

Международный научно-исследовательский журнал

«Прогрессивная экономика»

№ 5 / 2024 https://progressive-economy.ru/vypusk_1/prognozirovanie-ekonomicheskikh-cziklov-s-ispolzovaniem-mashinnogo-obucheniya/

Научная статья / Original article

Шифр научной специальности ВАК: 5.2.2

УДК 338.5

DOI: 10.54861/27131211_2024_5_67



ПРОГНОЗИРОВАНИЕ ЭКОНОМИЧЕСКИХ ЦИКЛОВ С ИСПОЛЬЗОВАНИЕМ МАШИННОГО ОБУЧЕНИЯ

*Мирончук В.А., кандидат экономических наук, доцент кафедры
экономической кибернетики, Кубанский государственный аграрный
университет (КубГАУ), г. Краснодар, Россия*

*Иванцов К.А., студент, Кубанский государственный аграрный университет
(КубГАУ), г. Краснодар, Россия*

*Гордеев Е.С., студент, Кубанский государственный аграрный университет
(КубГАУ), г. Краснодар, Россия*

Аннотация. Целью данной статьи является рассмотрение способов использования методов машинного обучения в прогнозировании экономических циклов. Методологическую основу исследования составляет применение различных регрессионных методов, в частности, линейной и полиномиальной регрессии в тандеме с методом линейно-клеточного автомата. Авторами изучены различные точки зрения на определение понятия «машинное обучение», определена степень использования искусственного интеллекта в различных сферах жизни общества, рассмотрены основные типы задач, для решения которых при помощи методов машинного обучения обеспечивается максимальная эффективность и производительность. В процессе исследования авторами раскрыты преимущества и недостатки использования методов машинного обучения. На основании анализа макроэкономических показателей, предоставленных Федеральной службой государственной статистики, продемонстрированы возможности применения методов машинного обучения для предсказания будущих состояний в экономике. Авторами описаны ключевые экономико-математические методы, выведена точность их применения для прогнозирования экономических циклов. Предложенные подходы позволяют улучшить существующие методики прогнозирования, а также позволяют отдельным успешно адаптироваться к изменяющимся экономическим условиям. Направлением дальнейших исследований является объединение различных методов машинного обучения, таких как полиномиальная регрессия и линейно-клеточные автоматы для повышения точности и надежности прогнозирования.

Ключевые слова: машинное обучение, экономическое прогнозирование, экономические циклы, анализ данных, искусственный интеллект.

FORECASTING ECONOMIC CYCLES USING MACHINE LEARNING

Mironchuk V.A., *Candidate of Economic Sciences, Associate Professor of the Department of Economic Cybernetics, Kuban State Agrarian University (KubGAU), Krasnodar, Russia*

Ivantsov K.A., *student, Kuban State Agrarian University (KubGAU), Krasnodar, Russia*

Gordeev E.S., *student, Kuban State Agrarian University (KubGAU), Krasnodar, Russia*

Abstract. This article examines the main ways to study and predict economic cycles using machine learning methods, and also assesses the degree of their application. The methodological basis of the study is the use of various regression methods, in particular, linear and polynomial regression in tandem with the linear cellular automaton method. The authors studied various points of view on the definition of the concept of "machine learning", determined the degree of use of artificial intelligence in various spheres of society, considered the main types of tasks for which maximum efficiency and productivity are provided using machine learning methods. In the course of the research, the authors revealed the advantages and disadvantages of using machine learning methods. Based on the analysis of macroeconomic indicators provided by the Federal State Statistics Service, the possibilities of using machine learning methods to predict future economic conditions are demonstrated. The authors describe the key economic and mathematical methods, and derive the accuracy of their application for forecasting economic cycles. The proposed approaches make it possible to improve existing forecasting techniques, and also allow individuals to successfully adapt to changing economic conditions. The direction of further research is to combine various machine learning methods such as polynomial regression and linear cellular automata to improve the accuracy and reliability of forecasting.

Keywords: machine learning, economic forecasting, economic cycles, data analysis, artificial intelligence.

JEL classification: C15, C32, C55.

Для цитирования: Мирончук В.А., Иванцов К.А., Гордеев Е.С. Прогнозирование экономических циклов с использованием машинного обучения // Прогрессивная экономика. 2024. № 5. С. 67–84. DOI: 10.54861/27131211_2024_5_67.

Статья поступила в редакцию: 05.05.2024 г. Одобрена после рецензирования: 24.05.2024 г. Принята к публикации: 24.05.2024 г.

