

ТЕХНИЧКО РЕШЕЊЕ

Назив	Естиматор производње електричне енергије ветрогенератора заснован на машинском учењу
Аутори	Деа Пујић, Валентина Јанев, Марко Јелић, Катарина Станковић
Категорија	Ново техничко решење у фази реализације (М85) Доказ: Протокол о тестирању
Кључне речи	естиматор производње, обновљиви извори, ветрогенератор, неуралне мреже

За кога је решење рађено (правно лице или грана привреде):
Техничко решење је рађено за потребе ветроелектране Крново.
Година када је решење комплетирано:
2022
Година када је почело да се примењује и од кога:
Примена техничког решења је планирана за средину 2023.
Област и научна дисциплина на коју се техничко решење односи:
Техничко-технолошке науке; информационо-комуникационе технологије

Технички елаборат:

- Проблем који се техничким решењем решава
- Стање решености тог проблема у свету
- Опис техничког решења са карактеристикама, укључујући пратеће илустрације и техничке цртеже
- Референце

ТЕХНИЧКИ ЕЛАБОРАТ

Проблем који се техничким решењем решава:

To decrease reliance on fossil fuels and address the pressing issue of climate change, renewable energy sources like solar panels and wind turbines have been implemented in recent years. These sources, however, come with their own set of challenges. The stochastic nature of renewable energy, which is the result of its high dependency on meteorological conditions, makes it difficult to plan for their usage and this in turn affects the stability of the electrical grid. The mismatch between energy production and demand can lead to power outages and other disruptions in the grid. As renewable energy becomes more prevalent in the energy market, accounting for a larger share of the overall energy mix, it is crucial to have accurate predictions for accessible energy in order to maintain a stable grid. In this regard, the need for accurate Renewable Energy Sources (RES) production forecaster is obvious, and it has been considered as a crucial aspect of any technical solution aimed at improving the integration of renewable energy into the grid. Amongst the various forms of renewable energy, wind energy has been considered as one of the most promising options due to its large potential and relatively low cost. Therefore, the forecast of wind turbine production has become a critical part of ensuring a stable grid.

As a part of the research within this solutions, wind turbine production forecasting model has been developed based on the forecasted meteorological conditions. Moreover, it was integrated with the data storage platform, for both obtaining the relevant inputs and storing back the provided outputs.

Стање решености тог проблема у свету:

As the use of renewable energy sources (RES) continues to grow, the importance of accurate production forecasting models becomes increasingly critical. With the increasing share of RES on the production side, it is crucial to have a good understanding of the expected energy production from these sources. This is why forecasting models for renewable energy production have become a popular area of research in recent times. There are many different types of forecasting methodologies, depending on the specific renewable energy source, the time horizon, and the availability of data. Some of the most widely used methodologies include statistical methods, machine learning techniques, and physical models.

In this report, the focus is on the available methodologies for forecasting wind turbine energy production for the next day, using historical meteorological and production data. Day-ahead forecasting is particularly important for wind energy as it allows grid operators and other stakeholders to plan for variations in wind energy production and make adjustments to the grid as necessary. Accurate forecasting of wind energy production is essential for ensuring a stable and reliable energy grid, and for making effective decisions about the integration of renewable energy into the grid.

As reviewed in [1] various data-based models do exist for day-ahead wind production forecasting. The first one that appeared were probabilistic models proposed by Box-Jenkins

and its modifications for modelling various time series problems, such as Autoregressive Moving Average (ARMA), ARMA with an exogenous input (ARMAX), etc.

Nevertheless, much more successful turned out to be various neural network architectures, since they are capable of extracting relevant features and modelling complex dependences. In that context, various types of networks could be found in literature for solving considered problem:

- Multilayer perceptron [2];
- Radial basis function neural networks could be found in older papers such as [3] and [4];
- Convolutional neural networks (CNN) have been presented in various papers. For example, [5] were first to apply CNNs for solving wind production forecasting problem, whilst [6] have proven CNN's advantage against statistical and simpler machine learning models such gradient boosting for short-term wind production forecasting;
- Long short-term memory (LSTM) networks for wind production forecasting have been utilized in [7], whilst [8] included LSTM architecture hyper-parameter optimization by introducing genetic approach.

