

УДК 543.68+663.221

УСТАНОВЛЕНИЕ СОРТОВОЙ И РЕГИОНАЛЬНОЙ ПРИНАДЛЕЖНОСТИ БЕЛЫХ ВИН С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

© 2019 г. А. А. Халафян¹, З. А. Темердашев¹, * А. А. Каунова¹, А. Г. Абакумов¹, В. О. Титаренко¹, В. А. Акинъшина¹, Е. А. Ивановец¹

¹Кубанский государственный университет, факультет химии и высоких технологий
350040 Россия, Краснодар, ул. Ставропольская, 149

*E-mail: temza@kubsu.ru

Поступила в редакцию 22.03.2018 г.

После доработки 26.06.2018 г.

Принята к публикации 25.12.2018 г.

Для установления региональной и сортовой принадлежности белых вин исследованы 153 образца белых вин наименований “Рислинг” (49), “Шардоне” (56) и “Мускат” (48), произведенных на территории основных винодельческих предприятий географических зон Краснодарского края. Содержания микро- и макроэлементов в винах определяли методом атомно-эмиссионной спектроскопии с индуктивно связанной плазмой. Хемометрические исследования проводили нейронными сетями Neural Network в среде пакета STATISTICA. Из совокупности 15 определяемых микро- и макроэлементов корреляционным анализом выделены 5 микроэлементов (Fe, Mg, Rb, Ti, Na) – предикторов построенной нейросетевой модели, которая успешно идентифицировала наименования вин. Для установления региона произрастания винограда строили нейросетевую модель по 6 предикторам – 5 микроэлементам и установленному наименованию вин. Разработан программный продукт, который автоматизирует необходимые вычисления.

Ключевые слова: региональная и сортовая принадлежность вин, элементный анализ, нейросетевые технологии.

DOI: 10.1134/S0044450219060057

Одной из самых сложных задач в аналитической химии вина является установление подлинности и его географического происхождения. Единичные параметры оценки качества вин не в полной мере достаточны для определения соответствия товара его маркировке. Для установления подлинности и региональной принадлежности вин, а также изменений при их фальсификации используются подходы, основанные на определении минерального и изотопного состава, исследовании спектральных характеристик, определении фенольных и летучих соединений, с использованием различных методов анализа [1, 2]. Выявление критериев подлинности и региональной принадлежности вин основано на получении и анализе большого массива данных об анализируемых объектах с последующей его обработкой хемометрическими методами с целью выявления скрытой взаимосвязи между компонентами вин [1–10]. Сочетание современного инструментария для анализа данных с возможностями хемометрических методов позволяет с более высокой достоверностью идентифицировать вина по региональному признаку. Информация об элементном составе вин может быть полезна также для кон-

троля технологического процесса и в сочетании с хемометрическими методами обработки данных позволит установить происхождение вин [11, 12]. Например, содержания металлов в винах, произведенных в разных винодельческих регионах Европы, достаточно сильно различаются [13], что может помочь решению задачи идентификации их региональной принадлежности (табл. 1).

Факторами естественной вкусовой изменчивости вин являются отличия условий произрастания винограда, из которого изготовлено вино – климатические условия, минеральный состав почвы, технология возделывания винограда, срок сбора винограда и т.д. На минеральный состав вин могут влиять различные факторы (почва, климат, рельеф и др.), поэтому для их идентификации многие исследователи изучают и выбирают те элементы, которые в наименьшей степени зависимы от внешних воздействий для данной географической зоны [3–6, 8, 9, 14, 15]. Например, авторы работы [14] в качестве таковых используют Sr, Mn, Mg, Li, Co, Rb, B, Cs, Zn, Al, Ba, Si, Pb и Ca.

