

УДК 004.8:378 · DOI: 10.31429/2224042X_2026_82_56

Выявление группы риска по студенческой автономности в условиях использования искусственного интеллекта: нейро-нечёткий подход (ANFIS)

Identification of a risk group for student autonomy in the context of artificial intelligence use: a neuro-fuzzy (ANFIS) approach

Фощан Г. И., Литвинский К.О.,
Тодовянский А.А.

Кубанский государственный университет,
Краснодар, Россия

Foschan G.I., Litvinsky K.O.,
Todovyansky A.A.

Kuban State University, Krasnodar, Russia

Аннотация. Рассматривается выявление группы риска снижения учебной автономности студентов при использовании ИИ. Для риск-оценки применена интерпретируемая нейро-нечёткая модель ANFIS. Качество оценено RMSE/MAE и корреляцией Спирмена; выполнены диагностика ошибок и перестановочная важность признаков. Максимальный вклад дают случаи сдачи работ, полностью выполненных ИИ, и сильное влияние ИИ на учебный процесс.

Abstract. This paper addresses the identification of a risk group for reduced student learning autonomy under the use of AI tools. An interpretable neuro-fuzzy ANFIS (Adaptive Neuro-Fuzzy Inference System) model is applied to estimate risk. Model quality is evaluated using RMSE/MAE and Spearman's rank correlation; error diagnostics and permutation-based feature importance are also performed. The strongest contribution to reduced autonomy is associated with submitting assignments fully completed by AI and the pronounced influence of AI on the learning process.

Ключевые слова: учебная автономность, группа риска, искусственный интеллект, нейро-нечёткая модель, ANFIS, интерпретируемое машинное обучение, перестановочная значимость.

Keywords: learning autonomy, risk group, artificial intelligence, neuro-fuzzy model, ANFIS, interpretable machine learning, permutation importance.

Цитирование: Фощан Г. И., Литвинский К.О., Тодовянский А.А. Выявление группы риска по студенческой автономности в условиях использования искусственного интеллекта: нейро-нечёткий подход (ANFIS) // ЭКОНОМИКА: теория и практика. 2026. № 2. С. 56–62. DOI: 10.31429/2224042X_2026_82_56

История публикации: рукопись поступила 16.04.2026, опубликована 19.06.2026.

Введение

За несколько последних лет инструменты искусственного интеллекта (ИИ) прочно вошли в учебную практику и сегодня сопровождают значительную часть повседневной работы студентов [8; 11; 13; 21]. Нейросети помогают искать информацию, формулировать тексты, разбирать задачи, готовить учебные материалы; на эти инструменты постепенно смещается часть когнитивной работы, которую раньше студент выполнял своими силами, и сама структура учебного труда заметно меняется [8; 11; 13].

Такое смещение, в свою очередь, создаёт риск ослабления учебной автономности студентов. Учебная автономность – это способность учащегося самому планировать свою работу, доводить её до результата, контролировать ход выполнения

и отвечать за итог [5; 9; 22]. Если же ИИ используется не как помощник, а как замена самостоятельной работы — например, когда студент сдаёт ответы, целиком сгенерированные нейросетью, — у него постепенно формируется зависимость от инструмента, а собственная самостоятельность угасает [8; 11; 17].

Роль ИИ в образовании сейчас активно обсуждается, однако работ, в которых критерии выявления «группы риска» по автономности были бы формализованы прикладным образом, по-прежнему мало. Образовательным организациям нужны не общие выводы, а рабочий инструмент: количественная модель, способная одновременно ранжировать студентов по уровню риска и показывать, почему конкретный респондент к этой группе отнесён [8; 13; 21].

Мы предлагаем способ «перевести» качественные практики использования ИИ в формализованный риск-профиль, пригодный для первичного скрининга. Описанием связей здесь ограничиться нельзя – нужна интерпретируемая модель, которая выдаёт непрерывную оценку риска в диапазоне [0; 1] и объясняет, откуда эта оценка взялась, через логику нечётких правил [10; 12; 15; 20]. Подход новый в том смысле, что мы соединяем скоринг по опросным данным с интерпретируемой структурой ANFIS — функциями принадлежности и правилами IF-THEN — и при этом обязательно проверяем качество и устойчивость получаемых выводов [10; 6; 18; 20]. Для образовательной практики это существенно: модель не только ранжирует студентов по уровню риска, но и показывает, какие именно правила и факторы привели к итоговой оценке для каждого респондента.

