

17. Конгрес геолога Србије 17 th Serbian Geological Congress	Књига апстраката Book of Abstracts	808-813	Врњачка Бања, 17-20. мај 2018. Vrnjačka Banja, May 17-20, 2018.
--	---------------------------------------	---------	--

ГЕОЛОШКИ, МОРФОЛОШКИ И ПЕДОЛОШКИ ЧИНИОЦИ ТЕРОАРА СМЕДЕРЕВКЕ

Милош Марјановић¹, Александар Стојаковић², Биљана Аболмасов¹, Драгана Ђурић¹,
Урош Ђурић³, Јелка Крушић¹, Катарина Андрејев⁴, Милева Самарџић-Петровић³

¹ Универзитет у Београду, Рударско-геолошки факултет, e-mail: milos.marjanovic@rgf.bg.ac.rs

² Emporio Consulting, Београд

³ Универзитет у Београду, Грађевински факултет

⁴ MEDGOLD Resources Corp., Serbia Office

Кључне речи: тероар, Смедеревка, машинско учење, просторна анализа.

УВОД

Тероар осликава скуп педолошких, микро-климатских и историјских утицаја на одлуку о заснивању и узгајању винове лозе као и на могућност њихове квалитативне и квантитативне експлоатације. За виноградаре он је од пресудног значаја приликом одабира сортимента. Некада су се у Европи виноградаре одређивали на основу породичног искуства. Са развојем науке, педолошка карактеризација земљишта је означила почетак новог приступа у заснивању винограда, па су се и водеће светске винарије у последњих 30-ак година окренуле науци. У овом истраживању се отишло и корак даље у односу на педолошки приступ, јер се само земљиште сматра производом подлоге и поднебља, па је логично проширити контекст тероара на оне чиниоце које иначе условљавају одређујуће карактеристике земљишта, попут геолошких и морфолошких (Burns, 2010). На тај начин се прелиминарно могу издвојити зоне повољног сплета чинилаца на ширем (регионалном) подручју, те наводити даља, детаљнија испитивања земљишта. Анализирањем ширег подручја омогућава се боље стратешко планирање, нарочито у погледу очувања ретких и аутохтоних сорти.

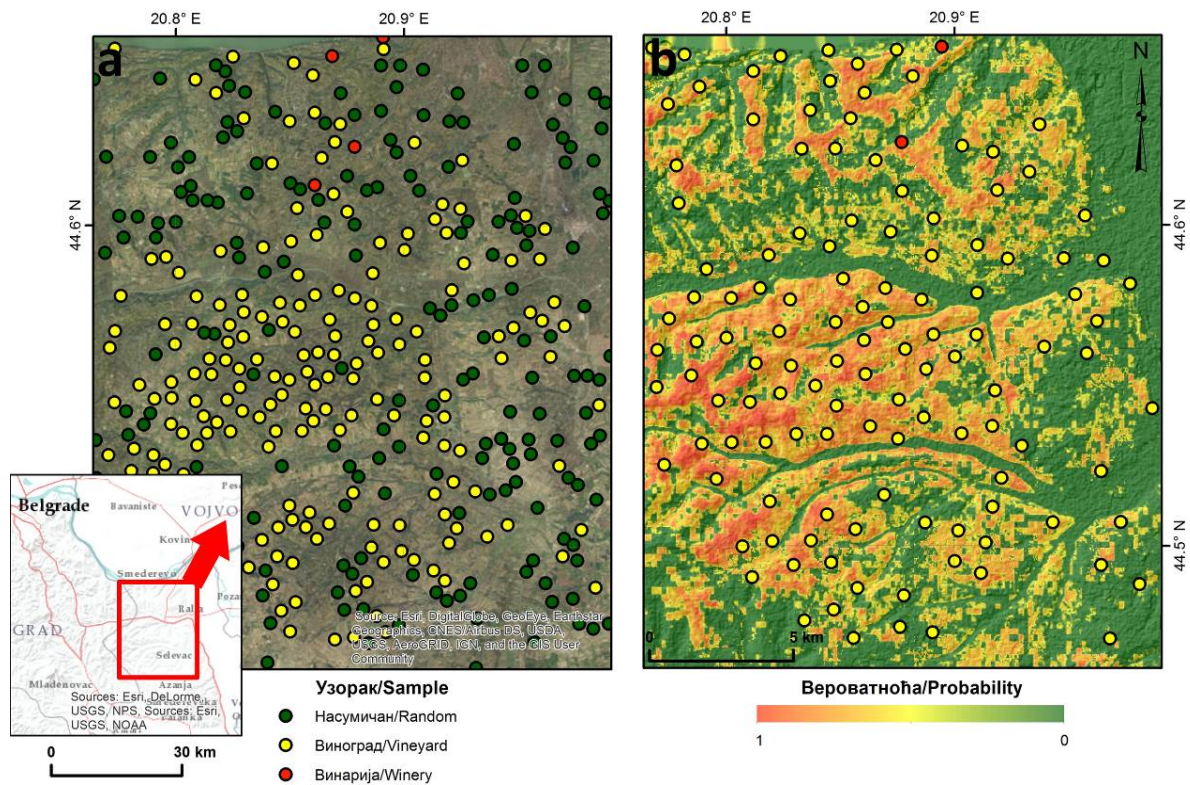
Аутохтоне сорте су за винаре, аутохтони генетски потенцијал. Таква је и Смедеревка, која се стидљиво поново сади, али без икаквог плана или консултовања струке. До II светског рата Смедеревка (позната као „жута“) се узгајала претежно у Смедеревском виногорју, али се водило рачуна на којим потесима се сади, какав је састав земљишта, каква је експозиција, утицај рефлексације воде и многи други чиниоци. Квалитет је био немерљиво бољи у поређењу са Смедеревком узгајаном у периоду социјализма 1950–1990, обележеном високоприносном, комбинатском праксом „Годомина“. Потес Плавинац у Смедереву (искуствено) даје Смедеревку најлепших сензорних карактеристика, иако су познатији микролокалитети Златно Брдо (*Mons Aureus*) и Петријево.