Таблица 1. Содержание некоторых металлов (мг/л) в винах ряда стран [13]

Элемент	Чехия	Франция	Германия	Италия	Испания
K	553–3056	265–426	480–1860	–	338–2032
Na	2.0–110	7.7–14.6	6–25	–	3.5–300
Ca	40–210	65–161	58–200	88–151	12–241
Mg	7.8–138	55–96	56–105	53–60	50–236
Al	–	0.56–1.27	–	–	0.57–14.3
Cu	–	н/о–0.48	0.02–0.71	–	н/о–3.1
Fe	0.9–5.2	0.81–2.51	0.4–4.2	–	0.4–17.4
Mn	0.28–3.26	0.63–0.96	0.5–1.3	–	0.1–5.5
Rb	0.56–1.20	0.64–0.72	0.2–2.9	0.50–9.90	0.1–5.3
Sr	0.34–0.53	0.22–0.47	0.12–1.28	0.40–1.16	0.28–1.50
Zn	–	0.44–0.74	0.3–1.5	–	н/о–4.63
Ba	0.09–0.12	0.025–0.24	0.04–0.26	0.07–0.14	0.01–0.35
Cd	–	н/о–0.0002	–	–	н/о–0.019
Co	н/о–0.018	0.004–0.011	0.004–0.005	0.003–0.006	н/о–0.040
Cr	0.032–0.037	0.030–0.057	0.022–0.078	0.023–0.034	0.025–0.029
Li	0.015–0.052	0.008–0.036	0.005–0.043	–	0.002–0.13
Ni	–	н/о–0.052	–	–	0.005–0.079
Pb	–	0.006–0.023	–	–	0.001–0.043
V	0.020–0.054	0.06–0.23	0.01–0.14	–	0.026–0.043

* н/о – не обнаружен.

Металлы в винах содержатся в широких диапазонах концентраций, мг/л: макроэлементы (Ca, K, Na, и Mg) от 10 до 1000, минорные элементы (Al, Fe, Cu, Mn, Rb, Sr и Zn) 0.1–10 и микроэлементы (Ba, Cd, Co, Cr, Li, Ni, Pb, V и др.) 0.0001–1 [13]. В связи с этим проблема установления в вине микроэлементного “образа” винограда, из которого оно произведено, представляет не только научный, но и практический интерес [15–19].

В случаях, когда между винами из разных сортов винограда есть определенное органолептическое сходство, например цвет, терпкий, кислый вкус, важной является возможность идентификации сорта винограда по микроэлементному составу [20]. По сути, решение сформулированной проблемы сводится к установлению по содержаниям микроэлементов в образце некупажированного вина сорта винограда, из которого оно было изготовлено и региона (зоны) его произрастания.

В настоящей работе на образцах белых вин трех наименований, произведенных на территории Краснодарского края, рассмотрена возможность определения сорта винограда и региона его произрастания нейронными сетями с использованием совокупности данных элементного анализа.

ЭКСПЕРИМЕНТАЛЬНАЯ ЧАСТЬ

Объекты исследования. Для рассмотрения возможности определения региональной и сортовой принадлежности белых вин исследовали 153 образца сухих, полусладких и полусухих вин наименований “Рислинг” (49), “Шардоне” (56) и “Мускат” (48), произведенных на территории основных винодельческих предприятий географических зон Краснодарского края: ЗАО “Запорожское”, ООО “Кубань-Вино”, ОАО АПФ “Фанагория”, ООО АПК “Мильстрим-Черноморские вина”, ЗАО АФ “Кавказ”, ЗАО “Абрау-Дюрсо”, ЗАО АПК “Геленджик”, ЗАО АФ “Мысхако”, ООО “Фирма Сомелье”, ООО АФ “Саук-Дере”, ООО “Союз-Вино”, отнесенных к разным географическим зонам (подзонам) Краснодарского края: Южно-предгорной и Черноморской зонам, Анапской и Таманской подзонам. Исследуемые вина были предоставлены непосредственно производителями или приобретены в торговой сети.

