

УДК: 636.85.52: 579.6: 004.032.26
DOI: 10.52419/issn2072-2419.2024.4.239

НЕЙРОСЕТЕВОЙ АНАЛИЗ КАЧЕСТВА СИЛОСОВАННЫХ КОРМОВ ПО ИНДЕКСУ БИОКОНСОЛИДАЦИИ БИОСИСТЕМЫ МОЛОЧНОКИСЛЫХ БАКТЕРИЙ

Воробьев Н.И.^{1,2} – канд. технических наук, вед. научн. сотр., ст. научн. сотр. (ORCID 0000-0001-8300-2287); **Ильина Л.А.**³ – д-р биол. наук, рук. молекулярно-генетической лаборатории (ORCID 0000-0003-2490-6942); **Лаптев Г.Ю.**³ – д-р биол. наук, директор (ORCID 0000-0002-8795-6659); **Селина М.В.**^{1*} – канд. пед. наук, доц. каф. экономики и цифровых технологий в АПК (ORCID 0000-0001-8201-1042); **Гусельникова А.А.**¹ – нач. отдела организации и мониторинга НИД (ORCID 0000-0003-0284-5253)

¹ФГБОУ ВО «Московская государственная академия ветеринарной медицины и биотехнологии - МВА имени К.И. Скрябина»

²ФГБНУ ВНИИ сельскохозяйственной микробиологии

³ООО «Биотроф»

*selina.marina@gmail.com

Ключевые слова: фрактальный профиль микрофлоры силоса, силосные закваски и консерванты, индексы газообразования и молочной кислоты, нейросеть.


Key words: fractal profile of silage microflora, silage inoculants and preservatives, gas and lactic acid indices, neural network.

Финансирование: Материалы подготовлены в рамках конкурса Российского научного фонда 2022 года «Проведение фундаментальных научных исследований и поисковых научных исследований малыми отдельными научными группами» (соглашение № 23-26-00234 от 12.01.2023 г.) <https://rscf.ru/project/23-26-00234>

Поступила: 17.10.2024

Принята к публикации: 02.12.2024

Опубликована онлайн: 16.12.2024



РЕФЕРАТ

В данном исследовании с помощью оригинальной нейросетевой информационной технологии удалось провести интеллектуальный анализ молекулярно-генетических данных

микрофлоры силоса и оценить влияние силосных заквасок и консервантов на направленность микробиологических биохимических процессов в силосных биомассах. Выходным продуктом интеллектуального анализа фрактальных профилей микрофлоры силоса стали индексы CSIgaZ и CSIImU, выбранные для количественного представления с точки зрения микробиологических данных интенсивности газовыделений силоса и количества молочной и уксусной кислот в силосе. По индексу CSIImU удалось оценить возростание молочной кислоты и уменьшение уксусной кислоты в силосе, что сигнализирует о замедлении развития гнилостных микроорганизмов в силосе, а по индексу CSIgaZ –

уменьшение газовыделений силоса, что свидетельствует об благоприятных анаэробных условиях, в которых протекают микробиологические биохимические процессы в силосе. Проведенный в молекулярно-генетической лаборатории ООО «Биотроф» лабораторный опыт по силосованию ежи сборной показал, что «Биотроф-111» (на основе *Bacillus subtilis*, произв. ООО «Биотроф») создает наилучшие анаэробные условия в силосуемой растительной биомассе, при которых микрофлора силоса биоконсолидируется в биосистему молочнокислых бактерий с минимальным значением индекса $CSI_{GaZ} = 3,1$ и максимальным значением индекса $CSI_{mU} = 6,8$, то есть в этом варианте силосования ежи сборной микрофлоре силоса удастся сгруппироваться так, что одновременно обеспечивается относительно низкая интенсивность газовыделений силоса, ускоренное образование молочной кислоты и замедленное образование уксусной кислоты в силосе, а значит в этих условиях процессы завершатся с наилучшими качественными питательными показателями силоса.

ВВЕДЕНИЕ/ INTRODUCTION

Качество заготовленного силоса зависит от интенсивности процессов анаэробного молочнокислого брожения, от pH силосованной массы и от ингибирования в анаэробных условиях развития вредных гнилостных микроорганизмов, плесневых грибов и дрожжей, то есть ингибирования путем ограничения поступления атмосферного кислорода в растительную биомассу [1]. Для интенсификации процессов анаэробного брожения применяются силосные закваски, содержащие молочнокислые бактерии и антимикробные пептиды [2, 3]. Ведущей культурой заквасок остаются молочнокислые бактерии, синтезирующие органические кислоты и способствующие поддержанию на высоком уровне качественных и количественных, биохимических и питательных характеристик силоса [4]. В итоге, все технологические и биологические агроприемы при силосовании направляются на создание благоприятных условий для развития молочнокислых бактерий и неблагоприятных условий для развития маслянокислых, уксуснокислых, гнилостных бактерий и дрожжей.

При силосовании и консервировании растительных субстратов в кормопроизводстве используются следующие микробиологические препараты: «Биотроф 600» на основе *Lactobacillus plantarum*; «Биотроф 700» на основе *Lactobacillus buchneri*; «Биотроф-AC» на основе *Lactobacillus plantarum* и *Lactobacillus buchneri*; «Биотроф-111» на основе *Bacillus subtilis* (произв. ООО «Биотроф») [5-7];

«Christian Hansen» на основе культур молочнокислых бактерий (произв. компания CHR HANSEN, Дания) [8]. В качестве растительного сырья для силосования используются бобово-злаковые смеси, козлятник восточный, клевер, люцерна, кукуруза [9-11]. Для заготовки силоса, сенажа и консервирования плющеного фуражного зерна применяются также химические консерванты, например, «AIV» (произв. «Taminco Finland OY»), содержащий смесь муравьиной, пропионовой, бензойной органических кислот [7].

