

Раннее прогнозирование среднего балла диплома студентов университета: нейросетевой подход

Е. Е. Васильева¹, Д. С. Курушин², С. С. Власов³

Пермский национальный исследовательский политехнический университет

¹VasilevaEE@list.ru, ²dan973@yandex.ru, ³sss203bds07s12345@mail.ru

Аннотация. В исследовании на основе нейросетевого подхода решена задача раннего прогнозирования среднего балла выпускника университета на основе данных об академической успеваемости студентов на втором курсе. Полученные результаты могут быть использованы в управлении образовательным процессом в высшем учебном заведении для повышения его эффективности и подготовки кадров в соответствии с требованиями современной экономики.

Ключевые слова: *средний балл; успеваемость; студенты; университет; нейронная сеть; нейросеть; прогнозирование; социальная система*

Прогнозирование итоговых результатов обучения студентов является одной из наиболее важных задач в управлении образовательным процессом в университете. Раннее прогнозирование результатов обучения позволит эффективно управлять процессом обучения, профессионального развития и дальнейшего трудоустройства успешных студентов и, одновременно, принимать меры по снижению риска потенциально неудовлетворительного результата обучения. Прогнозирование результатов обучения необходимо для предоставления студентам возможных индивидуальных мер поддержки или предложений по корректировке их индивидуальной образовательной траектории.

Актуальность темы подтверждается наличием значительного количества международных научных публикаций. Так, например, в [1] рассматривается возможность кросс-валидного прогнозирования результатов обучения студентов первого курса на основе данных, характеризующих их до начала обучения в университете: результатов обучения в старшей школе, ожиданий, способностей, мотивации и других. В [2] прогнозирование академической успеваемости студентов младших курсов реализовано на основе факторной и регрессионной моделей, входными параметрами которых также являются когнитивные характеристики личности студентов и величины их среднего балла в школе.

Университет представляет собой сложную социальную систему. Задачи прогнозирования процессов, протекающих в таких системах, трудно формализуемы, что связано с проблемой обоснованного выделения в большом объеме информации объективно значимых факторов и выявлением неочевидных взаимосвязей между ними. Применение традиционных инструментов математического

моделирования, таких как метод экстраполяции, корреляционно-регрессионный анализ, метод экспертных оценок, может оказаться невозможным либо низкоэффективными. Современными средствами решения подобных задач являются искусственные нейронные сети (ИНС). Последние исследования позволяют говорить об успешном применении нейронных сетей (НС) для оценивания результатов обучения в университете, например [3], [4], [5], [6].

Задача настоящего исследования: основываясь на данных об академической успеваемости студентов дневного отделения 2 курса прогнозировать их итоговый средний балл при окончании университета.

Методы исследования: системный анализ, нейросетевое моделирование.

В качестве инструмента для достижения поставленной задачи выбран пакет Statistica Neural Networks программы Statistica.

Для исследования использованы данные об академической успеваемости 25 студентов дневного отделения экономического направления подготовки университета. Незначительное количество исследуемых студентов обусловлено особенностями организации учебного процесса. Учебные планы по различным направлениям подготовки отличаются набором изучаемых дисциплин. На каждом направлении обучается от одной до пяти групп студентов. На первом курсе значительную долю изучаемых предметов составляют общеобразовательные дисциплины, и сильное влияние на успеваемость студентов оказывает уровень их школьной подготовки. Начиная со второго курса, в программе обучения значимую роль начинают играть профессионально ориентированные предметы. Таким образом, раннее прогнозирование успешности итогов обучения целесообразно осуществлять по результатам успеваемости за второй курс в разрезе отдельных направлений подготовки, что объективно ограничивает численность попадающих в исследование студентов. Однако, среди современных научных публикаций встречаются описания успешного решения задач методами искусственных нейронных сетей, в которых авторы имели дело с подобными ситуациями ограниченности информации. Так, в работе пермских исследователей [7] рассмотрена ситуация с еще меньшим количеством входных данных, чем в настоящем исследовании.