МЕТОДЕ

Савремени научни трендови следе „Четврту парадигму у науци“ (Heу et al. 2009) и резултат су масовног прикупљања података. Са друге стране, „Четврта индустријска револуција“ (Schwab 2016) на чијем смо зачетку, указује на технолошке напретке који револуционаризују начин на који се ти пета-бајти података могу употребити. Другим речима, нова научна открића чекају да прегледамо све те податке и увидимо законитости унутар њих.

Просторне анализе спадају у ред оних које могу да искористе и податке (сателитске снимке, глобалне и локалне карте и моделе који нуде прогнозе вредности најразличитијих параметара) и технолошке (рачунарске) капацитете за њихову анализу. Како и анализа подобности за гајење одређене винове лозе спада у класичан просторни проблем (Jones et al. 2004, Vaudour et al. 2010), овде ће бити искоришћени глобални и локални подаци, као и напредне методе како би се, уз

неопходну дозу искуства, добила информација о подобним и неподобним теренима за гајење аутохтоне сорте Смедеревка у околини Смедерева (Слика 1).



Слика 1. а) Предметно подручје (околина Смедерева), са локацијама узорака коришћеним за моделовање, б) модел вероватноће погодности подручја за гајење сорте Смедеревке.

Figure 1. a) The area of interest (near Smederevo), with locations of samples used for modeling, b) the probabilistic model of suitability for growing Smederevka vine.

Методолошки приступ своди се најпре на лоцирање познатих винограда, на којима се Смедеревка успешно гаји. Даље преостаје да се искористе сателитски ресурси како би се погустила ова информација (Слика 1а) и искористила у наредном кораку, који подразумева употребу алгоритама машинског учења, који раде на једноставном принципу тренинга и екстраполације. Такође је потребно прикупити низ чинилаца за које се искуствено сматра да имају утицаја на тероар. У том својству одабрани су геолошки, морфолошки и педолошки чиниоци, представљени дигиталним подлогама одговарајуће резолуције и покрића (Табела 1).

Алгоритам најпре у фази тренинга добија примере успешног гајења ове сорте, и на тим локацијама корелише утицаје свих придружених чинилаца (Табела 1). На основу задатих примера и чинилаца успоставља математичко/статистичко правило или функцију, која дефинише који сплет чинилаца и у којој мери повољно утиче на гајење одабране сорте лозе. Такође је потребно да „научи“ и на којим локацијама то није случај (негативни примери). У наредној фази могуће је искористити „научено“ правило/функцију и екстраполирати је на читаво подручје од интереса, уз предуслов да је покривено истим подлогама/чиниоцима. Тиме је могуће предвидети нове локације повољне за гајење одабране лозе. У овом раду је коришћен Random Forest алгоритам, о чијим детаљима упућујемо на Witten et al. 2011.