Готовность и качество силосной биомассы оценивают по количеству маслянокислых бактерий и других бактерий, вызывающих гнилостные процессы в силосе, по потерям питательных веществ в биомассе силоса и по содержанию в нем микотоксинов [12]. Косвенными показателями качества силоса являются отношение количества молочной кислоты к количеству уксусной кислоты в биомассе силоса и объем газов, выделенных при силосовании [13, 14]. Из этого следует, измеряя состав микрофлоры силоса и количество органических кислот, синтезированных микроорганизмами при силосовании, можно косвенным образом оценить качество силосования растительных субстратов.

Исследования микробиоценоза силоса, проведенные молекулярно-генетическим NGS методом, продемонстрировали расширенное генотипическое разнообразие микрофлоры силоса, насчитывающее тысячи оперативно таксономических единиц

(ОТЕ) [15, 16]. Обнаружение большого количества ОТЕ в силосе значительно осложнило исследование зависимости качества силоса от состава его микрофлоры и от биоконсолидации микроорганизмов в биосистему молочнокислых бактерий. Кроме этого, молекулярно-генетические данные силоса (ед. измер.: шт. ОТЕ в г высушенного силоса), количество в силосе молочной и уксусной органических кислот (ед. измер.: процентное содержание в силосе органических кислот) и количество выделяемых газов являются цифровыми данными разнородных биологических и биохимических объектов: микрофлоры силоса и физико-биохимических продуктов метаболизма микроорганизмов. Поэтому для изучения взаимосвязи этих разнородных характеристик силосования мы были вынуждены применить интеллектуальный нейросетевой анализ данных – вычислительную нейронную сеть [17-19]. Нейросетевая обработка молекулярно-генетических данных микрофлоры силоса позволила нам провести сравнение силосных заквасок и консервантов, используя значения специальных безразмерных индексов, характеризующих интенсивность накопления в силосе молочной и уксусной кислот, а также интенсивность выделения газов силосными биомассами [20]. Целью исследования являлся интеллектуальный нейросетевой анализ фрактальных молекулярно-генетических профилей микрофлоры силоса и оценка по результатам анализа влияния биопрепаратов на биоконсолидацию микрофлоры силоса в биосистему молочнокислых бактерий и на интенсивность разложения растительных субстратов с выделением молочной и уксусных кислот, характеризующих качество готового силоса. При этом предполагалось, что сравнение эффективности биопрепаратов для силосования будет проведено по индексу газовыделений силоса и по индексу молочно-уксусного соотношения органических кислот, которые предполагается вычислять, используя только молекулярно-генетические данные микрофлоры силоса.

МАТЕРИАЛЫ И МЕТОДЫ / MATERIALS AND METHODS

Фрактальный профиль ОТЕ

При биоконсолидации микроорганизмов в биосистемы интенсивность биохимических процессов в силосе может значительно возрасть [21-23], так как в биосистемах микроорганизмы выполняют биохимические операции организованно и по наиболее экономичным и производительным биохимическим схемам. В биосистемах микроорганизмы концентрируются в одном направлении и сосредоточены на предварительном разложении растительных субстратов с накоплением в силосе молочной органической кислоты. Образованная биосистема молочнокислых бактерий дополнительно должна характеризоваться замедленным образованием уксусной органической кислоты и низкой интенсивностью выделения силосной биомассой сопутствующих газов, так как снижение интенсивности этих процессов повышает качество силоса. Для оценки общей целевой настроенности биосистемы молочнокислых бактерий на высококачественный силос мы решили использовать фрактальный профиль ОТЕ и исследовать особенности его формы в различных вариантах проведенного опыта [24].

Фрактальные профили микроорганизмов можно составить из частот ОТЕ, определенных молекулярно-генетическим методом [25]. Фрактальный профиль ОТЕ формируется расстановкой частот ОТЕ в монотонно убывающий числовой ряд (рис. 1). Среди возможных форм фрактальных профилей ОТЕ силоса выделяется особая идеальная степенная форма, соответствующая геометрическому цифровому ряду (например ряду: 0.1, 0.01, 0.001,...) [26]. Мы выбрали идеальный фрактальный профиль ОТЕ в качестве опорного базиса, относительно которого рассчитывается величина отклонения фактических фрактальных профилей ОТЕ, а по вычисленному отклонению – уровень биоконсолидации микроорганизмов в биосистему молочнокислых бактерий.




Рисунок 1 – Фрактальный профиль ОТЕ. По Y-оси отложены значения $\ln(10^4 \cdot f_k)$.

f_k , k – частота встречаемости ОТЕ и порядковый номер позиции ОТЕ во фрактальном профиле. Пунктирная линия представляет идеальный степенной фрактальный профиль ОТЕ.




Рисунок 2 – Нейросеть, обрабатывающая фрактальные профили ОТЕ силоса и вычисляющая индексы CSigaZ и CSImU. FPro, FwI – матрица фрактальных профилей ОТЕ и матрица WaveLet-преобразованных данных матрицы FPro. FNorm, CNorm – матрицы нормализованных данных матрицы FwI и произведения матриц FNorm $\times$ Corr. Corr – матрица коэффициентов корреляции между столбцами матрицы FNorm. FDist, CDist – матрицы евклидовых расстояний между столбцами матриц FNorm, CNorm. FCom, CCom – матрицы собственных векторов матриц FDist, CDist. Learning – цикл обучения-поиска корректного алгоритма нейросети. Comby – база алгоритмов нейросети. FBio – матрица опытных данных по выделению газов и образованию молочной и уксусной кислот при силосовании.