Nevertheless, as stated by [1], the highest performances have been achieved by hybrid neural networks. In [9], authors proposed combination of CNN layers and radial basis function neural network with a double Gaussian function for 24-hour ahead production forecasting. Furthermore, [10] proposed hybrid approach which combines LSTM and Gaussian mixture model for successful forecasting performances and concludes that LSTM can greatly improve forecasting performances.

Taking all of previous into consideration, it was concluded that neural networks achieves the highest estimation performances, and thus have been chosen as the approach within this research. In order to provide as highest prediction accuracy as possible, hybrid modelling approach was chosen, as it is presented in the next section.

Опис техничког решења са карактеристикама, укључујући пратеће илустрације и техничке цртеже:

Data collection

For the purpose of the development of the ML-based wind power production forecasting model, historical production data (measurements) and metrological data were required. They were obtained from the Krnovo Wind Plant (located in Montenegro at location 42° 53' 32.87" N, 19° 3' 43.39" E). This wind farm contains 26 wind turbines – 20 with the capacity of 2.85 MW and 6 with the capacity of 2.5 MW, and hence, historical production with an hourly resolution has been collected for 6-months period.

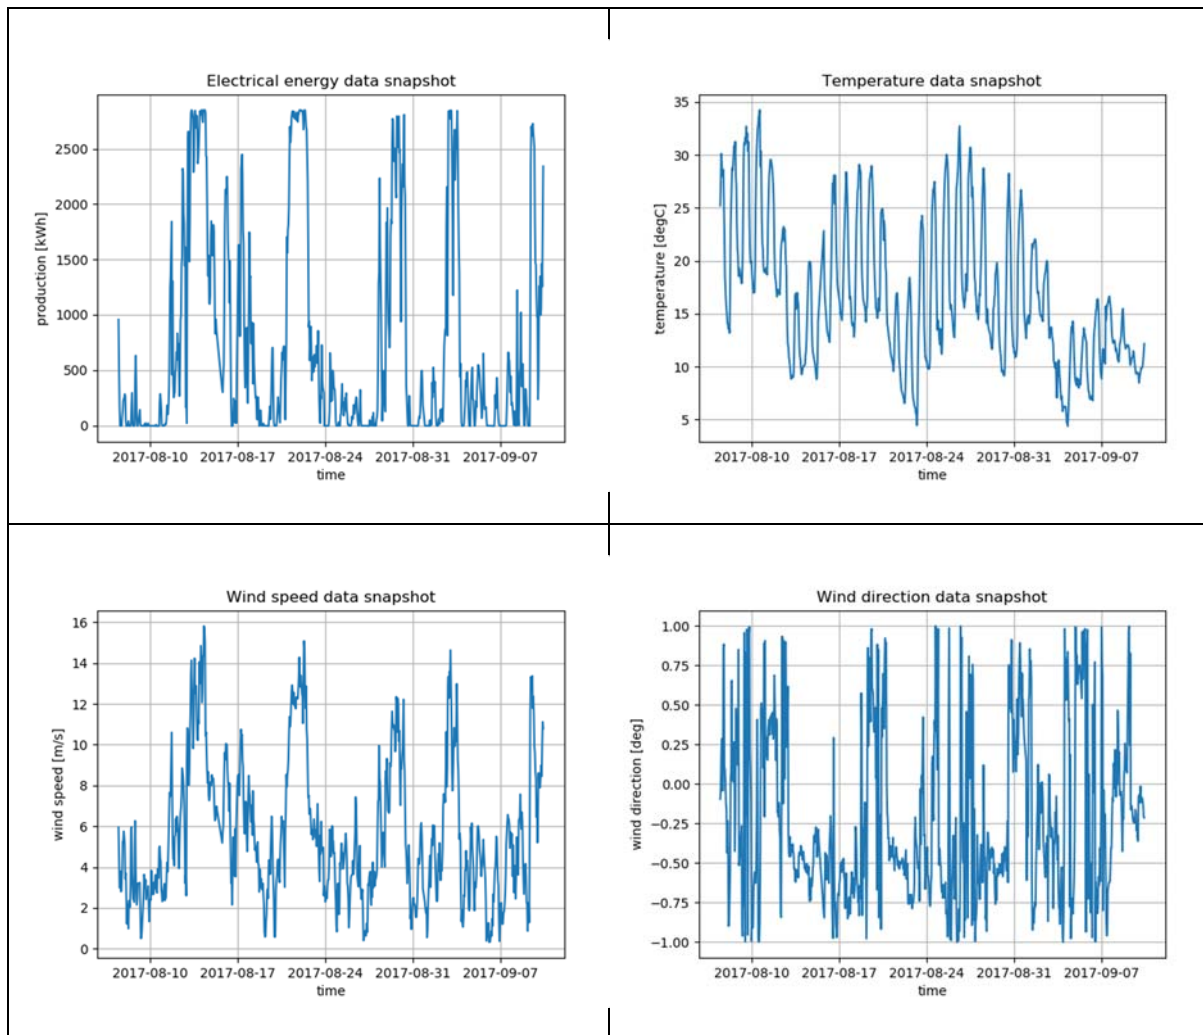


Figure 1. Wind production and meteorological data

The modelling has been carried out using data for 2.85 MW turbines. Production data has been collected with the hourly resolution, which was sufficient, since the goal is to provide a 24-hours ahead hourly WT production forecast. Apart from the production data, for the training and testing purposes, meteorological data was required, as well, due to high dependency between the production and meteorological conditions. Thus, data has been collected from the local meteorological station, and contained the following parameters: **wind speed, wind direction and temperature**. This data had 10 minutes resolution, and therefore, was sampled to match the production measurements. Even though it is expected that RES production is highly dependant on the weather conditions, in order to corroborate this statement Figure 2 and Figure 3 are given. The first one is intended to depict high correlation between the production and wind speed, since peaks in the production coincide with the peaks in the wind speed and vice a versa. Additionally, the second figure represents the dependency between the production and wind speed obtained from the data, together with the expected theoretical curve from [2]. From all of the above, it could be concluded that obtained data is valid and it is justified to exploit it for the training and testing purposes of the model.

After the collection, the data has been cleaned. Firstly, all the invalid measurements were removed from the data set, such as negative production, production above the total capacity, negative wind speed etc. After that, outliers were removed. For these purposes, joint