Цель работы — построить и проинтерпретировать модель, которая выделяет группу риска по снижению учебной автономности при использовании ИИ, и сделать это на основе нейро-нечёткого подхода (ANFIS). Параллельно мы диагностируем качество получаемой модели.

Эмпирическую базу составили ответы 259 респондентов, представляющих разные группы участников образовательного процесса. Основную часть выборки составили студенты российских вузов — 188 человек, или 72,6% от общего числа опрошенных. Кроме того, в исследование были включены школьники старших классов — 34 человека, или 13,1%, и преподаватели — 37 человек, или 14,3%. Такое распределение выборки позволило сохранить фокус исследования на студенческой аудитории, для которой проблема учебной автономности при использовании ИИ является наиболее актуальной, но одновременно учесть более широкий образовательный контекст: опыт учащихся до поступления в вуз и позицию преподавателей, наблюдающих изменения в учебном поведении обучающихся. Анкета включала вопросы о том, как респонденты применяют ИИ в учёбе и как сами оценивают его влияние на собственную учебную работу. Изначально все ответы были качественными; для последующей обработки мы перевели их в числовой эквивалент по шкале от 0 до 1.

В роли зависимой переменной выступает показатель behavioral dependence — риск-индикатор того, что учебная автономность студента

снижается. Логика простая: чем выше значение этого показателя, тем сильнее вероятная зависимость от ИИ и тем выше шанс, что респондент попадёт в группу повышенного риска. Независимыми переменными мы взяли пять ключевых показателей; они соответствуют ответам на следующие вопросы анкеты:

- 1) Q32. Как вы относитесь к качеству ответов нейросетей;
- 2) Q33. Как использование нейросетей повлияло на вашу учёбу;
- 3) Q34. Приходилось ли вам сдавать работы, полностью сделанные ИИ;
- 4) Q38. Снижает ли использование ИИ ваш уровень самостоятельности;
- 5) Q40. Можете ли вы представить учёбу без нейросетей.

Мы строим модель как регрессионный скоринг: на выходе получается непрерывная оценка риска в диапазоне [0; 1], а уже по этой оценке, задав пороговое правило, можем выделять группы риска. В основе скоринга — модель ANFIS [6; 18; 7] (Sugeno/TSK-типа); она объединяет два компонента:

- 1) нечёткие функции принадлежности (membership functions, MF) для каждого признака;
- 2) систему правил вида IF-THEN, где IF задаётся степенями принадлежности, а THEN — линейной моделью следствий (консеквентов).

В качестве функций принадлежности мы взяли гауссовы — по две на каждый признак (MF1 и MF2); полное число правил в системе получилось 32. Чтобы убедиться в корректности выводов, мы дополнительно провели:

- анализ остатков и график Residuals vs y_{pred} для выявления систематических смещений и гетероскедастичности;
- проверку нормальности остатков [2] (Q-Q plot) как диагностический критерий качества аппроксимации;
- permutation importance [3] ($\Delta RMSE$) для оценки важности признаков;
- чтение правил (top rules) для интерпретации логики модели.

Результаты исследования

График «остатки–предсказание» (рис. 1) показывает, как ведёт себя ошибка модели в зависимости от уровня предсказанного риска




Рис. 1. Residuals vs y_pred

(остаток = $y_{true} - y_{pred}$). В идеале точки должны лежать симметрично вокруг нулевой линии и не складываться в какую-либо структуру — это означало бы, что модель не завышает и не занижает риск ни в одном из диапазонов. На нашем графике структура всё-таки видна: точки группируются в характерные «полосы». Причина в природе данных — анкетные шкалы дискретны, и число уровней целевой переменной ограничено, поэтому ошибки естественным образом образуют кластеры.