For citation: Mironchuk V.A., Ivantsov K.A., Gordeev E.S. Forecasting economic cycles using machine learning // Progressive Economy. 2024. No. 5. pp. 67–84. DOI: 10.54861/27131211_2024_5_67.

The article was submitted to the editorial office: 05/05/2024. Approved after review: 24/05/2024. Accepted for publication: 24/05/2024.

Вклад авторов

Вклад Е.С. Гордеева состоит в сборе данных и написании текста статьи. Вклад К.А. Иванцова состоит в предложении темы исследования, в сборе и обработке статистических и других данных, редакторских правках статьи. Вклад В.А. Мирончука состоит в консультировании и руководстве в процессе проведения исследования.

Contribution of the authors

E.S. Gordeev's contribution consists in collecting data and writing the text of the article. K.A. Ivantsov's contribution consists in the proposal of the research topic, in the collection and processing of statistical and other data, and editorial edits of the article. V.A. Mironchuk's contribution is to provide advice and guidance in the process of conducting research.

Введение

Экономические циклы, характеризующиеся периодическими подъемами и спадами в экономической активности, признаны неотъемлемой чертой развития национальных экономик современных стран. Экономические циклы продолжают оказывать значительное влияние на экономическую стабильность и рост в условиях современной экономики: для обеспечения устойчивого роста национальной экономики необходимо не только понимать предпосылки к возникновению экономических циклов, но также и иметь возможность точно предсказать наступление нового цикла. Понимание будущего состояния экономики позволяет предприятиям эффективно управлять продажами и сбытовой политикой [2], а государственным структурам – адаптировать мероприятия макроэкономической политики в соответствии с потребностями экономической системы на определенной стадии жизненного цикла [8].

В процессе определения будущего состояния экономической системы именно методы машинного обучения демонстрируют высокую эффективность в анализе сложных и больших данных. Традиционные эконометрические модели, основанные на линейных взаимосвязях и ограниченном количестве переменных, все чаще дополняются или заменяются более сложными и гибкими алгоритмами машинного обучения, способными выявлять скрытые закономерности в данных и учитывать множество факторов, влияющих на экономическую динамику. Настоящая статья посвящена исследованию возможностей машинного обучения в прогнозировании экономических циклов.

В рамках представленной исследовательской работы рассматриваются основные алгоритмы машинного обучения, их применение к экономическим данным, а также анализируется эффективность этих методов по сравнению с традиционными эконометрическими подходами. Особое внимание уделяется практическим аспектам внедрения машинного обучения в процессы

экономического прогнозирования и оценке его потенциала для улучшения устойчивости экономического роста.

Целью данной работы является рассмотрение способов использования методов машинного обучения в прогнозировании экономических циклов. Практическая значимость данной статьи заключается в том, что полученные выводы не только подчеркивают важность понимания экономических циклов в контексте глобализации, но и предлагают инновационные подходы к прогнозированию будущих состояний экономической системы с использованием современных технологий.

Обзор литературы

На сегодняшний день машинное обучение (Machine learning) повсеместно используется в большинстве существующих областей научной и производственной деятельности, например, при выявлении заболеваний в медицине [7; 10], прогнозировании поведения животных в сельском хозяйстве [3], отборе дефектной продукции в производстве [6] и множестве других, в том числе и в экономике, как удобный инструмент для автоматизации. Машинное обучение позволяет сократить трудозатраты на многочисленные рутинные процессы, требующие анализа и обработки больших объемов данных, при этом создание программы машинного обучения не требует от разработчика написания комплексного алгоритма под каждую задачу: нужны только данные, по которым алгоритм машинного обучения сам подстроит себя под выполнение определенной задачи.

Машинное обучение в своей основе отличается от других алгоритмов. Для этого стоит сравнить работу тривиальной программы от машинного обучения. Так, обычные алгоритмы получают на вход данные, в большинстве случаев заданные пользователем программы, далее программа совершает манипуляции над данными и в завершении выдает выходные данные. В отличие от них программа машинного обучения получает как входные, так и выходные данные, в совокупности называемые выборкой, на их основе алгоритм строит зависимость или функцию. При правильно составленной выборке функция, получая свежие входные данные, способна быстрыми темпами классифицировать их по ранее выработанному шаблону или аналогичным образом спрогнозировать вероятные значения данных.