Материалы и методики исследований. Элементный состав исследуемых образцов вин устанавливали методом атомно-эмиссионной спектроскопии с индуктивно связанной плазмой с использованием iCAP-6000 (Thermo Scientific), определяли содержание 15 элементов (Al, Ba, Ca, Cu, Fe, K, Mg, Mn, Na, Rb, Ti, Sr, Li, Zn, Ni). При определении практически всех исследуемых металлов использовали их наиболее чувствительные аналитические линии

за исключением Al, Ca, Mg, Sr, для которых выбрали альтернативные линии из-за спектральных наложений, а в случае некоторых макроэлементов из-за необходимости снижения интенсивности сигнала. При оптимизации условий определения элементов учитывали влияние операционных характеристик прибора (мощность генератора, скорость потока аргона) на величину аналитического сигнала элементов в модельных растворах и в растворах исследуемых образцов. Изучали взаимное влияние микро- и макрокомпонентов, а также фоновых компонентов подготовленных к анализу образцов на модельных растворах, содержащих их переменные количества. Металлы количественно определяли путем разбавления испытуемых образцов вин с учетом результатов исследований [5, 15–19, 21, 22].

Для анализа испытуемых образцов использовали стандартные образцы: ГСО 7780-2000 (Li), ГСО 8062-94 (Na), ГСО 7767-2000 (Mg), ГСО 7854-2000 (Al), ГСО (K), ГСО 7772-2000 (Ca), ГСО 7205-95 (Ti), ГСО 8056-94 (Mn), ГСО 8032-94 (Fe), ГСО 7785-2000 (Ni), ГСО 7836-2000 (Cu), ГСО 8053-94 (Zn), ГСО 7035-93 (Rb), ГСО 7783-2000 (Sr), ГСО 7760-2000 (Ba), ГСО 7778-2000 (Pb). Другие реактивы, используемые в работе, имели квалификацию не ниже х. ч.

Хемометрическое решение задачи определения сорта винограда и региона его произрастания нейронными сетями реализовано в программе Statistica Neural Network [23, 24].

РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Ранее нами [25] для изучаемой совокупности белых вин при помощи традиционных методов прикладной статистики – дискриминантного анализа и деревьев классификации – были построены вероятностно-статистические модели, которые позволили по концентрациям 15 микроэлементов в вине идентифицировать сорт винограда и регион, в котором он был выращен. Предложенные модели основаны на предположении, что происхождение почвы является важным показателем микроэлементного состава вина. Такого рода идентификация возможна при наличии инструментального и методического обеспечения многоэлементного анализа [25].

В данной работе проанализирована возможность установления наименования вин и их географического происхождения при значительно меньшем количестве микроэлементов с высокой прогностической точностью с использованием нейросетевых моделей.

Для выделения микроэлементов – предикторов нейросетевых моделей классификации – использовали непараметрическую корреляцию Спирмена, характеризующую взаимосвязь на-

именований образцов вин, региона, в котором был выращен виноград с концентрациями микроэлементов в этих образцах. В качестве предикторных переменных выбрали микроэлементы со статистически значимыми корреляционными связями – Fe, Mg, Rb, Ti, Na. Средние значения и стандартные отклонения содержаний микроэлементов в винах отражены в табл. 2. Видно, что имеются существенные отличия в средних значениях для вин различных наименований и регионов произрастания винограда. Именно эти отличия и определяют возможность построения классификационных моделей, в том числе и нейронными сетями.

Многочисленное повторение вычислительных экспериментов показало, что наиболее адекватную нейросетевую модель установления подлинности вин и их географического происхождения целесообразно строить в 2 этапа. Сначала следует построить сеть для предсказания наименований вин по концентрациям микроэлементов Fe, Mg, Rb, Ti, Na. На втором этапе по большему количеству предикторов, а именно по предсказанному наименованию (качественный предиктор) и тому же набору микроэлементов (количественные предикторы), строят сеть для определения региона произрастания винограда.