distribution between the production and the wind speed has been analysed. The production has been divided into 200W wide bins and for each been joint distribution has been analysed. All samples that were in the distribution tails were removed. Examples of the removed points are circled in Figure 3. Finally, required data pre-processing has been carried out. Namely, wind direction was measured in degrees, so transformation using trigonometric function over these values has been carried out. After data exploration, analysis and cleaning was carried out, data has been randomly divided into training, validation and testing set in the way that model input parameters were meteorological parameters, while outputs were measured forecasted values.

Results

After the data was prepared, the model development process was carried out. The model was defined as mapping between the meteorological parameters to the wind power production. Therefore, model inputs were the available forecasted meteorological parameters – wind speed and direction and temperature for the specific hour, whilst the output was corresponding hourly production. The 24-hour ahead horizon with an hourly resolution was achieved by utilizing the forecasted meteorological parameters with the same horizon and resolution as the model input.

For the modelling methodology, deep neural networks have been chosen, as they are capable of extracting relevant features and modelling complex dependences. As already presented in State of the art section, hybrid approaches are the most successful in providing precise forecasting. Since main focus during the development of the production forecasting model was to achieve as precise model as possible, a framework for optimizing the neural network architecture was created. This framework enabled optimization of various hyper parameters such as number and types of hidden layers and their corresponding hyper parameters, and number of training epochs, as well as training parameters such as learning rate. For this particular problem, in order to optimize the architecture, different numbers and types of neural network layers have been tested, including different combinations of Long-Short Term Memory (LSTM), Convolutional, Dense and Dropout layers. Apart from the optimization regarding the number and type of the hidden layers, activation functions have been chosen carefully, as well. Namely, since the value that should be estimated by the network is limited with the turbine capacity, tansig activation function has been selected.

In total 250 have been tested, and the optimal one that achieved the lowest Root Mean Square Error (RMSE) on the validation data has been determined, and presented in Table 1. Training process for the final model has been carried out using ADAM optimization method with the learning rate 0.001 and mean square error as the criterion function. Training has been carried out for 500 epochs, but with model reaching minimal loss on the validation data in 378th epoch, which is why this net has been chosen as the final one. It has achieved RMSE of **0.142 MW**, **0.154 MW** and **0.159 MW** on training, validation and testing data respectively. Apart from this numerical performance evaluation, performance characterization is given by estimation example in Figure 4. From it, one could noticed that there are examples in which the model fails to provide highly precise estimation, especially in period of peak or close to no production. However, main trends and mid values are precisely estimated. It should be pointed out that changes in wind speed and direction are very frequent, much more than on hourly basis, and hence, estimation on of the hourly production for wind power plan is challenging, so these errors are expected.

