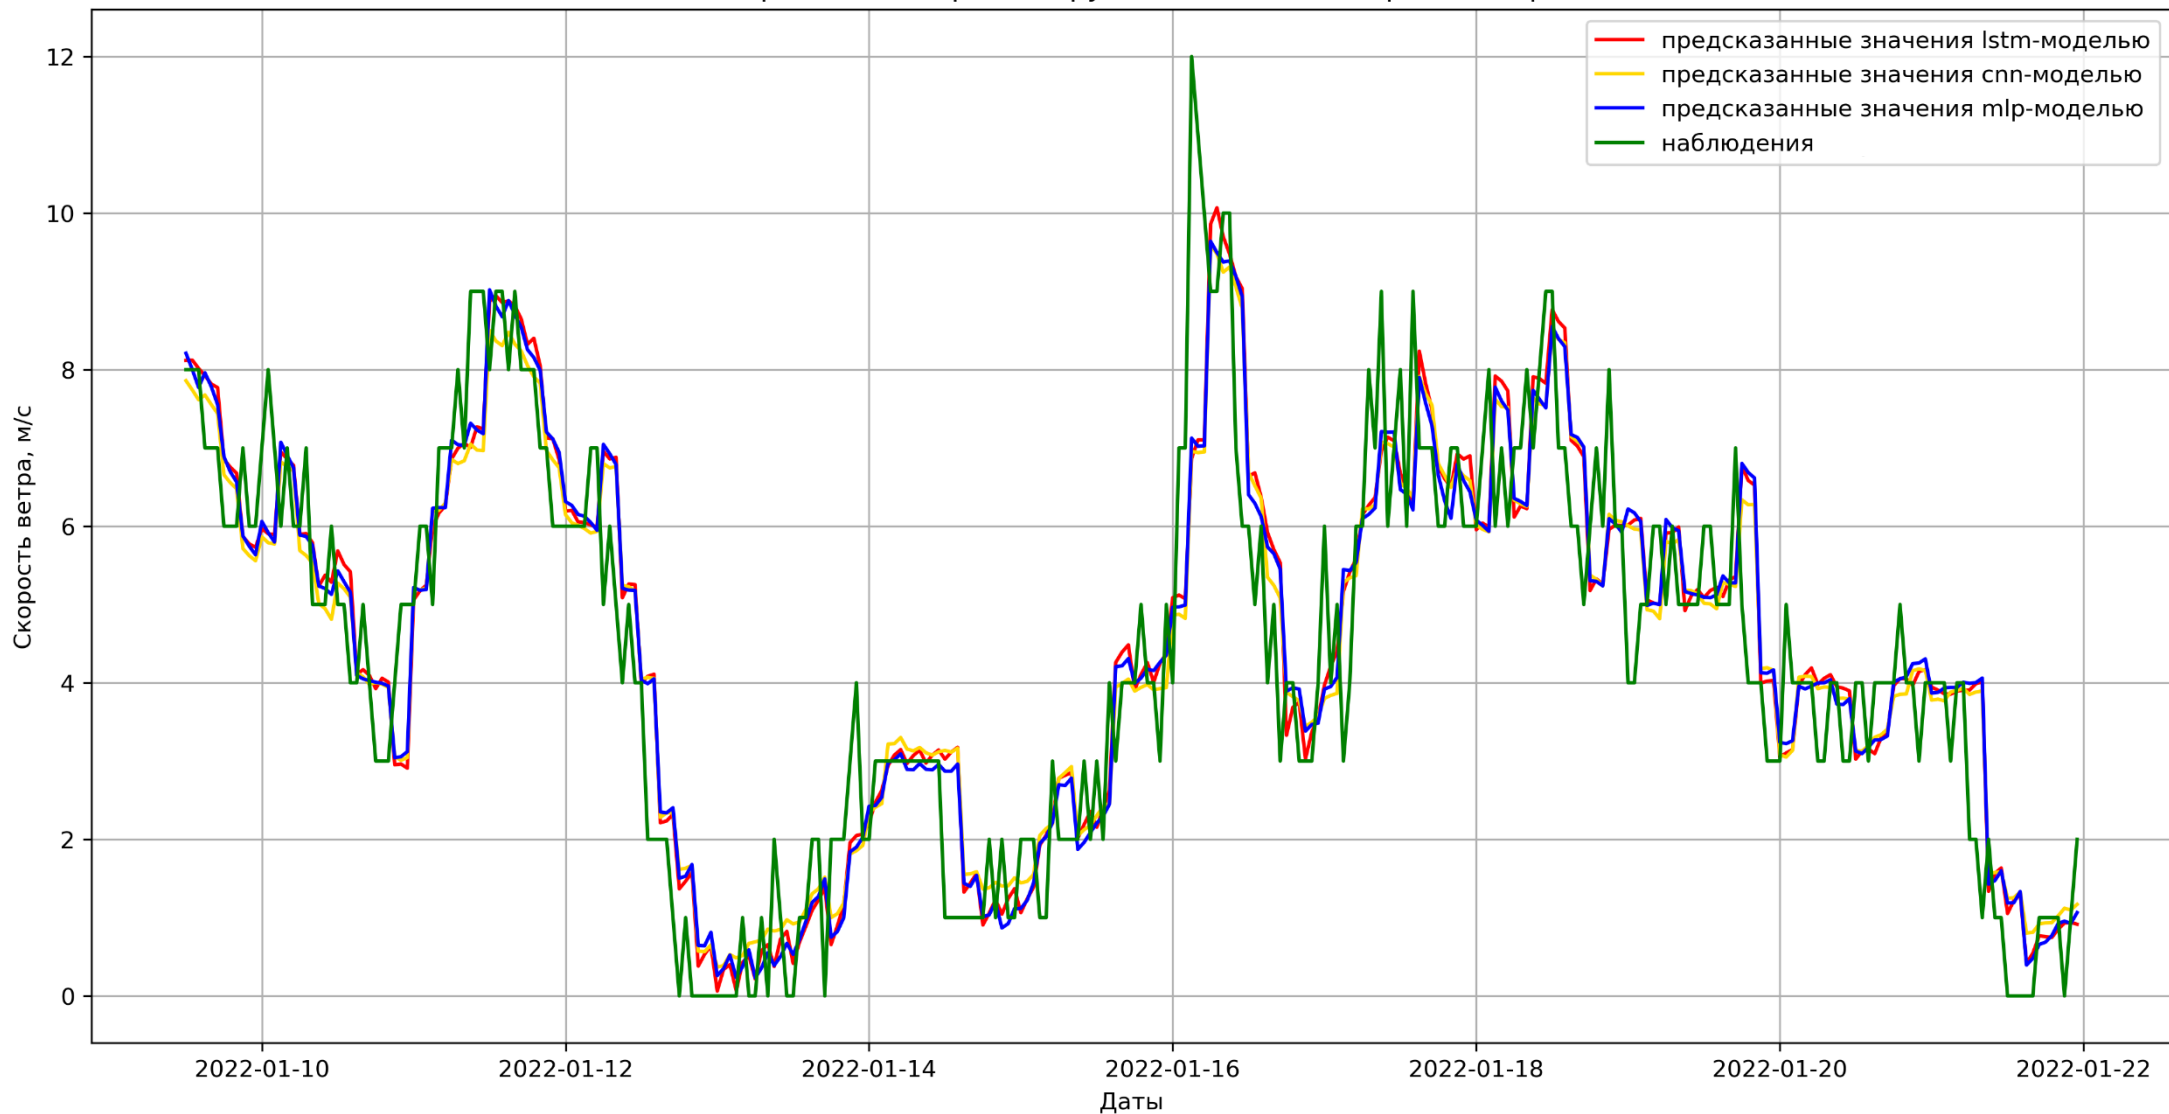
Сравнение результатов прогнозирования различных архитектур нейронных сетей на 1 час вперед