Программа Statistica Neural Network может строить заданное пользователем количество нейронных сетей, которые по критериям, характеризующим прогностические свойства сетей – производительности, количеству ошибок классификации и др., позволяют выбрать лучшую нейросетевую модель классификации. Производительность – это процент верно классифицированных образцов вин. Чем больше производительность, тем точнее прогноз; максимально возможная производительность равна 100%. Для увеличения прогностических свойств программа строила сети, предварительно разбив данные на 3 части – обучающую, контрольную и тестовую выборки. На первой стадии осуществляется обучение сети, результаты которого проверяются на контрольной выборке. После завершения процесса обучения сеть тестируется при помощи тестовой выборки. Поэтому наиболее важными являются значения прогностических критериев на тестовой выборке. Комбинируя различные варианты сетей, мы добивались построения сети с наилучшими прогностическими возможностями, поэтому количество построенных сетей различно.

Построение нейронной сети для определения наименования вин. Программой 153 образца вин разделены на 3 группы – обучающую, контрольную и тестовую выборки соответственно по 109, 22 и 22 образца. Производительности (%) лучшей из 50 построенных сетей (MLP 5-10-3) на обучающей, контрольной и тестовой выборках состави-

Таблица 2. Средние значения (c_{cp}) и стандартные отклонения (s) концентраций элементов (мг/л) в образцах разных вин

Элемент	Метрологические характеристики	Шардоне				Рислинг			Мускат			
		Таманская подзона	Анапская подзона	Южно-предгорная зона	Черноморская зона	Таманская подзона	Южно-предгорная зона	Черноморская зона	Таманская подзона	Анапская подзона	Южно-предгорная зона	Черноморская зона
Fe	c_{cp}	2.686	2.574	5.022	1.274	2.662	4.546	3.448	2.612	7.942	3.904	5.638
	s	2.046	0.297	0.434	1.073	1.850	0.837	2.906	1.572	0.616	0.526	0.397
Mg	c_{cp}	84.64	52.97	56.24	51.28	91.47	69.92	58.38	81.51	53.90	74.58	81.89
	s	44.50	1.447	7.362	4.488	44.24	8.690	12.67	23.24	4.321	10.05	11.83
Na	c_{cp}	47.78	0.023	58.47	31.53	77.53	38.68	58.77	69.58	35.73	47.42	72.01
	s	15.64	1.505	6.284	12.79	30.19	16.51	39.24	22.53	2.028	5.029	3.452
Rb	c_{cp}	1.795	0.0006	0.614	0.001	0.001	0.585	0.560	0.621	0.251	0.635	0.522
	s	1.754	0.00003	0.186	0.575	0.334	0.067	0.086	0.137	0.038	0.101	0.256
Ti	c_{cp}	0.016	0.013	0.020	0.022	0.023	0.031	0.024	0.012	0.014	0.169	0.023
	s	0.006	0.002	0.002	0.002	0.006	0.009	0.011	0.004	0.017	0.001	0.004

Таблица 3. Итоги классификации в выборках для наименований

Выборка	Правильность классификации	“Мускат”	“Рислинг”	“Шардоне”	Все
Обучающая	Все	33	33	43	109
	Правильно	33	33	43	109
	Неправильно	0	0	0	0
	Правильно (%)	100	100	100	100
	Неправильно (%)	0	0	0	0
Контрольная	Все	8	6	8	22
	Правильно	8	5	7	20
	Неправильно	0	1	1	2
	Правильно (%)	100	83.33	87.50	90.91
	Неправильно (%)	0	16.67	12.50	9.09
Тестовая	Все	7	10	5	22
	Правильно	7	9	5	21
	Неправильно	0	1	0	1
	Правильно (%)	100	90	100	95.45
	Неправильно (%)	0	10	0	4.55

ли 100, 90.91, 95.46 (табл. 3). Топология сети обозначена комбинацией букв и цифр. Аббревиатура из букв MLP определяет тип нейронной сети — многослойный персептрон; первая цифра (5) указывает на количество предикторных переменных в модели, которая складывается из числа количественных предикторов и количества значений качественных предикторов; вторая (10) и третья (3) — число скрытых и выходных нейронов.