Среди всех сфер использования машинного обучения наиболее востребованной можно выделить экономику. Цикличность есть одно из неотъемлемых явлений экономики. Экономический цикл – это периодически повторяющиеся изменения в экономике. Экономические циклы обычно включают четыре основные фазы: рост, пик, спад и дно (табл. 1).

Таблица 1

Основные фазы экономических циклов

Фаза экономического цикла	Описание
1. Экспансия (рост)	Экономика растет, происходит увеличение производства, уровня занятости и доходов. Кредитование расширяется, инвестиции растут, а потребление также увеличивается.
2. Пик	Пик представляет собой точку максимального роста экономики. На этой стадии производство находится на самом высоком уровне, а уровень занятости близок к максимуму. Цены и инфляция могут начать расти.
3. Рецессия (спад)	Рецессия начинается после пика и характеризуется снижением производства, уровня занятости и доходов. Инвестиции уменьшаются, потребление сокращается, а рынки акций и недвижимости могут испытывать обвал.
4. Дно	Дно цикла – это точка минимального уровня экономической активности. На этой стадии экономика достигает своего минимума, и начинается подготовка к новой фазе экспансии.

Источник: составлено авторами по данным [8]

Экономические циклы могут быть вызваны различными факторами, такими как изменения в инвестициях, денежной политике, технологическими изменениями, геополитическими событиями и др. Понимание экономических циклов помогает предсказывать тенденции в экономике и принимать более обоснованные решения в финансовой деятельности. Однако сущность основной проблемы прогнозирования в экономике заключается в том, что стандартные эконометрические модели имеют тенденцию «переоценивать» выборки, и поэтому результат может вводить в заблуждение.

Алгоритмы машинного обучения намного точнее и лишены человеческих мнений и суждений. В традиционной эконометрике чем сложнее модель, на которую вы опираетесь, тем выше дисперсия и меньше систематическая ошибка. Таким образом, ошибки прогнозирования всегда будут присутствовать. Именно здесь на помощь приходит машинное обучение в экономике. Алгоритмы машинного обучения могут свести к минимуму ошибку прогнозирования. Более того, алгоритмы машинного обучения могут одновременно анализировать множество альтернативных моделей, тогда как в традиционной эконометрике представляется возможным анализировать только одну модель за раз [4]. Следовательно, возможность обработки больших объемов данных является преимуществом методов машинного обучения [1].

Многие крупные компании, в том числе, например, Amazon, следуя современным тенденциям развития информационных технологий, активно инвестируют в разработки в области искусственного интеллекта (далее – ИИ). В России технология ИИ также применяется крупнейшими фирмами, которые стремятся быть «локомотивами инноваций» [5]. Таким образом, можно прийти к выводу о практической и теоретической значимости исследования, направленного на разработку методологической базы применения алгоритмов машинного обучения для решения задач прогнозирования.

Материалы и методы

Методы машинного обучения в зависимости от решаемых задач можно разделить на регрессию и классификацию. Методы классификации предназначены для определения функции (зависимости), которая оптимально разделяет входные данные на две или более группы, а методы регрессии направлены на предсказание следующего элемента последовательности. Прогнозирование в обоих случаях осуществляется по одинаковому принципу: сначала обучается функция на выбранной обучающей выборке, а затем уже обученная функция применяется к новым входным данным для получения прогнозов. Для реализации методов линейной и полиномиальной регрессии в данной статье был использован язык python с подключенной библиотекой sklearn. Для метода линейно-клеточного автомата была написана авторская программа на языке C++. Основу исследования составляет применение различных регрессионных методов, в частности, линейной и полиномиальной регрессии в tandem с методом линейно-клеточного автомата.

Поскольку развитие экономики зависит от макроэкономических показателей, таких как ВВП, уровень безработицы и инфляция [8], в качестве материалов исследования выбран показатель ВВП [9]. Исходные данные представлены на рис. 1.




Рис. 1. Поквартальный показатель ВВП России в текущих ценах за период с 1995 по 2023 гг., млрд. руб.

Источник: составлено авторами по данным [9]

Результаты и обсуждение

Линейная регрессия представляет собой базовый метод, необходимый для понимания сути регрессионного подхода. Цель линейной регрессии – обучить линейную функцию, которая будет иметь наименьшую ошибку схождения с действительным показателем ВВП, то есть найти линейную функцию, наиболее приближенную к реальному показателю ВВП. Для этого вычисляется коэффициент детерминации (показатель ошибки). Так, в ходе обучения алгоритм линейной регрессии выявляет функцию, имеющую наименьший показатель ошибки. Такая функция будет являться оптимальной для данной выборки и по совместительству будет представлять собой линейный тренд.

