

УДК 004.852
DOI 10.58649/1694-8033-2024-3(119)-447-450

БОГАТЫРЕВ М.М.
Ж. Баласагын атындагы КУУ
БОГАТЫРЕВ М.М.
КНУ имени Ж. Баласагына
BOGATYREV M.M.
KNU named after J. Balasagun
ORCID: 0009-0008-7791-4579

АЙЫЛ ЧАРБА ТАРМАГЫН ТЕРЕҢ ҮЙРӨНҮҮ: АНЫН ӨСҮҮ ТЕМПИНИН БОЛЖОЛУ

**ГЛУБОКОЕ ОБУЧЕНИЕ В СЕКТОРЕ СЕЛЬСКОГО ХОЗЯЙСТВА: ПРОГНОЗ
ТЕМПОВ ЕГО ПРИРОСТА**

**DEEP LEARNING IN THE AGRICULTURE SECTOR: FORECAST FOR ITS GROWTH
RATE**

Кыскача мүнөздөмө: Айыл чарба секторуна байланыштуу айрым социалдык-экономикалык көйгөйлөрдү чечүү калктын өсүшүн жана дүйнөдө да, Борбордук Азия регионунда да экологиялык абалдын өзгөрүшүн эске алуу менен актуалдуу болуп баратат. Айыл чарбасында процесстердин динамикасын узак мөөнөттүү пландаштыруу жана болжолдоо азык-түлүк коопсуздугуна жетүүнүн жана өлкөдөгү социалдык туруктуулукту сактоонун негизги ташына айланып баратат. Бул кагазда дан түшүмдөрүнүн негизги түрлөрүн өндүрүүнүн көлөмүн алдын ала айтуу үчүн мугалим менен терең машиналык окууну түзүү, окутуу жана колдонуу үчүн моделдөө тармагында компьютердик технологияларды жана иштеп чыгууларды колдонуу жөнүндө ойлоноу пландаштырылууда.

Аннотация: Решение определенных социально-экономических задач, связанных с сектором сельского хозяйства, приобретает актуальность в свете роста численности населения и изменений экологической ситуации как в мире, так и в Центральноазиатском регионе. Перспективное планирование и прогнозирование динамики процессов в сельском хозяйстве становится краеугольным камнем достижения продовольственной безопасности и поддержания социальной стабильности в стране. В данной работе рассматривается использование возможностей компьютерных технологий и разработок в сфере моделирования для создания, обучения и применения глубокого машинного обучения с учителем для прогнозирования объема производства основных видов зерновых культур.

Abstract: The solution of certain socio-economic problems related to the agricultural sector is becoming relevant in the light of population growth and changes in the environmental situation both in the world and in the Central Asian region. Long-term planning and forecasting of the dynamics of processes in agriculture is becoming the cornerstone of achieving food security and maintaining social stability in the country. In this paper, it is planned to consider the use of computer technologies and developments in the field of modeling for the creation, training and application of deep machine learning with a teacher to predict the volume of production of the main types of grain crops.

Негизги сөздөр: терең үйрөнүү; болжолдоо; айыл чарбасы; терең окуу куралы; «Matlab» программалык камсыздоосу.

Ключевые слова: глубокое обучение; прогнозирование; сельское хозяйство; набор инструментов глубокого обучения; программное обеспечение «Matlab».

Keywords: deep learning; forecasting; agriculture; deep learning toolbox; “matlab” software.

Введение. Сельское хозяйство представляет собой важнейшую сферу жизнедеятельности человека, характеризующуюся как одну из самых волатильных, подверженных ярко выраженной сезонной динамике. В этой связи прогнозирование показателей сельского хозяйства на кратко- и

долгосрочную перспективу, с одной стороны, приобретает первоочередную задачу, с другой – осложняется спецификой данной отрасли в целом. Кроме того, для оценки будущих тенденций в сельском хозяйстве необходимо помнить о многофакторности и высокой зависимости процессов сельского хозяйства от тех же самых климатических условий или от поставок удобрений и горюче-смазочных материалов, в том числе дизельного топлива.