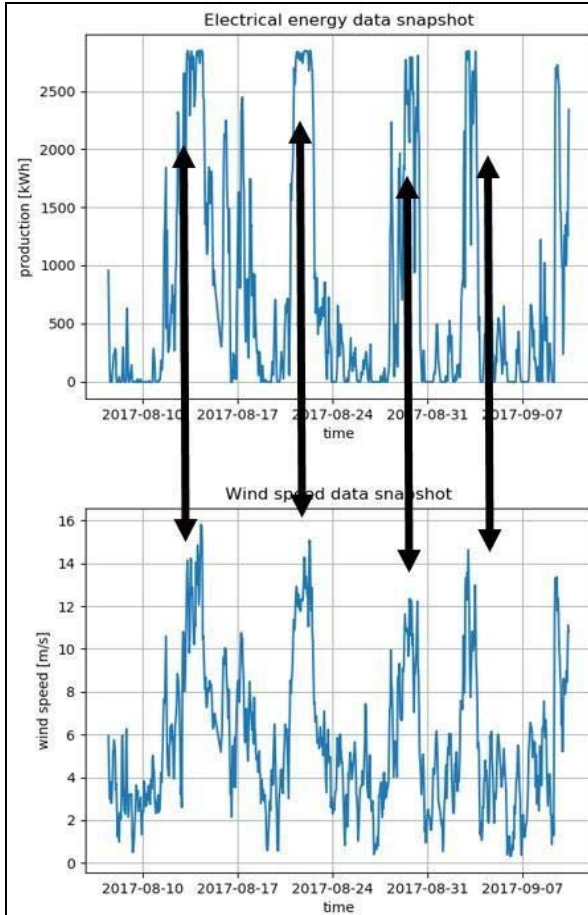


Figure 2. Correlation between the wind speed and production measurements

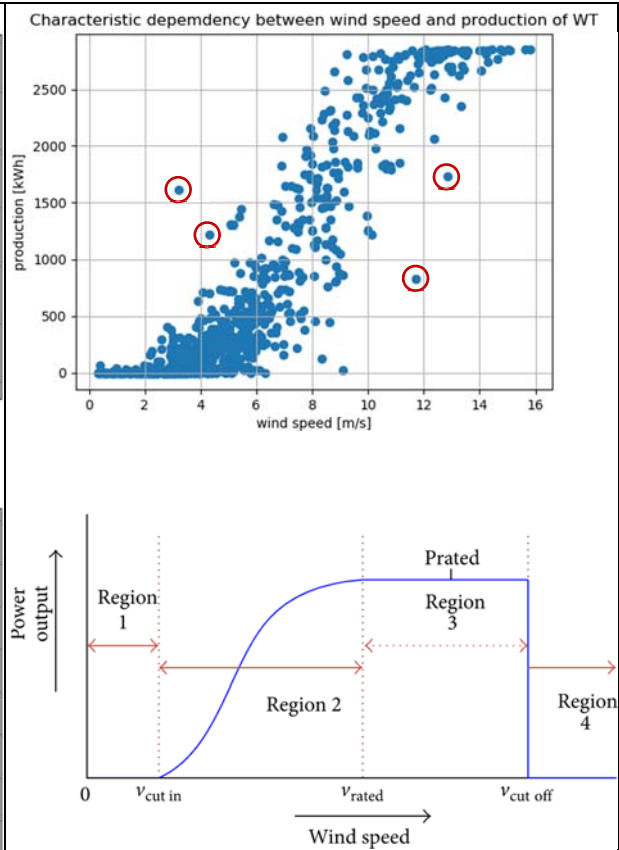


Figure 3. Dependency between the wind speed and the wind turbine production

Table 1. Architecture of the optimal deep neural network for wind production forecasting

Layer	num. of filters	filter size	num. of neurons	activation function	factor
LSTM	-	-	64	tansig	-
LSTM	-	-	128	tansig	-
Dropout					0.5
CNN	64	3	-	tansig	-
Dropout Layer	-	-	-	-	0.5
Dense Layer	-	-	300	tansig	-
Dense Layer	-	-	150	tansig	-
Dropout	-	-	-	-	0.5
Dense Layer	-	-	1	tansig	-




Figure 4 - Example of model estimation performance on testing set

As presented within the State of the art section, hybrid neural network approaches intend to provide improved estimation performances in comparison with other methods, which is the main reason why authors have decided to choose the hybrid approach within this research. Hence, as explained and analysed in the previous section, various layers and architectures have been analysed, and thus, the main contribution of this approach is the development of a framework for optimizing the neural network architecture for solving particular problem, which was, in this case, day-ahead wind production forecasting. As a result a hybrid model was developed which combines convolutional, LSTM, dense and dropout layers.