Результатом работы алгоритма является уравнение, описывающее линейную функцию, соответствующую действительному показателю ВВП на 92.47 % согласно коэффициенту детерминации, что означает высокую степень схождения между ожидаемыми и прогнозируемыми данными.

Значения линейной регрессии (оценочной функции) вычисляются по формуле (1):

$$f(x) = \sum_{j=0}^k \beta_j x_j + \varepsilon \quad (1)$$

где $j = \overline{0, k}$, β – коэффициент регрессии, ε – случайная ошибка.

Для того, чтобы предсказанный ответ (x) как можно ближе соответствовал реальному (y), методом наименьших квадратов вычисляется коэффициент детерминации (2):

$$\sum_i (y_i - f(x_i))^2 \rightarrow \min \quad (2)$$

Результат вычисления функции с помощью метода линейной регрессии представлен на рис. 2.




Рис. 2. Результат вычисления линейной функции с помощью метода линейной регрессии

Источник: разработано авторами по данным [9]

Анализируя представленные данные, можно сделать вывод, что линейная функция не отражает динамику реального показателя ВВП. В данном случае функцией, более четко описывающей действительный показатель ВВП, представляется полином. В ходе работы полиномиальной регрессии происходят процессы, идентичные линейной, за исключением трансформации линейной функции в полиномиальную, но результат полиномиальной в разы точнее. Коэффициент детерминации полиномиальной регрессии составляет 97.62 %, показатель оптимально описывает функцию ВВП. Уравнение полиномиальной регрессии имеет вид (3):

$$f(x) = \sum_{j=0}^k b_j x^j + \varepsilon \quad (3)$$

где b_j – параметры полинома, $j = \overline{0, k}$, ε – случайная ошибка.

Для того, чтобы предсказанный ответ (x) как можно ближе соответствовал реальному (y), методом наименьших квадратов вычисляется коэффициент детерминации для полиномиальной регрессии. Результат вычисления полинома с помощью метода полиномиальной регрессии представлен на рис. 3.




Рис. 3. Результат вычисления полинома с помощью метода полиномиальной регрессии

Источник: разработано авторами по данным [9]

Несмотря на то, что функция полиномиальной регрессии хорошо описывает график, предсказательная возможность данной модели достаточно мала, что можно проследить, если попробовать предсказать элементы графика. Для иллюстрации данного утверждения уберем часть данных исходного графика и спрогнозируем их, используя полученную модель (рис. 4).




Рис. 4. Результат прогнозирования ВВП с помощью метода полиномиальной регрессии

Источник: разработано авторами по данным [9]

Анализ предсказательной силы полиномиальной модели представлен в таблице 2. В данном случае коэффициент детерминации для предсказанного участка составляет 0.819%, что считается приемлемым.

Таблица 2

Данные вычислений полиномиальной регрессии

Номер предсказанного элемента	Действительное значение	Предсказанное значение	Отклонение
85	18885.12	23381.39	4496.27
86	20452.23	23951.61	3499.37
87	22235.12	24528.80	2293.68
88	24043.61	25112.96	1069.35
89	20586.12	25704.10	5117.98
90	21917.57	26302.21	4384.64
91	23718.22	26907.30	3189.08
92	25621.25	27519.36	1898.11
93	22474.46	28138.39	5663.93
94	24969.76	28764.40	3794.64
95	27196.84	29397.38	2200.53
96	29220.58	30037.33	816.75
97	24608.60	30684.26	6075.66
98	26628.59	31338.16	4709.57
99	28346.03	31999.03	3653.00
100	30025.08	32666.88	2641.80
101	24865.96	33341.70	8475.74
102	23775.43	34023.49	10248.06
103	27786.26	34712.26	6926.00
104	31230.48	35408.00	4177.52

105	27939.81	36110.72	8170.91
106	31885.14	36820.41	4935.26
107	35358.52	37537.07	2178.55
108	40111.49	38260.71	1850.79
109	36398.50	38991.32	2592.82
110	36540.16	39728.90	3188.74
111	38245.09	40473.46	2228.37
112	42251.41	41224.99	1026.43
Сумма	787317.45	XX	111503.56

Источник: разработано авторами по данным [9]

В дальнейшем прогнозировании будет применяться метод линейно-клеточного автомата. Поскольку целью прогнозирования для линейно-клеточного автомата являются спады и подъемы, алгоритму необходим временной ряд, с помощью которого можно предсказывать данные изменения. Для этого для каждой единицы данных, представленной в табл. 2, вычисляется разность между предыдущим и текущим элементом. В таком случае первый элемент последовательности приравнивается к нулю. Таким образом, из 112 данных 84 будут использованы для обучения линейно-клеточного автомата, а 28 последующих элементов будут предсказаны. В результате мы получаем диаграмму спадов и подъемов показателя ВВП, представленную на рис. 5.