Показатель темпов роста сельского хозяйства является одним из важнейших экономических индикаторов. В период изменения климатических условий (настоящее время уже поддается такой классификации) актуальным становится вопрос оценки потенциального производства сельскохозяйственной продукции как в мире, так и в регионе. Низкое производство неизбежно может привести к негативным последствиям не только для цен на соответствующие товары [1], но и для социально-экономической обстановки в целом. Заблаговременная оценка урожайности в сельскохозяйственном секторе позволит принять своевременные меры со стороны государства, министерств и ведомств.

С развитием компьютерных технологий прогнозирование в целом и процессов сельского хозяйства, в частности, стало более точным и полным (учитывается максимально возможное количество факторов). Дополнительным положительным фактором повышения качества прогнозирования выступает доступность различных данных, в частности, по производству, урожайности сельскохозяйственных культур, экологической обстановке, количеству необходимых удобрений и минеральных веществ для увеличения урожайности, стоимости горюче-смазочных материалов и другой необходимой информации.

В данной работе представлены результаты проведения глубокого машинного обучения для прогнозирования динамики объема производства сельского хозяйства, как одной из составляющих ВВП Кыргызской Республики, с использованием исторических данных в количестве 190 наблюдений.

Глубокое машинное обучение. Метод глубокого обучения выбран постольку, поскольку совмещает в себе актуальность, набирающую популярность в использовании, и тот факт, что он позволяет генерировать прогнозы и определять будущую динамику движения показателей и индикаторов различных сфер человеческой деятельности.

В статье за основу принимается классическая структура глубокой нейронной сети, которая представляет собой взвешенно-взаимосвязанные нейроны (вычислительные блоки), организованные в слои. Компоновка слоев следующая:

- входной слой;
- скрытые слои;
- выходной слой.

Следует отметить, что входной слой включает количество нейронов, соответствующее количеству исходных переменных, а количество нейронов выходного слоя соответствует количеству классов в данных. Данные характеристики соответствуют нейронной сети прямого распространения, где нейроны слоя не связаны между собой, а связаны только с нейронами соседнего слоя. Активация нейрона производится на основе расчета веса его влияния на основе суммы входных данных.

Поскольку темпы роста сельского хозяйства представляют собой статистический ряд данных, для целей прогнозирования выбрана рекуррентная нейронная сеть (Recurrent Neural Networks (RNN)) [2], которая представляет собой модель глубокого обучения, настроенную на обработку и преобразование временных рядов статистических данных в такой же последовательный ряд данных.

Схема работы схожа с классической нейронной сетью, однако скрытый слой имеет свойство повторяющейся обработки. Он сохраняет предыдущие данные со входного слоя с последующим их использованием в новом цикле обработки/прогноза. Следует отметить, что поскольку обработка данных происходит последовательно, снижается эффективность при работе с большим массивом информации. Соответственно для этого необходимо больше памяти и времени на реализацию процесса обучения и получения приемлемых результатов.

Из множества вариантов архитектуры рекуррентной нейронной сети в работе предлагается использовать долговременную кратковременную память (Long short-term memory (LSTM)). Подобная вариация позволяет увеличивать объем памяти модели для хранения данных за более длинный промежуток времени. Отметим, что классическая RNN запоминает самое последнее входное значение, при том что LSTM позволяет запоминать большее количество полезной

информации из всего ряда данных. Функция забывания позволяет LSTM эффективнее использовать ресурсы вычислительной техники и в определенной степени экономить время на итерациях. К основным компонентам архитектуры LSTM следует отнести состояние ячейки и фильтры, контролирующее это состояние, которые, в свою очередь, подразделяются на: забывания, входной и выходной фильтры.

На основе различных схем существуют вариации LSTM.

Смотровые глазки. Наиболее распространенная вариация, предполагающая, что фильтры могут наблюдать состояние ячейки.