Нейросетевые вычисления

В качестве цифровых индикаторов уровня биоконсолидации микроорганизмов силоса в биосистему молочнокислых бактерий нами были выбраны индексы когнитивной значимости цифровых данных CSigaZ = 0...10 б/р и CSImU = 0...10 б/р (Cognitive Saliency Index) [27, 28]. При этом предполагается, что индекс CSigaZ количественно будет представлять интенсивность газовыделений при силосовании, а индекс CSImU – величину отношения количества молочной кислоты к количеству уксусной кислоты в силосе. Нейросеть (рис. 2) запрограммирована вычислять значения индексов CSigaZ и CSImU только по отклонению фактического фрактального профиля микрофлоры силоса от идеальной формы. Для этого в нейросети предполагается использовать процедуры регрессионного, корреляционного, кластерного и дискриминантного статистических анализов [29, 30]. Дополнительно в нейросети на программном уровне организован доступ к сервису обучения-поиска алгоритма нейросети Learning, который позволяет изменять алгоритм вычисления индексов CSigaZ и CSImU и осуществлять циклический поиск корректного алгоритма вычисления этих индексов [31-34].

1 этап. Слой нейронов L1 упорядочивает частоты ОТЕ во фрактальных профилях (матрица FPro) и преобразует данные матрицы FPro по формуле (1) в данные матрицы FwI.

$$FwI_{k,l} = \ln(FPro_{k,l} \cdot 10^4) - \ln(FPro_{k+1,l} \cdot 10^4), \quad (1)$$

где $\sum_{k=1}^N FPro_{k,l} = 1$; $FPro_{k,l}$ – частоты встречаемости ОТЕ, записанные в матрицу FPro; $k=1, \dots, N-1$; $l=1, \dots, M$ – порядковые номера строк и столбцов в матрице FPro; N, M – число ОТЕ во фрактальном профиле и число вариантов опыта.

2 этап. Слой нейронов L1 нормализует цифровые данные матрицы FwI с помощью стандартной функции нормализации числовых данных *Normalization ()* [35] и записывает результаты нормализации в матрицу FNorm.

$$FNorm = Normalization(Fwl) \quad (2)$$

3 этап. Слой нейронов L1 вычисляет корреляционную матрицу Corr, используя данные в строках матрицы FNorm и стандартную процедуру *Correlation()* [36].

$$Corr = Corralation(FNorm) \quad (3)$$

4 этап. Слой нейронов L1 вычисляет произведение матриц FNorm×Corr, нормализует полученные цифровые данные стандартной процедурой *Normalization()* и записывает результаты нормализации в матрицу CNorm.

$$CNorm = Normalization(FNorm \times Corr).$$

(4)

5 этап. Слой нейронов L2 вычисляет матрицы Евклидовых расстояний FDist и CDist, используя цифровые данные столбцов матриц FNorm и CNorm, и стандартную вычислительную процедуру *Euclid-Distance()* [37].

$$FDist_{kl} = EuclidDistance(FNorm_{1k}, \dots, FNorm_{Nk}; FNorm_{1l}, \dots, FNorm_{Nl}),$$

(5)

$$CDist_{kl} = EuclidDistance(CNorm_{1k}, \dots, CNorm_{Nk}; CNorm_{1l}, \dots, CNorm_{Nl}),$$

(6)

где $k, l = 1, \dots, M$ – порядковые номера столбцов в матрицах FNorm и CNorm; M, N – число столбцов и строк в матрицах FNorm и CNorm.

6 этап. Слой нейронов L2 вычисляет матрицы FCom и CCom, используя данные матриц FDist, CDist и стандартную процедуру вычисления собственных векторов симметричных матриц *EigenVectors()* [38].

$$FCom = EigenVectors(FDist), \quad (7)$$

$$CCom = EigenVectors(CDist). \quad (8)$$

7 этап. Слой нейронов L3 вычисляет значение индекса CSIgaZ и CSImU после выбора алгоритма из базы алгоритмов Comby в цикле обучения-поиска нейросети Learning. Вычислительные алгоритмы в базе алгоритмов Comby представляют собой алгебраические выражения с операциями сложения, вычитания, умноже-

ния и деления и данными матриц FNorm, CNorm, FDist, CDist, FCom, CCom в разной комбинации.

8 этап. Слой нейронов L4 анализирует в каждом цикле настройки-обучения нейросети Learning корреляцию (r) индексов CSIgaZ и CSImU с данными матрицы Fbio. Если корреляция этих индексов не удовлетворяет условию $Abs(r) \geq 0.7$, то выбор алгоритма из базы Comby продолжается, а при удовлетворении условия $Abs(r) \geq 0.7$ настройка-обучение нейросети заканчивается и вычисленные значения индексов CSIgaZ и CSImU принимаются, как корректные.

РЕЗУЛЬТАТЫ / RESULTS

Микробиологические и биохимические данные силосования

В лабораторном опыте, проведенном в молекулярно-генетической лаборатории ООО «Биотроф» [39], были получены микробиологические и биохимические данные (табл. 1, 2) силосованной растительной массы ежи сборной с биопрепаратами: «Биотроф 600» на основе *Lactobacillus plantarum*; «Биотроф-111» на основе *Bacillus subtilis* (произв. ООО «Биотроф»); «Christian Hansen» на основе культур молочнокислых бактерий (произв. компания CHR HANSEN, Дания), а также с химическим консервантом «AIV» (произв. «Taminco Finland OY», содержащим смесь муравьиной, пропионовой, бензойной кислот).