РЕЗУЛТАТИ

На слици 1а је приказан полазни сет узорака, како визуелно препознатих винограда (жуте тачке) уз помоћ сателитске *Google* подлоге, тако и на основу познатих локација засада винарија

(црвене тачке). Приказане су и насумично одабране локације (зелене тачке) које се *a priori* могу сматрати неповољним за узгајање Смедеревке, при чему се водило рачуна да насумичност не буде сасвим случајна, већ довољно удаљена од лоцираних винограда, а да при том не спада у одређену класу вегетационог индекса NDVI (0,3–0,5). Ове локације су коришћене за тренирање Random Forest алгоритма (са стандардним подешавањима параметара у програму *Weka* 3.9), који је трениран и на позитивним и негативним примерима. Тренинг је извршен над сетом података из Табеле 1, при чему је сет редукван помоћу корелационих својстава. Наиме, сви параметри који немају јасно успостављену корелацију са тренинг сетом нису ушли у даљи процес моделовања. Коначан модел добијен је екстраполацијом над сетом са истим припадајућим чиниоцима као у случају тренинга (Слика 1b). Ради оцене модела, добијене зоне вероватноће су преклопљене контролним тачкама (не коришћеним у фази моделовања), представљеним жутим и црвеним тачкама (Слика 1b).

Табела 1. Листа чинилаца коришћених за предикцију.
Table 1. List of factors used for prediction.

Улазни подаци/ Input data	Појединачни чиниоци/ Individual factors	Извор/ Source
Визуелни и процесирани узорци/ <i>Visual and processed samples</i>	Визуелна обележја винограда; NDVI/ <i>Visual signatures of vineyards; NDVI</i>	GoogleEarth, LANDSAT 30 m www.earthexplorer.usgs.gov
Геолошки/ <i>Geological</i>	Алувијум; Алувијално-пролувијални нанос; Ст. речна тераса; Глиновити песак, Лес; Пролувијум; Миоценски песак и пешчар; Прашинаста глина; Мл. речна тераса, Миоценски песак, глина и шљунак; Мл.-Плеистоценски лес/ <i>Alluvium; Alluvial-proluvial deposits; Early fluvial terrace; Clayey sands; Loess; Proluvial deposits; Miocene sands and sandstones; Silty clays; Late fluvial terrace; Miocene sands, clays and gravels; Late Pleistocene Loess</i>	Геолошки завод Србије/ <i>Geological Survey of Serbia</i> www.geoliss.mre.gov.rs
Геоморфолошки/ <i>Geomorphologic</i>	Апсолутна висина; Релативне висине у односу на локални ерозиони базис; Експозиција; Висина дренажне мреже; Индекс конвергенције; Фактор дужине падине; Закривљеност; Нагиб; Индекс влажности/ <i>Absolute elevation, Altitude above channel network, Aspect, Channel network base elevation, Convergence index, LS-factor, Curvature, Slope, Wetness index</i>	ASTER GDEM 30 m www.earthexplorer.usgs.gov
Педолошки/ <i>Pedologic</i>	Дубина до основне стене; Процентуални садржај глиновите, прашинасте, песковите и органске компоненте на 15-200 cm; pH на 15-200 cm/ <i>Bedrock depth; Clay, silt, sand and organic % at 15-200 cm; pH at 15-200 cm</i>	SoilGrid www.soilgrids.org

Прелиминарни резултати (Слика 1b), указују на потенцијалну могућност примене методологије у решавању постављеног просторног проблема. Постоје два преимућства овог приступа: показује који су то од припадајућих чинилаца најзначајнији, а показује и где се налазе зоне које су потенцијално подобне за узгајање. Као најбитнији издвојени су: Садржај глиновите компоненте у тлу [%] на 15 и 100 cm дубине, Садржај прашинасте компоненте у тлу [%] на 60 и 200 cm дубине, Садржај органске компоненте у тлу [%] на 15 cm дубине, Алувијални нанос, Миоценски пескови и пешчари, Лесне насlage, Апсолутне висине терена [m], Релативне висине у односу на локални ерозиони базис [m], и Висина дренажне мреже [m]. Уочавају се поклапања са контролним сетом података, али је модел конзервативан, тј. прецењује повољну класу. Другим речима, превише је територије издвојено као повољно. Зато се даљим анализама могу „пикирати“ најповољнија подручја, у некој од даљих разрада модела. Побољшања су најпре могућа на пољу допуне тренинг података подацима са терена, поготово за највишу класу, која је по величини непропорционална осталим двама класама. Донекле је могуће очекивати побољшања која би настала евентуалном применом неког другог алгоритма.