Q-Q график (рис. 2) — это способ визуально проверить, насколько распределение остатков согласуется с нормальным законом. Если точки в центральной области ложатся близко к прямой, значит, на «типичных» наблюдениях ошибки ведут себя адекватно. Отклонения на хвостах — другая история: они говорят о выбросах, асимметрии или «тяжёлых хвостах», и для опросных данных с неоднородными профилями респондентов это вполне ожидаемо. В нашем случае такие хвостовые отклонения мы интерпретируем так: есть часть студентов с нетипичными сочетаниями ответов, и для них аппроксимация работает хуже. Прикладную применимость модели это не отменяет, но напоминает: риск-скоринг — вероятностный индикатор, и для крайних случаев

результаты лучше подтверждать дополнительными процедурами [2].

Идея перестановочной важности простая: чтобы оценить вклад признака в качество модели, мы случайно перемешиваем его значения и смотрим, насколько сильно ухудшается ошибка. Если RMSE после такой процедуры заметно растёт — значит, признак для риск-скоринга действительно ценный. На рис. 3 отчётливо видно, что главный вклад в выделение группы риска дают вопросы про практики, наиболее близкие к «замещению» самостоятельной работы — в первую очередь опыт сдачи работ, полностью сделанных ИИ (Q34), и оценка влияния ИИ на учёбу (Q33). Остальные признаки тоже работают, но их вклад в итоговый скоринг ощутимо меньше. Прикладной смысл этого результата вот в чём: мы можем понять, какие вопросы анкеты — ключевые индикаторы риска и должны остаться в диагностическом инструменте, а какие можно безболезненно сократить, не потеряв качество скрининга [3].

Корреляционная тепловая карта показывает попарные связи между пятью признаками анкеты (Q32, Q33, Q34, Q38, Q40), целевой переменной *behavioral_dependence* и остатками модели (*residual*). Это диагностический срез — с его помощью мы оцениваем, насколько признаки связаны

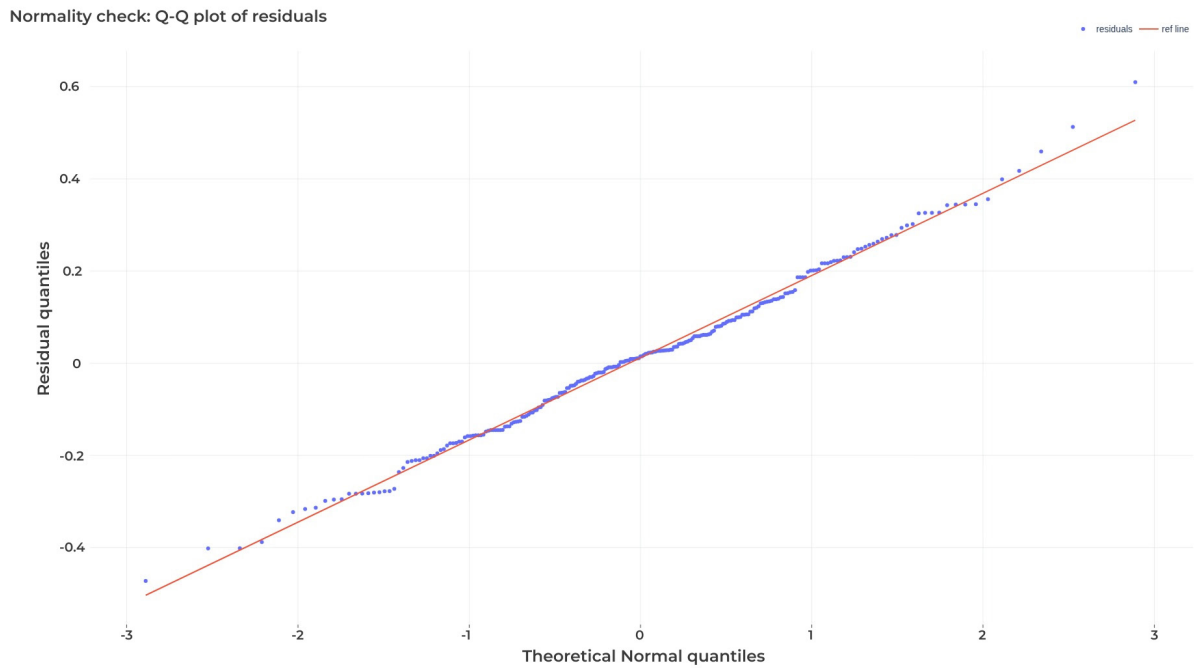


Рис. 2. Normality check (Q-Q plot)