На оборудовании лаборатории ООО «Биотроф» были измерены и построены фрактальные профили ОТЕ (табл. 1), соответствующие образцам силоса:

Образец силоса в начале силосования и без заквасок;

Образец силоса на 32 сутки силосования и без заквасок;

Образец силоса на 32 сутки силосования с консервантом AIV;

Образец силоса на 32 сутки силосования с закваской Биотроф-111;

Образец силоса на 32 сутки силосования с закваской Биотроф-600;

Образец силоса на 32 сутки силосования с закваской Christian Hansen.

Фрактальные профили ОТЕ и физико-биохимические данные образцов силоса представлены в таблице 1.

Рассчитанные нейросетью значения индексов CSIgaZ и CSImU представлены в таблице 1 и на рисунке 3.

Среди исследованных заквасок «Биотроф-111» (на основе *Bacillus subtilis*, произв. ООО «Биотроф») выделяется созданием наилучших анаэробных условий в силосуемой растительной биомассе, при которых микрофлора силоса биоконсолидируется в биосистему молочнокислых бактерий с минимальным значением

индекса CSIgaZ = 3,1 (табл. 1, рис. 3) и максимальным значением индекса CSImU = 6,8 (табл. 1, рис. 3), то есть в этом варианте силосования ежи сборной микрофлоре силоса удастся сгруппироваться так, что одновременно обеспечивается относительно низкая интенсивность газовойывделений силоса, ускоренное образование молочной кислоты и замедленное образование уксусной кислоты в силосе. В остальных вариантах опыта такое соотношение газовойывделений и образования органических кислот не наблюдается.

Таблица 1 – Фрактальные профили ОТЕ (частота ОТЕ в %) и соответствующие им данные газовойывделения силоса (объемные %), отношения молочной кислоты к уксусной кислоте в силосе (б/р) и значения индексов CSIgaZ и CSImU (б/р)

№ ОТЕ	Номера образцов силоса					
	1	2	3	4	5	6
1	32,4	34,4	33,4	34,3	39,7	54,7
2	12,6	20,4	23,0	20,7	16,9	8,03
3	9,03	9,86	15,1	6,70	6,65	6,73
4	6,71	7,90	4,75	3,91	3,88	6,10
5	5,50	5,14	4,13	3,13	3,66	3,53
6	5,04	3,09	2,62	2,91	3,42	2,69
7	3,82	2,61	2,50	2,79	3,18	2,40
8	3,41	2,07	2,19	2,60	2,99	2,15
9	3,23	1,92	1,85	2,41	2,63	2,00
10	2,86	1,66	1,44	2,28	2,44	1,54
11	2,28	1,63	1,38	1,99	1,94	1,40
12	2,06	1,42	1,15	1,82	1,72	1,17
13	1,76	1,36	1,06	1,72	1,60	1,04
14	1,56	1,27	0,88	1,66	1,50	0,94
15	1,39	0,97	0,78	1,58	1,38	0,90
16	1,19	0,76	0,68	1,50	1,20	0,86
17	1,10	0,73	0,61	1,43	1,10	0,81
18	0,96	0,56	0,53	1,31	1,02	0,69
19	0,89	0,52	0,43	1,20	0,78	0,60
20	0,76	0,50	0,41	1,14	0,72	0,48
21	0,57	0,46	0,39	1,06	0,59	0,45
22	0,49	0,39	0,38	0,99	0,55	0,41
23	0,39	0,37	0,29	0,86	0,46	0,38
Газовойывделение	0	52,38	29,72	11,27	42	33
Отношение кислот	0	8,7	4,3	11,1	1,4	4,3
CSIgaZ	2,5	6,9	5,2	3,1	7,4	4,9
CSImU	3,1	7,4	5,3	6,8	2,5	4,9




Рисунок 3 – Значения индексов CSIgZ и CSImU, представляющих количественно интенсивность газовыделения при силосовании растительных биомасс и отношение количества молочной кислоты в силосе к количеству уксусной кислоты. Номера столбиков соответствуют номерам образцов силоса (табл. 1).

Индексы на старте процессов силосования без заквасок не равны нулю (CSIgZ = 2,5, CSImU = 3,1, табл. 1, рис. 3), а на 30-е сутки силосования достигают значительно больших величин (CSIgZ = 6,9, CSImU = 7,4, табл. 1, рис. 3). Это означает, что микрофлора силоса затрачивает определенное время на самоорганизацию биосистемы молочнокислых бактерий и это удлиняет время приготовления силоса. Применение же закваски «Биотроф-111» сокращает стартовый период самоорганизации биосистемы молочнокислых бактерий, а значит силосование растительной биомассы с закваской будет происходить не хаотично, а с самого начала будет происходить строго под контролем биосистемных микроорганизмов.

ВЫВОДЫ / CONCLUSION

С помощью информационной технологии, использующей нейросеть, удалось провести интеллектуальный анализ [40] влияния силосных заквасок и консерваторов на направленность микробиологических биохимических процессов в силосных биомассах. Интеллектуальный нейросетевой анализ фрактальных профилей микрофлоры силоса выявил не только биоконсолидацию силосной микрофлоры

в биосистему, возглавляемую молочнокислыми бактериями, но и определил наилучшую закваску, которая направляет биохимические процессы на наилучшие качественные и количественные показатели приготовленного силоса. Таким образом, микробиологическое сопровождение анаэробного брожения силосной растительной биомассы закваской «Биотроф-111» обеспечивает созревание силоса с наилучшими качественными и количественными показателями [5, 6].