Integration

The main inputs to this service are the forecasted meteorological parameters. Therefore, they are obtained from WeatherBit¹ web service and stored as a part of the MySQL data base on the data storage platform on hourly bases. WeatherBit provides 120 hour-ahead forecast of various meteorological parameters, including once relevant for the models developed. The service is developed to be interoperable with any other energy related services since it could be integrated with the rest of the platform through the data base i.e. all necessary inputs are obtained from the data base, and outputs are stored within the data base as well, so other services could utilize them. Finally, integrated and developed forecasting service has been dockerized and deployed on the service and scheduled to be executed on hourly basis using cronjob.

Референце:

- [1] S. Hanifi, X. Liu, Z. Lin, and S. Lotfian, "A Critical Review of Wind Power Forecasting Methods—Past, Present and Future," *Energies*, vol. 13, no. 15, Art. no. 15, Jan. 2020, doi: 10.3390/en13153764.
- [2] B. Bilal *et al.*, "Wind turbine power output prediction model design based on artificial neural networks and climatic spatiotemporal data," in *2018 IEEE International*

¹ <https://www.weatherbit.io/>

- Conference on Industrial Technology (ICIT)*, Feb. 2018, pp. 1085–1092. doi: 10.1109/ICIT.2018.8352329.
- [3] G. Sideratos and N. D. Hatziaargyriou, “Probabilistic Wind Power Forecasting Using Radial Basis Function Neural Networks,” *IEEE Transactions on Power Systems*, vol. 27, no. 4, pp. 1788–1796, Nov. 2012, doi: 10.1109/TPWRS.2012.2187803.
- [4] X. Wu, B. Hong, X. Peng, F. Wen, and J. Huang, “Radial basis function neural network based short-term wind power forecasting with Grubbs test,” in *2011 4th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT)*, Jul. 2011, pp. 1879–1882. doi: 10.1109/DRPT.2011.5994206.
- [5] A. Zhu, X. Li, Z. Mo, and R. Wu, “Wind power prediction based on a convolutional neural network,” in *2017 International Conference on Circuits, Devices and Systems (ICCDs)*, Sep. 2017, pp. 131–135. doi: 10.1109/ICCDs.2017.8120465.
- [6] M. Solas, N. Cepeda, and J. L. Viegas, “Convolutional Neural Network for Short-term Wind Power Forecasting,” in *2019 IEEE PES Innovative Smart Grid Technologies Europe (ISGT-Europe)*, Sep. 2019, pp. 1–5. doi: 10.1109/ISGTEurope.2019.8905432.
- [7] I. Delgado and M. Fahim, “Wind Turbine Data Analysis and LSTM-Based Prediction in SCADA System,” *Energies*, vol. 14, no. 1, Art. no. 1, Jan. 2021, doi: 10.3390/en14010125.
- [8] F. Shahid, A. Zameer, and M. Muneeb, “A novel genetic LSTM model for wind power forecast,” *Energy*, vol. 223, p. 120069, May 2021, doi: 10.1016/j.energy.2021.120069.
- [9] Y.-Y. Hong and C. L. P. P. Rioflorido, “A hybrid deep learning-based neural network for 24-h ahead wind power forecasting,” *Applied Energy*, vol. 250, pp. 530–539, Sep. 2019, doi: 10.1016/j.apenergy.2019.05.044.
- [10] J. Zhang, J. Yan, D. Infield, Y. Liu, and F. Lien, “Short-term forecasting and uncertainty analysis of wind turbine power based on long short-term memory network and Gaussian mixture model,” *Applied Energy*, vol. 241, pp. 229–244, May 2019, doi: 10.1016/j.apenergy.2019.03.044.

ПРИЛОЗИ

- Доказ: Протокол о тестирању од стране корисника
- Листа раније прихваћених техничких решења (појединачно по аутору и за све ауторе)



Test protocol for software solution

Machine learning based renewable energy production forecaster for wind power plant developed by Institute Mihajlo Pupin, Belgrade Serbia

Herein, we confirm that the software solution **Machine learning based renewable energy production forecaster for wind power plant**, developed by Institute Mihajlo Pupin, Belgrade, Serbia (PUPIN), has been successfully tested by Rebasian Technologies AB, Stockholm, Sweden.