Топология сети схематично изображена на рис. 1. Сеть имеет 5 входов, обозначающие предикторные переменные X_i — концентрации микроэлементов; 10 скрытых нейронов Y_j ; 3 выходных нейрона, представляющие объекты классификации Q_k — наименования вин “Мускат”, “Рислинг”, “Шардоне”, а также связи между ними в виде весов W_{ij} , W_{jk} .




Рис. 1. Нейронная сеть для определения наименований белых вин.

Частоты правильно и неправильно классифицированных сетью образцов вин в выборках приведены в табл. 4, из которой следует, что образцы трех сортов вин обучающей выборки классифицированы без ошибок. Образцы “Муската” определены также без ошибок для всех выборок. Наименьший процент правильной классификации в обучающей, контрольной и тестовой выборках в случае “Рислинга” – 100, 83.33, 90%. Значительно бóльшие доли правильной классификации в случае “Шардоне” – 98.21, 87.5, 100%. Таким образом, для двух наименований вин из трех – “Муската” и “Шардоне” – в тестовой выборке доля правильно классифицированных образцов составила 100%, для “Рислинга” – 90%. Общее количество ошибочных случаев классификации из 153 образцов – 3 ($\approx 2\%$), т.е. нейронной сетью правильно идентифицировано примерно 98% образцов вин.

Для сравнения приведем данные работы [25], в которой описаны результаты классификации наименований вин по 15 микроэлементам дискриминантным анализом: из 56 образцов “Шардоне” ошибочно как “Мускат” классифицирован 1 образец, что соответствует 98.21% правильной классификации; из 49 образцов “Рислинга” ошибочно как “Мускат” классифицирован также 1 образец, что соответствует 97.96% правильной классификации. Наибольшее количество ошибок классификации в случае “Муската” – из 47 образцов ошибочно как “Шардоне” и “Рислинг” клас-

сифицированы соответственно 1 и 3 образца, что соответствует 91.67% правильной классификации. Общий процент правильной классификации достаточно высок и составил 96.07%. Таким образом, нейронная сеть при меньшем количестве предикторов в модели показала более высокую точность классификации вин по наименованиям!

По чувствительности сети можно оценить вклады каждого предиктора в ее прогностические свойства, в нашем случае микроэлементов в классификационную модель. Из значений чувствительности, представленных в табл. 4, следует, что во всех трех выборках вклады микроэлементов в прогностические свойства сети убывают в последовательности Fe, Ti, Rb, Na, Mg.

Построение нейронной сети для определения региона. Возможность предсказания наименования сети по 5 выбранным микроэлементам сделала возможным решение более сложной задачи – определения региона произрастания винограда по сочетанию микроэлементов Fe, Mg, Rb, Ti, Na и наименованиям вин – “Мускат”, “Рислинг”, “Шардоне”. Для решения этой задачи програм-

Таблица 4. Анализ чувствительности сети

MLP 5-10-3	Fe	Ti	Rb	Na	Mg
Тестовая	70.27	26.14	23.13	21.49	18.91
Обучающая	6080.92	5017.31	3831.60	1970.31	1648.02
Контрольная	34.05	21.21	13.57	10.78	10.70

Таблица 5. Итоги классификации в выборках для регионов

Выборка	Правильность классификации	Анапская подзона	Таманская подзона	Черноморская зона	Южно-предгорная зона	Все
Обучающая	Все	14	50	24	21	109
	Правильно	12	49	24	19	104
	Неправильно	2	1	0	2	5
	Правильно (%)	85.71	98	100	90.48	95.41
	Неправильно (%)	14.29	2	0	9.52	4.59
Контрольная	Все	3	12	3	4	22
	Правильно	3	11	3	4	21
	Неправильно	0	1	0	0	1
	Правильно (%)	100	91.67	100	100	95.5
	Неправильно (%)	0	8.33	0	0	4.54
Тестовая	Все	1	11	5	5	22
	Правильно	1	11	5	5	22
	Неправильно	0	0	0	0	0
	Правильно (%)	100	100	100	100	100
	Неправильно (%)	0	0	0	0	0