Рис. 3. Permutation Importance (Δ ARMSE)

друг с другом, и заодно проверяем, не «цепляются» ли ошибки модели за какой-то из исходных факторов. В матрице связи между вопросами в основном слабые или умеренные. Это говорит о том, что признаки не дублируют друг друга, и каждый пункт

анкеты ловит свой аспект практик и отношения к ИИ. Чуть более заметные корреляции с behavioral dependence дают вопросы про практическое использование ИИ и его влияние на учёбу. У residual корреляции с отдельными признаками низкие, т.е.

Correlation heatmap: features + target + residual




Рис. 4. Корреляционная тепловая карта: признаки, целевая переменная, остатки

ошибки не объясняются простым линейным перекосом по какому-то одному фактору. При этом есть заметная связь между остатками и самой целевой переменной: точность модели в разных диапазонах риск-оценки получается неодинаковой.

Если смотреть на метрики в совокупности, модель показывает приемлемые характеристики для задачи скрининга. Коэффициент ранговой корреляции Спирмена (ρ) на тестовой выборке оказался около 0,46 [16] — это значит, что респонденты ранжируются по уровню риска корректно. По перестановочной важности больше всего в прогноз вкладываются два признака: опыт сдачи работ, целиком выполненных ИИ (Q34), и оценка влияния нейросетей на учёбу (Q33). Диагностика ошибок не выявила, чтобы остатки сильно зависели от какого-то отдельного признака — это согласуется с корреляционной матрицей «features–target — residual». Что из всего этого следует на практике? При выделении группы риска нельзя ориентироваться только на пороговое значение скоринга — нужно учитывать, что в разных диапазонах риск-оценки модель работает с разной точностью,

а на хвостах распределения ошибок возможны локальные эффекты, которые стоит проверять отдельно для крайних случаев.

Заключение

На практике модель можно использовать для первичного отбора студентов, которым нужна дополнительная педагогическая поддержка, чтобы развивать у них навыки самоконтроля и укреплять привычку к самостоятельной учебной работе, особенно сейчас, когда ИИ применяется так активно. Факторы, которые мы выделили, в педагогическом плане читаются как индикаторы того, что самостоятельная деятельность подменяется работой ИИ.

Главное преимущество ANFIS в этой задаче — сочетание непрерывной риск-оценки и интерпретируемости: модель выделяет группу риска по порогу или квантилю, и сразу объясняет результат через понятные комбинации ответов. Но есть и ограничение: шкалы у нас дискретные, на крайних значениях ошибки ведут себя своеобразно, поэтому модель разумнее использовать

как инструмент первичного отбора, а не финального решения. На практике хорошо работают два варианта: квантильный отбор (например, верхние 15–25% по риску) или комбинированная схема — модель плюс экспертная оценка.

Решения этой проблемы делятся, по сути, на два подхода. Первый — регулировать доступ к генеративным моделям. Но он плохо работает на практике: ИИ-инструменты обходятся технически легко, а доступность их слишком высока. Второй подход кажется куда продуктивнее — учить студентов грамотно работать с генеративными моделями.

Сюда входят курсы, отдельные дисциплины и интенсивы, на которых разбирают, как ставить задачи нейросети, как проверять и верифицировать её ответы, как работать с источниками — и, главное, как сохранять самостоятельность, относясь к ИИ как к инструменту поддержки, а не замене учебной работы.

В дальнейшем хотелось бы расширить выборку, уточнить шкалы и формулировки опросника, а заодно проверить, насколько устойчивы наши результаты на данных из других образовательных организаций.