Исходная база данных представлена на рис. 1.

	S1	S2	NoF	NoA	Gender	AverScore
1	2,67		1	4	1	2
2	3,5	3,6	0	3	1	3,4
3	4,33	4,2	0	4	0	4,4
4	3,83	3,9	0	0	1	3,7
5	3	2,7	0	7	1	2
6	4,17	4,2	0	0	0	4,2
7	3,67	4,6	0	0	0	4,4
8	3,5	3,7	0	0	1	3,7
9	4,17	4,7	0	0	0	4,3
10	4,33	4,7	0	0	0	4,5
11	4,5	4,5	0	3	1	4,5
12	3,17	3,7	3	6	1	3,6
13	5	5	0	0	1	5
14	4,17	3,7	1	0	0	3,7
15	4	4,1	0	0	0	4
16	3,5	3,8	1	1	1	3,6
17	4,33	4	0	1	0	4
18	4,67	4,7	0	0	0	4,7
19	4,17	4,4	0	5	0	4,3
20	4,17	3,8	0	2	0	3,8
21	3,67	3,5	0	1	0	3,4
22	3,67	3,8	0	0	1	3,6
23	3,67	3,1	0	3	0	2
24	5	5	0	0	1	5
25	3,17	2,83	2	5	1	2

Рис. 1. База данных для проведения исследования

В качестве зависимой переменной выступает *AverScore* (*Average Score*) – средний балл диплома.

Независимые переменные: *S1* – средний балл по итогам зимней сессии, *S2* – средний балл по итогам летней сессии, *NoF* (*Numbers of Failures*) – количество неудовлетворительных оценок при сдаче рассматриваемых сессий, *NoA* (*Number of Absences*) – количество неявок на экзамены при сдаче рассматриваемых сессий, *Gender* – пол студента. Значение переменной *Gender* носит бикатегориальный характер, и с учётом ограничения представления данных нейронной сети в виде чисел представляется как 1 – мужской, 0 – женский.

Рассмотрим распределение данных по исследуемым 25 студентам в пространстве среднего балла диплома (*AverScore*) и средних баллов по итогам сессий (*S1*, *S2*) для визуальной оценки зависимости между ними (рис. 2).

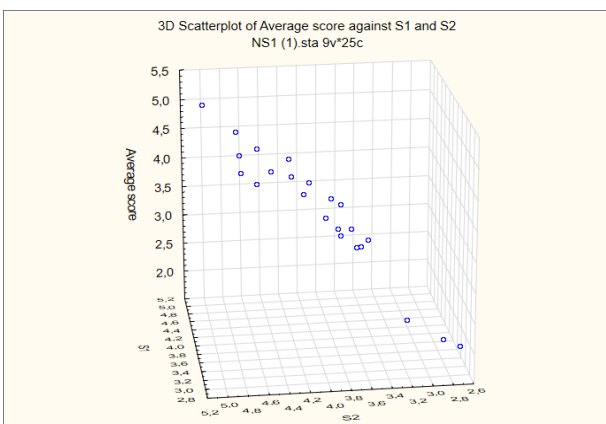


Рис. 2. Диаграмма рассеяния данных в осях средних баллов диплома, зимней и летней сессий

На основе визуальной оценки можно констатировать, что распределение данных не случайное и подчиняется некоторому закону.

Для дальнейшего исследования исходная база данных разделена случайным образом на три подвыборки: обучающую, контрольную и тестовую, которые содержат результаты по 18, 4 и 3 студентам соответственно.