ЗАКЉУЧАК

Озбиљним научим, мултидисциплинарним приступом, коришћењем просторних података (од регионалних ка локалним), као и педолошким и геохемијским детаљним анализама омогућила би се заштита домаћег потенцијала у домену аутохтоних сорти. Виноградарима би се оваквим приступом помогло у планирању за наше услове (а не да се преписују инострани стандарди и препоруке), што би водило ка квалитативној и квантитативној експанзији узгајања винове лозе и производње врхунских вина пореклом из Србије.

GEOLOGICAL, MORPHOLOGIC AND PEDOLOGIC COMPONENTS OF THE TERROIR OF SMEDEREVKA

**Miloš Marjanović¹, Aleksandar Stojaković², Biljana Abolmasov¹, Dragana Đurić¹,
Uroš Đurić³, Jelka Krušić¹, Katarina Andrejev⁴, Mileva Samardžić-Petrović³**

¹) University of Belgrade, Faculty of Mining and Geology, e-mail: milos.marjanovic@rgf.bg.ac.rs

²) Emporio Consulting, Belgrade

³) University of Belgrade, Faculty of Civil Engineering

⁴) MEDGOLD Resources Corp., Serbia Office

Key words: terroir, Smederevka, machine learning, spatial analysis.

INTRODUCTION

Terroir depicts a set of pedologic, micro-climatic and historical factors that have a say in deciding whether and where to practice viticulture and determines its qualitative and quantitative exploitation potential. For winemakers, it is paramount for targeting a viticulture variety. European winemakers use to guide their choices by the family tradition. Scientific breakthroughs, i.e. pedological characterization of the soil, introduced a new approach for viticulture, and drove the world-leading wineries to turn to scientific approach in the last 30 years. In this research, we went one step further in respect to pedological approach. Since the soil itself is considered as a product of its bedrock and climate, it is logical to also include those factors that condition the properties of the soil itself in the terroir context, such as geological and morphologic factors (Burns, 2010). It is thereby, possible to perform a preliminary delineation of zones with suitable set of factors at regional scales, and direct the subsequent, more detailed soil investigations. By analyzing wider areas, it becomes possible to plan more strategically, especially when it comes to preservation of rare and indigenous vine varieties.

From winemakers' perspective, indigenous vine varieties represent the true genetic potential. Smederevka, which is shyly re-introduced, but without any planning and consulting the profession is one such example. Before the 2nd World War, Smederevka (colloquially known as "the Yellow") was grown predominantly in the Smederevo wine region, but with caution to the micro-location, soil composition, slope aspect, sun reflection off the water surface, etc. The quality was unparalleled in comparison to the same vine from 1950–1990, a period marked by a high-yield, collective farming practice of the "Godomin" company back in the socialism. Locality Plavinac in Smederevo (from experience) has the Smederevka vine with the best sensory characteristics, although micro-localities Zlatno Brdo (Mons Aureus) and Petrijevo are more familiar.

METHODS

Contemporary trends in science follow "The fourth paradigm of science" (Hey et al. 2009), and entail massive data collection. On the other hand, "The fourth industrial revolution" (Schwab 2016) which we are facing now, indicates unprecedented technological progress that revolutionizes the ways

we can use these petabytes of data. In other words, new scientific breakthroughs await us to check all that data and reveal their hidden patterns.

Spatial analyses belong can benefit from both, data (collected from satellite images, global and local maps and models that offer estimates of various parameters of interest) and computational capacities for analyzing them. Suitability of an area for growing specified crop is a no less of a spatial problem (Jones et al. 2004, Vaudour et al. 2010). Therefore, global and local data, as well as advanced methods, with a drop of necessary experience, will be exploited to locate the areas that are suitable or unsuitable for growing indigenous variety Smederevka, on the example of the Smederevo area (Figure 1).

Methodological approach is based on locating the vineyards where Smederevka is successfully grown. It is proceeded by densifying similar locations using the satellite imagery resources (Figure 1a), and use this information in the next step, which includes implementation of the machine learning algorithm that work on a simple principle of training and extrapolating. It is also necessary to list all the factors that are empirically considered influential on the terroir. In that context, geological, morphologic and pedologic factors are chosen, represented by various digital maps of appropriate resolution and coverage (Table 1).