Исторические и прогнозируемые значения скорости ветра




Сравнение результатов прогнозирования различных архитектур нейронных сетей на 3 часа вперед

Исторические и прогнозируемые значения скорости ветра




Сравнение результатов прогнозирования различных архитектур нейронных сетей на 6 часов вперед

Исторические и прогнозируемые значения скорости ветра




Сравнение результатов прогнозирования различных архитектур нейронных сетей на 1 час вперед

Исторические и прогнозируемые значения скорости ветра




Сравнение результатов прогнозирования различных архитектур нейронных сетей на 3 часа вперед

Исторические и прогнозируемые значения скорости ветра



Сравнение результатов прогнозирования различных архитектур нейронных сетей на 6 часов вперед

Исторические и прогнозируемые значения скорости ветра



Обучение и тестирование моделей на других данных

	datetime	T2(C)	Psurf(mm)	Hum(%)	W10(m/s)	DIR10(deg)
0	2020-01-01 01:00:00	-14.5	748.2	79	3.3	189
1	2020-01-01 02:00:00	-13.8	747.9	78	3.7	190
2	2020-01-01 03:00:00	-13.1	748.1	79	4.1	194
3	2020-01-01 04:00:00	-13.0	748.1	79	4.4	194
4	2020-01-01 05:00:00	-13.1	748.1	79	4.7	194
...
24835	2022-10-31 20:00:00	-4.0	753.0	78	1.3	57
24836	2022-10-31 21:00:00	-4.4	752.9	80	1.1	50
24837	2022-10-31 22:00:00	-4.7	752.8	82	1.2	45
24838	2022-10-31 23:00:00	-5.0	752.8	82	0.9	51
24839	2022-11-01 00:00:00	-5.4	752.7	84	0.6	41

Рис. 9. Структура исходных метеорологических данных.

Также реализованные модели нейронных сетей были обучены и протестированы на другом наборе данных. Исходные метеорологические данные для исследования были получены с метеостанций ЦКП «Атмосфера» ИОА СО РАН за период времени с 01.01.2020 по 31.10.2022. Размер набора данных составляет 24840 ежеhourных наблюдений. Исходные данные включают в себя те же временные ряды. Но в этом наборе данных температура и скорость ветра заданы **с точностью до десятых долей.**

Максимальная скорость ветра: 13.6 м/с.
Средняя скорость ветра: 2.3 м/с.