Рис. 5. Обработка данных к линейно-клеточному автомату

Источник: разработано авторами по данным [9]

После обработки данных представляется возможным приступить к прогнозированию с помощью линейно-клеточного автомата. Суть метода заключается в том, чтобы разделить весь график на термы, обозначающие значение от высшего к низшему. Для графика ВВП выделим четыре терма, обозначенные буквами от «А» до «D», где «А» соответствует всем высшим

значениям, а «D» – низшим. Два промежуточных термина «В» и «С» будут соответственно обозначать значения выше и ниже среднего уровня. Следует отметить здесь, что метод линейно-клеточного автомата включает фактор субъективного выбора: поскольку для подразделения на термины необходимо оценить график и обозначить в нем минимальные и максимальные значения в различных диапазонах, для разных диапазонов высшие и низшие значения могут существенно отличаться. Например, в начале диапазона значение 22.94 может представляться пиковым, тогда как в конце таким значением будет 3662.54. После выделения пиков необходимо установить границы, соединяющие минимальные и максимальные значения в единую замкнутую цепь, в которой все значения ряда преобразуются в термины. Пример пользовательской оценки представлен на рис. 6.




Рис. 6. Пример пользовательской оценки

Источник: разработано авторами

Преобразование данных в терм-ряд представлено в таблице 3.

Таблица 3

Преобразование данных в терм-ряд

Пример терм-ряда, составленного из 2-х термов
ABBAABBAABBAABBBBBAABBAABBAABBAABBBABBBABV BABBABBAABBBABBBABBBABBBABBBABBBABBB
из 4-х термов
ADDBACDBACDBACDCDDBBBCDBACDAACDBACDBADDDCADDCA DCADDDADDBADDDCADDADDDADDDADDDADDDADDD

Источник: разработано авторами

Следующий этап – это верификация. На данном этапе график, преобразованный в терм-ряд, подвергается поиску закономерностей. Для этого находятся переходы из одного термина в другие, и число таких переходов отдельно подсчитывается. Например, в рассматриваемом ряду переходов из термина «А» в терм «А» – 9, в «В» – 20, а из «В» в «А» – 19, и в «В» – 35.

Теоретически это означает: шанс того, что из термина «А» значение перейдет в терм «В», равен 20/29. Но верификация не заканчивается на вычислении простых выражений переходов из «А» в остальные термины; для каждого термина, имеющего количество переходов более одного, также вычисляются свои переходы. Итогом таких вычислений являются терм-

последовательности с внушительной длиной, к примеру, «АВВААВВВАВВВАВВВАВВВАВВА». Любая последовательность термов называется конфигурацией. Найдя конфигурацию максимальной длины, можно приступить непосредственно к этапу прогноза (табл. 4).

Таблица 4

Вычисление Верификации

Конфигурация-1									
А	А	9	29		В	А	19	54	
	В	20				В	35		
Конфигурация-2									
АА	А	0	9		АВ	А	0	20	
	В	9				В	20		
ВА	А	9	19		ВВ	А	19	34	
	В	10				В	15		
Конфигурация-3									
ААВ	А	0	9		АВВ	А	8	20	
	В	9				В	12		
ВАА	А	0	9		ВАВ	А	0	10	
	В	9				В	10		
ВВА	А	9	19		ВВВ	А	11	14	
	В	10				В	3		

Конфигурация-24									
АВВААВВВАВВВАВВВА ВВВАВВА	А	1	1		АВВААВВВАВВВАВВВА ВВВАВВВ	А	1	1	
	В	0				В	0		
АВВВАВВВАВВВАВВВА ВВВАВВВ	А	1	1						
	В	0							

Источник: разработано авторами

После верификации осуществляется этап валидации, в котором происходит сам прогноз. Для этого берется последовательность максимально возможной длины, например, «АВВААВВВАВВВАВВВАВВВАВВА» и вычисляется суммарный шанс перехода каждой отдельной терм-последовательности, состоящей в «АВВААВВВАВВВАВВВАВВВАВВА» во все возможные терм-переходы, то есть для «А» вычисляются шанс перехода в «А» и в «В», потом для «ВА» в «А» и в «В», после для «ВВА», и т.д. до «АВВААВВВАВВВАВВВАВВВАВВА» в «А» и в «В». Пример вычисления валидации представлен в таблице 5.