Таблица 6. Анализ чувствительности сети

LP 8-15-4	Fe	Наименование вина	Na	Ti	Mg	Rb
Тестовая	3.82	3.55	2.32	1.61	2.22	1.18
Обучающая	4.58	3.20	3.05	1.74	1.42	1.08
Контрольная	2.00	2.00	1.88	1.49	0.98	1.01
Среднее	3.47	2.92	2.42	1.61	1.54	1.08

мой Statistica Neural Network 153 образца вин были также разделены на обучающую, контрольную и тестовую выборки с тем же количеством образцов – 109, 22 и 22. Для указанных выборок достигнуты высокие производительности построенной сети MLP 8-15-14 – соответственно 95.41, 95.46 и 100%. Наибольший процент (100) правильной классификации сетью получен для Черноморской зоны – без ошибок определены образцы по всем выборкам (табл. 5). Далее по точности классификации следует Таманская подзона – по обучающей, контрольной и тестовой выборкам классифицированы правильно соответственно 98, 91.67 и 100%. Хуже всего классификация для образцов Анапской подзоны. Общее количество ошибочных классификации из 153 образцов – 6, что составило $\approx 4\%$, т.е. нейронной сетью правильно идентифицировано примерно 96% образцов вин. Важно то, что на тестовой выборке образцы правильно классифицированы по всем регионам.

Значения чувствительности сети приведены в табл. 6. Из последней строки табл. 6, в которой представлены средние значения чувствительности предикторов по всем 3 выборкам, следует, что средние вклады предикторов в прогностические свойства сети для определения региона убывают в последовательности: Fe, Наименование вина, Na, Ti, Mg, Rb. Если сравнить с вкладами в прогностическую нейросетевую модель идентификации наименований вин, то легко заметить, что вклады микроэлементов существенно изменились.

В работе [25] задачу идентификации региона произрастания винограда решали отдельно для вин “Мускат”, “Рислинг”, “Шардоне” двумя методами – дискриминантным анализом и деревьями классификации. Количество микроэлементов, используемых в дискриминантном анализе для вин “Мускат”, “Рислинг”, “Шардоне”, составило соответственно 14, 9 и 13. Деревьями классификации для всех наименований вин было задействовано значительно меньшее число микроэлементов – 4. Количество ошибочных класси-



Рис. 2. Стартовое окно программы.

фикаций обучающей выборки обоими методами равно 0.

Учитывая, что нейронными сетями на тестовой выборке также достигнута наибольшая точность прогноза – 100%, можно утверждать, что посредством классических методов прикладной статистики – дискриминантного анализа и деревьев классификации, а также эвристической процедуры нейронные сети – построены приемлемые модели классификации для установления сорта винограда и места его произрастания.

При этом нейросетевые модели обладают рядом преимуществ:

- при высоких прогностических свойствах позволяют по сочетанию 5 микроэлементов определить наименование вин; далее по наименованию и сочетанию тех же микроэлементов определить регион произрастания винограда.

- для всех наименований вин и регионов произрастания винограда модели построены по одной и той же совокупности микроэлементов: Fe, Mg, Na, Rb, Ti;

- для всех наименований вин регион произрастания винограда определяется по одной нейросетевой модели.

Полученные в процессе обучения параметры сетей – их топология и значения весов – позволили в среде программирования Visual C# разработать автономный программный продукт, автоматизирующий процесс идентификации наименований белых вин, с последующим определением

регионов произрастания винограда. Стартовое окно программы изображено на рис. 2. В предусмотренные поля интерфейсного окна следует ввести значения концентраций микроэлементов Fe, Mg, Na, Rb, Ti и нажать на кнопку “Рассчитать”. В нижней левой части окна появится наименование вина (“Мускат”) и регион, в котором был выращен виноград (Анапская зона).