- Description** This service provides production forecast estimation for a wind turbine at the Krnovo plant in Montenegro for one day ahead with an hourly resolution. The estimation is provided in accordance with the forecasted meteorological parameters obtained from WeatherBit through PLATOON platform. The Forecasting model is an optimised hybrid ensemble model.
- Inputs** 24-hour ahead forecast of the following meteorological parameters with an hourly resolution:
- Wind speed
 - Wind direction
 - Temperature
- Outputs** 24-hour ahead forecasted wind power production with an hourly resolution

The testing has been organised in cooperation with experts from TECNALIA Research & Innovation, Bilbao, Spain in the framework of the 2nd Open Call of the EU project PLATOON. A benchmark test was conducted with the Enerflow (wind power forecaster) provided by Rebasian Technologies AB. The archived results are satisfactory. There are two options for using the PUPIN service: a) via PLATOON's Marketplace; and b) by deployment at premises.

This confirmation has been issued on request received by the Institute Mihajlo Pupin and in relation to monitoring of innovation activities by the Ministry of Education, Science and Technological Development of the Republic of Serbia.

Stockholm, Sweden

Date:
2023-01-16

Mihai Chiru,
CTO at Rebasian Technologies AB

A handwritten signature in blue ink that reads 'Mihai Chiru'.

Деа Пујић, листа техничких решења

M83

1. Деа Пујић, Марко Јелић, Никола Томашевић, Марко Батић: "Систем за управљање потрошњом електричне енергије на бази ВИ", 2021, ТР 32010
2. Марко Јелић, Никола Томашевић, Деа Пујић, Марко Батић, "Систем за планирање снабдевања електричном енергијом географских острва", 2021, ТР32010

M85

1. Душан Попадић, Деа Пујић, Лазар Бербаков, Валентина Јанев, Сања Вранеш: "Семантички систем за препоручивање мера ради побољшања енергетске ефикасности и сигурности у паметним зграда", 2020, ТР32010
2. Деа Пујић, Марко Јелић, Марко Батић, Никола Томашевић: "Рангирање корисника по енергетској ефикасности коришћењем ненадгледаног приступа", 2020, ТР32010
3. Деа Пујић, Никола Томашевић, Лазар Бербаков, Сања Вранеш: "Спецификација, развој и интеграција система за неинтрузивни мониторинг потрошње електричне енергије", 2019, ТР32010

Валентина Јанев, листа техничких решења

M81

1. Вук Мијовић, Никола Томашевић, Валентина Јанев, Младен Станојевић, Сања Вранеш: "Симулационо и тренинг окужење за обуку особља аеродрома", 2013, TP32010

M84

1. Валентина Јанев, Сања Вранеш, Дејан Пауновић: "Интеграција и управљање семантичким 'језером података'", 2020, TP32010