Обучение и тестирование моделей на других данных

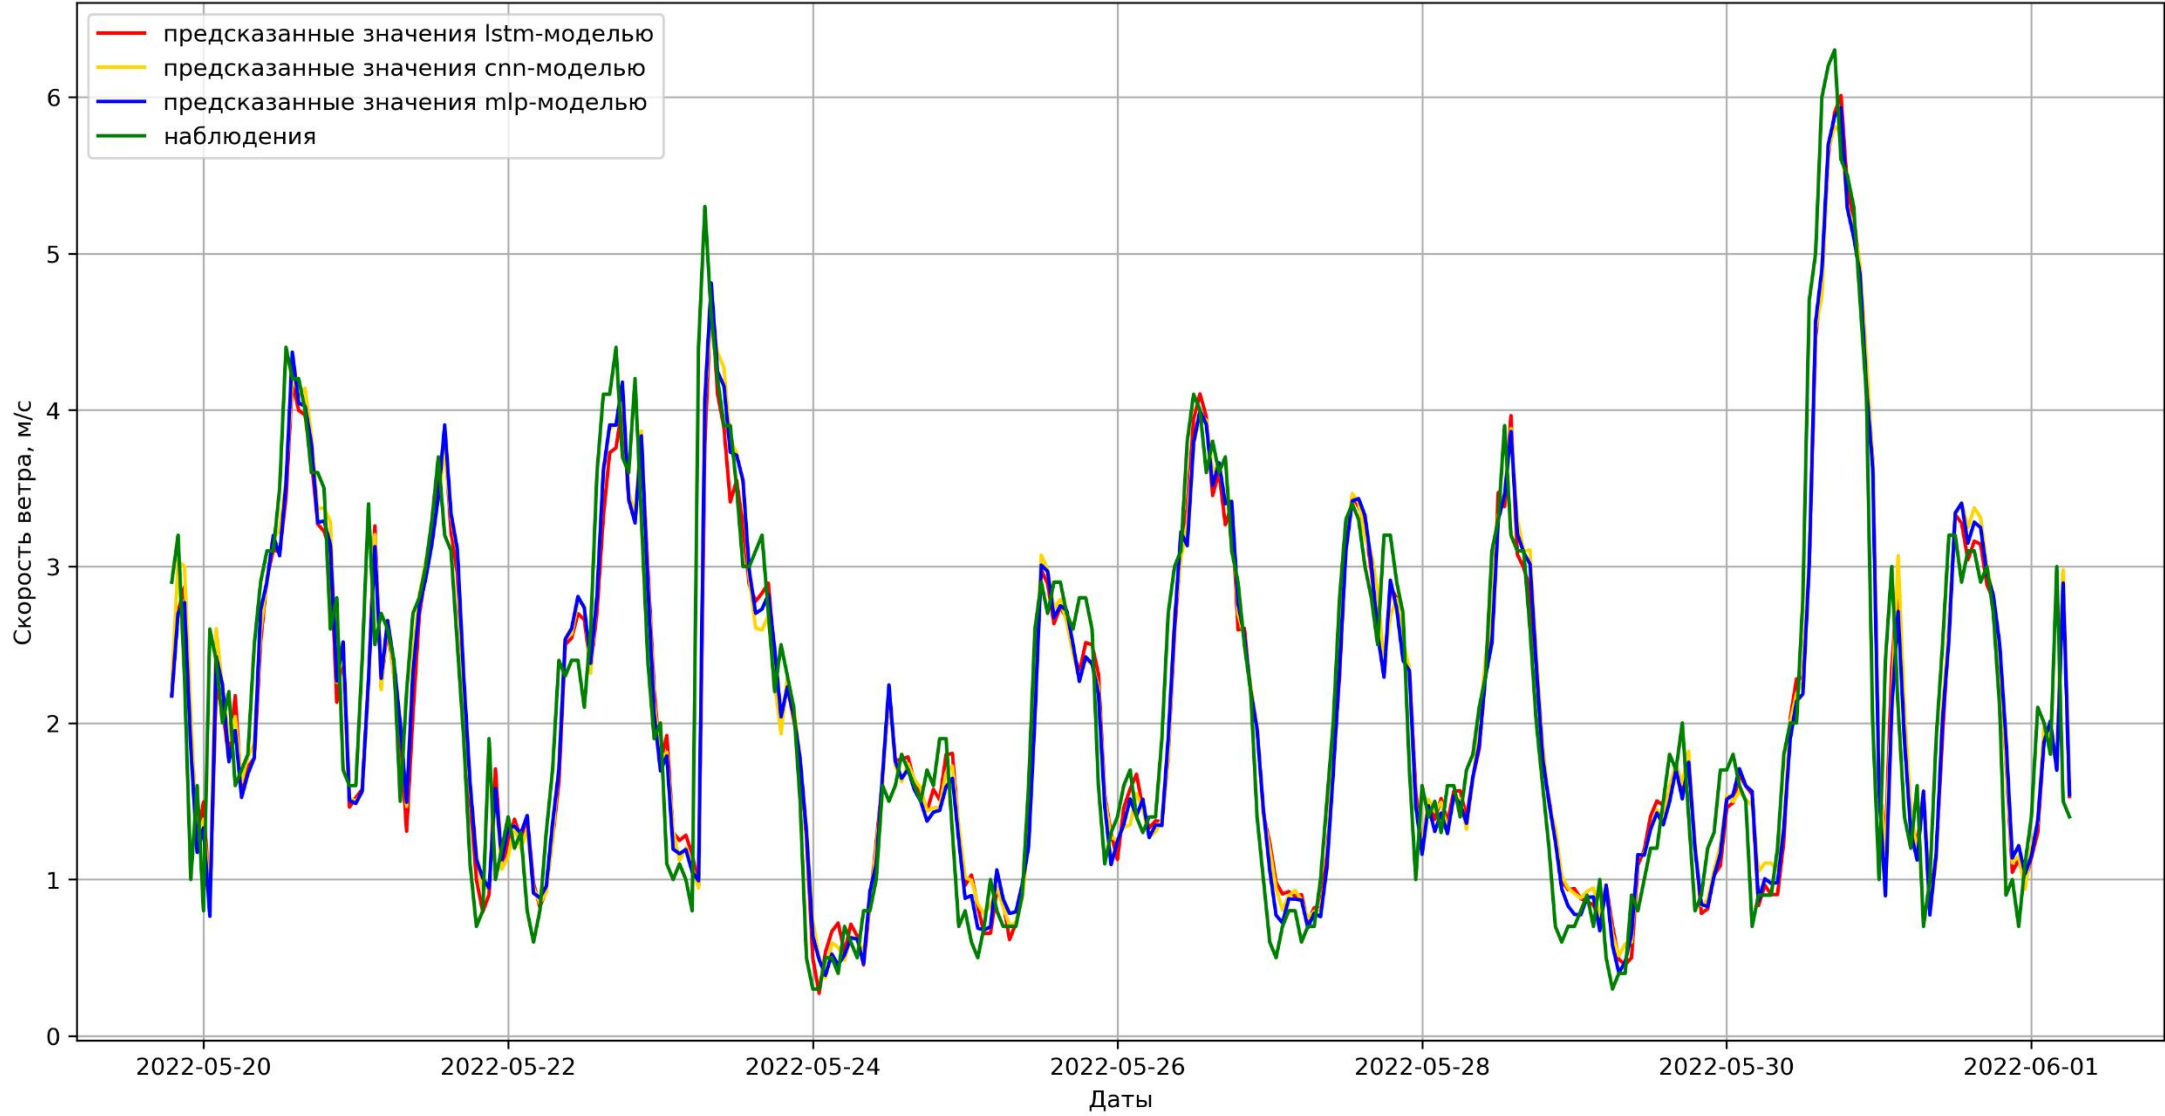
1 час	<i>MAE</i>	<i>R²</i>	<i>IOA</i>	<i>Время обучения</i>
MLP	0.31	0.84	0.96	50.6 с
LSTM	0.31	0.84	0.95	449.9 с
CNN	0.33	0.84	0.95	70.8 с