Библиографический список

1. Моросанова В.И., Фомина Т.Г., Цыганов И.Ю. Осознанная саморегуляция и отношение к учению в достижении учебных целей. М.; СПб., 2017.
2. Сидоренко Е.В. Методы математической обработки в психологии. СПб.: 2000.
3. Altmann A, Tološi L, Sander O, Lengauer T. Permutation importance: a corrected feature importance measure // *Bioinformatics*. 2010. Vol. 26, No. 10. P. 1340–1347. DOI: 10.1093/bioinformatics/btq134
4. Breiman L. Random forests // *Machine Learning*; 2001. Vol. 45, No. 1. P. 5–32.
5. Holec H. *Autonomy and Foreign Language Learning*. Oxford: Pergamon Press; 1981. 53 p.
6. Jang J.-S.R. ANFIS: Adaptive–Network–Based Fuzzy Inference System // *IEEE Transactions on Systems, Man, and Cybernetics*; 1993. Vol. 23, No. 3. P. 665–685.
7. Jang J.-S.R., Sun C.-T., Mizutani E. *Neuro–Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*. Upper Saddle River, NJ: Prentice Hall; 1997. 614 p. ISBN 0–13–261066–3.
8. Kasneci E, Seßler K, Küchemann S. [et al.] ChatGPT for good? On opportunities and challenges of large language models for education // *Learning and Individual Differences*; 2023. Vol. 103. Art. 102274.
9. Little D. Language Learner Autonomy: Some Fundamental Considerations Revisited // *Innovation in Language Learning and Teaching*; 2007. Vol. 1, No. 1. P. 14–29.
10. Mamdani E.H., Assilian S. An experiment in linguistic synthesis with a fuzzy logic controller // *International Journal of Man–Machine Studies*; 1975. Vol. 7, No. 1. P. 1–13.
11. Miao F, Holmes W. *Guidance for generative AI in education and research* Paris: UNESCO; 2023. URL: <https://unesdoc.unesco.org/ark:/48223/pf0000386693>
12. Molnar C. *Interpretable Machine Learning: A Guide for Making Black Box Models Explainable* 2nd ed; 2022. URL: <https://christophm.github.io/interpretable-ml-book/> (дата обращения: 25.02.2026).
13. Ouyang F, Jiao P. Artificial intelligence in education: The three paradigms // *Computers and Education: Artificial Intelligence*; 2021. Vol. 2. Art. 100020.
14. Pedregosa F, Varoquaux G, Gramfort A. [et al.] Scikit-learn: Machine learning in Python // *Journal of Machine Learning Research*; 2011. Vol. 12. P. 2825–2830.
15. Ribeiro M.T., Singh S, Guestrin C. «Why Should I Trust You?» Explaining the Predictions of Any Classifier // *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)*. New York: ACM, 2016. P. 1135–1144.
16. Spearman C. The proof and measurement of association between two things // *The American Journal of Psychology*; 1904. Vol. 15, No. 1. P. 72–101.
17. Susnjak T, McIntosh T.R. ChatGPT: The End of Online Exam Integrity? // *Education Sciences*; 2024. Vol. 14, No. 6. Art. 656.
18. Takagi T, Sugeno M. Fuzzy identification of systems and its applications to modeling and control // *IEEE Transactions on Systems, Man, and Cybernetics*. 1985. Vol. 15, No. 1. P. 116–132.
19. Willmott C.J., Matsuura K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance // *Climate Research*; 2005. Vol. 30, No. 1. P. 79–82.
20. Zadeh L.A. Fuzzy sets // *Information and Control*; 1965. Vol. 8, No. 3. P. 338–353.
21. Zawacki-Richter O, Marín V.I., Bond M., Gouverneur F. Systematic review of research on artificial intelligence applications in higher education – where are the educators? // *International Journal of Educational Technology in Higher Education*; 2019. Vol. 16. Art. 39.
22. Zimmerman B.J. Becoming a Self-Regulated Learner: an overview // *Theory Into Practice*; 2002. Vol. 41, No. 2. P. 64–70.