M85

1. Валентина Јанев, Сања Вранеш, Дејан Пауновић, Душан Попадић: "Интегрисање и објављивање повезаних података у фармацеутском домену", 2021, TP32010
2. Душан Попадић, Деа Пујић, Лазар Бербаков, Валентина Јанев, Сања Вранеш: "Семантички систем за препоручивање мера ради побољшања енергетске ефикасности и сигурности у паметним зградама", 2020, TP32010
3. Валентина Јанев, Јелена Јовановић: "Развој сервиса за помоћ одлучивању у процесној и прерађивачкој индустрији", 2019, TP32010
4. Никола Томашевић, Валентина Јанев, Сања Вранеш: "Развој система за управљање критичним инфраструктурама у ванредним ситуацијама заснован на парадигми обраде комплексних догађаја", 2018, TP32010
5. Валентина Јанев, Јелена Јовановић, Сања Вранеш: "Развој генеричког модела за оцену квалитета великих количина повезаних података (Big Linked Data)", 2018, TP32010
6. Валентина Јанев, Стефан Стојков, Марко Нанковски: "Развој архитектуре и имплементација софтверског сервис/алата за анализу квалитета великих количина повезаних података", 2018, TP32010
7. Валентина Јанев, Дејан Пауновић, Стефан Стојков, Марко Нанковски, Јелена Кљајић, Сања Вранеш: "Примена Linked Open Data у оквиру електронске управе (e-government) и у домену управљања ванредним ситуацијама (emergency management)", 2017, TP32010
8. Валентина Јанев, Дејан Пауновић, Сања Вранеш: "Методологија развоја Linked Data апликација помоћу SOFIA алата", 2017, TP32010
9. Валентина Јанев, Дејан Пауновић, Вук Мијовић, Урош Милошевић, Сања Вранеш: "Унапређење применљивости и функционалности компоненте за просторно-временску анализу Linked Data", 2016, TP32010
10. Валентина Јанев, Никола Томашевић, Дејан Пауновић, Урош Милошевић, Јелена Јовановић, Сања Вранеш: "LinkedData.rs Садржаји за електронско учење", 2016, TP32010
11. Валентина Јанев, Вук Мијовић, Урош Милошевић, Огњен Стаменковић, Богдан Павковић, Лазар Бербаков, Сања Вранеш: "Софтверска компонента за праћење и анализу ланца снабдевања на мобилним уређајима", 2015, TP32010
12. Никола Томашевић, Марко Батић, Јелена Јовановић, Валентина Јанев, Вук Мијовић, Сања Вранеш: "Емулатор мерног окружења за тестирање система за оптимизацију токова енергије међусобно повезаних ентитета са различитим изворима енергије", 2015, TP32010
13. Валентина Јанев, Дејан Пауновић, Урош Милошевић, Богдан Павковић, Лазар Бербаков, Сања Вранеш: "Софтверски модул за прецизну навигацију у затвореном простору", 2015, TP32010
14. Валентина Јанев, Богдан Павковић, Лазар Бербаков, Марко Батић, Младен Станојевић, Јелена Јовановић-Васовић, Вук Мијовић, Сања Вранеш: "Спецификација техничког решења система за управљање ванредним ситуацијама", 2014, TP32010

15. Младен Станојевић, Валентина Јанев, Дејан Пауновић, Урош Милошевић, Сања Вранеш: "Софтверска компонента за просторно-семантичку визуализацију и претраживање на мобилним уређајима", 2014, TP32010
16. Вук Мијовић, Богдан Павковић, Валентина Јанев, Јелена Јовановић-Васовић, Урош Милошевић, Сања Вранеш: "Разрада сценарија за тестирање решења за управљање ванредним ситуацијама", 2014, TP32010
17. Марко Батић, Богдан Павковић, Лазар Бербаков, Валентина Јанев, Младен Станојевић, Вук Мијовић, Никола Томашевић, Сања Вранеш: "Анализа и спецификација комуникационих мрежа потребних након ванредне ситуације, током фазе спасавања", 2014, TP32010
18. Вук Мијовић, Валентина Јанев, Урош Милошевић, Дејан Пауновић, Сања Вранеш: "Софтверска компонента за просторно-временску анализу Linked Data", 2014, TP32010
19. Вук Мијовић, Никола Томашевић, Валентина Јанев, Младен Станојевић, Сања Вранеш: "Симулационо и тренинг окружење за обуку особља аеродрома", 2013, TP32010
20. Валентина Јанев, Вук Мијовић, Урош Милошевић, Младен Станојевић, Сања Вранеш: "Linked data статистичко окружење", 2013, TP32010
21. Вук Мијовић, Валентина Јанев, Урош Милошевић, Младен Станојевић, Сања Вранеш: "RDF Data Cube валидациони алат", 2013, TP32010
22. Валентина Јанев, Урош Милошевић, Вук Мијовић, Сања Вранеш: "Српски SKAN", 2013, TP32010
23. Валентина Јанев, Вук Мијовић, Lydia Kraus, Никола Томашевић, Јелена Јовановић, Младен Станојевић, Сања Вранеш: "Оперативни сценарији за аеродром", 2012, TP32010
24. Валентина Јанев, Вук Мијовић, Lydia Kraus, Никола Томашевић, Јелена Јовановић, Младен Станојевић, Сања Вранеш: "Систем за подршку одлучивању у кризним ситуацијама на аеродрому", 2012, TP32010
25. Марко Батић, Дејан Пауновић, Валентина Јанев, Вук Мијовић, Lydia Kraus, Сања Вранеш: "Интегрисани, системски модел микро-мреже, који укључује изворе, складишта и спрегу са спољашњом електромрежом", 2012, TP32010
26. Валентина Јанев, Дејан Пауновић, Јелена Јовановић, Марко Батић, Вук Мијовић, Сања Вранеш: "Развој семантичког web портала за е-колаборацију и дисеминацију резултата", 2011, TP32010
27. Никола Томашевић, Валентина Јанев, Младен Станојевић, Марко Рибарић, Марко Батић, Вук Мијовић, Сања Вранеш: "Развој генеричке онтологије просторних и функционалних компоненти комплексних објеката (CO2 – Complex Object Ontology)", 2011, TP32010
28. Марко Батић, Никола Томашевић, Валентина Јанев, Марко Рибарић, Младен Станојевић, Сања Вранеш: "Проширење генеричке CO2 онтологије за управљање објектима са микромрежама локалних обновљивих извора енергије", 2011, TP32010
29. Никола Томашевић, Вук Мијовић, Валентина Јанев, Младен Станојевић, Сања Вранеш: "Проширење генеричке CO2 онтологије за управљање аеродромима", 2011, TP32010
30. Сања Вранеш, Никола Томашевић, Дејан Пауновић, Јелена Јовановић, Валентина Јанев, Младен Станојевић: "Развој метамодела података и "mark-up" језика за потребе комуникације са SCADA системима", 2011, TP32010
31. Вук Мијовић, Никола Томашевић, Валентина Јанев, Младен Станојевић, Сања Вранеш: "Анализа захтева и израда UML модела софистицираног графичког корисничког интерфејса", 2011, TP32010
32. Валентина Јанев, Вук Мијовић, Lydia Kraus, Никола Томашевић, Дејан Пауновић, Јелена Јовановић, Сања Вранеш: "Дефинисање могућих сценарија примене SOFIA окружења на аеродрому „Никола Тесла", 2011, TP32010