Таблица 5

Вычисление валидации

Прогнозируемый элемент	Конфигурация с максимальной глубиной	Переход в	Ненормированное значение функции	Сумма ненормированных элементов	Значение функции принадлежности	Прогнозируемое число	Удачность прогноза
2015.75	BABBBABBB ABBBABBB BBBAB	A	3.87734	23	0.16858	B	+
		B	19.1227		0.83142		
2015.5	BBABBBABBB BABBBABBB ABBBAB	A	0.351852	22	0.015993	B	+
		B	21.6481		0.984007		
2015.25	BBBABBBAB BBABBBABBB BABBB	A	1.34862	21	0.06422	B	+
		B	19.6514		0.93578		

Источник: разработано авторами

Последний этап – предсказание, на деле это тоже верификация, но уже несуществующих значений. Зададим разное число термов для графика и приведем данные с вероятностями успешных предсказаний в табл. 6, проверку достоверности предсказания осуществляем просмотром полной выборки из 112 элементов.

Таблица 6

Результат работы линейно клеточного автомата с разным числом термов

Число термов	Максимальная длина последовательности термов (глубина)	Вероятность удачного самопрогноза	Вероятность удачного прогноза	
			следующих 28 значений	следующих 14 значений
2	24	93.33%	92.86%	100.00%
4	20	87.50%	89.29%	100.00%
8	20	78.13%	75.00%	92.86%
16	6	78.21%	50.00%	64.29%

Источник: разработано авторами

По данным, приведенным в таблице 6, можно сделать несколько выводов. Во-первых, вероятность удачного самопрогноза колеблется от 93 до ~78%, сам показатель указывает то, насколько алгоритм способен просчитать

данные, на которых обучался. Как видно из таблицы, показатель падает в зависимости от числа термов, и похоже никак не связан с максимальной глубиной конфигурации или вероятностью удачного прогноза последующих элементов графика. Для поиска корреляции вероятности удачного самопрогноза было проведено два эксперимента для линейно-клеточного автомата с числом термов, равным 4 (табл. 7).

Таблица 7

Определение факторов, влияющих на удачность самопрогноза

Эксперимент	Число термов	Максимальная длина последовательность и термов (глубина)	Вероятность удачного самопрогноза
Увеличенное число данных в выборке	4	12	79.54%
Изменённая пользовательская оценка	4	18	87.50%

Источник: разработано авторами

Как можно выделить из табл.7, вероятность успешного самопрогноза с измененной пользовательской оценкой не изменилась, тогда как увеличение числа данных в выборке понизило вероятность удачного самопрогноза.

Во-вторых, вероятность удачного предсказания значений тем больше, чем меньше количество значений, которые были предсказаны. Это заявление доказывает вероятность удачного прогноза следующих 14-ти значений, которая стабильно больше вероятности прогноза следующих 28-ми значений.

В-третьих, чем меньшее число термов, тем большая вероятность удачного предсказания. Это объясняется тем, что при меньшем числе термов область допустимых значений для одного терма больше, а чем шире область прогноза, тем больше шанс выполнить прогноз удачно.

В целом метод линейно-клеточного автомата идеально подойдет, если необходимо узнать общую тенденцию развития экономики. Так, при числе термов в 2 вероятность точного определения экономического цикла составляет 92.86%. Отметим здесь, что использование линейно-клеточного автомата для определения точной величины подъема или спада не подходит, поскольку при увеличении числа термов, а соответственно и точности вычисления – удачность прогноза падает. Приведем пример наглядного предсказания методом линейно-клеточного автомата циклов спада и подъема ВВП в табл. 8.