The algorithms are first trained by introducing the good examples of growing this variety, and correlate the influence of individual factors (Table 1). They establish a mathematical/statistical rule or function, based on the relation between the introduced examples and factors. This rule/function defines which factors influence positively to vine growth and to what extent. It is also necessary for them to “learn” where this is not the case (negative examples). In the next phase, it is possible to extrapolate the “learned” rule/function over the entire area of interest, given the same set of factors/maps. It is thereby, possible to predict new locations suitable for vine growing. Random Forest algorithm was used throughout this work, and the readers are directed to Witten et al. 2011, for further details.

RESULTS

Figure 1a depicts the initial dataset, including both, visually recognized vineyards (yellow dots) by using satellite Google background, and known vineyard locations of wineries (red dots). Randomly sampled locations (green dots) can be *a priori* considered as unsuitable for growing Smederevka. The randomness was not entirely arbitrary but controlled by restricting it to the zones far enough apart from recognized vineyards, as well as by controlling its vegetation index NDVI (to 0.3–0.5). These locations are used in the training of the Random Forest algorithm (using default parameter settings in Weka 3.9 software), which was training for both positive and negative examples. The training was completed over a dataset from Table 1, but the set was subsequently reduced by the correlation-based selection. Namely, all parameters with a lack of clear correlation with training data were not included in further modeling. The final model was obtained by extrapolating over a dataset with same data content regarding conditioning factors, like in the training stage (Figure 1b). Model was evaluated by overlapping it with a set of control points (unseen in the training stage), represented by yellow and red dots (Figure 1b).

Preliminary results (Figure 1b), indicate good potential of this methodology in solving the proposed spatial problem. There are two benefits of this approach: it shows which of those conditioning factors are the most important, as well as where are the zones potentially suitable for viticulture. The following are indicated as the most important: Clay component content in the soil [%] at 15 and 100 cm depths, Silt component content in the soil [%] at 60 and 200 cm depths, Organic component content in the soil [%] at 15 cm depth, Alluvial deposits, Miocene sands and sandstones, Loess deposits, Absolute elevation [m], Relative altitude from channel network (vertical distance to local erosion basis) [m], and Channel network base elevation [m]. The control points are matching relatively well, but the model is conservative, i.e., it overestimates suitability. In other words, there is too much coverage of the suitable class. Further analyses are to pinpoint suitable class more accurately, in further versioning of the model. Improvements can be introduced primarily by complementing the training samples by field data, especially for the highest class, which is unbalanced in comparison to the size of the other two. Some improvements can be expected from trying other algorithms.

CONCLUSION

Serious multidisciplinary scientific approach, using spatial data (from regional to local), as well as using detailed pedological and geochemical analyses, would allow conservation of the domestic potential in the indigenous vine growing domain. Such approach would help winemakers plan with our domestic conditions (instead of copying the foreign standards and recommendations), which will lead to qualitative and quantitative expansion of vine growing and producing excellent Serbian wine.

ЛИТЕРАТУРА / REFERENCES

- Burns, S., 2010. Terroir and the geology of wine. - In: Williams A. L., Pinches G. M., Chin C. Y., McMorran T. J., Massey C. I. (Eds.) *Geologically active*, Taylor and Francis Group, London, 321–331.
- Hey, T., Tansley, S., Tolle, K., 2009. *The Fourth Paradigm, Data-Intensive Scientific Discovery*. Microsoft Research, Redmond, Washington.
- Jones, G. V., Snead, N., Nelson, P., 2004. *Geology and Wine 8. Modeling Viticultural Landscapes: A GIS Analysis of the Terroir Potential in the Umpqua Valley of Oregon*. *Geoscience Canada* 31(4), 167–178.
- Schwab, K., 2016. *The fourth industrial revolution*. World Economic Forum, Cologny/Geneva.
- Vaudour, E., Carey, V. A., Gilliot, J. M., 2010. Digital zoning of South African viticultural terroirs using bootstrapped decision trees on morphometric data and multitemporal SPOT images. *Remote Sensing of Environment* 114, 2940–2950.
- Witten, I. H., Frank, E., Hall, M. A., 2011. *Data Mining—practical Machine Learning tools and techniques*, Elsevier, Burlington.