NEURAL NETWORK ANALYSIS OF SILAGE FORAGE QUALITY BASED ON THE BIOCONSOLIDATION INDEX OF LACTIC ACID BACTERIA BIOSYSTEMS

Vorobyov N.I.^{1,2} – Candidate of Technical Sciences, Lead Researcher, Senior Lecturer, (ORCID 0000-0001-8300-2287); **Ilyina L.A.**³ – Doctor of Biological Sciences, Head of Molecular Genetic Laboratory (ORCID 0000-0003-2490-6942); **Laptev G.Y.**³ – Doctor of Biological Sciences, Director (ORCID 0000-0002-8795-6659); **Selina M.V.**^{1*} – Candidate of Pedagogical Sciences, Associate Professor of the Department of Economics and Digital Technologies in the AIC1 (ORCID 0000-0001-8201-1042); **Guselnikova A.A.**¹ – Head of the Department of Organization and Monitoring of Scientific and Research Information (ORCID 0000-0003-0284-5253)

¹Moscow Veterinary Academy

²All-Russia Research Institute for Agricultural Microbiology

³LLC 'Biotrof'

* Selina.marina@@gmail.com

Financing: The materials were prepared within the framework of the 2022 Russian Science Foundation competition "Conducting fundamental scientific research and exploratory scientific research by small individual scientific groups" (agreement No. 23-26-00234 dated 12.01.2023) <https://rscf.ru/project/23-26-00234>

ABSTRACT

In this study, using the original neural

network information technology, it was possible to perform an intelligent analysis of molecular genetic data of silage microflora and evaluate the influence of silage starters and preservatives on the directionality of microbiological biochemical processes in silage biomass. The output product of the intelligent analysis of fractal profiles of silage microflora was the CSIgaZ and CSIImU indices, chosen to represent quantitatively, in terms of microbiological data, the intensity of silage outgassing and the amount of lactic and acetic acids in silage. According to the CSIImU index it was possible to evaluate the increase of lactic acid and decrease of acetic acid in silage, which signals the slowing down of development of putrefactive microorganisms in silage, and according to the CSIgaZ index - the decrease of silage gas emissions, which indicates favourable anaerobic conditions in which microbiological biochemical processes in silage take place. The laboratory experiment on silage of hedgehog silage conducted in the molecular genetic laboratory of 'Biotrof' Ltd. showed that 'Biotrof-111' (based on *Bacillus subtilis*, produced by 'Biotrof' Ltd.) creates the best anaerobic conditions in the silaged plant biomass, where the microflora of silage bioconsolidates in the biosystem of lactic acid bacteria. LLC 'Biotrof' creates the best anaerobic conditions in the silage plant biomass, in which the silage microflora bioconsolidates into a biosystem of lactic acid bacteria with a minimum value of CSIgaZ index = 3.1 and a maximum value of CSIImU index = 6.8, that is, in this variant of silage hedgehog silage microflora of silage manages to group in such a way, that simultaneously provides a relatively low intensity of silage gas emissions, accelerated formation of lactic acid and slow formation of acetic acid in silage, and thus in these conditions the processes will be completed with the best quality nutritional indicators of silage.

СПИСОК ИСТОЧНИКОВ

- 1.Зенькова Н.Н. Практическое руководство по использованию кормовых ресурсов в кормопроизводстве: практическое руководство / Зенькова Н.Н., Ганущенко О.Ф.; Шлома Т.М.; Ковалева И.В. // Витебск: ВГАВМ. 2021. 176 с.
- 2.Лаптев Г.Ю.Закваска Промилк обеспечивает качество силоса и зерносенажа / Лаптев Г.Ю., Йылдырым Е.А., Ильина Л.А., Новикова Н.И., Тюрина Д.Г., Маркман И.Л. // Животноводство России. №4. 2023. С. 50-55.
- 3.Лаптев Г.Ю. Предотвращаем вторичную ферментацию и аэробную порчу силоса / Йылдырым Е.А., Тюрина Д.Г., Новикова Н.И., Ильина Л.А., Черватенко Д.Ю. // Животноводство России. №4. 2024. С. 52-54.
- 4.Лаптев Г.Ю. Эффективность препарата «Биотроф-600» для борьбы с нежелательной микрофлорой при хранении плющеного зерна. / Сб. «Актуальные проблемы заготовки, хранения и рационального использования кормов» международной научно-практической конференции, посвященной 100-летию со дня рождения доктора сельскохозяйственных наук, профессора С.Я. Зафрена // М.: 2009. С. 41-45.
- 5.Йылдырым Е.А, Биотроф-111: все возможное делает сразу / Йылдырым Е.А., Тюрина Д.Г. // Животноводство России. 2021. №4. С. 48-51
- 6.Победнов Ю.А. Эффективность силосования кукурузы и трав с препаратом Биотроф 111 (рекомендации) / Победнов Ю.А., Мамаев А.А., Худокормов В.В., Шукин Н.Н., Горькин А.М., Бородуля В.И., Лаптев Г.Ю., Солдатов В.В. // М.: ФГУ РЦСК, 2010. 17 с.
- 7.Биконя С.Н. Повышение питательной ценности силоса и сенажа с использованием биоконсервантов / Дисс. канд. с.-х. наук // Волгоград: Волгоградский ГАУ. 2023. 128 с.
- 8.Chagarovskii V., Chagarovskii A. Study of the biological activity of direct ferments of the Christian Hansen company used in the production of lactic acid milk products/ Ukraine Mikrobiolohichnyi Zhurnal . 2003. 5(1): 78 – 83.
- 9.Driehuis F. Fermentation characteristics and aerobic stability of grass silage inoculated with *Lactobacillus buchneri*, with or without homofermentative lactic acid bacteria/