Таблица 8

Результат прогноза экономических спадов и подъемов методом линейно-клеточного автомата

Номер элемента	Действительное значение	Условие: если «предыдущий элемент» > «текущий элемент», то «Упало», иначе «Возросло»	Предсказанные значения	Успешность предсказания
84	23079.84			
85	18885.12	Упало	Упало	+
86	20452.23	Возросло	Возросло	+
87	22235.12	Возросло	Возросло	+
88	24043.61	Возросло	Возросло	+
89	20586.12	Упало	Упало	+
90	21917.57	Возросло	Возросло	+
91	23718.22	Возросло	Возросло	+
92	25621.25	Возросло	Возросло	+
93	22474.46	Упало	Упало	+
94	24969.76	Возросло	Возросло	+
95	27196.84	Возросло	Возросло	+
96	29220.58	Возросло	Возросло	+
97	24608.6	Упало	Упало	+
98	26628.59	Возросло	Возросло	+
99	28346.03	Возросло	Возросло	+
100	30025.08	Возросло	Возросло	+
101	24865.96	Упало	Упало	+
102	23775.43	Упало	Возросло	-
103	27786.26	Возросло	Возросло	+
104	31230.48	Возросло	Возросло	+
105	27939.81	Упало	Упало	+
106	31885.14	Возросло	Возросло	+
107	35358.52	Возросло	Возросло	+
108	40111.49	Возросло	Возросло	+
109	36398.5	Упало	Упало	+
110	36540.16	Возросло	Возросло	+
111	38245.09	Возросло	Возросло	+
112	42251.41	Возросло	Возросло	+
			Сумма	27 из 28

Источник: разработано авторами

Таким образом, предсказание данных как методом линейно-клеточного автомата, так и полиномиальной регрессией, прошло успешно. Оба метода имеют как свои достоинства, так и ограничения. Метод линейной регрессии позволяет точно предсказать тенденции роста или снижения экономических циклов, недостатком же служит невозможность получения подробного

значения изменений экономических циклов. Метод полиномиальной регрессии, в свою очередь, не обладает возможностью предсказания спадов и подъемов, но имеет высокую предсказательную эффективность в вычислении тренда развития экономических показателей. По отдельности методы позволяют корректно и результативно предсказывать дальнейшие сдвиги экономики.

Заключение

Проведенное исследование вносит авторский вклад в изучение возможностей применения методов машинного обучения для прогнозирования экономических циклов. В статье доказана значимость понимания экономических циклов в условиях глобализации экономики и предложен математический инструмент прогнозирования будущих состояний экономических систем. Использование алгоритмов машинного обучения позволяет не только повышать точность прогнозов, но и учитывать множество факторов, влияющих на экономическую динамику, что зачастую недоступно традиционным эконометрическим моделям.

Результаты данного исследования выступают основой для дальнейших научных изысканий авторов в рамках данной области. В частности, в последующих публикациях планируется произвести объединение различных методов машинного обучения, таких как полиномиальная регрессия и линейно-клеточные автоматы, что позволит получать более точные и надежные прогнозы.

Литература

1. Арашов М. Машинное обучение в экономике – как оно используется? // *Eo ipso*. 2022. № 11. С. 46–48.
2. Веселов Д.И. Основные проблемы промышленных предприятий в условиях цифровизации // *Прогрессивная экономика*. 2024. № 3. С. 5–13.
3. Гирфанов А.И., Папаев Р.М., Загидуллин Л.Р. Использование машинного обучения для исследования форм поведения животных / *Международный форум Kazan Digital Week-2022: Сборник материалов Международного форума*. Казань. 21–24 сентября. 2022. Казань: Научный центр безопасности жизнедеятельности. 2022. С. 751–755.
4. Давыдов, А. Н. использование машинного обучения в экономике // *Современные проблемы лингвистики и методики преподавания русского языка в ВУЗе и школе*. 2022. № 38. С. 845–848.
5. Маслакова П.И., Осенний В.В., Бурда А.Г. Направления использования машинного обучения и искусственного интеллекта в экономики и перспективы их развития // *Цифровизация экономики: направления, методы, инструменты : Сборник материалов II всероссийской научно-практической конференции*. Краснодар: Кубанский государственный аграрный университет имени И.Т. Трубилина, 2020. С. 51–54.
6. Нумонова Н.Р. Обзор литературы: применения основных подходов и методов машинного обучения в сфере экономики / *Цифровизация*

как драйвер развития науки и образования: Сборник статей III Международной научно-практической конференции. Петрозаводск. 15 июня. 2021. Петрозаводск: Международный центр научного партнерства «Новая Наука». 2021. С. 31–36.