33. Вук Мијовић, Никола Томашевић, Валентина Јанев, Марко Рибарић, Марко Батић, Младен Станојевић, Сања Вранеш: "Развој новог, мултипарадигматичног СЕР/ЕСА језика за управљање комплексним објектима", 2011, ТР32010
34. Сања Вранеш, Младен Станојевић, Валентина Јанев, Вук Мијовић, Никола Томашевић, Lydia Kraus: "Спецификација захтева и израда UML модела архитектуре SOFIA окружења", 2011, ТР32010
35. Вук Мијовић, Никола Томашевић, Lydia Kraus, Младен Станојевић, Валентина Јанев, Сања Вранеш: "Развој прве верзије прототипа архитектуре SOFIA окружења", 2011, ТР32010
36. Валентина Јанев, Дејан Пауновић, Јелена Јовановић, Марко Батић, Сања Вранеш: "Развој прототипа система за управљање документима на аеродромима", 2011, ТР32010
37. Вук Мијовић, Никола Томашевић, Валентина Јанев, Марко Рибарић, Дејан Пауновић, Јелена Јовановић, Младен Станојевић, Сања Вранеш: "Развој прве верзије демонстрационог прототипа примене SOFIA окружења на аеродрому "НиколаТесла", 2011, ТР32010

Марко Јелић, листа техничких решења

M82

1. Марко Батић, Никола Томашевић, Марко Јелић, Сања Вранеш: “Развој интегрисаног оптимизационог алгоритма за анализу утицаја флексибилности потрошње на оптималну конфигурацију хибридних микро-мрежа”, 2019, ТР32010

M83

1. Деа Пујић, Марко Јелић, Никола Томашевић, Марко Батић: “Систем за управљање потрошњом електричне енергије на бази ВИ”, 2021, ТР32010
2. Марко Јелић, Никола Томашевић, Деа Пујић, Марко Батић, “Систем за планирање снабдевања електричном енергијом географских острва”, 2021, ТР32010
3. Марко Јелић, Никола Томашевић, Марко Батић: “Симулација и евалуација ефеката флексибилности крајње потрошње електричне енергије на географским острвима”, 2020, ТР 32010

M84

1. Марко Јелић, Марко Батић, Никола Томашевић, “Ефекти управљања потрошњом електричне енергије на исплативост ОИЕ”, 2021, ТР32010

M85

1. Деа Пујић, Марко Јелић, Марко Батић, Никола Томашевић: “Рангирање корисника по енергетској ефикасности коришћењем ненадгледаног приступа”, 2020, ТР32010

Катарина Станковић, листа техничких решења

Нема претходних техничких решења