- Driehuis F., Oude Elferink S.J.W.H., Van Wikselaar P.G. // *Grass Forage Sci.*, 2001, 56(4): 330-343 (doi: 10.1046/j.1365-2494.2001.00282.x).
10. Tabacco E. Dry matter and nutritional losses during aerobic deterioration of corn and sorghum silages as influenced by different lactic acid bacteria inocula / Tabacco E., Righi F., Quarantelli A., Borreani G. // *J. Dairy Sci.*, 2011, 94: 1409-1419 (doi: 10.3168/jds.2010-3538).
11. Rigy E. Ensiling alfalfa with hydrolyzed corn meal additive and bacterial inoculant / Rigy E., Zsédely E., Tóth T., Schmidt J. // *Acta Agronomica Óvariensis*, 2011, 53(2): 15-23.
12. Лаптев Г.Ю. Анализ накопления микотоксинов в кормовом растительном сырье и силосе / Лаптев Г.Ю., Новикова Н.И., Дубровина Е.Г., Ильина Л.А., Йылдырым Е.А., Никонов И.Н., Филиппова В.А., Бражник Е.А. // *Кормопроизводство*. 2014. №10. с. 36-39.
13. Победнов Ю.А., Косолапов В.М. Биологические основы силосования люцерны с препаратами молочнокислых бактерий (обзор) / *Сельскохозяйственная биология*. 2018. Т. 53, № 2. С. 258-269.
14. Осипян Б.А., Мамаев А.А. Эффективность применения препаратов «Биотроф 600» и «Биотроф 700» при силосовании обеспеченного сахаром растительного сырья / *Кормопроизводство*. 2014. № 11. С. 35-39.
15. Нетрусов А.И., Бонч-Осмоловская Е.А., Горленко В.М. Экология микроорганизмов / М.: Академия, 2004. 272 с.
16. Чубенко Г.И. Методы идентификации бактерий: метод. пособие / Благовещенск: Амурская ГМА, 2018. 44 с.
17. Гафаров Ф.М., Галимянов А.Ф. Искусственные нейронные сети и приложения: учеб. пособие. – Казань: Изд-во Казан. ун-та, 2018. 121 с.
18. Круглов В.В., Борисов В.В. Искусственные нейронные сети. Теория и практика / М.: Горячая линия Телком, 2002. 382 с.
19. Воробьев Н.И., Селина М.В., Гусельникова А.А. Нейросетевая программа анализа состояния микробиоты животных / Свидетельство государственной регистрации программы для ЭВМ № 2024614895 от 29.02.2024 Заявка МВА имени К.И. Скрябина № 2024613194 от 16.02.2024.
20. Witten I.H., Frank E., Hall M.A., Kaufmann M. *Data Mining: Practical Machine Learning Tools and Techniques*. 3rd ed. / Witten I.H., Frank E., Hall M.A., Kaufmann M. // Elsevier, 2011. 629 p.
21. Ben-Jacob E. Bacterial self-organization: coenhancement of complexification and adaptability in a dynamic environment / *Phil. Trans. R. Soc. Lond. A*. 2003. 361: 1283-1312.
22. Young I.M., Crawford J.W. Interactions and self-organization in the soil-microbe complex / *Science*, 2004, 304(5677): 1634-1637.
23. Crawford J.W., Deacon L., Grinev D., Harris J.A., Ritz K., Singh B.K., Young I. Microbial diversity affects self-organization of the soil-microbe system with consequences for function / *Journal of the Royal Society Interface*. 2012, 9(71): 1302-1310.
24. Воробьев Н.И. Биосистемная самоорганизация и фрактальная структура частотно-таксономических профилей микробиоты кишечника бройлеров под влиянием кормовых пробиотиков / Воробьев Н.И., Егоров И.А., Кочиш И.И., Никонов И.Н., Ленкова Т.Н. // *Сельскохозяйственная биология*. 2021. 56(2): 400-410.
25. Кочиш И.И. Нейросетевое моделирование фрактальной самоорганизации микробно-организменных биосистем в кишечниках птиц / Кочиш И.И., Воробьев Н.И., Никонов И.Н., Селина М.В. // *Ветеринария и Зоотехния*. 2022. №12. С. 57-65.
26. Manfred Schroeder. *Fractals, Chaos, Power Laws: Minutes from an Infinite Paradise* / NY: 2009. Dover Publications. 448 p.
27. Sutrop U. List Task and a Cognitive Salience Index / *Field methods*. 2001. V. 13(3). P. 263-276.
28. Загоруйко Н.Г. Когнитивный анализ данных / Новосибирск: Академическое изд-во ГЕО. 2013. 183 с.
29. Ким Дж.-О. Факторный, дискриминантный и кластерный анализ/ Ким Дж.-