Объединенные фильтры. В такой вариации фильтры забывания и входной фильтр влияют совместно на процесс забывания какой-либо информации в период обучения. Как правило, новая информация записывается тогда, когда старая информация стирается.

Управляемые рекуррентные нейроны. Данная вариация немного быстрее и проще в использовании, так как содержит на один фильтр меньше. Как и в предыдущей вариации фильтры забывания и входа объединены в один. Фильтр забывания же заменен на фильтр сброса и устроен иначе.

Глубокие управляемые рекуррентные нейроны. Являются разновидностью описанной выше вариации и содержат фильтр глубины в целях использования ячеек памяти других (соседних) слоев.

Механизм часов. В данной вариации скрытый слой имеет дополнительные модули, каждый из которых обрабатывает входные данные со своей временной детализацией.

В качестве основного программного обеспечения для реализации поставленной задачи взята широко распространённая и зарекомендовавшая себя платформа «Matlab» и подгружаемый к ней инструмент для обучения нейронных сетей Deep learning toolbox [3]. Данный инструмент позволяет воспользоваться возможностями вычислительной техники в полном объеме. Запрограммированность отдельных блоков позволяет за относительно короткий промежуток времени строить различные модели и проводить соответствующие итерации для апробации предположений. Для временных рядов использовалась функция LSTM (LSTM network for sequence-to-sequence classification).

В качестве входного и выходного слоев определен 1 параметр, то есть одна переменная, в нашем случае темп прироста сельского хозяйства. Параметр запоминания информации с предыдущих слоев выставлен на значение 100. Эксперименты показали, что с большими значениями увеличивается время на итерации, при незначительном изменении конечного результата. Значение параметра epochs, то есть полного прохода данных для обучения нейронной сети, выбрано на уровне 1000, а переменная первоначальной обучающей позиции (Initial Learn Rate) равна 0.0003. При таких значениях параметров в процессе итераций с каждым новым полным проходом сокращались потери в обучении (mini-batch loss), а также показатель среднеквадратичной ошибки (root-mean-square error (RMSE)) (см. таблицу).

Значения показателей итераций при значении параметра Initial Learn Rate = 0.0003 и 0.0001 (разграничены наклонной чертой)

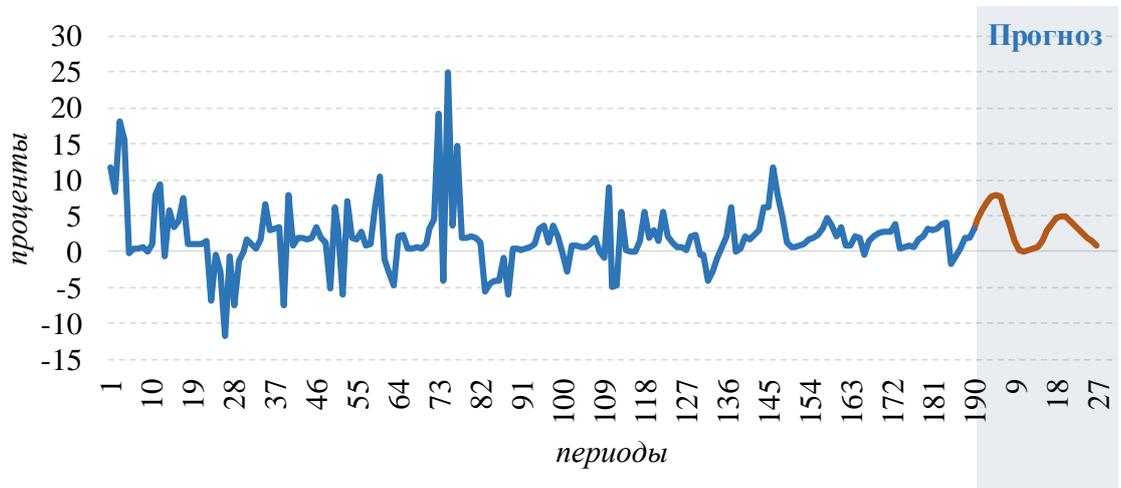
Проход (Epoch)	Итерация (Iteration)	Среднеквадратичная ошибка (Mini-batch RMSE)	Потери (Mini-batch Loss)
1	1	1,00 / 1,00	0,5 / 0,5
50	50	0,95 / 0,98	0,4 / 0,5
100	100	0,92 / 0,96	0,4 / 0,5
...
950	950	0,76 / 0,91	0,3 / 0,4
1000	1000	0,75 / 0,90	0,3 / 0,4