* * *

Таким образом, на примере белых вин, произведенных в Краснодарском крае, показана принципиальная возможность по концентрациям определенных микроэлементов при помощи классических статистических методов – дискриминантного анализа, деревьев классификации, а также эвристической процедуры нейронные сети – успешно идентифицировать как наименование вин, так и регион их произрастания. При этом более технологичными и менее затратными в реализации, а значит и более эффективными, являются нейросетевые модели. Более важным является установленный в результате исследований факт, что определенный набор микроэлементов в вине содержит информацию не только о сорте винограда, из которого оно произведено, но и о месте его произрастания. Современный инструментарий анализа данных позволяет по “микроэлементной” памяти вина с высокой достоверностью восстановить сорт винограда и место его выращивания.

Работа выполнена при финансовой поддержке Российского фонда фундаментальных исследований (проект № 18-03-00059) с использованием научного оборудования ЦКП “Эколого-аналитический центр” Кубанского госуниверситета, уникальный идентификатор RFMEFI59317X0008.

СПИСОК ЛИТЕРАТУРЫ

1. *Schlesier K., Fauhl-Hassek, Forina C., Cotea M., Kocsi V., Schoula E., van Jaarsveld R., Wittkowski F.R.* Characterisation and determination of the geographical origin of wines. part i: Overview // *Eur. Food Res. Technol.* 2009. V. 230. № 1. P. 1.
2. *Daniel C., Smyth H.* Analytical and chemometric-based methods to monitor and evaluate wine protected designation // *Compr. Analyt. Chem.* 2013. V. 60. P. 385.
3. *Geana I., Iordache A., Ionete R., Marinescu A., Ranca A., Culea M.* Geographical origin identification of Romanian wines by ICP-MS elemental analysis // *Food Chem.* 2013. V. 138. P. 1125.
4. *Selih Vid S., Sala M., Drgan V.* Multi-element analysis of wines by ICP-MS and ICP-OES and their classification according to geographical origin in Slovenia // *Food Chem.* 2014. V. 153. P. 414.
5. *Martin A.E., Watling R.J., Lee G.S.* The multi-element determination and regional discrimination of Australian wines // *Food Chem.* 2012. V. 133. P. 1081.
6. *Rodrigues S.M., Otero M., Alves A.A., Coimbra J., Coimbra M.A., Pereira E., Duarte A.C.* Elemental analysis for categorization of wines and authentication of their certified brand of origin // *J. Food Comp. Anal.* 2011. V. 24. № 4–5. P. 548.
7. *Халафян А.А., Якуба Ю.Ф., Темердашев З.А., Каунова А.А., Титаренко В.О.* Вероятностно-статистическое моделирование органолептических качеств виноградных вин // *Журн. аналит. химии.* 2016. Т. 71. № 11. С. 1196. (*Khalafyan A.A., Yakuba Yu.F., Temerdashev Z.A., Kaunova A.A., Titarenko V.O.* Statistical-probability simulation of the organoleptic properties of grape wines // *J. Analyt. Chem.* 2016. V. 71. № 11. P. 1138.)
8. *Geana E.I., Marinescu A., Iordache A.M., Sandru C., Ionete R.E., Bala C.* Differentiation of Romanian wines on geographical origin and wine variety by elemental composition and phenolic components // *Food Anal. Methods.* 2014. V. 7. P. 2064.
9. *Dinca O.R., Ionete R.E., Costinel D., Geana I.E., Popescu R., Stefanescu I., Radu G.L.* Regional and vintage discrimination of Romanian wines based on elemental and isotopic fingerprinting // *Food Anal. Methods.* 2016. V. 9. P. 2406.