В качестве типа нейронной сети был выбран многослойный перцептрон, качество которого и пригодность для решения поставленной задачи подтверждается исследованиями [8], [9]. Так как не существует единственного алгоритма для определения и теоретического обоснования параметров нейронной сети, мы создали выборку из 25 случайно настроенных нейронных сетей, чтобы, опираясь на их параметры, выделить среди них наиболее удачные. Такой подбор наиболее удачных параметров без приближений представляет собой реализацию известного метода «проб и ошибок». Тестовый подбор ИНС показал, что лучшие из них обладают 7–10 скрытыми нейронами и используют в качестве функции активации гиперболический тангенс, который относится к сигмоидальному виду функции. Результаты тестовых моделей приведены на рис. 3.

Net. name	Training perf.	Test perf.	Validation p...	Algorithm	Error f.
MLP 5-9-1	0.974614	0.999996	0.999752	BFGS 11	SOS
MLP 5-7-1	0.972626	0.995713	0.994293	BFGS 8	SOS
MLP 5-7-1	0.974229	0.999623	0.999854	BFGS 11	SOS
MLP 5-10-1	0.970791	0.958072	0.989254	BFGS 10	SOS
MLP 5-9-1	0.970925	0.998857	0.999838	BFGS 9	SOS

Рис. 3. Результаты тестовых моделей ИНС

Сравним результаты лучшей и худшей из получившихся моделей. На рис. 4 представлена поверхность отклика удачной модели, на рис. 5 – неудачной.

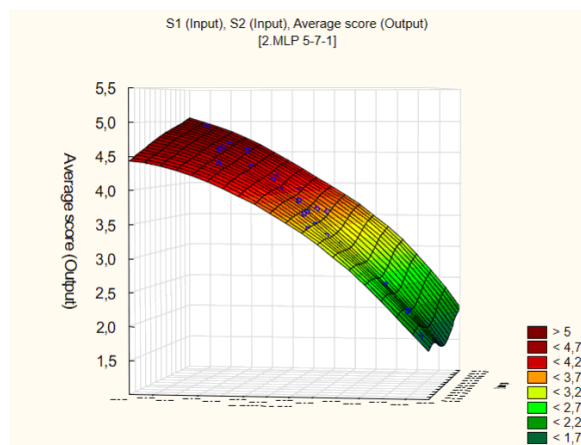


Рис. 4. Поверхность отклика удачной модели

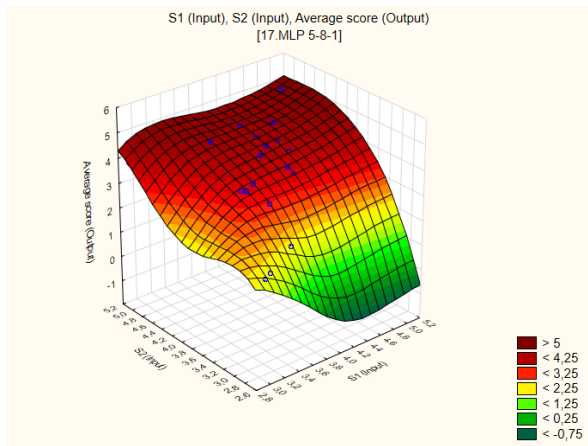


Рис. 5. Поверхность отклика неудачной модели

Поверхность отклика показывает, насколько хорошо нейронные сети распознают зависимость между важными входами, в нашем случае между *S1* и *S2* и выходом *Average score*. К сожалению, объективно никогда нельзя ответить на вопрос, возможно ли смоделировать НС точнее полученных. Если результаты полученной НС приемлемы для исследователя, то потребность в дальнейшем улучшении отпадает. На рис.4 мы видим, что поверхность отклика удачной модели практически полностью соответствует диаграмме рассеяния, что говорит о достаточном уровне распознавания зависимости.

Для решения вопроса о качестве полученной сети рассмотрим локальный (рис. 6) и глобальный (рис. 7) анализы чувствительности. Первый описывает поведение полученных графиков, а второй показывает степень важности входных данных. [10], [11], [12].