Источник: промежуточные расчеты при выполнении скрипта модели в «Matlab».

Как видно из таблицы, значение ошибки и пропусков при показателе 0,0003 значительно ниже, чем при показателе, равном 0,0001.

Общая картина прогноза после итераций с наиболее приемлемыми значениями параметров модели представлена на рисунке.

На основании динамики (см. рисунок) можно сделать вывод, что модель учитывает определенные колебания, информация о которых имеется на временном отрезке для обучения (периоды с 1 по 190). Результаты моделирования и прогноза подойдут для анализа долгосрочных тенденций и циклов в сельском хозяйстве, для разработки стратегического плана и реализации своевременных и необходимых мер политики.



Фактические и прогнозные значения темпов прироста сельского хозяйства

Дальнейшее исследование данной тематики возможно по направлению расширения нейронной сети дополнительными данными, учитывающими как внешние, так и внутренние факторы, влияющие на рост сельского хозяйства. В качестве объясняющих переменных в общую базу данных дополнительно возможно включить такие показатели, как [4]:

- урожайность зерновых культур;
- температура окружающей среды;
- количество осадков;
- изменение цен на ГСМ, в частности, на дизельное топливо;
- государственная поддержка (дотации) и качество земельных ресурсов.

Дополнительно для улучшения качества прогнозов и получения более стабильных расчетов необходимо очистить ряд от сезонных колебаний.

В качестве инструментов реализации также следует упомянуть о широко распространенных библиотеках «Keras» и системы «TensorFlow» для глубокого изучения в среде «Python» [5-6].

Заключение. Представленная в статье модель глубокого обучения на основе рекуррентной нейронной сети с архитектурой долгосрочной краткосрочной памяти показала возможность получения оценок перспективной динамики рассматриваемого показателя. Однако на фоне сложности и многогранности данного подхода необходимо дальнейшее исследование и расширение модели для прогнозирования темпов прироста сельского хозяйства и других переменных, имеющих важность и интерес к исследованию.

Список использованной литературы

1. Керимбекова Р.А., Бакыт кызы Акмарал, Оморбекова К.О. Влияние инфляции на экономическое и социальное развитие Кыргызстана // Вестник КНУ им. Ж. Баласагына, 2022, №1 (109), с.169-173. – URL: https://vestnik.knu.kg/wp-content/uploads/2023/01/vknu_1_109_2022.pdf (дата обращения: 11.03.2024).
2. Что такое RNN? – Режим доступа: <https://aws.amazon.com/ru/what-is/recurrent-neural-network/> (дата обращения: 08.03.2024).
3. Deep learning toolbox. – URL: <https://www.mathworks.com/help/deeplearning/> (дата обращения: 08.03.2024).
4. Официальный веб-сайт Национального статистического комитета Кыргызской Республики. – URL: <https://stat.kg/ru/statistics/selskoe-hozyajstvo/> (дата обращения: 02.03.2024).

5. Шамаев И. Keras Tutorial: Руководство для начинающих по глубокому обучению на Python. – URL: <https://python.ivan-shamaev.ru/keras-tutorial-beginner-guide-to-deep-learning-in-python/> (дата обращения: 11.03.2024).

6. Программирование на Python. – URL: <https://pythonim.ru/libraries/tensorflow-python> (дата обращения: 11.03.2024).