- О., Мюллер Ч.У., Клекка У.Р., Олдендерфер М.С., Блэшфилд Р.К. // М., 1989. 216 с.
30. Заикина А.С. Нейросетевой анализ соответствия микробно-организменной биосистемы кишечника бройлеровы фрактально-стохастической модели / Заикина А.С., Буряков Н.П., Воробьев Н.И., Никонов И.Н. // Пермский аграрный вестник, № 4(40). 2022. С. 98-106.
31. Jürgen Schmidhuber. Deep learning in neural networks: an overview / Neural Netw. 2015. Jan:61:85-117 (doi: 10.1016/j.neunet.2014.09.003)
32. Погодаев А.К. Применение нейросетевых моделей для построения продукционных правил экспертных систем / Погодаев А.К., Хабибуллина Е.Л., Инютин Д.М. // Прикладная математика и вопросы управления. 2021. № 2. С. 73-92.
33. Кулаков К.А., Димитров В.М. Основы тестирования программного обеспечения / Петрозаводск: Издательство ПетрГУ, 2018. 57 с.
34. Widrow, Bernard; et al. The no-prop algorithm: A new learning algorithm for multilayer neural networks / Neural Networks. 2013. 37. 182–188.
35. Mascarenhas, WF. Fast and accurate normalization of vectors and quaternions / Comp. Appl. Math. 2018. 37, 4649–4660.
36. Nikolić, D. Scaled correlation analysis: a better way to compute a cross-correlogram / Nikolić, D; Muresan, RC; Feng, W; Singer, W. // European Journal of Neuroscience. 2012. 35(5). 1–21.
37. Everitt, BS. Cluster Analysis / Everitt, BS, Landau S, Leese M, Stahl D. // John Wiley & Sons, 2011. 352 p.
38. Маркова Л.В., Корчевская Е.А. Численные методы нахождения собственных векторов и собственных значений матриц / Витебск: УО «ВГУ им. П. М. Машерова», 2011. 47 с.
39. Ёылдырым Е.А. Изучение эпифитной микрофлоры как источника формирования микробиоценоза силоса методом NGS-секвенирования / Ёылдырым Е.А., Лаптев Г.Ю., Ильина Л.А., Никонов И.Н., Филиппова В.А., Солдатова В.В., Бражник Е.А., Новикова Н.И., Гагкаева Т.Ю. // Сельскохозяйственная биология. 2015. Т. 50. №6. С. 832-838.
40. Дюк В. А., Флегонтов А. В., Фомина И. К. Применение технологий интеллектуального анализа данных в естественно-научных, технических и гуманитарных областях // Известия РГПУ им. А.И. Герцена. 2011. №138. С. 77–84.

REFERENCES

1. Zenkova N.N. Practical guide to the use of fodder resources in fodder production: a practical guide / Zenkova N.N., Ganushchenko O.F.; Shloma T.M.; Kovaleva I.V. // Vitebsk: VGAVM. 2021. 176 p. (In Russ.)
2. Laptev G.Yu. Promilk heaven will ensure the quality of silage and grain slage / Laptev G.Yu., Yildirim E.A., Ilyina L.A., Novikova N.I., Tyurina D.G., Markman I.L. // Livestock of Russia. 2023. 4: 50-55. (In Russ.)
3. Laptev G.Y. Prevent secondary fermentation and aerobic spoilage of silage / Yildirim E.A., Tyurina D.G., Novikova N.I., Ilyina L.A., Chervatenko D.Y. // Livestock of Russia. 2024. 4: 52-54. (In Russ.)
4. Laptev G.Y. Effectiveness of the preparation 'Biotrof-600' to combat undesirable microflora in the storage of conditioned grain. / Collection 'Actual problems of preparation, storage and rational use of forages' of the international scientific-practical conference devoted to the 100th anniversary of the birth of Doctor of Agricultural Sciences, Professor S.Y. Zafren // M.: 2009. 41-45. (In Russ.)
5. Yildirim E.A., Biotrof-111: all possible does at once / Yildirim E.A., Tyurina D.G. // Livestock of Russia. 2021. 4: 48-51 (In Russ.)
6. Pobednov Yu.A. Effectiveness of corn and grass silage with the preparation Biorof 111 (recommendations) / Pobednov Yu.A., Mamaev A.A., Khudokormov VV, Shchukin NN, Gorkin AM, Borodulya V.I., Laptev GY, Soldatova VV // M.: FSU RCSC, 2010. 17 p. (In Russ.)
7. Bikonya S.N. Increase of nutritive value of silage and haylage with the use of bioconservatives / Dissertation of Candidate of Agricultural Sciences // Volgograd: Volgograd GAU. 2023. 128 p. (In Russ.)