References

1. Morosanova, V. I., Fomina, T. G., & Tsyganov, I. Yu. (2017). *Osoznannaya samoregulyatsiya i otnoshenie k ucheniyu v dostizhenii uchebnykh tselei* [Conscious self-regulation and attitudes toward learning in achieving educational goals]. Nestor-Istoriya. (In Russian)
2. Sidorenko, E. V. (2000). *Metody matematicheskoi obrabotki v psikhologii* [Methods of mathematical data processing in psychology]. Rech'. (In Russian)
3. Altmann, A., Tološi, L., Sander, O., & Lengauer, T. (2010). Permutation importance: A corrected feature importance measure. *Bioinformatics*, 26(10), 1340–1347. <https://doi.org/10.1093/bioinformatics/btq134>
4. Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
5. Holec, H. (1981). *Autonomy and foreign language learning*. Pergamon Press.
6. Jang, J.-S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685. <https://doi.org/10.1109/21.256541>
7. Jang, J.-S. R., Sun, C.-T., & Mizutani, E. (1997). *Neuro-fuzzy and soft computing: A computational approach to learning and machine intelligence*. Prentice Hall.
8. Kasneci, E., Seßler, K., Küchemann, S., et al. (2023). ChatGPT for good? On opportunities and challenges of large language models for education. *Learning and Individual Differences*, 103, 102274. <https://doi.org/10.1016/j.lindif.2023.102274>
9. Little, D. (2007). Language learner autonomy: Some fundamental considerations revisited. *Innovation in Language Learning and Teaching*, 1(1), 14–29. <https://doi.org/10.2167/illt040.0>
10. Mamdani, E. H., & Assilian, S. (1975). An experiment in linguistic synthesis with a fuzzy logic controller. *International Journal of Man-Machine Studies*, 7(1), 1–13. [https://doi.org/10.1016/S0020-7373\(75\)80002-2](https://doi.org/10.1016/S0020-7373(75)80002-2)
11. Miao, F., & Holmes, W. (2023). Guidance for generative AI in education and research. UNESCO. <https://doi.org/10.54675/EWZM9535>
12. Molnar, C. (2022). *Interpretable machine learning: A guide for making black box models explainable* (2nd ed.). <https://christophm.github.io/interpretable-ml-book/>
13. Ouyang, F., & Jiao, P. (2021). Artificial intelligence in education: The three paradigms. *Computers and Education: Artificial Intelligence*, 2, 100020. <https://doi.org/10.1016/j.caeai.2021.100020>
14. Pedregosa, F., Varoquaux, G., Gramfort, A., et al. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12, 2825–2830.
15. Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). “Why should I trust you?” Explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (KDD '16)* (pp. 1135–1144). ACM. <https://doi.org/10.1145/2939672.2939778>
16. Spearman, C. (1904). The proof and measurement of association between two things. *The American Journal of Psychology*, 15(1), 72–101. <https://doi.org/10.2307/1412159>
17. Susnjak, T., & McIntosh, T. R. (2024). ChatGPT: The end of online exam integrity? *Education Sciences*, 14(6), 656. <https://doi.org/10.3390/educsci14060656>
18. Takagi, T., & Sugeno, M. (1985). Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, 15(1), 116–132. <https://doi.org/10.1109/TSMC.1985.6313399>
19. Willmott, C. J., & Matsuura, K. (2005). Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, 30(1), 79–82. <https://doi.org/10.3354/cr030079>
20. Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
21. Zawacki-Richter, O., Marín, V. I., Bond, M., & Gouverneur, F. (2019). Systematic review of research on artificial intelligence applications in higher education: Where are the educators? *International Journal of Educational Technology in Higher Education*, 16, 39. <https://doi.org/10.1186/s41239-019-0171-0>
22. Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory Into Practice*, 41(2), 64–70. https://doi.org/10.1207/s1543042tip4102_2

СВЕДЕНИЯ ОБ АВТОРАХ

Фоцан Галина Ивановна, канд. экон. наук, доцент, доцент кафедры теоретической экономики Кубанского государственного университета; e-mail: foshan@mail.ru

Литвинский Кирилл Олегович, канд. экон. наук, доцент, заведующий кафедрой экономики и управления инновационными системами Кубанского государственного университета; e-mail: litvinsky@econ.kubsu.ru

Тодовянский Андрей Андреевич, студент экономического факультета Кубанского государственного университета; e-mail: iws.reccolz@gmail.com