7. Поленок М.В., Бондаренко С.В., Козлова И.Р., Юркова О.Н. О методах машинного обучения при принятии управленческих решений в области здравоохранения / Вызовы цифровой экономики: тренды развития в условиях последствий пандемии COVID-19: Сборник статей IV Всероссийской научно-практической конференции, приуроченной к Году науки и технологий в России. Брянск: Брянский государственный инженерно-технологический университет. 2021. С. 225–229.

8. Садакова Е.Н., Куклин А.В. Причины экономических циклов и их государственное регулирование в России // Вектор экономики. 2023. № 3 (81). С. 1–12.

9. Федеральная служба государственной статистики. URL: <https://rosstat.gov.ru>.

10. Chekhovych M.G., Poreva A.S., Timofeyev V.I., Henaff P. Using of the Machine Learning Methods to Identify Bronchopulmonary System Diseases with the Use of Lung Sounds // Bulletin of National Technical University of Ukraine. Series Radiotechnique. Radioapparatus building. 2018. Vol. 73. P. 55–62.

References

1. Arashov M. Mashinnoe obuchenie v ekonomike – kak ono ispol'zuetsya? // Eo ipso. 2022. № 11. S. 46–48.

2. Veselov D.I. Osnovnye problemy promyshlennyh predpriyatij v usloviyah cifrovizatsii // Progressivnaya ekonomika. 2024. № 3. S. 5–13.

3. Girfanov A.I., Papaev R.M., Zagidullin L.R. Ispol'zovanie mashinnogo obucheniya dlya issledovaniya form povedeniya zhivotnyh / Mezhdunarodnyj forum Kazan Digital Week-2022: Sbornik materialov Mezhdunarodnogo foruma. Kazan'. 21–24 sentyabrya. 2022. Kazan': Nauchnyj centr bezopasnosti zhiznedeyatel'nosti. 2022. S. 751–755.

4. Davydov, A. N. ispol'zovanie mashinnogo obucheniya v ekonomike // Sovremennye problemy lingvistiki i metodiki prepodavaniya russkogo yazyka v VUZe i shkole. 2022. № 38. S. 845–848.

5. Maslakova P.I., Osennij V.V., Burda A.G. Napravleniya ispol'zovaniya mashinnogo obucheniya i iskusstvennogo intellekta v ekonomiki i perspektivy ih razvitiya // Cifrovizatsiya ekonomiki: napravleniya, metody, instrumenty : Sbornik materialov II vserossijskoj nauchno-prakticheskoy konferencii. Krasnodar: Kubanskij gosudarstvennyj agrarnyj universitet imeni I.T. Trubilina, 2020. S. 51–54.

6. Numonova N.R. Obzor literatury: primeneniya osnovnyh podhodov i metodov mashinnogo obucheniya v sfere ekonomiki / Cifrovizatsiya kak drajver razvitiya nauki i obrazovaniya: Sbornik statej III Mezhdunarodnoj nauchno-

prakticheskoy konferencii. Petrozavodsk. 15 iyunya. 2021. Petrozavodsk: Mezhdunarodnyj centr nauchnogo partnerstva «Novaya Nauka». 2021. S. 31–36.

7. Polenok M.V., Bondarenko S.V., Kozlova I.R., YUrkoval O.N. O metodah mashinnogo obucheniya pri prinyatii upravlencheskih reshenij v oblasti zdavoohraneniya / Vyzovy cifrovoj ekonomiki: trendy razvitiya v usloviyah posledstvij pandemii COVID-19: Sbornik statej IV Vserossijskoj nauchno-prakticheskoy konferencii, priurochennoj k Godu nauki i tekhnologij v Rossii. Bryansk: Bryanskij gosudarstvennyj inzhenerno-tekhnologicheskij universitet. 2021. S. 225–229.

8. Sadakova E.N., Kuklin A.V. Prichiny ekonomicheskikh ciklov i ih gosudarstvennoe regulirovanie v Rossii // Vektor ekonomiki. 2023. № 3 (81). S. 1–12.

9. Federal'naya sluzhba gosudarstvennoj statistiki. URL: <https://rosstat.gov.ru>.

10. Chekhovych M.G., Poreva A.S., Timofeyev V.I., Henaff P. Using of the Machine Learning Methods to Identify Bronchopulmonary System Diseases with the Use of Lung Sounds // Bulletin of National Technical University of Ukraine. Series Radiotechnique. Radioapparatus building. 2018. Vol. 73. P. 55–62.