Pointwise sensitivity analysis for Average score (NS1 (1).sta) Network: 17.MLP 5-8-1					
Grid points	S1 Sensitivity (true positives)	S2 Sensitivity (true positives)	Number of failures Sensitivity (true positives)	Number of absences Sensitivity (true positives)	Gender Sensitivity (true positives)
Minimum	0.093373	1.050748	-0.102066	-0.005166	4.13995
2	0.107832	2.362919	-0.113174	-0.007107	2.54041
3	0.117477	4.778648	-0.125343	-0.009154	1.33334
4	0.122395	6.752014	-0.138616	-0.011308	0.48616
5	0.123069	5.397657	-0.153016	-0.013579	-0.24003
6	0.120226	2.678914	-0.168548	-0.015982	-1.15071
7	0.114693	1.080092	-0.185192	-0.018829	-2.38460
8	0.107279	0.429238	-0.202896	-0.021234	-3.27219
9	0.098707	0.183539	-0.221574	-0.024111	-2.59019
Maximum	0.089568	0.086870	-0.241100	-0.027174	-0.47567

Рис. 6. Локальный анализ чувствительности

Sensitivity analysis (NS1 (1).sta) Samples: Train, Test, Validation					
Networks	S2	Gender	S1	Number of absences	Number of failures
2.MLP 5-7-1	16.637691	1.15043	1.87656	1.058550	1.056772
5.MLP 5-9-1	17.17476	1.03784	1.54123	1.068547	1.016078
17.MLP 5-8-1	32.40101	36.42547	13.34528	1.920925	0.430566
Average	22.07116	12.87125	5.58769	1.349341	0.834472

Рис. 7. Глобальный анализ чувствительности

Глобальный анализ чувствительности показал, что удачные модели самой важной считают переменную *S2*. Количество пропусков и неудовлетворительных оценок на экзаменах (переменные *NoF*, *NoA*) мало отразились на конечном результате. Это не означает, что зависимости нет, но данное количество наблюдений не позволяет нам объективно оценить влияние этих показателей на средний балл диплома. Такое положение дел в целом соответствует действительности и логически объяснимо: летняя сессия

традиционно считается итоговой за соответствующий курс обучения, когда студенты показывают результат, соответствующий их реальным возможностям обучения. Не показавшие высокой значимости данные в исследовании не отбрасывались. Сеть хорошо справилась с исключением степени влияния этих данных на общий результат.

Оценим точность работы полученных НС на случайной подвыборке из трех человек (рис. 8 и 9)