8. Chagarovskii V., Chagarovskii A. Study of the biological activity of direct ferments of the Christian Hansen company used in the production of lactic acid milk products/ Ukraine Mikrobiolohichnyi Zhurnal . 2003. 5(1): 78 – 83.
9. Driehuis F. Fermentation characteristics and aerobic stability of grass silage inoculated with *Lactobacillus buchneri*, with or without homofermentative lactic acid bacteria/ Driehuis F., Oude Elferink S.J.W.H., Van Wikselaar P.G. // Grass Forage Sci., 2001, 56(4): 330-343 (doi: 10.1046/j.1365-2494.2001.00282.x).
10. Tabacco E. Dry matter and nutritional losses during aerobic deterioration of corn and sorghum silages as influenced by different lactic acid bacteria inocula / Tabacco E., Righi F., Quarantelli A., Borreani G. // J. Dairy Sci., 2011, 94: 1409-1419 (doi: 10.3168/jds.2010-3538).
11. Rigy E. Ensiling alfalfa with hydrolyzed corn meal additive and bacterial inoculant / Rigy E., Zsédely E., Tóth T., Schmidt J. // Acta Agronomica Óvariensis, 2011, 53(2): 15-23.
12. Laptev G.Yu. Analysis of mycotoxin accumulation in fodder plant raw materials and silage / Laptev G.Yu., Novikova N.I., Dubrovina E.G., Ilyina L.A., Yildirim E.A., Nikonov I.N., Filippova V.A., Brazhnik E.A. // Fodder production. 2014. 10: 36-39. (In Russ.)
13. Pobednov Yu.A., Kosolapov V.M. Biological basis of alfalfa silage with preparations of lactic acid bacteria (review) / Agricultural Biology. 2018. 53(2): 258-269. (In Russ.)
14. Osipyan B.A., Mamaev A.A. Efficiency of application of preparations 'Biotroph 600' and 'Biotroph 700' at ensiling of plant raw materials provided with sugar / Fodder production. 2014. 11: 35-39. (In Russ.)
15. Netrusov A.I., Bonch-Osmolovskaya E.A., Gorlenko V.M. Ecology of microorganisms / M.: Akademiya, 2004. 272 p. (In Russ.)
16. Chubenko G.I. Methods of bacterial identification: method. manual / Blagoveshchensk: Amurskaya GMA, 2018. 44 p. (In Russ.)
17. Gafarov F.M., Galimyanov A.F. Artificial neural networks and applications: textbook. - Kazan: Izd-vo Kazan. un-sta, 2018. 121 p. (In Russ.)
18. Kruglov V.V., Borisov V.V. Artificial neural networks. Theory and practice / M.: Hotline Telkom, 2002. 382 p. (In Russ.)
19. Vorobyov N.I., Selina M.V., Guselnikova A.A. Neural network programme for the analysis of the state of animal microbiota / Certificate of state registration of computer program No. 2024614895 from 29.02.2024 Application of K.I. Skryabin MBA No. 2024613194 from 16.02.2024. (In Russ.)
20. Witten I.H., Frank E., Hall M.A., Kaufmann M. Data Mining: Practical Machine Learning Tools and Techniques. 3rd ed. / Witten I.H., Frank E., Hall M.A., Kaufmann M. // Elsevier, 2011. 629 p.
21. Ben-Jacob E. Bacterial self-organization: coenhancement of complexification and adaptability in a dynamic environment / Phil. Trans. R. Soc. Lond. A. 2003. 361: 1283-1312.
22. Young I.M., Crawford J.W. Interactions and self-organization in the soil-microbe complex / Science, 2004, 304(5677): 1634-1637.
23. Crawford J.W., Deacon L., Grinev D., Harris J.A., Ritz K., Singh B.K., Young I. Microbial diversity affects self-organization of the soil-microbe system with consequences for function / Journal of the Royal Society Interface. 2012, 9(71): 1302-1310.
24. Vorobyov N.I. Biosystem self-organisation and fractal structure of frequency-taxonomic profiles of microbiota of broiler intestine under the influence of feed probiotics / Vorobyev N.I., Egorov I.A., Kochish I.I., Nikonov I.N., Lenkova T.N. // Agricultural Biology. 2021. 56(2): 400-410. (In Russ.)
25. Kochish I.I. Neural network modelling of fractal self-organization of microbial-organism biosystems in the intestines of birds / Kochish I.I., Vorobiev N.I., Nikonov I.N., Selina M.V. // Veterinary and Zootechnia. 2022. 12: 57-65. (In Russ.)
26. Manfred Schroeder. Fractals, Chaos, Power Laws: Minutes from an Infinite Paradise / NY: 2009. Dover Publications. 448 p.

27. Sutrop U. List Task and a Cognitive Sali-
ence Index / *Field methods*. 2001. 13(3): 263-
276.
28. Zagoruiko N.G. Cognitive data analysis /
Novosibirsk: Academic Publishing House
GEO. 2013. 183 p. (In Russ.)
29. Kim J.-O. Factor, discriminant and cluster
analysis / Kim J.-O., Mueller C.W.,
Klecka W.R., Oldenderfer M.S., Blashfield
R.K. // *M.*, 1989. 216 p.
30. Zaikina A.S. Neural network analysis of
compliance of microbial-organism biosystem
of broiler intestine fractal-stochastic
model / Zaikina A.S., Buryakov N.P., Voro-
byev N.I., Nikonov I.N. // *Perm agrarian
bulletin*, 4(40). 2022: 98-106. (In Russ.)
31. Jürgen Schmidhuber. Deep learning in
neural networks: an overview / *Neural Netw.*
2015. Jan:61:85-117 (doi: 10.1016/
j.neunet.2014.09.003)
32. Pogodaev, A.K. Application of neural
network models for building the production
rules of expert systems / Pogodaev, A.K.;
Habibullina, E.L.; Inyutin, D.M. // *Applied
mathematics and control issues*. 2021. 2: 73-
92. (In Russ.)
33. Kulakov, K.A.; Dimitrov, V.M. Funda-
mentals of software testing / Petrozavodsk:
PetrSU Publishing House, 2018. 57 p. (In
Russ.)
34. Widrow, Bernard; et al. The no-prop al-
gorithm: A new learning algorithm for multi-
layer neural networks / *Neural Networks*.
2013. 37: 182–188.
35. Mascarenhas, WF. Fast and accurate nor-
malization of vectors and quaternions /
Comp. Appl. Math. 2018. 37: 4649–4660.
36. Nikolić, D. Scaled correlation analysis: a
better way to compute a cross-correlogram /
Nikolić, D; Muresan, RC; Feng, W; Singer,
W. // *European Journal of Neuroscience*.
2012. 35(5): 1–21.
37. Everitt, BS. Cluster Analysis / Everitt,
BS, Landau S, Leese M, Stahl D. // John
Wiley & Sons, 2011. 352 p.
38. Markova L.V., Korchevskaya E.A. Nu-
merical methods of finding eigenvectors and
eigenvalues of matrices / Vitebsk: P.M.
Masherov State University, 2011. 47 p. (In
Russ.)
39. Yildirim E.A. Study of epiphytic micro-
flora as a source of silage microbiocenosis
formation by NGS-sequencing method /
Yildirim E.A., Laptev G.Y., Ilyina L.A.,
Nikonov I.N., Filippova V.A., Soldatova
V.V., Brazhnik E.A., Novikova N.I.,
Gagkaeva T.Y. // *Agricultural Biology*.
2015. T. 50(6): 832-838. (In Russ.)
40. Duke V. A., Flegontov A. V. V., Fomina
I. K. Application of data mining technolo-
gies in natural science, technical and human-
itarian fields // *Izvestiya RGPU named after
A.I. Herzen*. 2011. 138: 77-84. (In Russ.)