3 часа	<i>MAE</i>	<i>R²</i>	<i>IOA</i>	<i>Время обучения</i>
MLP	0.43	0.71	0.91	18.7 с
LSTM	0.43	0.70	0.90	117.5 с
CNN	0.43	0.71	0.91	25.7 с

6 часов	<i>MAE</i>	<i>R²</i>	<i>IOA</i>	<i>Время обучения</i>
MLP	0.52	0.58	0.86	10.4 с
LSTM	0.53	0.56	0.84	78.2 с
CNN	0.52	0.59	0.86	13.9 с


Сравнение результатов прогнозирования различных архитектур нейронных сетей на 1 час вперед

Исторические и прогнозируемые значения скорости ветра




Сравнение результатов прогнозирования различных архитектур нейронных сетей на 3 часа вперед

Исторические и прогнозируемые значения скорости ветра



Сравнение результатов прогнозирования различных архитектур нейронных сетей на 6 часов вперед

Исторические и прогнозируемые значения скорости ветра



Прогнозирование порывов ветра на текущий час

	date_time	temp	press0	press	humid	dd	ff	gust
0	2015-12-10 09:00:00	-2	732.3	749.3	93	257.0	8	18
1	2021-02-19 08:00:00	-17	729.1	747.0	71	90.0	9	14
2	2022-02-23 07:00:00	-4	743.1	760.5	93	180.0	5	0
3	2018-10-09 21:00:00	11	744.7	761.2	58	180.0	8	14
4	2021-02-22 17:00:00	-18	746.6	765.0	65	235.0	2	0
...
4319	2014-04-09 12:00:00	9	743.9	760.5	58	213.0	8	14
4320	2021-06-15 08:00:00	14	747.1	763.5	67	213.0	2	0
4321	2017-03-20 11:00:00	-3	756.3	773.9	28	315.0	1	0
4322	2017-04-03 15:00:00	-3	746.9	764.3	50	180.0	9	14
4323	2015-11-09 11:00:00	-5	745.3	762.8	74	257.0	6	11

Рис. 10. Структура исходных метеорологических данных.

Исходные метеорологические данные для исследования выбирались для аэропорта Томск (Богашево) имени Николая Камова.

Исходных набор данных содержит 78768 наблюдений. Из них только 2162 наблюдений с порывами ветра.

Для сбалансированности данных были выбраны 2162 наблюдений с порывами и 2162 наблюдений без порывов (выбраны случайным образом).

Размер подготовленного набора данных составил 4324 наблюдений.

Прогнозирование порывов ветра на текущий час

Наша цель – предсказать порыв ветра на текущий час по измеренным стационарной метеостанцией значениям температуры, атмосферного давления, относительной влажности и направления ветра за этот же час.

Т. е. при помощи нейронной сети требуется получить функциональную зависимость

$$\text{gust} = F(\text{temp}, \text{press}, \text{humid}, \text{dd}).$$

Прогнозирование порывов ветра на текущий час

Model: "model"

Layer (type)	Output Shape	Param #
input_1 (InputLayer)	[(None, 5)]	0
dense (Dense)	(None, 50)	300
dense_1 (Dense)	(None, 20)	1020
dense_2 (Dense)	(None, 10)	210
dense_3 (Dense)	(None, 10)	110
dense_4 (Dense)	(None, 1)	11

Total params: 1,651

Trainable params: 1,651

Non-trainable params: 0

Функция активации – ReLU.

В этой нейронной сети осуществляется оптимизация целевой функции с подбором весовых коэффициентов методом адаптивной оценки моментов **Adam (Adaptive Moment Estimation)** (вариант стохастического градиентного спуска).

Сеть обучалась за фиксированное количество эпох (epochs = 200).

Рис. 11. Архитектура многослойного персептрона.

Прогнозирование порывов ветра на текущий час

Общее значение MAE по всему прогнозу составила 1.74 м/с. Результат удовлетворительный.

Дополнительно приведем значения коэффициента детерминации R^2 и индекса согласия IOA: $R^2 = 0.71$, IOA = 0.92.

В таблице приведены некоторые результаты прогнозирования порывов ветра в случайно выбранные даты.

Всего предсказанных значений – 865. Из них 167 предсказаний отличаются от исторических значений больше чем на 2 м/с. Это 19.3 % от всех предсказаний.

Историческое значение порыва ветра (м/с)	Прогноз порыва ветра (м/с)
16.0	12.91
0.0	0.009
12.0	12.04
11.0	0.00007
13.0	12.79
20.0	20.7
24.0	22.29
0.0	2.24
0.0	13.85

Заключение

- Рассмотрена корреляционная связь между скоростью ветра и другими метеорологическими параметрами. Рассчитанные корреляции указывают на важное значение метеорологический условий в прогнозировании скорости ветра.
- Для достижения цели работы были изучены и реализованы такие нейронные сети, как многослойный персептрон, рекуррентная нейронная сеть типа LSTM и сверточная нейронная сеть. Сравнительный анализ результатов прогнозирования всех 3-х архитектур, свидетельствует о том, что методы нейросетевого прогнозирования имеют большой потенциал в трудоемких, плохо формализованных задачах, например, как краткосрочный прогноз метеопараметров.
- Из сравнения результатов прогнозирования скорости ветра на двух наборах данных можно сделать вывод, что чем точнее заданы исходные данные, тем лучше будет прогноз нейронной сети.

Спасибо за внимание!