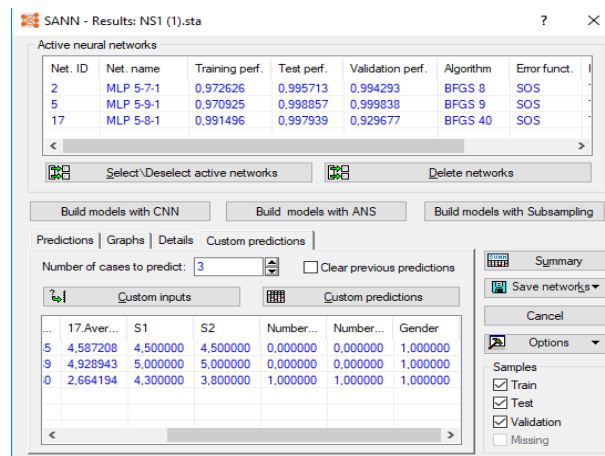


Рис. 8. Вводы

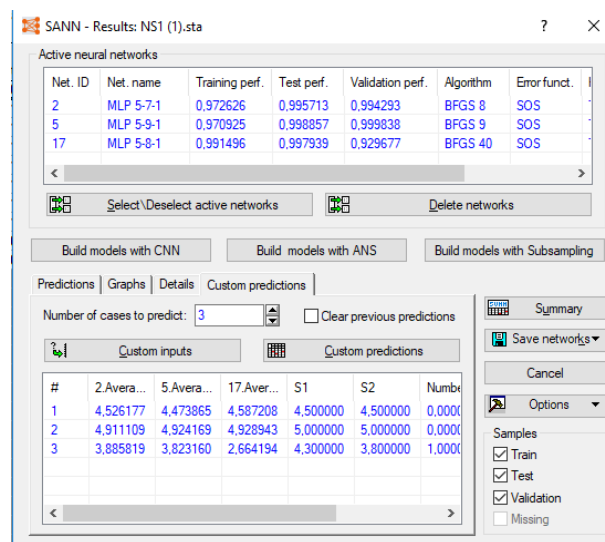


Рис. 9. Выводы

Как видим, лучшие из моделей (модели 2 и 5) хорошо предсказали средний балл диплома. Оценим качество лучшей из моделей по абсолютным остаткам на тестовой подвыборке, найдя показатель относительного отклонения от истинного значения целевой переменной (рис. 10).

Predictions spreadsheet for Average score (NS1 (1).sta) Samples: Test	
Case name	RelativeDev
MEAN case 1-3	0.0152360799

Рис. 10. Среднее значение относительного отклонения

На тестовой подвыборке ошибка лучшей НС составляет полтора процента, что для такой маленькой выборки является отличным результатом.

Характеристики полученной ИНС:

- многослойный перцептрон,
- 7 скрытых нейронов,
- контрольная производительность – 0,994293,
- алгоритм работы НС – BFGS 8,
- функция ошибки – сумма квадратов,
- функция активации скрытых нейронов – гиперболический тангенс,
- функция активации на выходе – тождественная,
- погрешность – в районе полутора процентов.

Испытаем полученную модель ИНС на группе из 15 студентов того же направления текущего года обучения. Полученный результат представлен на рис. 11.

Cases	Custom predictions spreadsheet (NS1 (1).sta)					
	2.Average score (t)	S1	S2	Number of failures	Number of absences	Gender
1	3.879577	4.200000	3.860000	0.000000	0.000000	1.000000
2	4.246567	4.000000	4.280000	0.000000	0.000000	1.000000
3	3.885894	3.600000	4.140000	0.000000	0.000000	0.000000
4	3.914345	3.800000	4.000000	0.000000	0.000000	1.000000
5	3.592536	3.800000	3.710000	0.000000	0.000000	1.000000
6	3.582566	3.800000	3.710000	0.000000	1.000000	1.000000
7	4.060932	3.800000	4.140000	0.000000	0.000000	1.000000
8	4.532050	4.600000	4.570000	0.000000	0.000000	0.000000
9	4.772076	4.800000	4.850000	0.000000	0.000000	0.000000
10	4.200468	4.200000	4.140000	1.000000	0.000000	1.000000
11	2.258995	3.200000	2.850000	1.000000	3.000000	1.000000
12	4.341061	4.200000	4.420000	0.000000	4.000000	0.000000
13	3.161405	3.000000	3.570000	1.000000	1.000000	1.000000
14	2.010295	3.000000	2.710000	1.000000	2.000000	1.000000
15	3.268154	3.800000	3.570000	0.000000	1.000000	0.000000

Рис. 11. Результаты тестирования ИНС

Из полученных выводов видно, что сеть рационально оценила возможности студентов в получении определенного среднего балла. Она прогнозирует несколько результатов с крайне низким средним баллом в районе трёх единиц (*cases: 13, 15*), и также дает два прогноза неудовлетворительной успеваемости для тех, кто не закончит университет, – средний балл ниже трех единиц (*cases: 11, 14*).

Сеть выявлена неявная зависимость между средними баллами в процессе обучения в районе 4,5 баллов и средним баллом диплома (*cases: 8*): несмотря на то, что ничего явным образом не говорит нам об этом, но сеть было определено, что итоговый средний балл будет ниже среднего арифметического балла за экзамены по итогам двух семестров.