10. *Каунова А.А., Титаренко В.О., Темердашев З.А., Секунова М.В., Попандопуло В.Г.* Анализ некоторых подходов по оценке качества, подлинности и региональной принадлежности вин // *Заводск. лаборатория. Диагностика материалов.* 2016. Т. 82. № 8. С. 69.
11. *Giaccio M., Vicentini A.* Determination of the geographical origin of wines by means of the mineral content and the stable isotope ratios: A review // *J. Comm. Sci. Tech. Qual.* 2008. V. 47. P. 267.
12. *Rios-Reina R., Elcoroaristizabal S., Ocaña-González J.A., García-González D.L., Amigo J.M., Callejón R.M.* Characterization and authentication of Spanish PDO wine vinegars using multidimensional fluorescence and chemometrics // *Food Chem.* 2017. V. 230. № 9. P. 108.
13. *Pohl P.* What do metals tell us about wine? // *Trends Anal. Chem.* 2007. V. 26. P. 941.
14. *Hopfer H., Nelson J., Collins T.S., Heymann H., Ebeler S.E.* The combined impact of vineyard origin and processing winery on the elemental profile of red wines // *Food Chem.* 2015. V. 172. P. 486.
15. *Jurado J.M., Alcázar Á., Palacios-Morillo A., de Pablos F.* Classification of Spanish DO white wines according to their elemental profile by means of support vector machines // *Food Chem.* 2012. V. 135. P. 898.
16. *Rapeanu G., Vicol C., Bichescu C.* Possibilities to assess the wines authenticity // *Innov. Romanian Food Biotech.* 2009. V. 5. P. 1.
17. *Grindlay G., Mora J., Gras L., de Loos-Vollebrecht M.T.* Atomic spectrometry methods for wine analysis: A critical evaluation and discussion of recent applications (Short Survey) // *Anal. Chim. Acta.* 2011. V. 691. № 1–2. P. 18.
18. *Ivanova-Petropulos V., Balabanova, B., Mitrev S., Nedelkovski D., Dimovska V., Gulaboski R.* Optimization and validation of a microwave digestion method for multi-element characterization of vranec wines (article) // *Food Anal. Methods.* 2016. V. 9. № 1. P. 48.
19. *Gonzálvez A., Armenta S., Pastor A., De La Guardia M.* Searching the most appropriate sample pretreatment for the elemental analysis of wines by inductively coupled plasma-based techniques (Article) // *J. Agric. Food. Chem.* 2008. V. 56. № 13. P. 4943.
20. *Guardia M., Gonzalez A.* Food Protected Designation of Origin: Methodologies and Applications. 1st ed. Amsterdam: Elsevier, 2013. V. 60. 773 p.
21. *Zioła-Frankowska A., Frankowski M.* Determination of metals and metalloids in wine using inductively coupled plasma optical emission spectrometry and mini-torch // *Food Anal. Methods.* 2017. V. 10. P. 180.
22. *Каунова А.А., Петров В.И., Цюпко Т.Г., Темердашев З.А., Перекотий В.В., Лукьянов А.А.* Идентификация вин по региональной принадлежности на основе мультиэлементного анализа методом АЭС-ИСП // *Журн. аналит. химии.* 2013. Т. 68. № 9. С. 917. (*Kaunova A.A., Petrov V.I., Tsiupko T.G., Temerdashev Z.A., Perekotii V.V., Luk'inov A.A.* Identification of wine provenance by ICP-AES multielement analysis // *J. Analyt. Chem.* 2013. V. 68. № 9. P. 831.)
23. *Hill T., Lewicki P.* Statistics Methods and Applications. Tulsa, OK: StatSoft, 2007. 719 p.
24. *Нейронные сети. Statistica Neural Networks. Методология и технологии современного анализа данных / Под ред. Боровикова В.П.* 2-е изд., перераб. и доп. М.: Горячая линия – Телеком, 2008. 392 с.
25. *Титаренко В.О., Халафян А.А., Темердашев З.А., Каунова А.А., Ивановец Е.А.* Использование статистических методов при классификации сортовой и региональной принадлежности белых вин // *Заводск. лаборатория. Диагностика материалов.* 2017. Т. 83. № 8. С. 65.