Таким образом, несмотря на ограниченность исходных данных, построенная сеть смогла научиться предсказывать рациональные результаты. Возможно, это тот случай, когда сеть нашла зависимость, выявить которую логическим образом невозможно. Этот феномен носит название «интуиция нейронных сетей» [12].

В итоге, поставленная задача решена. Построенная искусственная нейронная сеть демонстрирует возможность раннего прогнозирования среднего бала диплома выпускников университета в условиях ограниченности входных данных. Достигнутые результаты имеют значительную практическую ценность в сфере управления учебным процессом университета и могут быть использованы для повышения его эффективности в целях подготовки кадров, отвечающих требованиям современной экономики.

СПИСОК ЛИТЕРАТУРЫ

- [1] Meijer E., Cleiren M.P.H.D., Dusseldorp E., Buurman V.J.C., Hogervorst R.M., Heiser W.J. Cross-Validated Prediction of Academic Performance of First-Year University Students: Identifying Risk Factors in a Nonselective Environment (Article) // Educational Measurement: Issues and Practice. Volume 38. Issue 1. Spring 2019. Pages 36-47.
- [2] Al-Sheeb Bothaina A., Hamouda A.M., Abdella Galal M. Modeling of student academic achievement in engineering education using cognitive and non-cognitive factors // Journal of Applied Research in Higher Education. 2019.
- [3] Зайцева Т.В., Игрунова С.В., Путивцева Н.П., Пусная О.П., Нестерова Е.В. Использование нейросетевого подхода для оценивания профессиональных компетенций // Научные ведомости БелГУ. Серия История. Политоология. Экономика. Информатика. 2014. №15 (186). Выпуск 31/1. С. 139-146.
- [4] Yagsi A., Cevik M. Prediction of academic achievements of vocational and technical high school (VTS) students in science courses through artificial neural networks (comparison of Turkey and Malaysia) // Education and Information Technologies. 2019.
- [5] Ясницкий Л.Н. Развитие научной школы искусственного интеллекта в пермских университетах: история и научный приоритет (обзорная статья) // Прикладная математика и вопросы управления. 2018. № 4. С. 99-130.
- [6] Арзамасцев А.А., Азарова П.А., Зенкова Н.А. Модель профессиональных и личностных качеств студентов университета на основе искусственной нейронной сети с адаптивной структурой // Вестник Тамбовского университета. Серия: Естественные и технические науки. 2007. №5. С. 633-639.
- [7] Пермское отделение Научного Совета Российской Академии Наук по методологии искусственного интеллекта. Конев С.В., Сичинава З.И., Халлиулин В.Ф., Ясницкий Л.Н. Диагностика неисправностей авиационных двигателей [Электронный ресурс]. – URL: <http://permai.ru/files/projects/P01.pdf>
- [8] Аверин П.И. Вариант решения задачи прогнозирования признаков разрушения металлов с помощью нейронных сетей на основе данных вейвлет-анализа импульсов акустической эмиссии / П.И. Аверин, Н.И. Крайнюков // Вектор науки ТГУ. 2014. №4(18). С. 28-31.
- [9] Лозовой Я.С., Секирин А. И. Решение задачи прогнозирования с помощью нейронных сетей [Электронный ресурс]. – URL: http://www.rusnauka.com/1_NIO_2011/Informatica/78176.doc.htm
- [10] Гусев А.Л. Выбор информационного пространства для построения нейронной сети, как модели управления, в условиях зашумленных и неполных данных // Нейрокомпьютеры: разработка, применение. 2011. № 7. С. 55–57.
- [11] Ясницкий Л.Н., Богданов К.В., Черепанов Ф.М. Технология нейросетевого моделирования и обзор работ пермской научной школы искусственного интеллекта // Фундаментальные исследования. 2013. №1-3. С. 736-740.
- [12] Ясницкий Л.Н. Введение в искусственный интеллект. М.: Академия, 2005. 176 с.